



BaFin

Bundesanstalt für
Finanzdienstleistungsaufsicht

Big Data trifft auf künstliche Intelligenz

Herausforderungen und
Implikationen für Aufsicht
und Regulierung von
Finanzdienstleistungen





BaFin

Bundesanstalt für
Finanzdienstleistungsaufsicht

Big Data trifft auf künstliche Intelligenz

Herausforderungen und Implikationen für
Aufsicht und Regulierung von Finanzdienstleistungen

Hinweis zur BDAI Studie

Der vorliegende Bericht ist eine spekulative Studie der Bundesanstalt für Finanzdienstleistungsaufsicht (BaFin). Er behandelt die technologischen Entwicklungen Big Data Analytics und künstliche Intelligenz, entwickelt Szenarien zum möglichen Einfluss auf den Finanzmarkt und seine Akteure sowie mögliche Implikationen für die Finanzaufsicht. Zur Erstellung des Berichts hat die BaFin als Auftraggeberin mit externen Partnern aus Wissenschaft und Beratung kooperiert. Die Studie soll einen fachlich fundierten Anstoß zu einer offenen Diskussion über Auswirkungen der Digitalisierung auf etablierte Markt- und Aufsichtsstrukturen geben. Unter keinen Umständen sollte dieser Bericht so verstanden werden, als dass eine bestimmte beschriebene Technologie, ein Geschäftsmodell oder deren Einsatz als notwendig erachtet werden.

Die im Bericht enthaltenen rechtlichen Würdigungen bezwecken keine Darstellung der Verwaltungspraxis der BaFin.

Bitte beachten Sie, dass die Studie sorgfältig zusammengestellt worden ist, jedoch eine Haftung der BaFin für die Vollständigkeit und Richtigkeit der Studie ausgeschlossen ist. Die Haftung der BaFin für Schäden aus der Verletzung des Lebens, des Körpers oder der Gesundheit, die auf einer fahrlässigen Pflichtverletzung der BaFin oder einer vorsätzlichen oder fahrlässigen Pflichtverletzung deren Mitarbeitern bzw. den Verantwortlichen dieser Studie beruhen, bleiben hiervon unberührt.

Vorwort

Gesellschaft und Wirtschaft, insbesondere auch die Finanzwirtschaft, durchleben derzeit einen tiefgreifenden technologischen Wandel. Die Digitalisierung hat eine neue Stufe erreicht: Die digitale Vernetzung nimmt zu, und dank neuer Technologien wie durch das „Internet der Dinge“ lassen sich immer komplexere Aufgaben lösen. Riesige und weiterhin stark wachsende



Felix Hufeld

Präsident der BaFin

Datenmengen stehen zur Verfügung – Stichwort „Big Data“ (BD)–, die sich durch neue technische Möglichkeiten immer schneller und besser nutzen lassen – Stichwort „Artificial Intelligence“ (AI), auch durch selbstlernende maschinelle Systeme. Der nachfolgende Bericht beschreibt, wie Big Data und Artificial Intelligence zusammenspielen, wie tiefgreifend das Phänomen BDAI das Finanzsystem verändern kann und welche Implikationen sich daraus für Aufsicht und Regulierung ergeben können. Es wird deutlich, dass BDAI nicht nur dazu geeignet ist, bestehende Strukturen zu optimieren, sondern grundsätzlich neue Anwendungen, Produkte, Dienstleistungen und Geschäftsmodelle ermöglicht, mit allen Chancen und Risiken.

Um das Thema bestmöglich aus verschiedenen Blickwinkeln einschätzen zu können, hat die BaFin externe Experten hinzugezogen: Partnerschaft Deutschland, die Boston Consulting Group und das Fraunhofer Institut für Intelligente Analyse- und Informationssysteme.

Anhand von Marktbetrachtungen und Anwendungsbeispielen zeigt der Bericht denkbare Entwicklungen aus der Sicht von Banken, Versicherungsunternehmen und des Kapitalmarktes auf. Bewusst nimmt er aber auch die Perspektive des Verbrauchers ein, der zugleich auch Lieferant der Daten ist. Allen Beteiligten muss klar sein, dass BDAI Chancen, aber auch Risiken mit sich bringt. Diese Risiken müssen verstanden und adressiert werden.

Das gilt auch und vor allem für Aufsicht und Regulierung, deren Perspektive der Bericht im abschließenden Kapitel einnimmt. Die Aufsicht muss sich angesichts der schnell fortschreitenden Digitalisierung immer wieder fragen, ob ihre Aufsichtspraxis Schritt hält. Das Gleiche gilt für ihr Rüstzeug, die Regulierung. Aufsicht und Regulierung müssen technologieneutral sein, den Grundsatz „gleiches Geschäft, gleiches Risiko, gleiche Regel“ beherzigen und zugleich auf der Höhe der Zeit sein, was immer anspruchsvoller wird. Das zeigen die aufsichtlich-regulatorischen Leitfragen, die der Bericht aufwirft, und in deren Beantwortung noch viel Arbeit zu investieren ist.

Es liegt in der Natur einer so schnelllebigen Thematik wie BDAI, dass keine abschließenden Aussagen getroffen werden können – auch nicht mit einem umfänglichen Bericht wie dem vorliegenden. Zugleich halten wir es für erforderlich, intensiv über BDAI zu diskutieren. Mit diesem Bericht wollen wir einen substantiellen Beitrag dazu leisten. Wir freuen uns auf vielfältige weitere Diskussionen mit Vertretern der Finanzindustrie, der Wissenschaft und der internationalen Finanzregulierung.

Inhaltsverzeichnis

| | | |
|-------------|--|-----------|
| I. | Zusammenfassung | 7 |
| 1.1 | Einordnung | 7 |
| 1.2 | Auswirkungen auf das Finanzsystem | 8 |
| 1.2.1 | Banken | 9 |
| 1.2.2 | Versicherer | 10 |
| 1.2.3 | Kapitalmarkt | 11 |
| 1.3 | Erfolgsfaktoren für BDAI-Anwendung und -Innovationen | 12 |
| 1.4 | Aufsichtliche und regulatorische Implikationen | 12 |
| 1.5 | Übergeordnete Phänomene in gesamtgesellschaftlicher Sicht | 15 |
| II. | Einleitung: Wertschöpfung aus Daten mit Hilfe künstlicher Intelligenz | 17 |
| 2.1 | Big Data und Artificial Intelligence als Treiber eines tiefgreifenden Wandels | 17 |
| 2.2 | Eine neue Dynamik durch Big Data und Artificial Intelligence | 18 |
| 2.3 | Zielsetzung und Struktur dieser Studie | 22 |
| III. | Technologische Voraussetzungen für die Nutzung von Big Data und Artificial Intelligence | 24 |
| 3.1 | Von Big Data zu Artificial Intelligence | 26 |
| 3.2 | Maschinelles Lernen und seine Algorithmen | 26 |
| 3.2.1 | Überwachtes Lernen (Supervised Learning) | 27 |
| 3.2.2 | Unüberwachtes Lernen (Unsupervised Learning) | 28 |
| 3.2.3 | Bestärkendes Lernen (Reinforcement Learning) | 28 |
| 3.2.4 | Deep Learning: Maschinelles Lernen auf Big Data | 28 |
| 3.3 | Evaluation und Umsetzung von maschinellem Lernen | 30 |
| 3.3.1 | Evaluation von Modellen | 30 |
| 3.3.2 | Datenanalyse als Prozess | 32 |

| | | |
|------------|--|-----------|
| 3.4 | Machine-Learning-basierte Systeme und Anwendungen | 33 |
| 3.4.1 | Maschinelle Dokumentenanalyse | 34 |
| 3.4.2 | Spracherkennung | 35 |
| 3.4.3 | Question-Answering | 35 |
| 3.4.4 | Intelligente Agenten | 36 |
| 3.5 | Technische Lösungsansätze für gesellschaftliche Anforderungen an BDAI | 36 |
| 3.5.1 | Verständlichkeit von Modellen | 37 |
| 3.5.2 | Transparenz und Erklärbarkeit | 37 |
| 3.5.3 | Privacy-preserving Data Mining | 38 |
| 3.5.4 | Infrastrukturen für Datensouveränität | 39 |
| 3.5.5 | Nichtdiskriminierende Datenanalyse | 40 |
| IV. | Strategische Voraussetzungen | 42 |
| 4.1 | Förderung des Kunden- und Verbrauchervertrauens | 42 |
| 4.1.1 | Perspektive des Verbrauchers | 42 |
| 4.1.2 | Relevanz von Kunden- und Verbrauchervertrauen im Kontext von Finanzdienstleistungen | 45 |
| 4.1.3 | Komplexitätszunahme durch BDAI | 50 |
| 4.1.4 | Schlussfolgerung: Souveränität des Verbrauchers zur Vertrauensbildung | 52 |
| 4.2 | IT-strategische Erfolgsfaktoren | 54 |
| 4.2.1 | Datenqualität und -umfang, IT-Architektur und Cloud-Computing als Erfolgsfaktoren für die Nutzung von BDAI | 54 |
| 4.2.2 | Technologische Veränderungen erfordern neue Kompetenzen, Strukturen sowie agile Arbeitsmethoden | 58 |
| 4.2.3 | Die Bedeutung von Informationssicherheit im Kontext von BDAI | 59 |
| V. | Perspektive des Marktes | 63 |
| 5.1 | Einordnung | 63 |
| 5.2 | Marktbetrachtung Banken | 64 |
| 5.2.1 | Einleitung und Status quo | 64 |
| 5.2.2 | Auswirkungen von BDAI auf den Bankenmarkt | 66 |
| 5.2.3 | Auswirkungen von BDAI auf die Kundenschnittstelle | 71 |
| 5.2.4 | Auswirkungen von BDAI auf die Kernprozesse der Produktplattform | 75 |
| 5.2.5 | Neue Geschäftsmodelle durch BDAI | 77 |
| 5.2.6 | Anwendungsbeispiele in der Bankenbranche | 78 |

| | | |
|-------------|--|------------|
| 5.3 | Marktbetrachtung Versicherer | 95 |
| 5.3.1 | Einleitung und Status quo | 95 |
| 5.3.2 | Auswirkungen von BDAI auf den Versicherungsmarkt | 97 |
| 5.3.3 | Auswirkungen von BDAI auf die Kundenschnittstelle | 103 |
| 5.3.4 | Auswirkungen von BDAI auf die Kernprozesse | 104 |
| 5.3.5 | Neue Geschäftsmodelle durch BDAI | 106 |
| 5.3.6 | Erklärungskraft externer Daten | 107 |
| 5.3.7 | Anwendungsbeispiele in der Versicherungsbranche | 108 |
| 5.4 | Marktbetrachtung Kapitalmarkt | 135 |
| 5.4.1 | Einleitung und Status quo | 135 |
| 5.4.2 | Naheliegende Entwicklungen: „More of the same, only faster and better“ | 138 |
| 5.4.3 | Weiterführende Entwicklungen: Höhere Vernetzung und Komplexität | 142 |
| 5.4.4 | Anwendungsbeispiele | 146 |
| VI. | Perspektive der Aufsicht | 166 |
| 6.1 | Einordnung in den Kontext der Studie | 166 |
| 6.2 | Aufsichtlich-regulatorische Implikationen | 167 |
| 6.2.1 | Finanzstabilität und Marktaufsicht | 168 |
| 6.2.2 | Unternehmensaufsicht | 173 |
| 6.2.3 | Kollektiver Verbraucherschutz | 180 |
| 6.3 | Gesamtgesellschaftlicher Rahmen | 185 |
| VII. | Anhang | 188 |
| 7.1 | Detaillierte Beschreibung der Verfahren des maschinellen Lernens | 188 |
| 7.1.1 | Überwachtes Lernen (Supervised Learning) | 189 |
| 7.1.2 | Unüberwachtes Lernen (Unsupervised Learning) | 195 |
| 7.2 | Zusammenfassung der Papiere der europäischen Aufsichtsbehörden und des Financial Stability Boards | 198 |

Bildnachweis: Titelbild: iStock/spainter_vfx, alle Fotos Direktorium: Bernd Roselieb

I. Zusammenfassung

1.1 Einordnung

Big Data und Artificial Intelligence führen einen tiefgreifenden Wandel herbei | Gesellschaft und Wirtschaft erfahren zurzeit einen tiefgreifenden technologischen Wandel. Die digitale Vernetzung nimmt zu, und dank neuer Technologien können immer komplexere Aufgaben gelöst werden. Angetrieben wird diese Entwicklung insbesondere durch die Verfügbarkeit großer Datenmengen – Big Data (BD) – und die verbesserten Möglichkeiten, diese Daten zu nutzen – Artificial Intelligence (AI)¹. In diesem Bericht wird das Zusammenwirken beider Phänomene im Finanzsystem untersucht und als „BDAI“ bezeichnet. Beim Einsatz von BDAI werden meist Methoden des maschinellen Lernens angewandt. Dabei wird Computern durch Algorithmen die Fähigkeit verliehen, aus vorhandenen Daten zu lernen und das Erlernte anschließend auf neue Daten anzuwenden.

Erfolgreiche Umsetzungen von BDAI können sich selbstverstärkend rasch ausbreiten | Die Relevanz von BDAI steigt durch Wechselwirkungen zwischen Technologie, Unternehmen und Verbrauchern. Erstens erlaubt der technologische Fortschritt heute eine breite praktische Anwendung von BDAI. Zweitens setzen Unternehmen zur Optimierung ihrer Geschäftsmodelle und Prozesse vermehrt auf Daten und deren Verwertung. Drittens ist das Verhalten der Verbraucher zunehmend durch digitale Anwendungen geprägt, wodurch wiederum mehr Daten erzeugt werden und verfügbar sind. Insbesondere die letzten beiden Punkte können stark selbstverstärkend aufeinander wirken. In vielen Teilen der Finanzdienstleistungsbranche ist die mit der Nutzung von BDAI einhergehende sich selbstverstärkende Entwicklung noch im Anfangsstadium. Jedoch muss davon ausgegangen werden, dass diese rasch an Geschwindigkeit zunehmen wird.

BDAI ermöglicht Innovation | Durch die Kombination von Analytik und massenhaft verfügbaren Daten lassen sich neue Erkenntnisse gewinnen. Diese können auch im Finanzsystem für Produkt- und Prozessinnovationen genutzt werden. Solche Innovationen könnten disruptiv auf bestehende Wertschöpfungsprozesse wirken. In der Folge können neue Anbieter in den Markt eintreten, und etablierte Geschäftsprozesse und Marktstrukturen können sich ändern.

Aufsicht und Regulierung müssen sich frühzeitig mit innovativen Entwicklungen auseinandersetzen | Der Bericht befasst sich mit den potenziell tiefgreifenden Auswirkungen von BDAI-Technologie auf die Finanzdienstleistungsbranche. Es werden anhand von Marktbetrachtungen und Anwendungsbeispielen denkbare Entwicklungen aus der Sicht von Banken, Versicherungsunternehmen und des Kapitalmarktes, aber auch Auswirkungen auf Verbraucher skizziert. Experten aus Wissenschaft und Forschung wurden an der Erarbeitung dieses Berichts beteiligt.² Aus dieser ganzheitlichen Sicht werden aufsichtlich-regulatorische Implikationen und Leitfragen abgeleitet.

¹ Vereinfacht kann Artificial Intelligence als ein Zusammenspiel von Massendaten, ausreichenden Rechenressourcen und maschinellem Lernen aufgefasst werden. Ansätze zur generellen Nachbildung von menschlicher Intelligenz – harte AI – sind nach wie vor nicht absehbar.

² Die technologischen Beurteilungen in dieser Studie wurden im Wesentlichen vom Fraunhofer Institut für Intelligente Analyse und Informationssysteme IAIS unterstützt.

1.2 Auswirkungen auf das Finanzsystem

Bei der Betrachtung der Anwendung von BDAI in der Finanzdienstleistungsbranche werden drei zentrale Gruppen von Anbietern unterschieden:

- traditionell tätige Unternehmen (Incumbents), insbesondere beaufsichtigte Unternehmen wie Banken und Versicherer
- vergleichsweise junge, technologieorientierte Anbieter mit spezifischen Funktionen, von denen einige direkt beaufsichtigt werden (Fintechs/Insurtechs/Regtechs/Legaltechs)
- große, global agierende Technologieunternehmen (Bigtechs), die bislang überwiegend nicht unter die Aufsicht fallen

Nutzung von BDAI im Kapitalmarkt weiter fortgeschritten als bei Banken und

Versicherungsunternehmen | Banken und Versicherungsunternehmen fangen erst an BDAI einzusetzen.

Eine ausgeprägtere Anwendung von BDAI und damit einhergehende Effekte sind zunächst bereichsspezifisch an der Kundenschnittstelle, in den Kernprozessen und bei neuen Geschäftsmodellen zu erwarten. Im Kapitalmarkt hingegen wird BDAI bereits deutlich häufiger und umfangreicher genutzt, da dort seit vielen Jahren große Datenbestände und Algorithmen verwendet werden.

„The winner takes it all“-Marktstruktur kann durch BDAI begünstigt werden |

Je mehr Daten ein Unternehmen hat, desto mehr Erkenntnisse kann es gewinnen. Diese Erkenntnisse machen es möglich,

innovativere Produkte zu entwickeln, aus denen es wiederum zusätzliche Daten gewinnen kann. Der hierzu

erforderliche Datenzufluss erfolgt in vielen Fällen nach dem Konzept „Bezahlen mit Daten“, das bei vielen

plattformbasierten Geschäftsmodellen der Bigtechs zu beobachten ist. Dieser sich selbsttragende

Marktpenetrationsprozess könnte das Entstehen von monopolartigen BDAI-Anbietern begünstigen („The

winner takes it all“). Für den Verbraucher sind solche Angebote meist nur scheinbar kostenfrei, da sie

letztendlich durch die Auswertung der Daten finanziert werden, die sie den Anbietern zur Verfügung stellen,

beispielsweise über individualisierte Werbung („There is no free lunch.“).

Unregulierte BDAI-Anbieter können auch für den Finanzmarkt systemrelevant werden |

Dominante BDAI-Anbieter können Daten, die sie außerhalb des Finanzsektors gewinnen, auch im Finanzmarkt profitabel

einsetzen. Treten diese Unternehmen mit eigenen Angeboten in den Finanzmarkt ein, könnten sie dort

schnell systemrelevant werden. Systemrelevanz könnten sie aber auch mittelbar entfalten, indem sie der

Finanzdienstleistungsbranche ihre Daten oder Infrastrukturen kostenpflichtig zur Verfügung stellen,

wodurch dann Abhängigkeiten entstehen. Denn wenn sich die Erkenntnisse dieser BDAI-Anbieter für die

Finanzdienstleistungsbranche als wertvoll erweisen, etwa für die präzisere Risikoeinschätzung, wird ein

hoher Wettbewerbsdruck entstehen: Kaum ein Wettbewerber wird darauf verzichten wollen, auch auf diese

Erkenntnisse zuzugreifen.

1.2.1 Banken

BDAI-Innovationen verstärken die Disaggregation der Wertschöpfungskette – die Trennung von Kundenschnittstelle und Produktplattform³ ist möglich | Die Verbreitung von BDAI-Anwendungen verstärkt die bereits herrschende Tendenz zur Disaggregation von Wertschöpfungsketten im Bankenmarkt. Neue Wettbewerber besetzen mit ihren BDAI-getriebenen Geschäftsmodellen oder BDAI-Anwendungen Teile der Wertschöpfungskette. Einige neue Anbieter treten von der Kundenschnittstelle ausgehend in den Markt ein, andere besetzen Glieder der Wertschöpfungskette in der Produktplattform. Neue Anbieter sind heute nicht mehr gezwungen, ein vollständiges bankfachliches Produkt anzubieten, sondern können sich auf solche Teile der Wertschöpfung beschränken, die für sie einen besonders hohen Mehrwert liefern. Incumbents könnten dadurch zunehmend in die Rolle eines Infrastrukturdienstleisters für Angebote Dritter gedrängt werden. Darüber hinaus wäre es denkbar, dass Incumbents einzelne Funktionen in Form von Dienstleistungen anbieten.

Wettbewerb an der Kundenschnittstelle könnte durch BDAI-Innovation entschieden werden | Bei Angeboten mit direktem Kundenkontakt kann die Anwendung von BDAI einen nachhaltigen Wettbewerbsvorteil bringen, da sie dazu beitragen kann, veränderte Kundenerwartungen zu erfüllen. Wichtig sind beispielsweise die Schnelligkeit von Prozessen und Entscheidungen, eine reibungslose Interaktion zwischen Dienstleistern und Kunden sowie die Individualisierung/Personalisierung der Dienstleistung. Bigtechs könnten hierbei ihre Erfahrung bei der Automatisierung von personalisierten Dienstleistungen bzw. in der bedarfsorientierten Kundenansprache ausspielen, um die Kundenschnittstelle zu besetzen. Durch einen verstärkten Wettbewerb an der Kundenschnittstelle könnte es zu einer Umverteilung von Erträgen kommen.

Transaktionsdaten sind wertvoller BDAI-Dateninput und interessieren auch Anbieter außerhalb des Finanzsektors | Transaktionsdaten sind im Vergleich zu anderen Daten zu Kundenverhalten und -präferenzen besonders wertvoll für BDAI-Anwendungen, da sie das tatsächliche Ausgabeverhalten und die Zahlungsfähigkeit der Kunden nahezu tagesaktuell widerspiegeln und eine genaue Analyse ermöglichen. Diese Analyse kann beispielsweise als Basis für individualisierte Angebote der Bank dienen. Grundsätzlich sind Incumbents in ihrer Rolle als Hausbank in einer guten Ausgangsposition, um solche Analysen zu erstellen: Sie verfügen über umfangreiche Transaktionsdaten aus Zahlungsverkehr und Kontoführung und haben zudem eine Sicht auf das Gesamtportfolio aller Kunden. Auf diese Daten können aber auch Zahlungsdienstleister zugreifen, wenn Kunden damit einverstanden sind. Auch Unternehmen außerhalb der Finanzdienstleistungsbranche – insbesondere Bigtechs – könnten daher ihre Bemühungen verstärken, über Angebote an der Kundenschnittstelle, z.B. von Zahlungsdiensten, Zugriff auf diese Daten zu erhalten, um die daraus gewonnenen Daten zur Optimierung der Angebote auf der eigenen Plattform zu nutzen.

BDAI-Innovationen ermöglichen Effizienz- und Effektivitätsgewinne in Kernprozessen | Auf Produktplattformen bietet die Anwendung von BDAI großes Potential für alle bankfachlichen Kernprozesse. Effizienzgewinne sind typischerweise vor allem in Bereichen denkbar, in denen eine hohe Zahl hinreichend ähnlicher Vorgänge zu beobachten ist. Dies ist vor allem im Privatkundensegment und bei kleinen und mittleren Firmenkunden der Fall. Abwicklungsprozesse im Middle- und Backoffice könnten effizienter gestaltet werden, indem durch BDAI-Anwendungen Prozesse automatisiert werden, die bisher zu komplex für eine Automatisierung waren. Auch in Compliance-Prozessen, vor allem in der Geldwäscheprävention, ist durch den Einsatz von BDAI die Steigerung von Effizienz und Effektivität denkbar. BDAI-Anwendungen könnten zudem Modelle der Risikobewertung noch weiter präzisieren. Hierzu ist aber einschränkend anzumerken, dass in den vergangenen Jahrzehnten auf diesem Gebiet bereits erhebliche analytische und datenbasierte Optimierungsmaßnahmen vorgenommen wurden, sodass Verbesserungspotentiale unter Umständen begrenzter sind als beim Einsatz zur Prozessautomatisierung und -optimierung.

³ Als Produktplattform sollen im Folgenden solche Funktionen und Prozesse im Middle- und Backoffice zusammengefasst werden, die erforderlich sind, um Produkte und Dienstleistungen herzustellen, die an der Kundenschnittstelle (Frontoffice) angeboten werden.

Verkauf anonymisierter Datenauswertungen als potenzielles neues Geschäftsmodell – klassische Erträge sind hierdurch aber nicht zu ersetzen

| Die Monetarisierung von Daten ist als zusätzliche Ertragsquelle für Finanzinstitute vorstellbar. Hierzu gehört der Verkauf aggregierter, anonymisierter Informationen zu bestimmten Transaktions- und Stammdaten. Es ist allerdings nicht zu erwarten, dass sich damit kurzfristig die klassischen Erträge im Bankgeschäft ersetzen lassen. Zudem müssen Anbieter – auch bei formal erfolgter Einwilligung des Kunden – zwischen dem Zusatznutzen durch die Monetarisierung und potenziellen negativen Auswirkungen auf die Reputation und das Verbrauchervertrauen abwägen.

1.2.2 Versicherer

Der Datenmotor Kundenschnittstelle als ein Erfolgsfaktor in Marketing und Verkauf

| In der Versicherungsbranche lässt sich BDAI in vielfältiger Weise einsetzen, insbesondere im Vertrieb. Traditionelle Schadendaten könnten mit werthaltigen (externen) Daten über den Kunden ergänzt und mit BDAI-Methoden ausgewertet werden. Die so gewonnenen Erkenntnisse könnten dann für eine zielgenauere Akquise bzw. Cross-Selling genutzt werden. Dies ist vor allem für das Volumengeschäft interessant, also grundsätzlich im Privatkundengeschäft und dort in umsatzstarken Segmenten wie der Kraftfahrt-, der Hausrat- und der Wohngebäudeversicherung. Bei diesen Versicherungsprodukten sind die Kündigungsfristen kurz, und es werden daher vergleichsweise viele Verträge abgeschlossen. Die Weiterentwicklung der Prozesse an der Kundenschnittstelle durch Investitionen in BDAI-Technologie dürfte folglich gerade für traditionelle Versicherungsunternehmen an Bedeutung gewinnen. Denn dort werden die neuen Daten erfasst, welche die traditionellen Schadendaten ergänzen könnten.

Neue Anbieter mit Expertise in datengetriebenen Geschäftsmodellen können die Kundenschnittstelle besetzen

| Auch der Eintritt neuer Dienstleister für Versicherungen oder versicherungsnahen Leistungen ist denkbar und in Ansätzen bereits zu beobachten. Bigtechs oder Insurtechs könnten versuchen, über ihre Kernkompetenzen die Kundenschnittstelle durch stärker personalisierte Dienstleistungen und Ansprachen zu besetzen und damit den veränderten Erwartungen der Kunden entsprechen. Neue Anbieter, die diesen Ansatz verfolgen, agieren häufig als reine Versicherungsvermittler. Denkbar ist aber auch, dass sie den Zugang zu neuen relevanten Daten nutzen, um selbst oder in Zusammenarbeit mit Incumbents eigene Versicherungsprodukte anzubieten.

BDAI ermöglicht differenziertere Preisgestaltung sowie Effizienz- und Effektivitätsgewinne in Kernprozessen

| Der Einsatz von BDAI-Technologie in Versicherungsunternehmen dürfte Kernprozesse wie die Produktentwicklung und die Schadenregulierung verändern und sie effektiver und effizienter machen. So könnten neue Daten, beispielsweise aus Wearables oder der Telematik, und neue Analyse-Verfahren eine differenziertere Risikoeinschätzung und Preisgestaltung ermöglichen. Dies könnten Versicherer nutzen, um vermehrt situative Versicherungsprodukte zu entwickeln. Denkbar ist auch, dass sich mit Hilfe neuer BDAI-Technologien Risiko-, Verwaltungs- und erwartete Schadenskosten reduzieren lassen (u.a. durch bessere Betrugsprävention, Schadenprävention und -minimierung). Für den Versicherungsnehmer könnte die Interaktion mit dem Versicherer einfacher und weniger zeitaufwändig werden, da die Unternehmen durch stärker automatisierte Prozesse ihren Verwaltungsaufwand insbesondere bei der Schadenregulierung senken können. Je nach Risikoprofil und Bereitschaft zur Nutzung neuartiger Angebote können sich aber auch Nachteile für Versicherungsnehmer ergeben – in Form veränderter Prämien oder generell dem erschwerten Zugang zu Versicherungsdienstleistungen.

BDAI-basierte Schadenprävention und Verkauf anonymisierter Datenpakete als neue Ertragsquellen |

Daten zu Geld machen – dieses neue Geschäftsmodell ist auch in der Versicherungsbranche denkbar, wenn auch bislang nicht in nennenswertem Ausmaß zu beobachten. Versicherungsunternehmen können ihre Daten auf zweierlei Weise monetarisieren. Sie könnten beispielsweise erweiterte Dienstleistungen zur Schadenprävention anbieten, etwa in Form von Unwetterwarnungen im Rahmen einer Wohngebäude- oder Kraftfahrtversicherung. Durch häufigeren und für den Kunden nützlichen Kontakt könnten Versicherer die Versicherten enger an sich binden. Vorstellbar ist auch, dass Versicherer die Daten als anonymisierte Datenpakete an andere Unternehmen veräußern – unter Beachtung des Verbots des Betriebs von versicherungsfremden Geschäft⁴ und der datenschutzrechtlichen Rahmenbedingungen. Beim Umgang mit Daten aus Versicherungsverhältnissen ist allerdings für Versicherer große Umsicht geboten, um keine Reputations- und Vertrauensschäden zu riskieren.

1.2.3 Kapitalmarkt

„More of the same, only faster and better“ | Sollte BDAI verstärkt genutzt werden, ist auch im Kapitalmarkt mit Effizienz- und Effektivitätssteigerungen zu rechnen. Insbesondere wird BDAI in immer mehr Funktionen zur Frontoffice-Unterstützung, im Middle- und Backoffice sowie auf dem Gebiet der Compliance eingesetzt.

BDAI erlaubt eine weitere Automatisierung und Algorithmisierung – und damit eine verstärkte Maschine-Maschine-Interaktion und Beschleunigung bei Handel, Vertrieb und Produktentwicklung. Dabei ist über alle Assetklassen hinweg eine Zunahme bzw. ein Ausbau des algorithmischen Handels (nicht notwendigerweise hochfrequent) absehbar. Dadurch könnten noch bestehende Automatisierungs- und Digitalisierungspotentiale genutzt werden. Die weitere Algorithmisierung könnte auch den Bereich Advisory erfassen, der sich beispielsweise mit Unternehmenszusammenschlüssen beschäftigt. Das hätte zur Folge, dass bisher überwiegend menschliche Tätigkeiten beschleunigt und skalierbar werden.

Bisher haben Fintechs nur einen geringen Einfluss auf die Struktur des Kapitalmarktes insgesamt. Sie treten insbesondere in den Bereichen Data und Analytics sowie bei der Ausführung bzw. den Ausführungstechnologien und der Infrastruktur in Erscheinung. Fintechs entfalten sich bislang vor allem in Partnerschaft mit Incumbents. Entsprechend fungieren sie oft als verlängerte Werkbank, Ideengeber oder Spezialanbieter von Prozessänderungen und Effizienzsteigerungen.

Durch BDAI entstehen mehr Akteure, mehr Verbindungen und damit mehr Komplexität | BDAI erleichtert die Spezialisierung und fördert das Entstehen neuer Marktteilnehmer. Dadurch dürften die Wertschöpfungsketten noch weiter fragmentiert werden. Die dem Kapitalmarkt inhärente Verflechtung der Akteure könnte mit dem Eintritt neuer Marktteilnehmer überproportional zunehmen. Durch BDAI könnten also mehr Akteure, mehr Verbindungen und damit mehr Komplexität entstehen.

Hinzu kommt, dass die Nutzung von BDAI von leichtem und standardisiertem Datenzugang profitiert. Dadurch könnte die Zahl der Schnittstellen steigen und die Standardisierung im Front-, Middle- und Backoffice zunehmen. Wenn Teile der Wertschöpfungskette sich leichter auslagern lassen, müssen Make-or-Buy-Entscheidungen künftig möglicherweise neu bewertet werden.

Außerdem wird durch den Einsatz von BDAI die Rolle von Daten-, Analytics- und Prozessanbietern relevanter. Diese Anbietergruppe könnte sich aufgrund von Skaleneffekten noch stärker auf Incumbents konzentrieren. Bestehende Anbieter könnten von selbstverstärkenden Datenerzeugungsstrukturen profitieren. Hierbei werden bereitgestellte Daten zur Erzeugung neuer Daten genutzt, die wiederum von diesen Anbietern veräußert werden können.

⁴ Vgl. § 15 Versicherungsaufsichtsgesetz (VAG).

Finanzmarktfremde Daten wie Social-Media-Inhalte werden verstärkt für Prognosen verwendet, und Bewertungsfrequenzen für illiquide Assets werden erhöht | Die Nutzung von BDAI könnte die Transparenz für Unternehmen erhöhen, die dadurch ihre Wettbewerbspositionen verbessern oder neue Produkte herstellen könnten. Hierbei wird vor allem die Vielfalt der Daten deutlich, die im Kapitalmarkt genutzt werden. Sie reichen von Social-Media-Inhalten bis hin zu Satellitenbildern. Auch eine Finanzialisierung weiterer gesellschaftlicher und wirtschaftlicher Bereiche könnte vorangetrieben werden, z.B. durch Absicherungen gegenüber bisher nicht adressierbaren Ereignissen. Somit würden Bereiche mit der Finanzdienstleistungsbranche vernetzt, die bisher weniger mit ihr verflochten sind.

Darüber hinaus könnten sich durch die Verwendung von BDAI die Bewertungsfrequenzen für illiquide Assets erhöhen. Dadurch könnte sich die Erfassung von Marktwertschwankungen deutlich beschleunigen. Durch diese neuen Volatilitäten könnte das Marktgeschehen dynamischer werden.

1.3 Erfolgsfaktoren für BDAI-Anwendung und -Innovationen

BDAI-Readiness durch Ausgestaltung IT-strategischer und -operativer Rahmenbedingungen | BDAI-Anwendungen sind nur erfolgreich einsetzbar, wenn Daten in hinreichender Qualität und Menge vorliegen. Für die Bereitstellung von Daten ist eine geeignete Datenplattform notwendig. Zudem erfordern BDAI-Anwendungen neue Fähigkeiten und Methoden. So steigt beispielsweise der Bedarf an Mitarbeitern mit Data Scientist-Profilen. Zudem könnten moderne, agile Arbeitsweisen gefragt sein. Schließlich gilt es, in Zeiten zunehmender Vernetzung und Datennutzung für Informationssicherheit zu sorgen.

Verbrauchervertrauen als zentraler Erfolgsfaktor für die Anwendung von BDAI | Datengetriebene Anwendungen könnten vielen Verbrauchern einen Nutzen bieten, etwa über stark individualisierte Produkte und Dienstleistungen. Verbraucher sind allerdings sensibilisiert, was die Verwendung ihrer Finanz- und Gesundheitsdaten angeht. Datenmissbrauch und Lücken in der Informationssicherheit können ihr Vertrauen nachhaltig schädigen. Dabei geht es nicht nur darum, dass Vertrauen ein wertschöpfender Faktor ist. Es geht auch um Rechtspositionen, die – etwa in Gestalt der informationellen Selbstbestimmung – in Deutschland Verfassungsrang genießen.

Datensouveränität der Verbraucher ermöglicht Vertrauen in BDAI-Innovationen | Das Potential von BDAI lässt sich für Finanzdienstleistungen nur nutzen, wenn es gelingt, das Vertrauen der Verbraucher in die wunschgemäße und gesetzeskonforme Nutzung ihrer Daten zu gewinnen und zu erhalten. Neben technischen Möglichkeiten, die eine anonymisierte Analyse ermöglichen, könnte die Datensouveränität der Verbraucher ein Ansatz sein. Eine souveräne Entscheidung kann ein Verbraucher nur treffen, wenn er angemessen über die potenzielle Reichweite und die Konsequenzen der Nutzung seiner Daten aufgeklärt wird, wenn er verlässliche Kontrollmöglichkeiten hat und tatsächlich Wahlfreiheit besitzt. Diese Voraussetzungen müssen die Anbieter gewährleisten.

1.4 Aufsichtliche und regulatorische Implikationen

Finanzstabilität und Marktaufsicht

Regulierungslücken frühzeitig identifizieren und schließen | Mit Hilfe von BDAI sind Innovationen möglich, die den Markteintritt neuer Anbieter befördern. Deren Geschäftsmodelle sind möglicherweise regulatorisch bisher nicht adäquat erfasst. Solche Fälle müssen identifiziert werden, und es gilt, das Spektrum der zu beaufsichtigenden Unternehmen in dem Fall entsprechend zu erweitern.

Transparenz wahren und Kontrolle über neue Strukturzusammenhänge behalten | Durch die stärkere Vernetzung und die zunehmende Komplexität des Marktgeschehens können neue Risiken an den Schnittstellen zwischen den Marktteilnehmern entstehen. Die Vernetzung kann mittelbar entstehen, z.B. durch die Nutzung gleicher Modelle, Daten und Plattformen, aber auch unmittelbar durch neue Vertrags- und Handelsbeziehungen, die erst durch den Einsatz von BDAI erforderlich werden. Da diese Risiken nicht in der Organisationsstruktur der Marktteilnehmer entstehen, besteht die Gefahr, dass diese die Risiken nur unvollkommen identifizieren und steuern können. Aufsichtlich und regulatorisch gilt es daher, die Struktur dieses dynamischen Marktes und die daraus resultierenden Risiken zu bewerten und, wenn nötig, aufsichtlich zu mitigieren.

Systemrelevanz neu definieren und adressieren | Durch BDAI könnten neuartige systemrelevante Unternehmen entstehen, z.B. Daten-, Plattform- und Algorithmenanbieter. Zudem muss Systemrelevanz – wie oben angedeutet – nicht zwangsläufig aus einer rechtlichen Einheit erwachsen, sondern könnte sich auch aus der Interaktion verschiedener Marktteilnehmer ergeben. Klassische aufsichtliche Kennziffern wären dann zur Identifikation ungeeignet. Zudem entfalten bekannte Risikomitigationsmaßnahmen wie etwa Kapitalaufschläge unter Umständen nicht die intendierte Wirkung. Es stellt sich daher die Frage, ob und wie man den bank- und versicherungsfachlich geprägten Begriff der Systemrelevanz weiterentwickeln muss, um auch neuen Geschäftsmodellen bzw. neuen Marktstrukturen gerecht zu werden.

Technische Sicherheitsmaßnahmen aus dem Handel auf andere Bereiche übertragen | Technische Sicherheitsmaßnahmen, die bereits jetzt an Handelsplätzen und im algorithmischen Handel einen großen Raum einnehmen, sind konzeptionell nicht auf diese Anwendungsgebiete begrenzt. Es stellt sich die Frage, ob solche technischen Maßnahmen beim Einsatz von BDAI auch außerhalb von Handelsplätzen erforderlich und sinnvoll anwendbar sind.

Unternehmensaufsicht

BDAI in eine ordnungsgemäße Geschäftsorganisation einbetten | BDAI wird weitere Möglichkeiten zur Automatisierung marktüblicher Prozesse schaffen. Dies impliziert jedoch keine Übertragung der Verantwortlichkeit für die Ergebnisse von BDAI-gestützten Prozessen auf Maschinen. Wichtig ist deshalb, bei der Ausgestaltung von (teil-)automatisierten Prozessen den richtigen aufsichtlich-regulatorischen Rahmen zu setzen und die Einbettung in eine wirksame, angemessene und ordnungsgemäße Geschäftsorganisation zu gewährleisten. Um dies sicherzustellen, sind u.a. eine angemessene Dokumentation und ein wirksames Kontrollsystem erforderlich. Die Verantwortung auch für automatisierte Prozesse verbleibt letztinstanzlich bei der Leitungsebene des beaufsichtigten Unternehmens.

Blackbox-Verweise sind unzulässig – Erklärbarkeit von Modellen ist zu gewährleisten und kann den Analyseprozess verbessern | Es liegt in der Verantwortung des beaufsichtigten Unternehmens, die Erklärbarkeit/Nachvollziehbarkeit von BDAI-basierten Entscheidungen für sachkundige Dritte zu gewährleisten. Modelle lediglich als Blackbox zu betrachten, sieht die Aufsicht kritisch. Durch neue Ansätze ist es den Unternehmen, die diese Modelle verwenden, zumindest möglich, Einblicke in die Funktionsweise des Modells zu erhalten und die Gründe für Entscheidungen kenntlich zu machen. Darüber hinaus bietet eine bessere Verständlichkeit von Modellen die Chance, den Analyseprozess zu verbessern – etwa, indem die verantwortlichen Stellen im beaufsichtigten Unternehmen statistische Probleme erkennen.

Bestehende Governance-Konzepte weiterentwickeln | Es könnte im Zuge der fortschreitenden Automatisierung erforderlich sein, bestehende Governance-Konzepte auf automatisierte Prozesse zu erweitern. Beispielsweise könnte darüber nachgedacht werden, für bestimmte selektive und besonders risikobehaftete BDAI-Anwendungen besondere Schutzmaßnahmen einzuführen, die aus anderen technologischen Anwendungen bereits bekannt sind. In der Luftfahrt wird zur Geschwindigkeitsmessung z.B. ein zusätzliches unabhängiges System als zweites Augenpaar verwendet.

Aufsichtliche Anforderungen an Erklärbarkeit und Effektivität in Compliance-Prozessen definieren |

Dank BDAI lassen sich Anomalien und Muster besser erkennen. Compliance-Prozesse wie zum Beispiel die Geldwäsche- und die Betrugsprävention werden dadurch effektiver und effizienter. Die Ergebnisse der Algorithmen müssten aber nachvollziehbar sein, sodass die zuständigen Stellen und Strafverfolgungsbehörden sie verwenden können. Außerdem ist aufsichtlich und regulatorisch zu diskutieren, ob konkrete Mindestanforderungen an die Effektivität der verwendeten Verfahren formuliert werden sollten.

Ausweichen von Finanzkriminalität auf weniger versierte Institute vermeiden | Sollte BDAI bei einzelnen Instituten zu sehr effektiven Compliance-Prozessen führen, könnten Kriminelle auf Institute ausweichen, die auf diesem Gebiet einen Entwicklungsrückstand aufweisen. Diese Möglichkeit gilt es zu beobachten.

Voraussetzungen für BDAI-Nutzung in aufsichtlich abgenommenen Modellen definieren | Eine Verwendung von BDAI bei Modellen, welche die Aufsicht zulassen muss, stünde ebenfalls unter dem Vorbehalt einer entsprechenden aufsichtlichen Genehmigung im Einzelfall. Über den Einzelfall hinaus könnte die Frage gestellt werden, ob alle BDAI-Methoden für den Einsatz in aufsichtlich abzunehmenden Modellen gleichermaßen geeignet sind oder es Methoden gibt, die per se auszuschließen sind. Darüber hinaus ist zu prüfen, ob die bestehenden gesetzlichen (Mindest-)Anforderungen an die verwendeten Daten und die Modelltransparenz hinreichend sind oder erweitert werden sollten. Welcher Zuwachs an Komplexität für eine bestimmte Verbesserung der Vorhersagequalität angemessen bzw. akzeptabel wäre, könnte ferner Gegenstand einer generellen aufsichtlichen Diskussion werden. Weiterhin ist mit Blick auf dynamische BDAI-Modelle zu erörtern, bei welchen Anpassungen eine Modelländerung im aufsichtlichen Sinne vorliegt. Eine solche Änderung müssten die beaufsichtigten Unternehmen anzeigen und ggf. genehmigen lassen.

Erhöhte Informationssicherheitsrisiken adressieren und auch mit Hilfe von BDAI bekämpfen | Das Management von Informationssicherheitsrisiken steht durch die oben geschilderte BDAI-bedingte Komplexitätszunahme vor neuen Herausforderungen. Zum einen wächst die Angriffsfläche, wodurch die Kontrolle schwieriger wird. Zum anderen entstehen neue Angriffsformen. BDAI könnte im Umkehrschluss aber auch zur Abwehr von Informationssicherheitsrisiken genutzt werden, beispielsweise in der Analyse und Entdeckung von Gefahren. So könnte BDAI z.B. Unregelmäßigkeiten im Verhalten von Verbrauchern beim Online-Banking feststellen und einen möglichen Missbrauch aufdecken.

Kollektiver Verbraucherschutz

Unverhältnismäßiger Abschöpfung der Konsumentenrente⁵ entgegenwirken | BDAI gewährt tiefere Einblicke in Kundencharakteristika und erlaubt eine bessere Vorhersage des Kundenverhaltens. Insbesondere durch die Verknüpfung von finanzwirtschaftlichen Transaktions- und Verhaltensdaten mit Daten zu Präferenzen und Bedürfnissen lässt sich die Zahlungsbereitschaft und -fähigkeit auf Einzelkundenbasis offenlegen. Bei einer (Massen-)Individualisierung kann von jedem Kunden der Preis verlangt werden, den er maximal zu zahlen bereit ist. Es dürfte für Kunden schwer sein, die für sie (unsichtbare) Preisanpassung aufgrund der (Massen-)Individualisierung der Produkte und Dienstleistungen zu bemerken. Somit wird eine Abschöpfung der Konsumentenrente insbesondere auch für Anbieter mit plattformbasierten Geschäftsmodellen möglich, die nicht hauptsächlich Finanzdienstleistungen anbieten. Dies ist vor allem in Situationen kritisch, in denen Verbraucher ein Produkt zwar akut benötigen – etwa einen Kredit – in der sie aber faktisch keine Wahl mehr haben zwischen verschiedenen Angeboten. Auch kann es zu Informationsasymmetrien kommen, nämlich dann, wenn Kunden den Gegenwert der Daten, die sie zur Verfügung stellen sollen (Bezahlen mit Daten), und damit den faktischen Preis der Dienstleistung, nicht kennen. Verbraucher sind daher stärker für die Nutzungsmöglichkeiten und die Bedeutung ihrer (Finanz-)Daten zu sensibilisieren.

⁵ Als Konsumentenrente versteht man die Differenz zwischen dem Preis, den ein Verbraucher für ein Produkt oder eine Dienstleistung maximal zu zahlen bereit ist, und dem Preis, den er tatsächlich am Markt zahlen muss.

Hinreichenden Zugang zu Finanzdienstleistungen ermöglichen | Durch BDAI erst ermöglichte Selektionsmechanismen können den Zugang zu bestimmten Finanzdienstleistungen für einzelne Verbraucher unverhältnismäßig einschränken. Das kann besonders prekär werden, wenn Verbraucher durch eine geringere Produktauswahl benachteiligt werden, sie aber nicht nachvollziehen können, dass dies auf Grund personenbezogener Daten geschieht.

Rechtswidrige Diskriminierung vermeiden | Algorithmen könnten auf Merkmale abstellen, für die rechtlich eine Differenzierung verboten ist. Wenn Anbieter BDAI einsetzen, müssen sie sowohl bei der Programmierung der Algorithmen als auch bei der Kontrolle der erzeugten Ergebnisse darauf achten, dass bei der Anwendung einzelne Verbraucher oder auch Verbrauchergruppen nicht entgegen geltender Rechtsvorschriften diskriminiert werden.

Vertrauen in den Finanzmarkt sicherstellen – Kooperation mit Datenschutzbehörden könnte zunehmen | Die Gewährleistung von Privatsphäre und informationeller Selbstbestimmung ist auch und vor allem im Finanzsektor eine wesentliche Voraussetzung für nachhaltiges Vertrauen. Es liegt zwar in der Verantwortung von Datenschutzbehörden, die Umsetzung von Datenschutzvorgaben zu überwachen. Häufen sich jedoch Verstöße gegen den Datenschutz, kann es zu Missständen kommen, die auch die Finanzaufsicht angehen. Die Kooperation von Finanz- und Datenschutzbehörden wird daher zunehmend an Bedeutung gewinnen.

Faktischen Druck zur Datenfreigabe vermeiden | Sollte ein verbraucherseitig wahrgenommener Kontrollverlust auch im Kontext von Finanzdienstleistungen zunehmen und Alternativen zur Bereitstellung von Daten fehlen, könnte der wahrgenommene oder faktische Druck auf Verbraucher steigen, ihre Daten bereitzustellen. Es wäre denkbar, durch eine Anpassung von Regulatorik und Aufsicht sicherzustellen, dass hinreichend datensparsame bzw. konventionelle Finanzdienstleistungen als gangbare Alternativen angeboten werden. Auf diese Weise ließe sich einem faktischen Zwang zur Datenfreigabe entgegenwirken. Wie Datensparsamkeit bzw. Konventionalität zu definieren wären und welche Finanzdienstleistungen umfasst sein sollten, wäre zu erörtern.

Technische Möglichkeiten zur Verwendung von BDAI mit anonymisierten Daten nutzen | Viele BDAI-Anwendungen lassen sich auch mit hinreichend pseudonymisierten bzw. anonymisierten Daten kreieren. Dank technischer Datenschutzmaßnahmen (z.B. Privacy-preserving Data Mining) sind Innovationen auch ohne den Rückgriff auf persönliche Daten möglich, und durch ein Privacy-by-design-Konzept kann das Vertrauen der Verbraucher in BDAI-Innovationen zusätzlich gestärkt werden. Außerdem bietet sich der Einsatz weiterer innovativer Ansätze an, um einen sicheren Umgang mit persönlichen Daten auch im Zeitalter von BDAI zu ermöglichen.

1.5 Übergeordnete Phänomene in gesamtgesellschaftlicher Sicht

Aus digitalem Nutzerverhalten ableitbare Informationen könnten die Handlungsfreiheit von Verbrauchern einschränken | Bei der Analyse von digitalem Nutzerverhalten greifen Anbieter oft auf persönliche Daten zu bzw. auf Daten, die Rückschlüsse auf individuelle Eigenschaften von Verbrauchern zulassen. Solche Daten sind oft ein wesentlicher Bestandteil BDAI-basierter Innovationen und Dienstleistungen. Zugleich können mit den Informationen, die sich aus dem digitalen Nutzerverhalten ableiten lassen, Verbraucher in ihrem Verhalten beeinflusst und in ihrer Freiheit eingeschränkt werden. Da immer mehr Daten erzeugt und bereitgestellt werden, kann es für viele Verbraucher schwer werden einzuschätzen, wer über welche Daten zu seiner Person verfügt und wie er sie auswertet. Verbraucher könnten gezwungen sein, ihr Verhalten zu ändern, entweder indem sie (Online-)Dienste nicht mehr nutzen oder ihr Verhalten anpassen, um ihre digitale Spur zu optimieren.

Regulatorische Heterogenität vermeiden | BDAI-basierte Geschäftsmodelle wirken sich über nationale Grenzen hinweg gleichförmig aus. Dem steht eine auf vielen Gebieten heterogene Regulierungs- und Aufsichtspraxis gegenüber. Dadurch wächst die Gefahr, dass Anbieter Aufsichtsarbitrage ausnutzen. Der internationale Dialog über ein Level-Playing-Field nach der Maßgabe „gleiches Geschäft, gleiches Risiko, gleiche Regel“ wird daher insbesondere mit Blick auf neue Marktstrukturen immer wichtiger. Wobei die Besonderheiten nationaler Märkte auch künftig hinreichend berücksichtigt werden müssen.

II. Einleitung: Wertschöpfung aus Daten mit Hilfe künstlicher Intelligenz

2.1 Big Data und Artificial Intelligence als Treiber eines tiefgreifenden Wandels

Menschen und Organisationen sind zunehmend digital vernetzt, Computertechnologie kann mit zunehmender Genauigkeit menschlichen Input verstehen und komplexe Aufgaben, wie etwa das Übersetzen von Sprache⁶ und das Beantworten von Fragen durch digitale Assistenten⁷, übernehmen; Fahrzeuge beginnen, sich autonom zu bewegen. Darüber hinaus sind Computer in der Lage, die Fähigkeiten menschlicher Experten bei bestimmten Aufgaben zu übertreffen.⁸ Diese Entwicklungen werden durch die vielfältigen Möglichkeiten der Datenauswertung und -verarbeitung getrieben, die unter den Schlagworten „Big Data“ (BD) und „Artificial Intelligence“ (AI) zusammengefasst werden können. In diesem Kontext sind vor allem Methoden des „maschinellen Lernens“ (ML) in den vergangenen Jahren in den Fokus gerückt. Diese Studie nimmt eine ganzheitliche Perspektive auf die Auswirkungen dieses tiefgreifenden Wandels auf das Finanzsystem ein. Sie befasst sich mit dem Thema sowohl aus der Sicht der Finanzdienstleister als auch aus Sicht von Aufsicht und Regulierung. Neben den Chancen werden auch die Risiken einer vermehrten Nutzung von Big Data und Artificial Intelligence in der Finanzdienstleistungsbranche betrachtet. Aus den Ergebnissen werden mögliche Implikationen für Aufsicht und Regulierung sowie strategische Leitfragen abgeleitet, welche die internationale Gemeinschaft der Aufseher und Regulierer künftig voraussichtlich adressieren müssen.

Im Jahr 2001 führte das Marktforschungsunternehmen Gartner eine systematische Analyse der Herausforderungen und Potentiale durch, die sich durch große Datenmengen ergeben. In diesem Rahmen wurde das 3V-Modell entwickelt, welches Big Data anhand von drei Eigenschaften charakterisiert:

„Big Data is high-volume, high-velocity and/or high-variety information assets that demand cost-effective, innovative forms of information processing that enable enhanced insight, decision making, and process automation.“⁹

Zusätzlich zu den 3Vs (Volume, Velocity, Variety) von Gartner wurden später weitere Charakteristika von Big Data identifiziert, und das 3V-Modell wurde entsprechend ergänzt. Aus Sicht von Regulatorik und Aufsicht – und damit der Themenstellung dieser Studie – spielen vor allem zwei weitere Dimensionen eine wichtige Rolle: (Data) Veracity, also die Qualität und Richtigkeit von Daten, und (Data) Value, der potenzielle Wert von Daten bei zielgerichteter Verarbeitung.¹⁰

⁶ Siehe Wu et al., 2016, Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation. Online verfügbar: <https://arxiv.org/abs/1609.08144>, abgerufen am 19.02.2018.

⁷ Prominente Beispiele aus dem Alltag sind „Alexa“ von Amazon oder „Siri“ von Apple.

⁸ Beispielsweise wurde beobachtet, dass Maschinen bei der Diagnose von Lungenentzündungen und Krebs teilweise genauer sind als Menschen: Rajpurkar et al., 2017, CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. Online verfügbar: <https://arxiv.org/abs/1711.05225>, abgerufen am 19.02.2018. Liu et al., 2017, Detecting Cancer Metastases on Gigapixel Pathology Images. Online verfügbar: <https://arxiv.org/abs/1703.02442>, abgerufen am 19.02.2018.

⁹ Gartner, 2017, Gartner IT Glossary > Big Data – From the Gartner IT Glossary: What Is Big Data? Online verfügbar: <https://www.gartner.com/it-glossary/big-data>, abgerufen am 19.02.2018.

¹⁰ Vgl. IBM, 2015, Why only one of the 5 Vs of big data really matters. Online verfügbar: <http://www.ibmdatahub.com/blog/why-only-one-5-vs-big-data-really-matters>, abgerufen am 19.02.2018.

Big Data stellt ein Schlüsselement für Artificial Intelligence dar. Die produktive Nutzung von AI hängt wiederum stark von Umfang und Qualität verfügbarer Daten ab, mit denen Algorithmen trainiert und getestet werden. Daher werden in dieser Studie beide Themen, soweit dies sinnvoll ist, gemeinsam als Big Data und Artificial Intelligence (BDAI) betrachtet und besprochen.

Die Entwicklung entsprechender Methoden ist kein Phänomen des 21. Jahrhunderts, sondern setzte bereits zu Beginn der zweiten Hälfte des 20. Jahrhunderts ein.¹¹ Zentrales Element von AI ist das induktive Lernen: Im Gegensatz zu klassischen regelbasierten Herangehensweisen müssen nicht sämtliche Varianten einer zu automatisierenden Aufgabe ex ante definiert werden, vielmehr „lernt“ der Algorithmus ähnlich wie der Mensch auf Basis von Beispiel- bzw. Trainingsdaten. In den vergangenen Jahren wurden etwa in der Spracherkennung große Fortschritte erzielt: Neuronale Netze sind heute in der Lage, aus menschlichen Unterhaltungen ähnlich gute oder sogar präzisere Mitschriften zu erzeugen als Menschen.¹²

Das Zusammenspiel zwischen Big Data und Artificial Intelligence lässt sich an drei Grundschritten verdeutlichen, an deren Ende die Handlungs- und Umsetzungsfähigkeit von Maschinen durch BDAI steht: 1) das Sammeln von Daten, 2) die Analyse von Daten sowie 3) das Umsetzen der aus der Datenverarbeitung gewonnenen Erkenntnisse. Diese Schritte folgen einer einfachen Input-Process-Output-Systematik und werden durch zentrale Technologien ermöglicht, die in den vergangenen Jahren entscheidende Fortschritte erzielt haben. Beispiele für den Input sind die optische Zeichenerkennung (Optical Character Recognition) sowie die Erkennung von Sprache oder Gesichtern und Bildern (Voice and Speech Recognition sowie Image and Facial Recognition). Beim Processing geht es beispielsweise um die Verarbeitung von Informationen, das Lernen auf Basis von Beispielen und die Ableitung von Empfehlungen/Vorhersagen. Typische Output-Technologien umfassen etwa die Erzeugung von Sprache (Natural Language Generation) sowie die Umsetzung im Rahmen von Prozessautomatisierungen (Robotic Process Automation). In all diesen Beispielen werden Methoden und Verfahren des maschinellen Lernens genutzt.¹³

Derartige Technologien erlauben breit gefächerte Anwendungen, durch welche die Optimierung von Modellen und deren Schätzgüte und die Übernahme von menschlichen Tätigkeiten durch Maschinen ermöglicht werden. Während bereits seit langem Algorithmen beispielsweise für Risikomodelle in Banken eingesetzt werden, erlaubt das Zusammenspiel von Einlesen von Dokumenten via Optical Character Recognition (Input) und maschinellem Lernen (Processing) jetzt auch die maschinelle Dokumentenverarbeitung, d.h. die Erkennung von Text auch bei wenig strukturierten – etwa handschriftlichen – Dokumenten.

2.2 Eine neue Dynamik durch Big Data und Artificial Intelligence

Die Relevanz von BDAI steigt durch Wechselwirkungen zwischen der Technologie, den Unternehmen und den Verbrauchern. Erstens erlaubt der technologische Fortschritt eine breite praktische Anwendung von BDAI. Zweitens setzen Unternehmen zur Optimierung ihrer Geschäftsmodelle und -prozesse vermehrt auf Daten, deren Auswertung und Nutzung. Drittens ist das Verhalten der Verbraucher zunehmend durch digitale Anwendungen geprägt, wodurch wiederum die Datenerzeugung und -verfügbarkeit steigt.

¹¹ Beispielsweise im Sommer 1956 im Rahmen des Dartmouth Summer Research Project on Artificial Intelligence. Vgl. Moor, 2006, The Dartmouth College Artificial Intelligence Conference: The Next Fifty years. In: AI Magazine, Vol. 27, No. 4, S. 87 – 91.

¹² Siehe Xiong et al., 2016, Achieving Human Parity in Conversational Speech Recognition. Online verfügbar: <https://arxiv.org/abs/1610.0525>, abgerufen am 18.12.2017.

¹³ Detailliert beschrieben in Kapitel VII.7.1III.

Insbesondere die letzten beiden Punkte können stark selbstverstärkend aufeinander wirken. In der Finanzdienstleistungsbranche ist diese Entwicklung in Teilen noch im Anfangsstadium. Jedoch muss davon ausgegangen werden, dass sie sich verstärkt. Auf das Zusammenspiel von Technologie, Unternehmen und Verbrauchern wirken aktuell zudem zentrale regulatorische Veränderungen, insbesondere die überarbeiteten Vorschriften für Zahlungsdienste in der Europäischen Union (PSD 2)¹⁴ und die europäische Datenschutzgrundverordnung (EU-DSGVO). Die beschriebene Wechselwirkung soll im Folgenden detailliert dargestellt werden (vgl. Abbildung 1).

Abbildung 1: Dynamik aus Technologie, Unternehmen, Verbrauchern und regulatorischem Umfeld



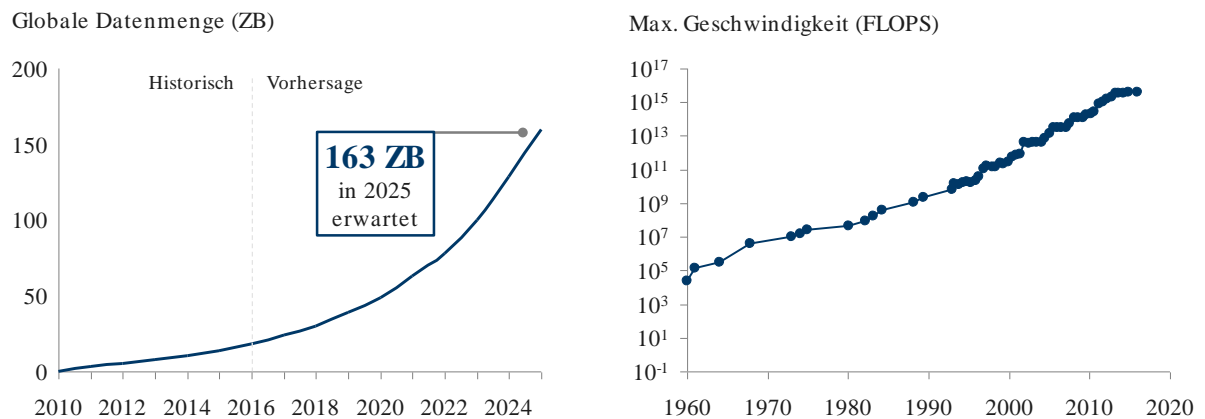
Große Datenmengen stehen zusammen mit leistungsfähiger Hardware und marktreifen Auswertungs- und Verarbeitungstechnologien für Daten zur Verfügung.

Die Ära der elektronischen Datenverarbeitung hat bereits in den 1970er Jahren begonnen. In dieser Zeit wurde die Grundlage für die Erzeugung, Speicherung und Verarbeitung großer Datenmengen gelegt. Das Zeitalter der Massendaten brach aber erst rund zwei Jahrzehnte später an: Mit der Verbreitung des Internets seit den 1990er Jahren wurde die digitale Welt Teil des täglichen Lebens von Verbrauchern und trägt seitdem zu einem rasanten Datenwachstum bei. Zudem sorgen Smartphones seit den 2000er Jahren für eine massive Zunahme von Bild-, Ton- und Positionsdaten. Schließlich steigert das Internet der Dinge (IoT) die Vernetzung und bringt seit einigen Jahren eine steigende Zahl neuer Messpunkte durch Sensoren hervor.

Neben der wachsenden Datenmenge hat auch die Rechenleistung von Computern exponentiell zugenommen (vgl. Abbildung 2). Außerdem steht vermehrt kostengünstiger Speicherplatz zur Verfügung, wodurch die Hardwareleistung zusätzlich gesteigert wird. Speicher- und Rechenkapazität müssen heute nicht mehr zwingend selbst vorgehalten werden, sondern können von Anbietern in der Cloud zur Verfügung gestellt werden. Dadurch ist es mittlerweile möglich, die benötigte Hardwareleistung auch punktuell für bestimmte Zeiträume und skalierbar abzurufen. Diese technologische Entwicklung senkt die Barrieren für die Nutzung von BDAI durch Unternehmen.

¹⁴ Payment Services Directive 2.

Abbildung 2: Anstieg der global verfügbaren Datenmenge und Rechenleistung¹⁵



Die Möglichkeiten von BDAI-Technologien und entsprechender Anwendungen haben in den vergangenen Jahren massiv zugenommen. Machine Vision ist beispielsweise elementarer Bestandteil des heute weit vorangeschrittenen autonomen Fahrens¹⁶, und die maschinelle Gesichtserkennung liefert oftmals bereits genauere Ergebnisse als die Gesichtserkennung durch den Menschen.¹⁷ Ein Beispiel für den Fortschritt in der maschinellen Spracherkennung sind smarte Lautsprecher, die heute hauptsächlich über die Stimme steuerbar sind. Der historische Vorläufer „Shoebbox“ von IBM konnte hingegen in den 1960er Jahren nur wenige vordefinierte Worte erkennen.

Technologieunternehmen haben bewiesen, dass sich durch den Einsatz von BDAI ein erheblicher Wettbewerbsvorteil erzielen lässt. Folglich fließt zunehmend mehr Kapital in Big-Data-Lösungen und AI-anwendende Unternehmen wie Fintechs.


Die Verfügbarkeit von Daten und der notwendigen Hardwareleistung, um diese Daten ökonomisch nutzen zu können, führte bei vielen Unternehmen zu einer Transformation der Wertschöpfung. Datengetriebene Geschäftsmodelle, bei denen Daten primär auf Basis von BDAI monetarisiert werden, haben einige Technologieunternehmen zu den heute nach Marktkapitalisierung mit am höchsten bewerteten Unternehmen aufsteigen lassen (vgl. Abbildung 3). Sieben der zehn Unternehmen mit der höchsten Marktkapitalisierung verfolgen ein datengetriebenes Geschäftsmodell und gelten als die innovativsten Technologieunternehmen.

¹⁵ ZB = Zettabyte, FLOPS = floating point operations per second. Quelle linke Grafik: IDC, 2017, Data Age 2025. Online verfügbar: <https://www.seagate.com/files/www-content/our-story/trends/files/Seagate-WP-DataAge2025-March-2017.pdf>, abgerufen am 19.02.2018. Quelle rechte Grafik: Denning et al., 2017, Exponential Laws of Computing Growth. Online verfügbar: http://www0.cs.ucl.ac.uk/staff/ucacbb/gggp/langdon_sse_8-feb-2017.pdf, abgerufen am 19.02.2018.

¹⁶ Siehe Dubey, 2016, Stereo vision—Facing the challenges and seeing the opportunities for ADAS applications. Online verfügbar: <http://www.ti.com/lit/wp/spr300/spr300.pdf>, abgerufen am 12.12.2017.

¹⁷ Vgl. MIT, 2017, Facial Recognition Is Getting Incredibly Powerful—and Ever More Controversial. In: MIT Technology Review. Online verfügbar: <https://www.technologyreview.com/the-download/608832/facial-recognition-is-getting-incredibly-powerful-and-ever-more-controversial/>, abgerufen am 12.12.2017.

Abbildung 3: Anteil Technologieunternehmen mit datengetriebenen Geschäftsmodellen an der Marktkapitalisierung der Top-10-Unternehmen¹⁸



¹ Zu diesem Zeitpunkt noch „Google“.

Weltweit wird zunehmend in BDAI investiert. So werden Investitionen in Big-Data-Lösungen von 2016 bis 2021 voraussichtlich jährlich um ca. 13 Prozent steigen.¹⁹ Auch die globalen Investitionen in entsprechende Fintechs sind in den vergangenen Jahren erheblich gestiegen. Von 2014 bis 2016 wuchs das weltweite Funding in Fintechs mit AI-bezogenen Geschäftsmodellen um ca. 60 Prozent auf über zwei Milliarden US-Dollar (USD). Das Kapital, mit dem AI-anwendende Fintechs finanziert wurden, betrug im Jahr 2016 etwa das Siebenfache im Vergleich zu 2010.²⁰ Die hohe Liquidität in den Märkten wird also auch von BDAI-Lösungen angezogen.

Für Verbraucher kann sich durch BDAI-Anwendungen ein erhöhter Nutzen ergeben. Durch Nutzung entsprechender Angebote werden zusätzliche Daten generiert, was wiederum eine Selbstverstärkung der BDAI-Dynamik bewirkt.

Zum einen können Prozesse in der Interaktion zwischen Unternehmen und Kunden deutlich vereinfacht und beschleunigt werden. Zum anderen wird eine datenbasierte, gezielte Vertriebssteuerung in Echtzeit möglich, was es erlaubt, Kunden maßgeschneiderte Produkte sowie Dienstleistungen zu offerieren. Durch eine immer granularere Segmentierung von Kunden und die Individualisierung von Produkten kann auf Seiten der Verbraucher die Bereitschaft steigen, entsprechende Angebote anzunehmen.

Durch den oft schnellen und einfachen Zugang zu digitalen Dienstleistungen in unterschiedlichen Branchen (u.a. durch die hohe Marktpenetration von Smartphones) können sich auch die Erwartungen der Verbraucher an Finanzdienstleistungen ändern. Das Verbraucherverhalten ist zunehmend durch digitale Technologie geprägt, die auf der Verarbeitung und Nutzbarmachung von Verbraucherdaten basiert. Dies wiederum kann auch im Finanzkontext zu einer höheren Datenverfügbarkeit führen. Zugleich ist jedoch häufig ein hohes Misstrauen gegenüber der Datennutzung durch Unternehmen zu beobachten. So stehen europäische Verbraucher laut Umfragen einer Kommerzialisierung ihrer persönlichen Daten kritisch gegenüber.²¹ Das Vertrauen der Verbraucher wird daher im Zusammenhang mit BDAI zu einem wichtigen Erfolgsfaktor. Dies gilt insbesondere mit Blick auf den Finanzsektor, da bei nicht adäquaten Praktiken der

¹⁸ S&P capital IQ: Top 10 Unternehmen (weltweit) nach Marktkapitalisierung an den Tagen 29.12.2006, 30.12.2011, 29.12.2017.

¹⁹ Investitionen in Form von Lizenzen für das Bereitstellungsmodell, laufender Wartung, On-Premise-Abonnements, Cloud-Abonnements, sonstigen) Dienstleistungen. Siehe Forrester, 2016, Big Data Management Solutions Forecast, 2016 To 2021 (Global).

²⁰ 2015 Zuwachs in AI-bezogenem Fintech-Funding insbesondere durch Palantirs 880-Millionen-Dollar-Finanzierungsrunde. Quelle: BCG FinTech Control Tower.

²¹ Vgl. De Mooy, 2017, Center for Democracy and Technology, Datensouveränität in Zeiten von Big Data, S. 8. Online verfügbar: <https://www.bertelsmann-stiftung.de/de/unsere-projekte/teilhabe-in-einer-digitalisierten-welt/projektnachrichten/datensouveraenitaet-in-zeiten-von-big-data/>, abgerufen am 18.01.2018.

Datennutzung das Vertrauen in den Finanzmarkt insgesamt beeinträchtigt werden könnte. Insgesamt kann durch BDAI die Wissensasymmetrie zwischen Kunden und Anbietern zunehmen. Dadurch wird es für Kunden potenziell schwerer nachzuvollziehen, ob ihre persönlichen Daten tatsächlich in ihrem Interesse genutzt werden.

Anpassungen im regulatorischen Umfeld können als zusätzliche Beschleuniger möglicher Veränderungen durch BDAI wirken, verlangen von den Unternehmen aber auch, Antworten auf drängende Fragen etwa zum Datenschutz zu finden.²²

Mit der PSD 2 werden Kontoinformations- und Zahlungsauslösedienste erstmals reguliert, welche zuvor häufig in einem rechtlichen Graubereich angeboten wurden. Entsprechende Dienstleister werden damit als offizielle Anbieter anerkannt. Die PSD 2 ermöglicht diesen, an der Kundenschnittstelle innovative Dienstleistungen anzubieten, da sie u.a. Daten von etablierten Finanzdienstleistern über klar definierte Schnittstellen erhalten können, wenn der Kunde dem zustimmt. Die EU-DSGVO hingegen bringt eine Reihe grundlegender Änderungen in der Datenschutzregulierung und eine Vielzahl neuer Anforderungen auch für Finanzdienstleister mit sich. Aus Verbraucher- und Datenschutzperspektive relevante Vorgaben der EU-DSGVO werfen mit Blick auf BDAI neue Fragen auf, welche die Anbieter adäquat adressieren müssen, um den Erwartungen der Verbraucher gerecht zu werden. Hierzu zählt die explizite Zustimmung der Verbraucher zur Datennutzung.

Einige internationale Aufsichts- und Regulierungsbehörden haben sich in den vergangenen Monaten bereits mit dem Veränderungspotential von Big Data und Artificial Intelligence beschäftigt. Ihre Ergebnisse werden im Anhang in Kapitel 7.2 kurz zusammengefasst.

2.3 Zielsetzung und Struktur dieser Studie

Diese Studie unternimmt den Versuch, eine ganzheitliche Perspektive einzunehmen. Es sollen explizit sowohl die Chancen als auch die Risiken einer vermehrten Nutzung von BDAI in der Finanzdienstleistungsbranche beleuchtet werden – und zwar entlang von Finanzstabilität und Marktaufsicht, Unternehmensaufsicht und kollektivem Verbraucherschutz. Die Betrachtung erfolgt aus drei Blickwinkeln: erstens aus Sicht der Finanzdienstleistungsbranche, also von Banken und Finanzdienstleistern, Versicherungsunternehmen und Akteuren am Kapitalmarkt²³, zweitens aus Sicht des Verbrauchers und drittens aus Sicht von Aufsichtsbehörden und Regulierung. Aus den Ergebnissen werden mögliche Implikationen und strategische Leitfragen für Aufsicht und Regulierung abgeleitet, welche die internationale Gemeinschaft der Aufseher und der Regulierer künftig möglicherweise zu adressieren hat. Diese Studie versucht jedoch, nicht bei den Leitfragen zu bleiben, sondern stellt auch mögliche Lösungsansätze zur Diskussion. Diese sind sowohl strategischer als auch technischer und/oder regulatorischer Natur.

Ein wesentliches Differenzierungsmerkmal dieser Studie ist die strategisch-ökonomische Betrachtung der Implikationen für die Marktteilnehmer. Diese erstreckt sich über Banken, Versicherungsunternehmen und den Kapitalmarkt. Zu dieser Betrachtung zählen die Beschreibung und Beurteilung möglicher Marktentwicklungen durch die vollständige Hebung des Potentials von BDAI und die systematische Darstellung von neun konkreten Anwendungsbeispielen. Die Kombination einer systematischen Marktbetrachtung mit konkreten Anwendungsbeispielen ermöglicht es, wesentliche Themen mit aufsichtlicher und regulatorischer Relevanz zu identifizieren und nachvollziehbar zu beschreiben. Im Rahmen dieser Marktbetrachtungen schätzt diese Studie auch das ökonomische Potential von BDAI-Anwendungen qualitativ ein, um so die potenzielle Durchdringung des Marktes durch BDAI und deren Nutzung durch

²² Vgl. Kapitel IV Erfolgsfaktoren für BDAI-Anwendung.

²³ Unter dem Begriff „Kapitalmarkt“ subsumieren wir in dieser Studie u.a. Wertpapierdienstleistungsunternehmen, Investmentvermögen, Kapitalverwaltungsgesellschaften und Betreiber von Handelsplätzen (Börsen).

Finanzdienstleister differenziert darzustellen. Die Studie ist also nicht auf bislang vorhandene BDAI-Anwendungen und deren Umsetzung beschränkt, sondern stellt dar, welches Veränderungspotential BDAI hat. Die Betrachtungen basieren auf umfassender Literaturrecherche, der Auswertung aktueller Daten Dritter und der Analyse selbst erhobener Daten.²⁴ Zusätzlich wurden zur Beurteilung der Marktentwicklungen Gespräche mit Marktteilnehmern geführt.

Der ganzheitliche Ansatz wird mit einer detaillierten Beschreibung der technischen und strategischen Umsetzung von BDAI abgerundet. Zur Fundierung der technologischen Analysen wurden Experten aus Wissenschaft und Forschung an der Studie beteiligt.²⁵ So werden in dieser Studie einer breiteren Leserschaft allgemein verständlich und im Sinne eines kurzen Nachschlagewerks die Analyseverfahren, die bei BDAI Anwendung finden, näher gebracht. Hierbei werden auch innovative Ansätze nicht vernachlässigt: Unter anderem wird beispielsweise ein Ansatz vorgestellt, der es erlaubt, eine Auswertung und ökonomische Nutzung von Daten bei gleichzeitiger Wahrung der Privatsphäre vorzunehmen. Mit Blick auf die strategische Umsetzung von BDAI wird zudem die Frage beantwortet, welche Voraussetzungen Unternehmen schaffen müssen, um BDAI erfolgreich anzuwenden. Es wird über die Wahrung des Verbrauchervertrauens als einen weiteren wichtigen Erfolgsfaktor für die Nutzung von BDAI diskutiert. Außerdem ist eine ganzheitliche IT-Strategie erforderlich, die sowohl eine funktionierende Organisationsstruktur als auch eine funktionierende Dateninfrastruktur sicherstellt.

Die Studie gliedert sich nachfolgend in vier Kapitel:

Kapitel III („Technologische Voraussetzungen für die Nutzung von Big Data und Artificial Intelligence“) veranschaulicht einer breiteren Leserschaft die technologische Komplexität von BDAI, stellt neue Innovationen in diesem Bereich vor und geht auf Themen wie Nachvollziehbarkeit von Algorithmen ein.

Kapitel IV („Strategische Voraussetzungen“) beschreibt strategische Erfolgsfaktoren für die Realisierung von BDAI in der Finanzdienstleistungsbranche. Die Darstellung der Voraussetzungen für eine erfolgreiche Realisierung von BDAI erleichtert es, das Veränderungspotential von BDAI einzuordnen und zu beurteilen und erweitert den Blick auf zusätzliche, für Regulierungs- und Aufsichtsbehörden relevante, Themenfelder. Das Kapitel konzentriert sich deshalb auf die beiden Themen Verbrauchervertrauen und IT-strategische Erfolgsfaktoren (z.B. Daten und Cloud sowie notwendige Kompetenzen wie die Qualifikation der Mitarbeiter und agile Methoden). Dem Kapitel vorangestellt ist eine Betrachtung von BDAI aus der Perspektive des Verbrauchers (Kapitel 4.1.1).

Kapitel V („Perspektive des Marktes“) befasst sich mit drei Branchen. Jede dieser Branchen – Banken, Versicherer, Kapitalmarkt – wird unter BDAI-Gesichtspunkten betrachtet, jeweils untermauert von drei Anwendungsbeispielen. Diese wiederum beziehen sich jeweils auf einen von drei spezifischen Nutzenbereichen von BDAI (Kundenschnittstelle, Kernprozesse, neue Geschäftsmodelle).

Kapitel VI („Perspektive der Aufsicht“) leitet aus allen vorangegangenen Kapiteln konkrete Implikationen für Regulatorik und Aufsicht ab. Diese werden anhand von drei Schwerpunkten (Finanzstabilität und Marktaufsicht, Unternehmensaufsicht und kollektiver Verbraucherschutz) aus aufsichtlicher und regulatorischer Perspektive erörtert. Daraus werden zudem Leitfragen abgeleitet.

²⁴ Die Marktbetrachtungen und Analysen der (technologischen) Erfolgsfaktoren für BDAI-Anwendung wurden von der strategischen Unternehmensberatung The Boston Consulting Group unterstützt.

²⁵ Die technologischen Beurteilungen in dieser Studie wurden im Wesentlichen vom Fraunhofer Institute for Intelligent Analysis and Information Systems unterstützt.

III. Technologische Voraussetzungen für die Nutzung von Big Data und Artificial Intelligence

Zusammenfassung

Maschinelles Lernen

Unter maschinellem Lernen (ML) versteht man, Computern durch geeignete Algorithmen die Fähigkeit zu verleihen, aus Daten zu lernen. Dadurch können sie ein Modell ihrer Welt aufbauen und die ihnen zugeordneten Aufgaben besser lösen.

Ansätze des ML lassen sich anhand der Lernaufgabe (man unterscheidet grundsätzlich zwischen Klassifikation, Regression und Clustering), der Datentypen (spezielle Ansätze existieren z.B. für Text, Sprache und Bilddaten) und der Algorithmen (wie wird das Problem technisch gelöst) charakterisieren.

ML-Verfahren können nicht selbstständig operieren, sondern müssen von Spezialisten (Data Scientists) aufgesetzt, angewandt und evaluiert werden.

Technische Hintergründe

Big Data ist ein Haupttreiber der Erfolge maschinellen Lernens. Vorteile lassen sich nicht nur aus dem Wachsen der Datenmengen ziehen, sondern insbesondere auch aus der zunehmenden automatischen Auswertbarkeit zuvor nicht analysierbarer Daten (z.B. Texte, Bilder, Sprache und Sensordaten).

Neue Hardware-Lösungen für das massiv parallele Rechnen und sinkende Hardwarekosten sind ein weiterer Haupttreiber für das maschinelle Lernen auf Basis von Big Data.

Algorithmen

Das ML ist aktuell stark in Bewegung, viele neue Ansätze wurden in den vergangenen Jahren entwickelt. Ein erfolgreicher Ansatz, der hinter vielen prominenten Anwendungen steckt, ist das Deep Learning, d.h. das Lernen komplexer neuronaler Netze. Das Deep Learning kann gerade bei der Anwendung auf Basis von Massendaten seine Vorteile ausspielen.

Häufig verwendete klassische Verfahren sind Klassifikationsverfahren wie Entscheidungsbäume oder Support Vector Machines, Regressionsverfahren wie die lineare Regression und Clusteringverfahren wie das k-Means-Clustering.

Aktuell gewinnt auch das bestärkende Lernen (Reinforcement Learning) an Bedeutung, das zur Steuerung von Maschinen bzw. intelligenten Agenten eingesetzt werden kann.

Artificial Intelligence

Aktuell vollzieht sich in der IT ein grundlegender Paradigmenwechsel: Während früher Fach- und IT-Experten das Verhalten komplexer Systeme programmiert haben, zeigt sich aktuell in vielen Einsatzgebieten das maschinelle Lernen auf Basis von Big Data als überlegen. In einigen Bereichen sind Computer bereits besser als menschliche Experten.

Diese Erfolge der KI sind allerdings immer noch nur in eingeschränkten Anwendungsbereichen zu finden. Ansätze zur generellen Nachbildung von menschlicher Intelligenz – die harte AI – sind nach wie vor nicht absehbar.

Etwas zugespitzt lässt sich dies auf die Formel Big Data + Rechenressourcen + ML = AI bringen.

Neue Anwendungen

Question-Answering beantwortet in natürlicher Sprache gestellte Fragen. Aktuelles Beispiel ist Amazons Alexa.

Dialogsysteme führen Dialoge in gesprochener Sprache mit Menschen und sind beispielsweise für den Einsatz in Call Centern interessant.

Intelligente Agenten führen komplexe Handlungen anstelle des Menschen aus. Aktuell sind herausragende Leistungen von intelligenten Agenten bei Spielen, z.B. Go, zu finden.

Neue Herausforderungen

Viele gesellschaftliche Anforderungen werden im maschinellen Lernen aufgegriffen und mit geeigneten Algorithmen angegangen. Dazu zählen der Datenschutz, der durch Privacy-preserving Data Mining adressiert wird, die Nicht-Diskriminierung von Personengruppen bei automatischen Entscheidungen, die Transparenz und Erklärbarkeit von komplexen Modellen und deren Ergebnissen sowie die Datensouveränität.

Für alle diese Herausforderungen gibt es im maschinellen Lernen Ansätze. Dennoch kann ML diese Fragen nicht allein lösen, da es sich nicht um rein technisch-statistische, sondern um gesellschaftliche Themen handelt. Es gibt insbesondere auf keine der Fragen eine bereits allgemein anerkannte Antwort; der Themenkomplex ist aktuell im Fokus vieler Forschungsaktivitäten.

3.1 Von Big Data zu Artificial Intelligence

In der IT vollzieht sich zurzeit ein grundlegender Paradigmenwechsel: Während früher das Verhalten komplexer Systeme im Zusammenspiel von Fach- und IT-Experten einprogrammiert oder allenfalls auf Basis sorgfältig ausgewählter statistischer Modellannahmen aus Daten adaptiert wurde, zeigt sich das maschinelle Lernen aktuell in vielen Einsatzgebieten als überlegen.

Die Idee, durch maschinelles Lernen Computern intelligente Fähigkeiten zu verleihen, ist nicht neu. Sie kam sehr bald nach der Erfindung der ersten Computer auf. Bereits 1950 nahm Alan Turing, ein britischer Mathematiker und einer der Vordenker der Artificial Intelligence an, dass ein wirklich intelligentes System sich wohl in seiner Gesamtheit nicht durch detailliert vorprogrammierte einzelne Verhaltensweisen werde realisieren lassen. Er träumte daher von Maschinen, die selbst lernen, mit ihrer Umgebung interagieren und somit künstlich intelligent werden:

*"Our problem then is to find out how to programme these machines to play the game. At my present rate of working I produce about a thousand digits of programme a day, so that about 60 workers, working steadily through the 50 years might accomplish the job, if nothing went into the waste paper basket. Some more expeditious methods seem desirable."*²⁶

Allerdings verhalf erst die weitgehende Verfügbarkeit großer Datenmengen dem maschinellen Lernen zu den Durchbrüchen, die den Computer bei bestimmten Aufgaben an die Fähigkeiten des Menschen heranreichen lassen. Dieser Paradigmenwechsel vom Programmieren zum Lernen hat weitreichende Auswirkungen: Genügend Daten vorausgesetzt, werden Probleme lösbar, für die mit klassischer Programmierung keine Lösung entwickelt werden kann. Die Erfolge des maschinellen Lernens sind allerdings bislang nur in sehr spezifischen Anwendungsbereichen zu finden. Ansätze zur generellen Nachbildung von menschlicher Intelligenz – die harte AI – sind nach wie vor nicht absehbar.

3.2 Maschinelles Lernen und seine Algorithmen

Maschinelles Lernen bezeichnet, sehr allgemein formuliert, die Idee, Computern durch geeignete Algorithmen die Fähigkeit zu verleihen, aus Daten und Erfahrungen zu lernen. Computer können damit ein Modell ihrer Welt aufbauen und die ihnen zugeordneten Aufgaben besser lösen.

Häufig wird nicht zwischen der speziellen Anwendung maschineller Lernverfahren und dem Gesamtprozess der Wissensentdeckung unterschieden, der laut einer häufig verwendeten Definition als „der nicht-triviale Prozess, valide, neue, potenziell nützliche und im Ergebnis verständliche Muster in Daten zu identifizieren“²⁷, bezeichnet wird. Dieser Gesamtprozess beinhaltet üblicherweise eine stark manuelle Komponente, die insbesondere die Definition der Aufgabe, die Auswahl und Aufbereitung von Daten und die Bewertung von Ergebnissen umfasst, während es sich beim maschinellen Lernen um den automatischen Teil der Modellerstellung handelt.

²⁶ Turing, 1950, Computing machinery and intelligence. Mind 49, S. 433–460.

²⁷ Fayyad et al., 1996, From Data Mining to Knowledge Discovery: An Overview. Advances in Knowledge Discovery and Data Mining, In: AAAI Press, S. 1–30.

Dimensionen des maschinellen Lernens

Typischerweise generiert ein Lernalgorithmus in einer ersten Phase, der Lern- bzw. Trainingsphase, ein Modell aus den Daten. In einer zweiten Phase, der Testphase, wird das Modell statistisch auf seine Qualität geprüft und – falls möglich – vom Anwender inhaltlich bewertet. In der darauf folgenden Anwendungsphase wird das Modell auf ungesehene Daten angewendet, um Prognosen abzugeben. Typische Anwendungen von maschinellen Lernverfahren im Finanzsystem sind Bonitätsbewertungen, die Prognose von Aktienkursen, das Erkennen von Betrugsversuchen in Kreditkartentransaktionen oder die Gruppierung von Privatkunden zu Vertriebszwecken.

Anwendungen von maschinellen Lernverfahren lassen sich anhand verschiedener Dimensionen charakterisieren. Die Wichtigsten sind:

- **Lernaufgabe:** Welche mathematisch-formale Aufgabe soll gelöst werden? Es haben sich diverse Standard-Lernaufgaben herausgebildet, welche die meisten Anwendungen abdecken. Die wichtigsten, die im Folgenden weiter beschrieben werden, sind das überwachte Lernen, das unüberwachte Lernen und das verstärkende Lernen.
- **Datentypen:** Im klassischen maschinellen Lernen ging man zunächst von tabellenartigen Daten aus. Später haben sich für verschiedenen Datentypen spezialisierte Verfahrensklassen gebildet, z.B. für die Analyse von Textdaten, Bildern, Audio/Sprache, Netzwerken und Zeitreihen.
- **Algorithmus/Modellklasse:** Eine technische Unterscheidung kann anhand der Art des Algorithmus oder anhand der Art des Modells vorgenommen werden. Typische Modellklassen sind bestimmte Arten numerischer Funktionen (z.B. lineare Funktionen, Polynome, Gauß-Funktionen) oder logische Modelle (z.B. Wenn-dann-Regeln und Entscheidungsbäume). Eine aktuell sehr prominente Algorithmenklasse ist das Deep Learning.

Diese Dimensionen sind nicht unabhängig voneinander. So lassen sich etwa sehr unterschiedliche Lernaufgaben mit sehr ähnlichen Algorithmen lösen. Für bestimmte Datentypen haben sich dagegen sehr spezielle algorithmische Ansätze herausgebildet, die für andere Arten von Daten nicht anwendbar sind.

3.2.1 Überwachtes Lernen (Supervised Learning)

Ziel des überwachten Lernens ist es, ein Zielmerkmal (auch Label genannt) anhand von erklärenden Merkmalen²⁸ zu prognostizieren. Das Label kann sowohl ein nominales Merkmal (z.B. Kunde kündigt seinen Vertrag oder nicht) oder ein numerisches Merkmal (z.B. Schadenshöhe) sein. Im ersten Fall spricht man von einem Klassifikations- und im zweiten von einem Regressionsproblem. Für eine detailliertere Erläuterung von repräsentativen Verfahren des überwachten maschinellen Lernens verweisen wir auf Kapitel 7.1.1.

Wichtig beim überwachten Lernen ist es, dass eine Verallgemeinerung des gelernten Wissens auf neue Datenmuster erwünscht ist. Reines Auswendiglernen der bereits gesehenen Datenpunkte reicht nicht aus. Schafft es das Modell, auch auf Basis ungesehener Daten ähnlich gute Vorhersagen zu erzeugen wie auf den Trainingsdaten, spricht man davon, dass das Modell gut generalisiert. Datenpunkte werden in diesem Sinne gewöhnlich auch Beispiele genannt, da es sich um Beispiele für den zu lernenden Zusammenhang handelt.

²⁸ In der Statistik und im maschinellen Lernen haben sich unterschiedliche Sprachgebräuche herausgebildet. In der Statistik wird ein Merkmal Variable genannt und insbesondere das Zielmerkmal als abhängige Variable bezeichnet.

3.2.2 Unüberwachtes Lernen (Unsupervised Learning)

Beim unüberwachten Lernen werden mit unterschiedlichen Verfahren intrinsische Muster aus den Daten extrahiert. Im Unterschied zum überwachten Lernen liegt hier also keine Frage vor, die sich in ein konkretes Zielmerkmal kodieren lässt. Dies macht das unüberwachte Lernen schwieriger als das überwachte Lernen, da die Qualität einer Lösung oft nur subjektiv durch den Anwender bestimmt wird und sich nicht objektiv über statistische Maße in die Algorithmen integrieren lässt.

Zwei der wichtigsten Lernaufgaben im unüberwachten Lernen sind das Clustering und die Anomalieerkennung – zum Beispiel zum Zwecke der Datenqualitätssicherung. Ziel des Clustering ist es, die Daten in Cluster (Gruppen) ähnlicher Beispiele aufzuteilen, d.h. zwei Beispiele im selben Cluster sollen möglichst ähnlich sein und Beispiele aus verschiedenen Clustern möglichst unähnlich. Eine mögliche Anwendung ist die Segmentierung von Kunden anhand von deren soziodemographischen Eigenschaften oder Kaufverhalten. Ein sehr häufig genutztes Clustering-Verfahren ist das k-Means-Clustering, das in Kapitel 7.1.2.1 im Detail und auf Basis von Beispielen aus dem Finanz- und Versicherungsbereich näher erläutert wird.

Bei der Anomalieerkennung (auch Ausreißerererkennung) sollen einzelne Datenpunkte, die nicht dem Muster des Großteils der Datenpunkte folgen, erkannt werden. Ein typisches Beispiel hierfür ist die Betrugserkennung. Beide Aufgaben sind insofern verwandt, als dass beim Clustering Datenpunkte, die keinem Cluster zugeordnet werden können Anomalien sind. Eine detaillierte Erläuterung der Anomalieerkennung findet sich in Kapitel 7.1.2.2.

3.2.3 Bestärkendes Lernen (Reinforcement Learning)

Eine weitere relevante Lernaufgabe neben dem überwachten und dem unüberwachten Lernen ist das bestärkende Lernen²⁹ (Reinforcement Learning). Es wird in Situationen angewandt, in denen Computersysteme in einer Umgebung verschiedene Aktionen durchführen können und nur gelegentlich ein Feedback in Form einer Belohnung erhalten, je nachdem, wie gut die erreichte Situation ist. Die Maschine soll lernen, welche Aktionen sie jeweils auswählen soll, um das Feedback (die Nutzenfunktion) zu maximieren.

Bestärkendes Lernen wird beispielsweise im Lernen von Strategien für Computerspiele verwendet, indem die Maschine gegen sich selbst spielt. Es lässt sich aber auch für Software-Agenten einsetzen. So kann zum Beispiel ein intelligenter Agent auf einer Website versuchen, den Benutzer durch geeignete Aktionen (z.B. Einblendung von Werbung oder Informationen) zu einer bestimmten Handlung (z.B. Klick auf die Werbung oder Vertragsabschluss) zu verleiten.

3.2.4 Deep Learning: Maschinelles Lernen auf Big Data

Eine aktuell sehr prominente Klasse von Lernverfahren, die hinter vielen Durchbrüchen in intelligenten Systemen steckt, ist die der tiefen Neuronalen Netze. Das Teilgebiet des maschinellen Lernens, das sich mit ihnen beschäftigt, wird Deep Learning³⁰ genannt. Weil Deep Learning in vielen aktuellen Anwendungen sehr wichtig ist, soll es an dieser Stelle eingehender beleuchtet werden.

²⁹ Sutton et al., 1998, Reinforcement Learning: An Introduction. The MIT Press.

³⁰ Goodfellow et al., 2016, Deep Learning. The MIT Press. Online verfügbar: <http://deeplearningbook.org>, abgerufen am 20.02.2018.

Konzeptionell besteht kein Unterschied zu den weiter oben vorgestellten klassischen neuronalen Netzen. Allerdings werden beim Deep Learning erheblich komplexere Netzarchitekturen eingesetzt. Sie können – anders als die klassischen Netzwerke mit zwei Schichten – hunderte Schichten und Milliarden von zu lernenden Parametern haben.³¹ Damit sind diese Netze trotz ihrer extrem hohen Ausdruckskraft effizient aus Daten lernbar. Die wichtigste Entscheidung beim Einsatz von Deep Learning besteht also in der Wahl der richtigen Netzarchitektur.

Tiefe neuronale Netze können jegliche Art von Rohdaten verarbeiten, die als Zahlenvektoren kodiert werden, auch Texte, Bilder oder Sprache. Sie sind deshalb so erfolgreich, weil sie aus den Rohdaten selbstständig Darstellungen lernen können, welche die eigentliche Aufgabe erleichtern, eben weil ähnliche Darstellungen eine ähnliche Bedeutung haben. Tiefe neuronale Netze finden automatisch Strukturen in den gegebenen Beispielen, welche die passenden Merkmale für die eigentliche Lernaufgabe liefern. Gewisse Datenvorverarbeitungsschritte, etwa zur computergraphischen Erkennung von Kanten und Flächen und zur linguistischen Erkennung von Lauten und Wörtern, entfallen. Da das Modell im Ganzen, von der Eingabe in Form von Rohdaten bis hin zur Ausgabe, trainiert wird, spricht man auch vom Ende-zu-Ende-Lernen (End to End Machine Learning). Hierin liegt der Fortschritt gegenüber dem klassischen Verfahren: Bei einem Computerprogramm muss das gesamte Verhalten manuell konstruiert werden, beim maschinellen Lernen der 1990er Jahre waren es nur noch die Merkmale, die mit großer Sorgfalt ausgewählt werden mussten. Aktuelle neuronale Netze lernen automatisch in ihren verdeckten Schichten immer abstraktere Repräsentationen und erledigen die Arbeit der Merkmalswahl automatisch mit.

Man unterscheidet tiefe neuronale Netze nach der Zahl und Breite der Schichten und den Verbindungen dazwischen. Bei tiefen neuronalen Netzen sind die Möglichkeiten theoretisch unerschöpflich, und es kommen immer wieder Netze mit neuen Strukturen hinzu³². Der Aufbau der Netze und Teilnetze richtet sich nach der Lernaufgabe, aber vor allem auch nach der Art und Bedeutung der Eingabe. So wurden insbesondere für die Bildverarbeitung Convolutional Neural Networks³³ (CNNs) entwickelt, für die Analyse von Zeitreihendaten zum Beispiel rekurrente Neuronale Netze³⁴ (RNNs) und für die Analyse von sukzessive abzuarbeitenden Folgen Long-Short-Term-Memory-Netze³⁵ (LSTMs).

Die Entwicklung des Deep Learning ist auch – neben algorithmischen Weiterentwicklungen – in Big Data begründet: Die kontinuierlich wachsenden Datenmengen stellen das maschinelle Lernen vor die Herausforderung, dass viele der klassischen Lernverfahren trotz der Weiterentwicklung von Speichertechnologien und Prozessoren auf Basis großer Datenmengen nicht mehr effizient ausgeführt werden können. Eine schnelle Ausführung bedingt die Parallelisierung auf viele Rechnerknoten, etwa auf GPU-Rechner (Graphics Processing Unit). Deep Learning zeichnet sich daher dadurch aus, dass es sich um eine der wenigen Klassen von Lernverfahren handelt, die sowohl sehr komplexe Modelle (neuronale Netze) erlaubt, als auch effizient mittels paralleler Computerinfrastrukturen auf Big Data trainiert werden kann. Umgekehrt hat das Deep Learning den Nachteil, dass seine Anwendung erst ab einer sehr großen Menge von Daten überhaupt sinnvoll ist. Liegen nur wenige Daten vor, können klassische Verfahren wieder ihre Stärken ausspielen.

³¹ Szegedy et al., 2015, Going Deeper with Convolutions. In: Computer Vision and Pattern Recognition (CVPR).

³² Van Veen 2016, The Neural Network Zoo. Online verfügbar: <http://www.asimovinstitute.org/neural-network-zoo/>, abgerufen am 20.02.2018.

³³ LeCun et al., 1998, Gradient-based learning applied to document recognition. In: Proceedings of the IEEE, 86, S. 2278 - 2324.

³⁴ Elman 1990, Finding structure in time. In: Cognitive science, 14, S. 179 - 211.

³⁵ Hochreiter et al., 1997, Long short-term memory. Neural Computation, 9, S. 1735 - 1780.

3.3 Evaluation und Umsetzung von maschinellem Lernen


Die beschriebenen Lernverfahren generieren Modelle unterschiedlicher Güte. Deswegen ist es entscheidend, die Güte eines Modells bewerten und vergleichen und den Datenanalyse-Prozess zu einem bestmöglichen Ergebnis steuern zu können. Dieses Kapitel beschreibt die Evaluationsmöglichkeiten der Modellgüte einzelner Verfahren und die üblichen Vorgehensweisen in Datenanalyse-Projekten. Hierdurch soll insbesondere verdeutlicht werden, dass BDAI keine universell einsetzbaren Methoden liefert, die ohne menschliches Zutun optimale Ergebnisse erzeugt. Stattdessen müssen verschiedene Modelle evaluiert und die Daten häufig aufwändig vorverarbeitet werden.

3.3.1 Evaluation von Modellen

Um potenzielle Probleme bei der Verwendung eines gelernten Modells zu vermeiden, muss dieses sorgfältig evaluiert werden. Qualitätsprobleme können aus verschiedenen Gründen auftreten. Die wichtigsten sind:

- Diskrepanz in der Formalisierung der Lernaufgabe: Die für die Geschäftsziele entscheidenden Kriterien können in der Regel nicht komplett formalisiert werden, sondern werden, damit man sie effizient in einem Algorithmus implementieren kann, vereinfacht oder modifiziert. Modelle müssen auch im Hinblick auf diese Diskrepanz untersucht werden.
- Datenselektions-Bias: Ein weiteres Problem besteht darin, dass bereits bei der Sammlung von Daten eine Verzerrung stattfinden kann. Dies kann durch Fehler im Datensammlungs- und Aufbereitungsprozess verursacht werden (etwa weil Daten fehlen und indem Informationen, die zum Zeitpunkt der Modellanwendung in der Praxis noch nicht vorhanden sind, mit in den Trainingsdatensatz aufgenommen wurden) oder dadurch, dass die Welt selbst sich ändert (in historischen Kreditentscheidungen wurden Minderheiten benachteiligt, deshalb ist der historische Datensatz zu Kreditausfällen zuungunsten von Minderheiten verzerrt). Die Gefahr hierbei ist, dass statistische Tests einen Datenbias prinzipiell nicht finden können, da auch eventuelle Testdaten denselben Bias aufweisen. Stattdessen müssen diese Probleme gefunden werden, indem man das Modell transparent macht, etwa durch eine Inspektion der wichtigen Attribute.
- Over-Fitting und Komplexität: Da Modelle immer aus endlich vielen Daten gelernt werden, besteht die Gefahr, dass sie den realen Prozess, der die Daten beschreibt, nicht richtig darstellen können. Wie in Abbildung 4 gezeigt, kann das Problem entweder darin bestehen, dass die Modellklasse des Algorithmus zu einfach ist, um die Daten angemessen zu beschreiben (man spricht dann von einem hohen Bias), oder dass das Modell so komplex ist, dass es zufällige Abweichungen in den Daten modelliert (hohe Varianz). Im zuletzt genannten Fall spricht man von einem Over-Fitting (Überanpassung). Diese Situation ist gefährlich, da das Modell auf Basis der Trainingsdaten qualitativ hochwertig zu sein scheint, es in Wirklichkeit aber nicht ist. Ein wichtiges Grundprinzip zur Vermeidung von Over-Fitting ist, dass Modelle immer auf neuen, nicht für das Training benutzten Daten getestet werden sollten.

Abbildung 4: Modellkomplexität und Generalisierungsfähigkeit



Für die Bewertung von Modellen existieren verschiedene Performanzmaße, welche die Qualität eines Modells in Bezug auf gegebene Daten quantifizieren. Bei binären Klassifikationsproblemen ergibt sich beispielsweise durch den Vergleich von Modellentscheidung (ja/nein) und wahrem Label eine Kreuztabelle:

| | Wahres Label „ja“ | Wahres Label „nein“ | Performanzmaße |
|-------------------------|-----------------------|----------------------|------------------------------------|
| Modellvorhersage „ja“ | True Positives (TP) | False Positives (FP) | Precision = $TP/(TP+FP)$ |
| Modellvorhersage „nein“ | False Negatives (FN) | True Negatives (TN) | |
| Performanzmaße | Recall = $TP/(TP+FN)$ | | Accuracy = $(TP+TN)/(TP+FP+FN+TN)$ |

Aus dieser Kreuztabelle lassen sich verschiedene Performanzmaße berechnen. Das am häufigsten genommene Maß ist die Accuracy (auch Korrektklassifikationsrate, Vertrauenswahrscheinlichkeit oder Treffergenauigkeit genannt), die dem Anteil der richtig klassifizierten Beispiele entspricht. Häufig kommt ein Label deutlich seltener vor als das andere. Dann sind gegebenenfalls Performanzmaße wie Precision (Anteil der richtigen Ja-Prognosen) und Recall (Anteil der gefundenen Ja-Fälle) relevanter. Es existieren auch viele andere Performanzmaße, zum Beispiel für Regressions- oder Clusteringaufgaben.

Beim operativen Einsatz von Modellen, insbesondere dann, wenn auf Basis neuer Daten kontinuierlich neue Modelle gelernt werden, genügt es nicht, die Modellqualität einmal zu evaluieren. Stattdessen müssen Eingabedaten, Modellqualität und die Qualität der umgebenden Softwareumgebung insgesamt kontinuierlich überwacht und auf Veränderungen getestet werden. Systeme, die auf maschinellem Lernen basieren, stellen aufgrund ihrer deutlich höheren Datenabhängigkeit entsprechend hohe Anforderungen an die Softwarequalität und an das Monitoring.³⁶ Technisch sind unterschiedliche Ansätze zur Validierung selbstlernender Algorithmen denkbar:

- eine automatisierte Durchführung der o.g. Prüfverfahren für jede Evolutionsstufe des Algorithmus; dies erfordert eine Zertifizierung der Prüfalgorithmen
- die Verwendung eines konventionellen Referenzsystems um sicherzustellen, dass sich der selbstlernende Algorithmus innerhalb vordefinierter Grenzen bewegt

³⁶ Sculley et al., 2015, Hidden Technical Debt in Machine Learning Systems. In: Advances in Neural Information Processing Systems, 28.


Im Ergebnis müssten für die Zertifizierung eines selbstlernenden Algorithmus neue Verfahren entwickelt werden, die prüfen, ob sich der Algorithmus korrekt weiterentwickelt, wenn beliebig neue Daten zugeführt werden.

3.3.2 Datenanalyse als Prozess

Maschinelle Lernverfahren können nicht selbstständig operieren, sondern müssen im Rahmen eines größeren Prozesses von Spezialisten aufgesetzt und angewandt werden. Bevor ein maschinelles Lernverfahren genutzt werden kann, muss zunächst das inhaltliche Problem in eine sinnvolle Analyseaufgabe übersetzt werden. Besteht die inhaltliche Aufgabe beispielsweise in der Kostenreduktion durch eine verbesserte Geldwäscheerkennung, so muss das Problem für den Einsatz von maschinellen Lernverfahren auf eine bekannte Lernaufgabe zurückgeführt werden (in diesem Fall das Lernen eines Klassifikationsmodells anhand bekannter historischer Geldwäschefälle). Außerdem müssen wichtige praktische Annahmen und Einschränkungen des Problems formal definiert werden (z.B.: Wie gravierend ist die fälschliche Markierung einer regulären Transaktion als Geldwäsche? Wird der Erfolg anhand der Zahl der verhinderten Betrugsfälle oder anhand des eingesparten Geldbetrags gemessen?). In einem zweiten Schritt müssen die relevanten Daten bereitgestellt werden. Bei der Geldwäscheerkennung können dies beispielsweise Transaktionsdaten, Stammdaten des Kontoinhabers und externe Daten über Händler sein. Sowohl das Wissen von der geschäftlichen Anwendung als auch das von potenziell relevanten Daten ist außerhalb der Welt des maschinellen Lernens angesiedelt. Ein Mensch muss sie daher definieren.

Die konkrete Anwendung von maschinellen Lernverfahren erfolgt dann in zwei Schritten, in denen zum einen die Daten für das Lernverfahren in der konkret verlangten Form bereitgestellt werden und zum anderen das Lernverfahren parametrisiert und ausgeführt wird. Beide Schritte sind eng aneinander gekoppelt. Über eine geeignete Darstellung der Daten kann das Hintergrundwissen des menschlichen Experten an das Lernverfahren übergeben werden, das dieses Wissen allein nicht oder nur sehr schwer erschließen kann. Beispielsweise kann bei einer Betrugserkennung aus den Adressen von Händlern und den Zeitstempeln von Transaktionen die Geschwindigkeit berechnet werden, mit der sich der Nutzer zwischen den Transaktionen von einem Ort zum anderen bewegt haben müsste. Eine extrem hohe Geschwindigkeit – etwa ein Karteneinsatz um 12 Uhr in Frankfurt und um 13 Uhr in Tokio – ist ein sehr guter Indikator dafür, dass eine Kreditkarte kopiert worden ist. Wird das Merkmal „Geschwindigkeit“ durch manuelle Vorverarbeitung bereitgestellt, so ist seine Nutzung für die meisten Lernverfahren trivial, die Erkennung dieses Musters aus den Rohdaten hingegen extrem schwierig.

Abbildung 5: Darstellung des CRISP-DM Prozesses



Nach der Anwendung des Lernverfahrens müssen die Ergebnisse validiert werden. Dies kann rein statistisch oder über qualitative Faktoren erfolgen. Falls möglich, werden aber auch verschiedene Ansätze angewandt, um das Modell zumindest in Teilen transparent zu machen und vom Anwendungsexperten überprüfen zu lassen. Beide oben genannten Schritte benötigen also menschliche Kontrolle. Die Anwendung in der realen Welt kann allein durch den Menschen erfolgen (z.B. indem die Zusammenarbeit mit häufig auffälligen Händlern gekündigt wird) oder innerhalb eines automatischen Systems (z.B. in einem Autorisierungssystem der Bank). Immer häufiger werden intelligente Systeme umgesetzt, deren Funktionalität durch Modelle des maschinellen Lernens zur Verfügung gestellt werden, wie beispielsweise Dialogsysteme.

Spätestens seit den 2000er Jahren hat sich im maschinellen Lernen mit dem steigenden Einsatz in Unternehmen die Erkenntnis durchgesetzt, dass es sich hierbei um ein standardisierbares, planbares Vorgehen handelt. Eines der bekanntesten Verfahren, welches das oben beschriebene Vorgehen standardisiert, ist der „Cross Industrial Standard Process for Data Mining“ (CRISP-DM). Dabei handelt es sich um einen iterativen Prozess mit sechs Phasen, wie in Abbildung 5 gezeigt.

Speziell für das Finanzsystem gibt es weitere spezialisierte Prüfverfahren. Beispielsweise werden für regulatorische Bonitätsmodelle unterschiedliche spezialisierte Prüfverfahren angewendet, die ohne Änderung übernommen werden können:

- Testfallgenerierung: Systematische Generierung von Testfällen, die nicht in den Trainingsdaten auftreten, aber z.B. in einer veränderten Marktlage auftreten könnten, inklusive einer Überprüfung der Plausibilität der Modellvorhersagen
- Repräsentativität: Nachweis anhand gewisser Annahmen an die Daten, dass das Modell repräsentativ für die produktiven Daten ist
- Stresstests: Systematische Veränderung der aktuellen Daten, um die Auswirkungen externer Schocks zu überprüfen (z.B. Verfall der Immobilienpreise)
- Plausibilitätsprüfungen: Beurteilung, ob die Prognosen oder Parameter eines Modells plausibel sind. Bei linearen Modellen können einzelne Parameter auf ihre Wirkrichtung geprüft werden. Bei komplexeren Modellen kann geprüft werden, ob die Wirkrichtung des Gesamtscores das erwartete Verhalten zeigt, z.B. ob bei der Kfz-Versicherung die Prognose der Unfallwahrscheinlichkeit mit der Dauer der Schadensfreiheit sinkt.

Deutlich komplexer ist die Situation beim Einsatz intelligenter Agenten (Bots). Hierunter verstehen wir Technologien, die komplexere menschliche Tätigkeiten ersetzen, etwa Dialogsysteme und der automatische Aktienhandel bis hin zur Entwicklung von Strategien. Was hierbei technisch sinnvoll und machbar ist, hängt stark vom Anwendungsfall und dem damit verbundenen Risikoprofil ab.

3.4 Machine-Learning-basierte Systeme und Anwendungen

Es gibt bereits viele Anwendungen, bei denen Methoden des maschinellen Lernens nicht nur eingesetzt werden, sondern sogar grundlegend neue Fähigkeiten entwickeln und so Mehrwert schaffen. Nachfolgend werden einige Anwendungen näher erläutert.

3.4.1 Maschinelle Dokumentenanalyse

In der klassischen Datenverarbeitung sind Texte aufgrund ihrer unstrukturierten Form nicht lesbar, falls es sich nicht um vordefinierte Formulare handelt. Zugleich sind Dokumente für viele Unternehmen die zentrale Datenbasis. Mit Hilfe von Textmining können Texte klassifiziert, gruppiert und Informationen automatisiert extrahiert und nutzbar gemacht werden. Neuere Anwendungen des Textmining bestehen darin, Texte automatisch zusammenzufassen oder Fragen dazu zu beantworten, was wiederum weitere Einsatzmöglichkeiten erzeugt.

Typische Anwendungen des Textminings im Finanzsystem sind die automatische Extraktion von wichtigen Informationen aus Schadensbeschreibungen zur weiteren Schadenbearbeitung, die Analyse typischer Beschwerdegründe von Kunden oder in Zukunft möglicherweise auch die Vollautomatisierung der Kundenkommunikation. Die digitale Erschließung von Dokumenten zum Zweck der Prozessautomatisierung ist Gegenstand mehrerer Anwendungsbeispiele in dieser Studie.

Inhaltlich unterscheidet sich das Textmining von anderen Bereichen des maschinellen Lernens vor allem in der Art und Weise, wie Daten aufbereitet und den Algorithmen zur Verfügung gestellt werden. Liegt der Text nur in Papierform oder als gescanntes Bild vor, muss gegebenenfalls noch ein Schritt zur Buchstabenerkennung (Optical Character Recognition, OCR) vorgeschaltet werden, für den es Standardsoftware gibt.

Die Verfahren, die abschließend beispielsweise zur Klassifikation benutzt werden, entsprechen dann wieder den Standardverfahren. Weil Textdaten oft in großer Zahl verfügbar sind, sind hierbei insbesondere Verfahren des Deep Learning sehr erfolgreich. Eine grundlegende Technik bilden die sogenannten Word-Embeddings³⁷, die Worte auf hochdimensionale numerische Vektoren abbilden, sodass inhaltlich ähnliche Worte auf ähnliche Vektoren abgebildet werden. Mit Hilfe solcher Ansätze steht für das Textmining die Nutzung numerischer Lernverfahren offen. Textmining-Ansätze sind stark von der jeweiligen Sprache abhängig. Hinzukommt, dass Textdaten in verschiedenen Sprachen sehr unterschiedlich verfügbar und die Forschungscommunities unterschiedlich groß sind. Hochqualitative Lösungen gibt es daher bislang nur für einige der meistgesprochenen Sprachen, insbesondere Englisch und Chinesisch. Dadurch entsteht ein Wettbewerbsnachteil, wenn andere Sprachen verarbeitet werden müssen.

Angetrieben durch diese Entwicklungen gibt es heute bereits einige auf Technologien der Artificial Intelligence aufbauende Software-Lösungen, die beliebige Dokumentenformen strukturieren, durchsuchbar machen und prüfen und aus ihnen Informationen extrahieren oder sogar neue Dokumente erzeugen. Eine Integration und Entwicklung solcher Lösungen wird auf Unternehmensseite – abgesehen von Digitalisierungsbestrebungen – auch zur Erfüllung regulatorischer Anforderungen vorangetrieben.

³⁷ Mikolov et al., 2013, Distributed Representations of Words and Phrases and their Compositionality. In: Advances in Neural Information Processing Systems 26.

3.4.2 Spracherkennung

Automatische Spracherkennung wandelt Audiosignale in Text um und erschließt somit das gesprochene Wort für weitere Analysen und Dienstleistungen. Spracherkennung basiert auf Modellen des maschinellen Lernens und besteht klassischerweise aus drei Komponenten: Ein akustisches Modell beschreibt, wie Phoneme der Sprache klingen, ein Lexikon enthält die Information, wie Wörter ausgesprochen werden, und ein Sprachmodell beschreibt, welche Wortfolgen (Sätze und andere Äußerungen) am wahrscheinlichsten sind. Hierbei werden aber auch immer mehr die bereits beschriebenen End-to-End-Modelle genutzt, die den gesamten Erkennungsprozess in einem komplexen tiefen neuronalen Netz abbilden.

Banken und Versicherer können Spracherkennung beispielsweise in Call Centern nutzen. Spracherkennung kann zu verschiedenen Zwecken eingesetzt werden³⁸:

- Erkennung von Emotionen, Stress, Wünschen und Erwartungen in der Stimme des Kunden. Durch geeignete Reaktion kann die Customer Experience verbessert werden.
- Monitoring und Coaching von Call-Center-Agenten, um die Servicequalität zu verbessern
- Reduzierung der operativen Kosten durch Automatisierung
- Identifikation von Up-Selling- und Cross-Selling-Möglichkeiten im Gespräch durch Monitoring des Gesprächsverlaufs
- Automatische Protokollierung in Textform zu Dokumentationszwecken und zur Weiterverarbeitung

Im Wesentlichen ist die Spracherkennung aber als eine Technologie zu sehen, die dem System eine grundlegende Fähigkeit zur sprachlichen Kommunikation verleiht. Dialogsysteme führen diese Technologie weiter, indem sie dem Computer die Fähigkeit verleihen, Gespräche zu führen. Dazu ist neben dem reinen Erkennen von Äußerungen des Gesprächspartners auch die Generierung einer geeigneten Antwort erforderlich.

3.4.3 Question-Answering

Question-Answering-Systeme können Fragen in natürlicher Sprache beantworten, zum Beispiel die Frage nach der Höhe des Kontostands mit der aktuellen Zahl in Euro als Antwort. Aktuelle Systeme können mehr oder weniger komplexe Fragen mit guter Genauigkeit beantworten. Komplexe Fragen, etwa nach dem Grund, oder logische Fragen, deren Beantwortung Weltwissen erfordert, sind dagegen noch außerhalb der aktuellen Möglichkeiten. Bekannt geworden ist Question-Answering durch den Auftritt des Systems Watson³⁹ in der Fernsehquizshow Jeopardy.

In der Regel kommen die Antworten aus Wissensbasen oder Textdokumenten. Question-Answering-Systeme müssen den Inhalt einer Frage verstehen, den verstandenen Inhalt auf eine Anfrage an ihre Antwortbasis abbilden und aus mehreren möglichen Antworten die plausibelste auswählen. Die Strategien zur Beantwortung werden dabei mittels Deep Learning und Natural Language Processing aus bekannten Frage-Antwort-Paaren gelernt, um eine möglichst hohe Flexibilität zu ermöglichen.

Für eine komplett natürlich wirkende Interaktion mit dem Menschen muss ein intelligentes Computerprogramm allerdings auch komplette Dialoge führen können. Im Unterschied zum reinen Question-Answering muss das System hierbei den Status des Dialogs verfolgen und auf das gewünschte Ziel hinarbeiten, was deutlich komplexer ist.

³⁸<http://searchcrm.techtarget.com/report/Top-five-benefits-of-speech-analytics-for-the-call-center>, abgerufen am 20.02.2018

³⁹ Ferrucci et al., 2010, Building Watson: An Overview of the DeepQA Project. In: AI Magazine, 31, S. 59 - 79.

3.4.4 Intelligente Agenten

Geht die Automatisierung eines Computerprogramms schließlich so weit, dass ein hoher Grad an Autonomie in der Entscheidung gegeben ist, spricht man neuerdings auch von Software-Agenten oder Bots. Ein Software-Agent oder intelligenter Agent ist ein Computerprogramm, das in einer komplexen Umgebung interagiert und im Auftrag eines Nutzers autonome Entscheidung trifft und Ziele verfolgt. Ein Agent für den Aktienmarkt könnte beispielsweise autonom Anlageentscheidungen fällen oder weitere Routineaufgaben erledigen.

Der Nutzen eines Agenten hängt offensichtlich ab von der Komplexität seines Weltverständnisses, der Intelligenz, mit der er Entscheidungen trifft, und der Flexibilität, sich auf ändernde Situationen einzustellen. Während der Einsatz von Agenten in operativen Anwendungen noch stark beschränkt ist, zeigen neue Entwicklungen bei Computerspielen die Perspektiven auf. Beispiele wie AlphaGo von Google,⁴⁰ das den menschlichen „Go“-Meister Lee Sedol geschlagen hat, oder das Genetische Fuzzysystem von Psibernetix⁴¹, das 2016 Air-Force-Piloten in einer simulierten Luftschlacht geschlagen hat, sind Indikatoren dafür, was heute schon technisch umsetzbar ist. Sowohl bei AlphaGo als auch bei dem Fuzzysystem von Psibernetix ist ein Verhalten zu beobachten, das sich von reinem Auswendiglernen unterscheidet.

Ein Übergang zu intelligenten Agenten lässt sich auch in der Kombination mit Robotic Process Automation (RPA) sehen. Der Einsatz von maschinellem Lernen in der RPA verspricht, den Menschen in drei seiner Kernfähigkeiten zu ersetzen oder zu ergänzen: der Kommunikation mit dem Kunden, beispielsweise durch Chatbots, der Extraktion relevanter Informationen und der Entscheidungsfindung. Das Fundament neuer Möglichkeiten der RPA bilden Services, welche die für den Prozess relevanten Informationen verstehen und nutzbar machen können, eine Aufgabe insbesondere für das Textmining. In komplexen Dokumenten sind neben dem Text als vorherrschendem Datentyp auch eingebettete Abbildungen, Tabellen etc. relevant. Bei der Extraktion von Informationen können mit vortrainierten Modellen zum Textverständnis oder zur Bildanalyse beispielweise Schadensmeldungen in Versicherungsunternehmen automatisch verarbeitet und die relevanten Informationen für die weiteren Bearbeitungsschritte extrahiert werden.

3.5 Technische Lösungsansätze für gesellschaftliche Anforderungen an BDAI

Die in den vorherigen Abschnitten vorgestellten Ansätze zu BDAI stellen den Status Quo des praktischen Einsatzes solcher Methoden dar. Mit dem immer umfassenderen Einsatz von Verfahren des maschinellen Lernens in immer kritischeren Anwendungen steigen auch die rechtlichen und ethischen Anforderungen an den Einsatz, und die öffentliche Aufmerksamkeit für Problemfälle nimmt zu. Im Folgenden sollen ausgewählte Forschungsansätze vorgestellt werden, die insbesondere berücksichtigen, inwieweit die Modelle unter regulatorischen, ethischen und rechtlichen Aspekten weiterentwickelt und ergänzt werden können. Aktuelle Forschungsarbeiten auf dem Gebiet des maschinellen Lernens beschäftigen sich insbesondere mit der Verständlichkeit, dem Datenschutz, der Datensouveränität und der Verhinderung von Diskriminierung bei automatischen Entscheidungen.

⁴⁰ Silver et al., 2016, Mastering the game of Go with deep neural networks and tree search. In: Nature, 529, S. 484 - 489

⁴¹ Ernest et al., 2016, Genetic Fuzzy based Artificial Intelligence for Unmanned Combat Aerial. In: Journal of Defense Management, 6.

3.5.1 Verständlichkeit von Modellen

Methoden des maschinellen Lernens, und dabei im Speziellen die des Deep Learnings, bergen im Vergleich zu einfacheren Anwendungen die Herausforderung, dass sie für den Anwender in vielerlei Hinsicht unverständlich sind. Sie gelten als Black Boxes, d.h. der Anwender hat keine direkte Möglichkeit zu erfahren, warum oder wie der Algorithmus seine Entscheidung gefällt und das Ergebnis produziert hat⁴². Das liegt hauptsächlich daran, dass die Ein- und Ausgabewerte bei neuronalen Netzen stark nichtlinear und auf sehr komplexe Weise miteinander verknüpft sind.

Welchen Stellenwert die Verständlichkeit der Ergebnisse im Vergleich zu anderen Anforderungen hat, z.B. zur statistisch ermittelten Qualität des Modells, ist keine technische Frage, sondern muss im Einzelfall entschieden werden. Eine bessere Verständlichkeit von Modellen bietet die Chance, den Analyseprozess zu verbessern, etwa indem der Anwender Probleme wie Overfitting und Datenbias erkennen kann. Bessere Verständlichkeit kann auch die spätere Akzeptanz der Ergebnisse erhöhen, vor allem dann, wenn es sich um rechtliche oder sicherheitstechnische Anwendungen handelt. Verständlichkeit wirkt dabei auf mehreren Ebenen: Sie hilft dem Data Scientist, Modelle zu bereinigen und zu verbessern; sie hilft dem Anwender, die Relevanz der Ergebnisse zu beurteilen; und sie hilft Entscheidungsträgern und Regulierern, die Zertifizierbarkeit und Zulassungsfähigkeit von lernenden Systemen in kritischen Anwendungen zu bewerten.

3.5.2 Transparenz und Erklärbarkeit

In Bezug auf die Verständlichkeit von AI-Systemen⁴³ unterscheidet man zwischen Transparenz und Erklärbarkeit. Transparenz bezeichnet die Eigenschaft, dass das Verhalten des Systems vollständig nachvollziehbar ist. Diese Forderung ist allerdings häufig nicht erfüllbar, da viele Modelle notwendigerweise komplex sind. Erklärbarkeit bezeichnet hingegen die Eigenschaft, für eine konkrete Einzelentscheidung des Systems die wesentlichen Einflussfaktoren aufzuzeigen. Diese Anforderung ist technisch deutlich einfacher zu erfüllen.

Für die Erzeugung transparenter Systeme gibt es im Wesentlichen zwei Ansätze:

1. Zum einen kann für beliebige Modelle versucht werden, verständliche Approximationen zu generieren. Diese Approximation sollte dabei die Eigenschaft haben, dass das Verhalten des originalen Modells bis auf eine möglichst kleine Abweichung nachgebildet wird, dabei aber eine für den Menschen verständliche Darstellung besitzt. Der TREPAN-Algorithmus⁴⁴ ist einer der ersten solchen Ansätze.
2. Zum anderen gibt es viele Ansätze, aus den Daten direkt verständliche Modelle zu erzeugen, wie etwa Entscheidungsbäume⁴⁵ oder Subgruppen⁴⁶. Diese Modellarten sind nicht immer optimal für die Lernaufgabe geeignet. Falls aber die Transparenz eine größere Bedeutung hat als die Ergebnisqualität, sind diese Verfahren vorzuziehen.

⁴² Beuth 2017, Die rätselhafte Gedankenwelt eines Computers, Die Zeit. Online verfügbar:

<http://www.zeit.de/digital/internet/2017-03/kuenstliche-intelligenz-black-box-transparenz-fraunhofer-hhi-darpa>, abgerufen am 20.02.2018

⁴³ Doshi-Velez et al., 2017, Accountability of AI under the Law: The Role of Explanation. Online verfügbar:

<https://arxiv.org/abs/1711.01134>, abgerufen am 20.02.2018.

⁴⁴ Craven et al., 1996, Extracting tree-structured representations of trained networks. In: Advances in Neural Processing Systems, 8, S. 24 - 30.

⁴⁵ Quinlan 1993, C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers, Inc.

⁴⁶ Grosskreutz et al., 2012, An Enhanced Relevance Criterion for More Concise Supervised Pattern Discovery. In: Proceedings of the 18th ACM SIGKDD Conference on Knowledge Discovery and Data Mining.

Das Generieren von Erklärungen ist zurzeit ein aktives Forschungsfeld des maschinellen Lernens⁴⁷. Einer der berühmtesten Ansätze ist der LIME-Algorithmus⁴⁸, der für den zu erklärenden Einzelfall und ähnliche Datenpunkte mit einfacheren Verfahren ein lokales Erklärungsmodell bildet. Dazu müssen Merkmale zur Verfügung stehen, die eine Interpretation durch den Menschen zulassen. Daher kann es beim Nachvollziehen von Ergebnissen der Methoden oft unverzichtbar sein, aus den Daten auf eine für den Menschen verständliche Ebene zu abstrahieren. Beispielsweise können Bildabschnitte in Superpixeln (zusammenhängendes Cluster von Pixeln) zusammengefasst werden, so dass sich deren Inhalt dem Menschen als neue Merkmale erschließen. Andere Ansätze basieren beispielsweise auf Prototypen und liefern repräsentative Einzelfälle zur Erklärung von Entscheidungen⁴⁹.

Insgesamt sind durch neue Ansätze auch bei sehr komplexen Modellen zumindest Einblicke in deren Funktionsweise möglich, und die Gründe für Entscheidungen sind nachvollziehbar, so dass eine reine Betrachtung von Modellen als Blackbox vermieden werden kann.

3.5.3 Privacy-preserving Data Mining

Der Schutz von persönlichen und Unternehmensdaten bildet für jede Datenverwendung den Handlungsrahmen. Neben rechtlichen und organisatorischen Maßnahmen, die einen hinreichenden Datenschutz sicherstellen sollen, gibt es auch geeignete technische Maßnahmen und IT-Infrastrukturen, die diesen Prozess vereinfachen und unterstützen sollen. Zum einen gibt es für technische Systeme das Prinzip des Privacy-by-Design, d.h. die Anforderung, das System so zu entwerfen, dass prinzipiell keine Informationen verarbeitet werden können, die in Bezug auf den Datenschutz problematisch sind. Als konkretes Beispiel ist vorstellbar, in Eingabemasken für Kundendaten keine Freitexteingaben zuzulassen, da deren Inhalt im laufenden Betrieb nur mit hohem Aufwand datenschutzrechtlich kontrollierbar ist. Problematisch wird dieser Ansatz dadurch, dass auch durch die Kombination relativ einfacher Informationen ein Rückschluss auf einzelne Personen oft möglich ist. Beispielsweise konnte gezeigt werden, dass in den USA 87 Prozent der Bevölkerung bereits durch Postleitzahl, Geschlecht und Geburtsdatum eindeutig identifiziert werden können⁵⁰.

Angetrieben von steigenden Anforderungen und Herausforderungen im Datenschutz werden des Weiteren unter dem Begriff „Privacy-preserving Data Mining“^{51,52} Techniken erforscht, die Datenschutzerfordernungen direkt in die Datenanalyse und Datenauswertung zu integrieren. Damit liefert dieses Forschungsgebiet Antworten auf Fragen wie „Welche Daten und Muster können ohne Bedenken veröffentlicht werden?“ und „Wie kann eine bestimmte Frage so analysiert werden, dass dabei keine sensiblen Informationen offengelegt werden?“

Die wesentliche Idee beim Privacy-preserving Data Mining ist, dass Merkmale, die eine Identifizierung ermöglichen – etwa Name und Adresse eines Versicherten – regelmäßig für die Datenanalyse nicht von Interesse sind. Im Gegenteil: Um ein allgemeingültiges Wissen zu erzielen, müssen die in den Daten gefundenen Muster genereller sein, als es für die Identifizierung einer einzelnen Person erforderlich wäre.

⁴⁷ Montavon et al., 2017, Methods for Interpreting and Understanding Deep Neural Networks. In: Digital Signal Processing, 73, S. 1 - 15.

⁴⁸ Ribeiro et al., 2016, "Why Should I Trust You?": Explaining the Predictions of Any Classifier, Proc. of the 22nd International Conference on Knowledge Discovery and Data Mining, S. 1135 - 1144.

⁴⁹ Been et al., 2016, Examples are not Enough, Learn to Criticize! Criticism for Interpretability. In: Neural Information Processing Systems 2016.

⁵⁰ Sweeney, 2000, Simple Demographics Often Identify People Uniquely. In: Carnegie Mellon University, Data Privacy Working Paper 3.

⁵¹ Grosskreutz et al., 2010, Privacy-preserving data-mining. In: Informatik-Spektrum, 33, S. 380 – 383.

⁵² Aggarwal et al., 2008, Privacy-Preserving Data Mining: Models and Algorithms. In: Springer.

Kompliziert wird die Situation dadurch, dass durch eine Kombination von Merkmalen möglicherweise doch wieder auf eine einzelne Person geschlossen werden kann. Vor allem ist sicherzustellen, dass aus Analyseergebnissen nicht auf sensitive Informationen wie Krankheiten oder Herkunft einzelner Personen geschlossen werden kann.

Zwei Hauptansätze zum Privacy-preserving Data Mining sind die Anonymisierung und die sichere verteilte Analyse. Die Anonymisierung versucht, kritische Informationen schon beim Zugriff auf die Daten zu unterdrücken, was den Ansatz sehr allgemein anwendbar macht, aber auch die Gefahr birgt, dass die Ergebnisse deutlich an Qualität verlieren. Ein Standardansatz der Anonymisierung ist die k-Anonymität. Hier werden die Daten so aufbereitet, dass es keine Abfrage gibt, die auf weniger als k Datenbankeinträge zutrifft. Ein anderer Ansatz, der Privacy über Randomisierungen in der Datenanalyse und Datenauswertung sicherstellt, ist die Differential Privacy⁵³. Die sichere verteilte Analyse zielt darauf ab, Informationslecks bei der Ausführung von Datenanalyse-Verfahren auf Basis der kompletten Daten zu vermeiden. Außerdem läuft bei der sicheren verteilten Analyse mit kryptographischen Methoden die Analyse von verteilten Daten so, dass die Teilnehmer außer dem gewünschten Ergebnis keinerlei weitergehende Informationen erhalten.

Insgesamt muss festgestellt werden, dass nach dem gegenwärtigen Stand der Wissenschaft die Möglichkeit, Privacy-preserving Data Mining durchzuführen, immer im konkreten Einzelfall nachgewiesen werden muss. Einen Ansatz, Datenschutz generell und automatisch für beliebige Arten von Analysen sicherzustellen, gibt es nicht. Trotzdem findet sich in der Literatur eine große Menge an Ansätzen, die bei einer Analyse von sensiblen Daten in Betracht gezogen werden können.

3.5.4 Infrastrukturen für Datensouveränität

Unternehmen der Finanzdienstleistungsbranche müssen nicht nur ihre eigene Datenverarbeitung kontrollieren und hierbei Datenschutz sicherstellen. Sie müssen auch den Datenaustausch und die gemeinschaftliche Bewirtschaftung von zum Teil sensiblen Daten innerhalb des Geschäftsökosystems im Griff haben. Da der Austausch von Daten nicht nur für den Geschäftsbetrieb notwendig ist, sondern auch Innovationen und neue Geschäftsmodelle fördert, werden Daten vermehrt zur strategischen Ressource für den Geschäftserfolg und steigen somit im Wert. Je mehr die Daten jedoch an Wert gewinnen, desto mehr besteht auch der Wunsch, sie zu schützen und zu kontrollieren – was wiederum im Widerspruch zum Datenaustausch steht.

Eine zentrale Schlüsselfähigkeit für Finanzdienstleister wird daher zunehmend die Datensouveränität.⁵⁴ Sie ist definiert als die „Fähigkeit einer natürlichen oder juristischen Person zur ausschließlichen Selbstbestimmung hinsichtlich des Wirtschaftsguts Daten“⁵⁵. Dies bedeutet, dass der Eigentümer der Daten souverän entscheiden, steuern und kontrollieren können muss, was mit seinen Daten geschieht, wer sie erhält und wozu sie verwendet werden. Hierzu werden neben ökonomischen und rechtlichen Rahmenbedingungen insbesondere auch informationstechnische Verfahren benötigt, welche die Voraussetzungen für Datensouveränität schaffen.

Ein Referenzprojekt ist die Ende 2014 gemeinschaftlich von Wirtschaft, Politik und Forschung ins Leben gerufene Initiative „Industrial Data Space“. Sie verfolgt das Ziel, die Entwicklung und die Nutzung des Industrial Data Space auf nationaler, europäischer und internationaler Ebene zu etablieren. Der Industrial Data Space positioniert sich als alternativer und ergänzender Architekturentwurf zu bestehenden Konzepten, die entweder dadurch charakterisiert sind, dass Daten vollständig zentral und entsprechend monopolistisch verwaltet werden, oder dadurch, dass jeder Datenaustausch individuell auszuhandeln ist.

⁵³ Dwork, 2006, Differential Privacy. 33rd International Colloquium on Automata, Languages and Programming (ICALP 2006). Springer, S. 1 – 12.

⁵⁴ In Kapitel 4.1 wird Datensouveränität aus der Verbraucherperspektive betrachtet

⁵⁵ Otto, 2016, Digitale Souveränität: Beitrag des Industrial Data Space. Fraunhofer.

Der Industrial Data Space stellt umfangreiche Mechanismen bereit, die die Vertraulichkeit, Integrität und Verfügbarkeit der Daten bei deren Austausch schützen. Die föderale Struktur des Industrial Data Space sichert den Dateneignern volle Souveränität über ihre Daten zu. Die Daten können bei Bedarf dezentral bei ihren Eigentümern verbleiben und werden nur im Rahmen der vereinbarten Nutzung und unter Anwendung strenger Schutzmaßnahmen ausgetauscht. Eine zentralisierte Datenhaltung, die in der Regel mit einem Kontrollverlust über die eigenen Daten einhergeht, wird hierdurch optional. Somit lassen sich auch kritische Daten von strategischem und ökonomischem Wert sicher und souverän austauschen und in Geschäftsökosystemen gemeinsam nutzen.

Die dezentrale Architektur des Industrial Data Space, die Zertifizierung der Teilnehmer, klar definierte Regeln und der Einsatz innovativer Sicherheitstechnologien zur Datenfluss- und Datennutzungskontrolle zielen darauf ab, Vertrauen zu schaffen und Unternehmen zu ermöglichen, Herren ihrer Daten zu bleiben. Der Industrial Data Space steigert daher nicht nur die Bereitschaft von Unternehmen zum Datenaustausch allgemein, sondern fördert vor allem auch den sicheren Austausch sensibler Daten, die bislang nur selten geteilt werden, und auf diese Weise für datengetriebene Innovationen zur Verfügung stehen.

3.5.5 Nichtdiskriminierende Datenanalyse

Für die Beschränktheit heutiger Systeme gibt es besorgniserregende Beispiele: So klassifizierte Google dunkelhäutige Menschen auf Bildern als Gorillas⁵⁶, und Microsoft musste seinen Chatbot Tay nach wenigen Stunden von Twitter zurückziehen, weil er von anderen Benutzern rassistisches Verhalten gelernt hatte⁵⁷. Die Beispiele zeigen, dass man mit Schiefen in der Datengrundlage umgehen können muss und dass AI-Systeme sich ethisch verhalten müssen.

Das Ergebnis eines auf maschinellem Lernen basierten Systems kann aus mehreren Gründen unethisch und diskriminierend sein: weil Entwickler oder Nutzer – bewusst oder unbewusst – ihm dieses Verhalten beigebracht bzw. es nicht verhindert haben, wie im Fall des Chatbots Tay, oder weil das System aus den Daten vorhandene Vorurteile gelernt und übernommen hat. So konnte etwa bei automatisch aus großen Textmengen aus dem Internet gelernten Wortzusammenhängen gezeigt werden, dass in den Texten zu Berufen Männer häufig mit Programmierern in Verbindung gebracht werden und Frauen mit Hausarbeit⁵⁸. Im ersten Fall wird im Analyseprozess also unethisches Verhalten eingebracht, im zweiten Fall werden in den Daten implizit vorhandene Vorurteile bzw. Rollenbilder erst durch das Verfahren zum Vorschein gebracht.

Verfahren der nichtdiskriminierenden Datenanalyse und -auswertung können dementsprechend technisch unterschiedliche Ansätze verfolgen⁵⁹. Die Daten können vor der Analyse von den kritischen Mustern befreit werden, etwa indem bei der Gesichtserkennung darauf geachtet wird, dass Geschlechter, Hautfarben und Alter repräsentativ in den Daten vertreten sind. Oder die Verfahren selbst können ethische Beschränkungen enthalten, was die erlaubten Lösungen angeht. Eine weitere Möglichkeit ist, dass die Ausgaben der Verfahren nachbearbeitet werden, etwa indem kritische Muster entfernt und Prognosen für benachteiligte Gruppen manuell verbessert werden.

⁵⁶ Zhang 2015, Google Photos Tags Two African-Americans As Gorillas Through Facial Recognition Software, In: Forbes. Online verfügbar: <https://www.forbes.com/sites/mzhang/2015/07/01/google-photos-tags-two-african-americans-as-gorillas-through-facial-recognition-software/>, abgerufen am 20.02.2018.

⁵⁷ Hunte, 2016, Tay, Microsoft's AI chatbot, gets a crash course in racism from Twitter, In: The Guardian. Online verfügbar: <https://www.theguardian.com/technology/2016/mar/24/tay-microsofts-ai-chatbot-gets-a-crash-course-in-racism-from-twitter>, abgerufen am 20.02.2018

⁵⁸ Bolikbasi et al., 2016, Man is to Computer Programme as Woman is to Homemaker? Debiasing Word Embeddings. In: Neural Information Processing Systems 29.

⁵⁹ Custers et al., 2013, Discrimination and Privacy in the Information Society – Data Mining and Profiling in Large Databases. Springer.

Die technische Herausforderung besteht jeweils darin, den ethischen/rechtlichen Begriff der Diskriminierung in eine mathematische Definition zu überführen, damit sie algorithmisch überprüft und verhindert werden kann. Lautet das Ziel beispielsweise, bei Versicherungstarifen nicht aufgrund des Geschlechts zu diskriminieren, kann man die Randbedingung einfügen, dass im Mittel für Männer und Frauen die gleiche Zahl von Positiventscheidungen gebildet werden muss. Das Merkmal Geschlecht zu löschen reicht hingegen nicht aus, da in vielen Fällen das Geschlecht auch durch korrelierte Merkmale mit hinreichender Genauigkeit erschlossen werden kann, etwa bei bestimmten Berufsgruppen.

Zusammenfassend gibt es zur nichtdiskriminierenden Datenanalyse und -auswertung zurzeit keinen aktuell akzeptierten Standard, allerdings sehr viele Ansätze und Forschungsaktivitäten, die sich mit dieser Frage beschäftigen. Die Problematik und mögliche Lösungsansätze können somit bei der Definition und Durchführung von Analyseprojekten als bekannt vorausgesetzt werden.

IV. Strategische Voraussetzungen

4.1 Förderung des Kunden- und Verbrauchervertrauens⁶⁰

4.1.1 Perspektive des Verbrauchers

BDAI kann zur Entwicklung von Prozess- und Produktinnovationen und somit auch zur Schaffung individualisierter Produkte und Dienstleistungen für Verbraucher eingesetzt werden. Dazu müssen regelmäßig hinreichend große und valide Datenmengen zur Verfügung stehen, die der Verbraucher oftmals selbst zur Verfügung stellt bzw. stellen soll. Der Verbraucher ist bei BDAI-Produkten nicht nur Kunde, sondern zugleich wichtiger Daten-Lieferant. Ob und wie Verbraucherdaten genutzt werden, ist für den Verbraucher jedoch nicht immer klar zu erkennen. Vermutlich werden sich die bereits erkennbaren Macht- und Informationsasymmetrien zwischen Verbrauchern und Unternehmen noch weiter verstärken. Zumindest in dieser Beziehung scheint der Verbraucher der potentiell schwächere, strukturell unterlegene Marktteilnehmer zu sein.

Verstärken sich diese Asymmetrien, können mittelbar kollektive Verbraucherinteressen betroffen sein, was insgesamt das Vertrauen in Finanzinstitute und Versicherungsunternehmen und damit auch die Integrität des Finanzmarktes schwächen kann. Daher gilt es, originäre kollektive Verbraucherinteressen bei der Anwendung von BDAI zu berücksichtigen.

Zwei konträre Interessen der Verbraucher

Das Verbraucherinteresse bei BDAI-basierten Produkten und Dienstleistungen kann vereinfacht in zwei Kategorien eingeteilt werden. Zum einen geht es dem Kunden um den unmittelbaren, individuellen Mehrwert durch das Nutzen eines BDAI-Produktes. Zum anderen haben Verbraucher ein Interesse am Erhalt ihrer Privatsphäre, ihrer Selbstbestimmung, Entscheidungsfreiheit und Autonomie⁶¹ – auf dem Finanzmarkt und darüber hinaus.

Diese beiden Verbraucherinteressen können in ein Spannungsfeld geraten: Der Nutzen von Privatsphäre, Selbstbestimmung, Entscheidungsfreiheit und Autonomie ist nicht sofort offensichtlich und scheint bei vielen Verbrauchern zunächst in den Hintergrund zu treten. Der Produktnutzen dagegen ist meist sofort sichtbar. Verbraucher erteilen daher die im europäischen Rechtsrahmen erforderliche Einwilligung in die Datennutzung sehr schnell – oft auch mangels Alternativen. Werden Daten dann jedoch in ausufernder Weise genutzt oder weitergegeben, was der Nutzer zum Zeitpunkt seiner Einwilligung nicht erwartet hätte, kann das Interesse an Privatsphäre, Datenschutz, Selbstbestimmung und Autonomie wieder in den Vordergrund treten. Auch bei formaler Rechtmäßigkeit kann eine vom Verbraucher als ausufernd empfundene Datennutzung das Potential haben, Vertrauenserrosionen hervorzurufen.⁶²

⁶⁰ Die Begriffe „Verbraucher“ und „Kunden“ werden in diesem Abschnitt gleichbedeutend verwendet. Unter Kunden werden sowohl Privatkunden als auch Freiberufler und kleine Unternehmen verstanden.

⁶¹ Vgl. Hoffmann-Riem, die Macht digitaler Konzerne, 01.10.2017, abrufbar unter https://www.law-school.de/fileadmin/content/law-school.de/de/units/unit_affil_riem/pdf/418_Die_Macht_digitaler_Konzerne.pdf, S. 2 ff., zuletzt eingesehen am 12.04.2018.

⁶² Schäfer 2018, Facebook Sturz erinnert an die Lehman-Pleite, Süddeutsche Zeitung. Online verfügbar: <http://www.sueddeutsche.de/digital/datenschutz-facebooks-sturz-erinnert-an-die-lehman-pleite-1.3926691>, abgerufen am 20.04.2018.

Verbraucher können Folgen von Datenfreigabe schwer abschätzen

Finanzwirtschaftliche Daten von Verbrauchern sind für Unternehmen besonders interessant, da sie den ökonomischen Kern eines Menschen offenlegen können (Einkommen, Vermögensstatus, Zahlungsverkehr/Ausgabeverhalten, Vertragsbeziehungen, Gesundheitsstatus usw.) und darüber hinaus eine Analyse seiner Persönlichkeit und Lebensgewohnheiten zulassen. Diese Daten lassen sich im Interesse des Verbrauchers verwenden – etwa für bedarfsgerechtere und individualisierte Angebote. Sie lassen sich aber auch dazu nutzen, die Zahlungsbereitschaft des Verbrauchers maximal auszunutzen, wie weiter unten zu lesen ist. Verbraucher sind bei BDAI-Anwendungen jedoch nur schwer in der Lage abzuschätzen, welche Folgen ihre Datenfreigabe auf lange Sicht haben kann. Es fällt ihnen auch oft schwer, die langfristigen Folgen der Datenfreigabe mit dem kurzfristigen Produktnutzen abzuwägen. In diesen Fällen besteht zwischen Datenlieferant und Datenverwender eine Informationsasymmetrie, was die tatsächliche Reichweite der Datenfreigabe und die Werthaltigkeit der Daten betrifft.

Unternehmen mit datenbasierten Geschäftsmodellen, die bislang weitgehend außerhalb der Finanzbranche agieren (z.B. Bigtechs), könnten ein starkes Interesse daran haben, sehr günstige Finanzprodukte mittels Quersubventionierung anzubieten, um an wertvolle finanzwirtschaftliche Transaktions- und Verhaltensdaten der Verbraucher zu gelangen. Dieses Wissen könnten diese Unternehmen monetarisieren und dazu nutzen, ihre Erlöse im Kerngeschäft zu steigern.

Unternehmen können Zahlungsbereitschaft ausnutzen

Mit BDAI-Anwendungen können Unternehmen finanzwirtschaftliche Daten mit anderen bereits vorliegenden Informationen verknüpfen und auf diese Weise bislang nicht mögliche, tiefe Einblicke in Verbrauchergewohnheiten und Persönlichkeitsstrukturen erhalten. Dieses zum Teil intime Wissen kann auch gegen das Interesse von Verbrauchern eingesetzt werden. Aus ökonomischer Sicht liegt es beispielsweise im Interesse eines Verbrauchers, dass Anbietern zumindest seine Zahlungsbereitschaft und -fähigkeit als Teil der Privatsphäre weitgehend verborgen bleiben. Dies gilt auch dann, wenn Verbraucher meinen, sie hätten „nichts zu verbergen“. Ansonsten besteht die Gefahr, dass Verbraucher beim Einsatz von BDAI überbewertete Produkte kaufen. Denn Unternehmen könnten mit Hilfe von BDAI tiefe Kenntnisse über die preisliche Schmerzgrenze breiter Verbrauchergruppen gewinnen, entweder weil sie selbst über die Daten verfügen oder indem sie solche Informationen zukaufen. Unternehmen könnten dieses Wissen gezielt zur Ertragssteigerung oder Risikooptimierung nutzen. Dabei geht es nicht nur darum, höhere Preise für bessere oder individuellere Leistungen zu zahlen, also beispielsweise um höhere Versicherungsprämien für die Absicherung höherer Risiken. Es geht auch darum, dass Unternehmen möglicherweise die Konsumentenrente⁶³ abschöpfen können. Denn BDAI-Anwendungen können es erleichtern, kostengünstig (massen-)individuelle Produkte und Dienstleistungen zu gestalten. Auf diese Weise lassen sich Standardprodukte mit individualisierten Bestandteilen versehen – ohne spürbare Mehrleistung der Unternehmen. Verbraucher haben es dadurch schwerer, zu vergleichen und auf andere Produkte auszuweichen.

Sie zahlen also nicht den marktüblichen Preis, sondern den Preis, der auf ihre individuelle Zahlungsbereitschaft zugeschnitten ist. Solange den Unternehmen die Zahlungsbereitschaft und -fähigkeit jedoch weitgehend verborgen ist, können Verbraucher dagegen marktwirtschaftliche Wohlfahrtseffekte realisieren und werden den marktüblichen Preis zahlen.

⁶³ Als Konsumentenrente versteht man die Differenz zwischen dem Preis, den ein Verbraucher für ein Produkt oder eine Dienstleistung maximal zu zahlen bereit ist, und dem Preis, den er tatsächlich am Markt zahlen muss. Durch eine kostengünstige (Massen-)Individualisierung ist es Anbietern von (digitalen) Produkten und Dienstleistungen über BDAI gegebenenfalls möglich, von jedem Kunden individuell den Preis zu verlangen, den er maximal zu zahlen bereit ist. So können Anbieter die Konsumentenrente abschöpfen. Dies setzt jedoch die Kenntnis der Zahlungsbereitschaft der Kunden voraus. Über den Einsatz von BDAI könnte das notwendige Wissen zumindest hypothetisch generiert und genutzt werden. Kunden könnten die für sie (unsichtbare) Preis Anpassung aufgrund der (Massen-)individualisierung der Produkte und Dienstleistungen dabei jedoch nur schwer ausmachen.

Diskriminierung sowie Druck auf die Datenfreigabe vermeiden

Mit Hilfe von BDAI-Anwendungen können neben der Zahlungsbereitschaft auch weitere persönliche Merkmale der Kunden, wie etwa der Gesundheitsstatus und sich abzeichnende Veränderungen im Leben offengelegt werden. Dies könnte eine (implizite) Diskriminierung der Verbraucher begünstigen. Beispielweise können Algorithmen (implizit) auf Merkmale abstellen, ohne dass diese direkt erhoben wurden. Erkennt man beispielsweise anhand der Muster der Finanztransaktionen ein geändertes (Einkaufs-) Verhalten, könnte man daraus auch auf bevorstehende Lebensereignisse schließen (z.B. Trennungen, Schwangerschaften), ohne dass hierzu konkrete Daten erhoben worden sind. Verbraucher können dann eine Diskriminierung nicht mit den Daten in Verbindung bringen, die sie zur Verfügung gestellt haben, und gegen die Diskriminierung vorgehen. Unternehmen könnten durch den Einsatz entsprechender Algorithmen eine (auch ungewollte) Diskriminierung vornehmen, was besonders brisant ist, sobald Verbraucher dadurch faktisch von Finanzprodukten ausgeschlossen werden. Eine bewusste Diskriminierung kann zum Beispiel darin bestehen, Preise so hoch anzusetzen, dass sie die individuelle Zahlungsbereitschaft- und -fähigkeit bestimmter Verbraucher überschreiten. Problematisch wäre es, wenn Kunden Ausschlussmerkmale nicht mehr erkennen und/oder beeinflussen können, um Zugang zu erschwinglichen Finanzdienstleistungen zu erhalten. Aufsichtlich oder regulatorisch relevant kann dieses Verhalten werden, wenn bei einem flächendeckenden Einsatz solcher Technologien ganze Verbrauchergruppen nur noch einen stark eingeschränkten, übersteuerten oder gar keinen Zugang zu konkreten Finanzdienstleistungen mehr haben.

Darüber hinaus könnte der flächendeckende Einsatz von BDAI dazu führen, dass Verbraucher faktisch gezwungen sind, digitale Angebote zu nutzen und Daten freizugeben. Dies widerspricht insbesondere den Interessen von Verbrauchern, die diese Produktart und eine umfangreiche Offenlegung von persönlichen Daten nicht wünschen oder die keine Daten bereitstellen können. Würden Produkte, die nicht auf BDAI basieren, deutlich teurer, könnte dies den faktischen Ausschluss von wichtigen Finanzprodukten bzw. eine Diskriminierung bedeuten. Der faktische Zwang, Daten freizugeben, ist auch nicht geeignet, das Vertrauen der Verbraucher in neue Technologien wie künstliche Intelligenz zu stärken. Verbrauchergruppen, die nicht digitalisierungsaffin sind oder die Freigabe umfangreicher Daten ablehnen, könnten somit ihre Interessen verletzt sehen.

„Bezahlen mit Daten“ verschärft das Problem

Vor allem beim Einsatz von BDAI im Geschäftsmodell „Bezahlen mit Daten“ ist der Verbraucher oft ein Datenlieferant, der es meist nicht überblickt, welcher Wert hinter seinen Daten steht und welche zusätzlichen Erkenntnisse aus diesem Rohstoff generiert werden können. Zudem nehmen Verbraucher solche Angebote fälschlicherweise als kostenlos wahr, obwohl es in einer Marktwirtschaft keine wirklich kostenlosen Angebote gibt (There is no free lunch!). Dass sie mit ihren Daten zahlen, bleibt vielen Verbrauchern verborgen bzw. sie kennen den tatsächlich zu zahlenden Preis nicht. Dieser Mangel an Transparenz verstärkt die oben beschriebenen Macht- und Informationsasymmetrien zwischen Unternehmen und Verbrauchern.

Einwilligung richtig gestalten und Datensouveränität herstellen

Die Nutzung personenbezogener Daten ist gemäß den europäischen Datenschutzregeln grundsätzlich von der Einwilligung der Nutzer abhängig. Damit ist die Einwilligung der neuralgische Punkt im Datenschutz. Werden Einwilligungen sehr weit gefasst, gleichen sie Ermächtigungen, mit denen Unternehmen ihre Handlungsspielräume zu Lasten der Nutzer ausweiten können.⁶⁴ Solche weitreichenden Einwilligungen sind außerhalb der Finanzindustrie häufig Bedingung für den Kauf oder die Nutzung eines Produktes oder einer Dienstleistung, wie z.B. des Nutzungsrechtes an Bildern eines Nachrichtendienstes, sofern die Bilder über diesen Dienst versandt wurden.

⁶⁴ Vgl. Hoffmann-Riem, Die Macht digitaler Konzerne, 01.10.2017, abrufbar unter https://www.law-school.de/fileadmin/content/law-school.de/de/units/unit_affil_riem/pdf/418_Die_Macht_digitaler_Konzerne.pdf, S. 12, zuletzt eingesehen am 12.04.2018.

Der Einwilligung in die Datennutzung und den Bedingungen der Einwilligung kommt bei der Wahrung der Verbraucherinteressen also eine zentrale Bedeutung zu. Anbieter müssen berücksichtigen, dass dem Verbraucher das Interesse am Datenschutz zum Zeitpunkt der Einwilligung deutlich weniger präsent ist, als der spontane Nutzen des Produktes. Das hat zur Folge, dass Verbraucher die Einwilligung aus Bequemlichkeit und Schnelligkeit oft blind erteilen. Anbieter sollten diese Schwäche nicht ausnutzen. Ohnehin ist es kritisch zu sehen, wenn Verbraucher einer weitreichenden Datennutzung nur zustimmen, weil sie die üblichen komplizierten Einwilligungen nicht lesen, sozialen Druck verspüren oder keine andere Wahl sehen als zuzustimmen, um das Produkt überhaupt nutzen zu können.

4.1.2 Relevanz von Kunden- und Verbrauchervertrauen im Kontext von Finanzdienstleistungen

Datengetriebene Anwendungen können für Verbraucher einen hohen Nutzen bieten, zugleich sind die Verbraucher sensibel, was die Nutzung ihrer Daten angeht.

Produkte und Dienstleistungen können, wie oben beschrieben, über die Nutzung von BDAI einen höheren individuellen Kundennutzen bieten. So können etwa durch die Verwendung von Verbraucher- und Verhaltensdaten personalisierte Angebote bereitgestellt werden. Es ist zu beobachten, dass manche Verbraucher für Dienstleistungen bzw. den wahrgenommenen Mehrwert eines Angebots ihre Daten zweckgebunden bereitstellen. Sie gewöhnen sich auch zunehmend an den daraus resultierenden Nutzen der Dienstleistungen wie die personalisierte Ansprache. Es ist möglich, dass Kunden eine ähnliche Erwartung künftig auch gegenüber Angeboten von Finanzinstituten und Versicherungsunternehmen haben werden.

Produkte und Dienstleistungen, die auf BDAI basieren, sind per Definition abhängig von hinreichender Datenverfügbarkeit. Für einige Dienstleistungen bzw. Produkte (etwa der privaten Krankenversicherung) ist die Bereitstellung persönlicher Daten unumgänglich. Andere Anwendungen hingegen sind weniger auf Daten mit konkretem Personenbezug angewiesen. In diesen Fällen können auch hinreichend anonymisierte/pseudonymisierte Daten verwendet werden. Entsprechende Methoden, wie das Privacy-preserving Data Mining, werden in Kapitel 3.5 dieser Studie beschrieben.⁶⁵ Ferner könnten Anbieter auch weitere innovative Technologien wie die Distributed Ledger bzw. Blockchain-Technologie nutzen, um personenbezogene Daten im Rahmen von BDAI-Innovationen besser zu schützen.

Umfragen zufolge haben Verbraucher Bedenken, wenn Unternehmen persönliche Daten nutzen. So geben in einer Eurobarometer-Umfrage nur 15 Prozent der europäischen Verbraucher an, dass sie noch eine vollständige Kontrolle über die Informationen hätten, die sie online bereitstellen.⁶⁶ 67 Prozent der Befragten äußern sich zudem über diesen Kontrollmangel besorgt. Darüber hinaus widersprechen 52 Prozent der Befragten⁶⁷ der Aussage: „Sie haben nichts dagegen, persönliche Informationen anzugeben, wenn Sie dafür kostenlose Online-Dienste nutzen können (z.B. kostenlose E-Mail-Adresse)“⁶⁸ Weiterhin geben annähernd 70 Prozent der Befragten an, dass sie besorgt darüber seien, dass ihre Informationen zweckfremd verwendet werden.⁶⁹

⁶⁵ Vgl. (auch für eine Diskussion über die Methoden im Kontext der EU-DSGVO) Marnau, 2016, Anonymisierung, Pseudonymisierung und Transparenz für Big Data. In: Datenschutz und Datensicherheit, S. 428 – 433.

⁶⁶ European Commission, 2015, Factsheet Data Protection Eurobarometer. Online verfügbar: http://ec.europa.eu/justice/data-protection/files/factsheets/factsheet_data_protection_eurobarometer_240615_en.pdf, abgerufen am 22.01.2018.

⁶⁷ 29 Prozent: „Stimme zu“, 15 Prozent: „Trifft nicht zu“, vier Prozent: „Weiß nicht“.

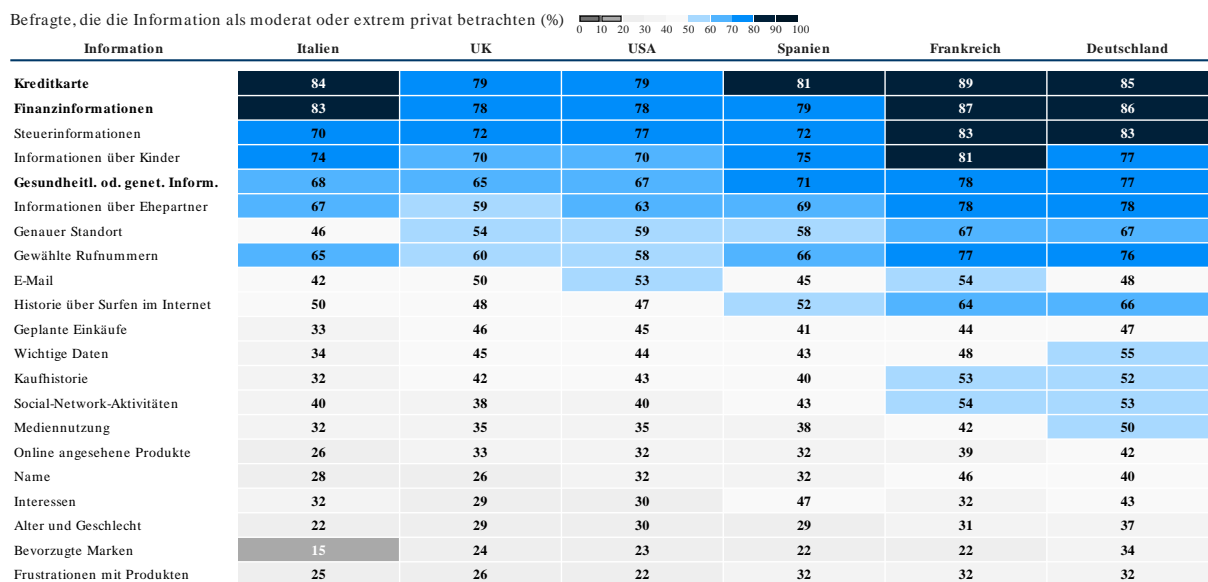
⁶⁸ European Commission, 2015, Factsheet Data Protection Eurobarometer. Online verfügbar: http://ec.europa.eu/justice/data-protection/files/factsheets/factsheet_data_protection_eurobarometer_240615_en.pdf, abgerufen am 22.01.2018.

⁶⁹ Vgl. Ebd.

Zwischen dem tatsächlichen Verhalten vieler Verbraucher und den in Umfragen geäußerten Bedenken gegenüber der Datennutzung bei Online-Dienstleistungen, besteht eine Diskrepanz. So wächst die Zahl von Verbrauchern, die entsprechende Dienstleistungen in Anspruch nehmen, beständig.⁷⁰ Wie sich diese Diskrepanz genau erklären lässt und warum persönliche Daten (z.B. in sozialen Netzwerken) trotz genereller Bedenken in großem Umfang weitergegeben werden, ist Gegenstand wissenschaftlicher und gesellschaftlicher Auseinandersetzung.⁷¹ Inwieweit sich die bei Online-Dienstleistungen und in sozialen Netzwerken beobachteten Verhaltensweisen auf Finanzdienstleistungen übertragen lassen, ist zudem kritisch zu hinterfragen, denn Finanzdaten sind besonders sensibel.

Insgesamt lässt sich festhalten, dass Verbraucher heutzutage zumindest sensibilisiert sind, was die Datennutzung durch Unternehmen angeht. Besonders sensibel sind Verbraucher, wenn es um die Nutzung von Finanz- und Gesundheitsdaten geht. Sowohl in den großen Volkswirtschaften der Europäischen Union als auch in den USA werden diese Daten als besonders privat angesehen (vgl. Abbildung 6). Finanzdienstleister haben diese besondere Sensibilität bei der Gestaltung von BDAI-Angeboten zu berücksichtigen. Etwaige missbräuchliche Verwendung – ausreichend ist hier die subjektive Wahrnehmung des Kunden – könnten zu einem Vertrauensverlust führen.

Abbildung 6: Sensibilität für Datentypen im internationalen Vergleich⁷²



Frage: „Für wie privat halten Sie die folgenden Arten persönlicher Daten?“ Antwort auf einer Skala von 1 bis 5, wobei 1 für „gar nicht privat“ und 5 für „extrem privat“ steht.

⁷⁰ Die Zahl der täglich aktiven Facebook-Nutzer ist von Q1 2011 bis Q4 2017 von 372 Millionen auf 1.401 Millionen (+277 Prozent) gewachsen. Quelle: Statista, 2018, Number of daily active Facebook users worldwide as of 4th quarter 2017 (in millions). Online verfügbar: <https://www.statista.com/statistics/346167/facebook-global-dau/>, abgerufen am 16.02.2018.

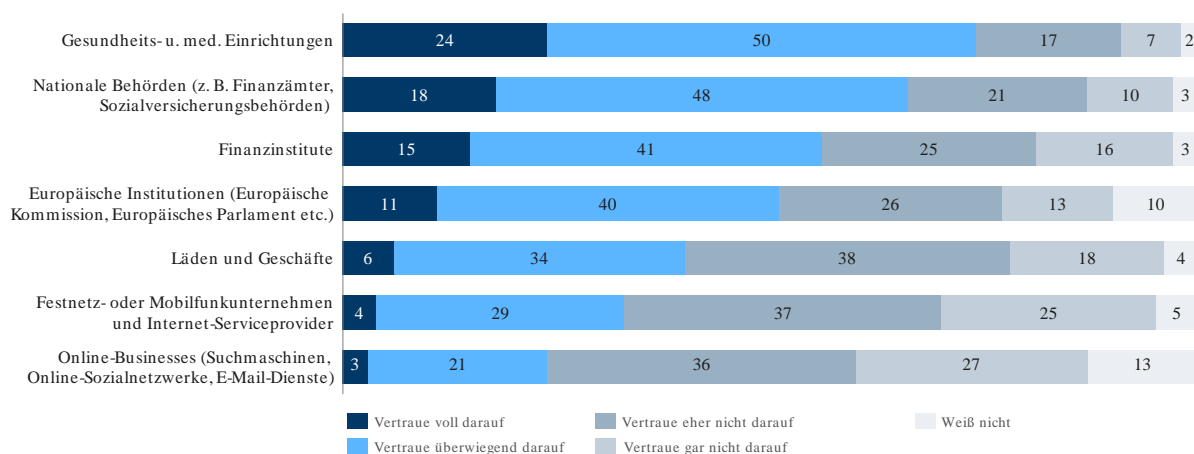
⁷¹ In Betracht kommt eine Vielzahl von psychologischen, soziologischen, situativen und ökonomischen Faktoren. Siehe: Kokolakis, 2015, Privacy attitudes and privacy behavior: A review of current research on the privacy paradox phenomenon. In: Computers & Security. Online verfügbar: https://www.researchgate.net/publication/280244291_Privacy_attitudes_and_privacy_behaviour_A_review_of_current_research_on_the_privacy_paradox_phenomenon, abgerufen am: 19.02.2018. Genannt werden unter anderem der Wunsch nach Anerkennung und Teilhabe in der (virtuellen) Gemeinschaft, Gewöhnungs- und Gewohnheitseffekte und der Wunsch nach Bequemlichkeit und Schnelligkeit. Auch der essentielle Nutzen von Privatsphäre und potenzielle Konsequenzen der Datenbereitstellung werden möglicherweise verdrängt, vergessen bzw. sind aufgrund von Informationsasymmetrien nicht bekannt. Schließlich könnte eine wahrgenommene Abwesenheit von Wahlfreiheit eine Rolle spielen.

⁷² BCG Big Data and Trust Consumer Survey 2015 (Umfrage unter mehr als 8.000 Verbrauchern in Italien, UK, USA, Spanien, Frankreich und Deutschland). Quelle: Rose et al., 2016, Bridging the Trust Gap: Data Misuse and Stewardship by the Numbers.

Etablierte Finanzinstitute genießen ein hohes Kunden- und Verbrauchervertrauen. Eine missbräuchliche Verwendung oder Nutzung von Daten kann deshalb negative Folgen für die Kundenbeziehung und – je nach Ausmaß – das Vertrauen in die Finanzdienstleistungsbranche insgesamt haben.

Die Finanzdienstleistungsbranche genießt im Branchenvergleich ein hohes Verbrauchervertrauen, was den Umgang mit persönlichen Daten angeht (vgl. Abbildung 7). 56 Prozent der europäischen Verbraucher vertrauen Finanzinstituten, dass sie ihre persönlichen Informationen schützen.

Abbildung 7: Vertrauen in den Schutz persönlicher Informationen durch Behörden und Privatunternehmen⁷³



Frage: „Verschiedene Behörden (Ministerien, Kommunen, Behörden) und Privatunternehmen sammeln und speichern persönliche Informationen über Sie. Inwieweit vertrauen Sie darauf, dass die folgenden Behörden und Privatunternehmen Ihre persönlichen Informationen schützen?“


Ein Ländervergleich erlaubt ein differenziertes Bild (vgl. Abbildung 8). Im Verhältnis zum EU-28-Durchschnitt fällt etwa auf, dass Befragte aus Deutschland, Frankreich, den Niederlanden und Spanien gegenüber Online-Businesses besonders wenig Vertrauen haben, was den Umgang mit ihren persönlichen Daten angeht.⁷⁴

Online verfügbar: <https://www.bcg.com/de-de/publications/2016/big-data-technology-digital-bridging-trust-gap-data-misuse.aspx>, abgerufen am 21.02.2018.

⁷³ European Commission, 2015, Special Eurobarometer 431.

⁷⁴ Zu einem ähnlichen Ergebnis kommt auch eine Umfrage der GfK im Auftrag des Bundesverbands deutscher Banken. Vgl. Bankenverband, 2017, Bank der Zukunft: Die Kunden auf dem Weg zur Digitalisierung mitnehmen! Online verfügbar: <https://bankenverband.de/newsroom/meinungsumfragen/bank-der-zukunft-die-kunden-auf-dem-weg-zur-digitalisierung-mitnehmen/>, abgerufen am 15.01.2018.

Abbildung 8: Vertrauen in Finanzdienstleister und Online-Businesses im Vergleich⁷⁵



Frage: „Verschiedene Behörden (Ministerien, Kommunen, Behörden) und Privatunternehmen sammeln und speichern persönliche Informationen über Sie. Inwieweit vertrauen Sie darauf, dass die folgenden Behörden und Privatunternehmen Ihre persönlichen Informationen schützen?“

Das Vertrauen der Kunden und Verbraucher in Finanzinstitute und Versicherungsunternehmen ist historisch gewachsen. Weil Verbraucher im Umgang mit ihren persönlichen Finanzdaten sehr sensibel sind, ist das Vertrauen in die Finanzinstitute stets ein zentrales Element für die Geschäftsentwicklung gewesen (z.B. Bankgeheimnis). Der Schutz persönlicher Daten war und ist eine zentrale Aufgabe und Pflicht des Managements. Der Stellenwert des Datenschutzes im Unternehmen wird dadurch unterstrichen, dass für die meisten Unternehmen die Ernennung eines Datenschutzbeauftragten gesetzlich vorgeschrieben ist. Der Beauftragte ist wiederum mit besonderen Privilegien, wie etwa einem besonderen Kündigungsschutz, ausgestattet. Durch die Regulierung und Beaufsichtigung von Finanzdienstleistungen wurde das Vertrauen in den Markt und die Geschäftspraktiken von Finanzinstituten durch die öffentliche Hand zusätzlich gestärkt.

Grundsätzlich lassen sich zwei Risiken in Bezug auf das Kunden- bzw. Verbrauchervertrauen unterscheiden. Zum einen kann eine aus Verbrauchersicht zweckfremde Verwendung von Daten, also ein wahrgenommener Datenmissbrauch, der je nach Situation auch als eine Verletzung der Privatsphäre gesehen werden könnte, das Vertrauen des Verbrauchers in die Datennutzung schädigen. Zum anderen kann Vertrauen durch Datendiebstahl oder -pannen, also mangelhafte oder fehlende Informationssicherheit, geschädigt werden. Hierunter können Vorfälle verstanden werden, bei denen Unberechtigte Zugriff auf persönliche Daten von Verbrauchern erhalten – sei es durch einen mutwilligen Angriff von außen oder Fehler des Unternehmens (vgl. Kapitel 4.2).


Bei einem wahrgenommenen Datenmissbrauch geht es nicht im engeren Sinne um die Verletzung von Nutzungsvereinbarungen mit dem Finanzdienstleister. Weniger relevant ist auch, ob die missbräuchliche Datenverwendung für den Verbraucher tatsächlich einen ökonomischen Schaden verursacht. Gemeint ist vielmehr die – wenn auch subjektive – Wahrnehmung des Verbrauchers, dass der Anbieter die Daten auf eine Weise verwendet, die nicht dem von ihm verstandenen Zweck entspricht.⁷⁶

⁷⁵ European Commission, 2015, Special Eurobarometer 431.

⁷⁶ Vgl. Rose et al., 2016, Bridging the Trust Gap: Data Misuse and Stewardship by the Numbers. Online verfügbar: <https://www.bcg.com/de-de/publications/2016/big-data-technology-digital-bridging-trust-gap-data-misuse.aspx>, abgerufen am 21.02.2018.

Darüber hinaus stellen Datendiebstähle und -pannen ein Risiko für die Kundenbeziehung dar, da sie das Vertrauen der Kunden in die Sicherheit ihrer Daten erschüttern könnten. Wie ein Blick auf die abnormale Abwanderungsrate zeigt,⁷⁷ können die negativen Effekte auf die Kundenbeziehung in der Finanz- und der Gesundheitsbranche besonders hoch sein. (vgl. Abbildung 9).

Abbildung 9: Abnormale Abwanderungsrate im Branchenvergleich⁷⁸



Die EU-DSGVO beabsichtigt die Stärkung des Daten- und Verbraucherschutzes in der neuen Datenwelt.

Mit der EU-Datenschutzgrundverordnung (EU-DSGVO) sollen Verbraucherrechte und Datenschutz gestärkt werden. Sie trat im Mai 2018 in Kraft. Die EU-DSGVO bringt einige tiefgreifende Änderungen in der Datenschutzregulierung und eine Vielzahl neuer Anforderungen für Unternehmen mit sich. Je nach Anpassungsbedarf der Unternehmen kann die EU-DSGVO auch weiterreichende Implikationen für die Geschäfts- und IT-Praktiken von Unternehmen haben. Die neue Verordnung ist in jedem EU-Mitgliedsstaat unmittelbar anzuwenden. Zentrale Ziele der EU-DSGVO sind ein EU-weit konsistenter Umgang mit personenbezogenen Daten, ein starker Schutz der Privatsphäre mit klar definierten Verantwortlichkeiten bei Verstößen sowie mehr Rechte und Selbstbestimmung für Verbraucher.

Ein zentrales Element zur Stärkung der Verbraucherrechte in der EU-DSGVO ist die explizite Einwilligung in die Nutzung personenbezogener Daten. Diese Einwilligung stellt ein Rechtmäßigkeitskriterium dar und unterliegt bestimmten Bedingungen:⁷⁹ Entsprechend dem Erwägungsgrund 32 der EU-DSGVO „[...] sollte [eine Einwilligung] durch eine eindeutige bestätigende Handlung erfolgen, mit der freiwillig, für den konkreten Fall, in informierter Weise und unmissverständlich bekundet wird, dass die betroffene Person mit der Verarbeitung der sie betreffenden personenbezogenen Daten einverstanden ist [...]“.⁸⁰ Freiwilligkeit

⁷⁷ Der Kundenverlust infolge eines Datendiebstahls oder einer Datenpanne kann in einer abnormalen Abwanderungsrate gemessen werden. Diese gibt das Mehr des zu erwartenden Kundenverlusts gegenüber dem Szenario ohne Datendiebstahl/-panne wieder.

⁷⁸ Ponemon Institute, 2017, 2017 Cost of Data Breach Study, S. 20. Online verfügbar: <https://www.ponemon.org/library/2017-cost-of-data-breach-study-united-states>, abgerufen am 29.11.2017. * Daten nur von 2016.

⁷⁹ Art. 6 EU-DSGVO, Rechtmäßigkeit der Verarbeitung und Art. 7 EU-DSGVO, Bedingungen für die Einwilligung.

⁸⁰ Erwägungsgrund 32 EU-DSGVO, Einwilligung.

setze zudem voraus, dass der Verbraucher eine „[...] echte oder freie Wahl hat und somit in der Lage ist, die Einwilligung zu verweigern oder zurückzuziehen, ohne Nachteile zu erleiden.“⁸¹ Gemäß Artikel 12 der EU-DSGVO sollen Informationen und Mitteilungen von Unternehmen gegenüber Verbrauchern unter anderem mit Bezug auf die Erhebung von personenbezogenen Daten „[...] in präziser, transparenter, verständlicher und leicht zugänglicher Form in einer klaren und einfachen Sprache [...]“⁸² übermittelt werden. Es soll zudem der Grundsatz der Transparenz gelten. Dieser sieht vor, dass „[...] gegebenenfalls zusätzlich visuelle Elemente verwendet werden. [...] Dies gilt insbesondere für Situationen, wo die große Zahl der Beteiligten und die Komplexität der dazu benötigten Technik es der betroffenen Person schwer machen, zu erkennen und nachzuvollziehen, ob, von wem und zu welchem Zweck betreffende personenbezogene Daten erfasst werden, wie etwa bei der Werbung im Internet.“⁸³

Eine weitere Rahmenbedingung für die explizite Zustimmung zur Datennutzung ergibt sich aus Artikel 7 Absatz 4, in dem „Koppelgeschäfte“ im Rahmen der Datenerhebung adressiert werden. Vor dem Hintergrund des Prinzips der Freiwilligkeit⁸⁴ muss demnach „[b]ei der Beurteilung, ob die Einwilligung freiwillig erteilt wurde, [...] dem Umstand in größtmöglichem Umfang Rechnung getragen werden, ob unter anderem die Erfüllung eines Vertrags, einschließlich der Erbringung einer Dienstleistung, von der Einwilligung zu einer Verarbeitung von personenbezogenen Daten abhängig ist, die für die Erfüllung des Vertrags nicht erforderlich sind.“

4.1.3 Komplexitätszunahme durch BDAI

Durch BDAI-Anwendungen erhöht sich die Komplexität der Datennutzung. Dies kann für Verbraucher die Nachvollziehbarkeit erschweren.

Durch die zunehmende Komplexität und Vielfältigkeit der Datennutzung könnte die Nachvollziehbarkeit der Datenverwendung und -auswertung für Verbraucher noch schwieriger werden. So entstehen durch die Disaggregation von Wertschöpfungsketten und Auslagerungen auf Drittanbieter unübersichtliche Datennetzwerke, die für die Verbraucher nur schwer zu verstehen sind (vgl. Kapitel 4.1). Dies stellt Anbieter vor neue Herausforderungen, Verbraucher adressatengerecht über die Datennutzung zu informieren. Gelingt dies den Anbietern nicht, könnte die Wissensasymmetrie zwischen Verbrauchern und den datenverarbeitenden Anbietern entsprechender Angebote weiter zunehmen.

Mit fortschreitender Digitalisierung wird es zudem generell für Verbraucher immer schwieriger nachzuvollziehen, welche Daten über sie tatsächlich zur Verfügung stehen und potenziell herangezogen werden können. Die gesamte Datenhistorie aus digitalen Verbraucheraktivitäten und die Verknüpfung dieser mit Daten, die nicht originär dem datenverarbeitenden Unternehmen zur Verfügung gestellt wurden, sind für den Einzelnen nur sehr schwer bis gar nicht zu überblicken.

⁸¹ Erwägungsgrund 42 EU-DSGVO, Beweislast und Erfordernisse einer Einwilligung.

⁸² Art. 12 EU-DSGVO, Transparente Information, Kommunikation und Modalitäten für die Ausübung der Rechte der betroffenen Person.

⁸³ Erwägungsgrund 58 EU-DSGVO, Grundsatz der Transparenz.

⁸⁴ Erwägungsgrund 43 EU-DSGVO, Zwanglose Einwilligung: „Die Einwilligung gilt nicht als freiwillig erteilt, wenn zu verschiedenen Verarbeitungsvorgängen von personenbezogenen Daten nicht gesondert eine Einwilligung erteilt werden kann, obwohl dies im Einzelfall angebracht ist, oder wenn die Erfüllung eines Vertrags, einschließlich der Erbringung einer Dienstleistung, von der Einwilligung abhängig ist, obwohl diese Einwilligung für die Erfüllung nicht erforderlich ist.“

Die strategische Relevanz des Kunden- bzw. Verbrauchervertrauens ist abhängig von der Position und Ausrichtung der Anbieter.

Die aktive Adressierung der beschriebenen Herausforderungen kann helfen, Kunden- bzw. Verbrauchervertrauen zu erhalten und weiter auszubauen. Auf Basis der in Kapitel V detailliert dargestellten Marktbetrachtungen lassen sich diesbezüglich drei Szenarien unterscheiden, die eine jeweils spezifische Herangehensweise in Bezug auf das Kunden- bzw. Verbrauchervertrauen implizieren.

1. Evolutionäre Weiterentwicklung traditioneller Finanzdienstleister unter Nutzung von BDAI

Für traditionelle Finanzdienstleister, die bereits ein vergleichsweise hohes Kunden- bzw. Verbrauchervertrauen genießen, gilt es bei einer evolutionären Weiterentwicklung unter Nutzung von BDAI (insbesondere an der Kundenschnittstelle) darauf zu achten, ihren Vertrauensvorteil nicht zu verlieren. Im Vergleich zu Anbietern, denen Kunden nicht so stark vertrauen, könnte ein möglicher Imageschaden durch Datenmissbrauch schwerwiegendere Folgen haben. Deshalb wären neben der Sicherstellung der Konformität mit der EU-DSGVO auch neue innovative Lösungsansätze zum Erhalt und Ausbau des Vertrauens in die Datennutzung zu prüfen. Die traditionellen Finanzdienstleister haben hierbei die Möglichkeit, ihren Vertrauensvorsprung als Wettbewerbsvorteil zu nutzen. So könnte das bereits hohe Vertrauensniveau dazu führen, dass Verbraucher eher bereit sind, einer Nutzung ihrer persönlichen Daten und Informationen zuzustimmen.

2. Transformation traditioneller Finanzdienstleister hin zu einem datengetriebenen BDAI-Geschäftsmodell (z.B. Gründung einer Plattformbank)

Für traditionelle Finanzdienstleister, die eine Transformation zu einem schwerpunktmäßig datengetriebenen BDAI-Geschäftsmodell anstreben, besteht durch das vorhandene Kunden- und Verbrauchervertrauen eine große Chance. Damit einher geht aber auch ein erhöhtes Risiko, bei missbräuchlicher Verwendung der Daten dieses Vertrauen zu schädigen. So könnte etwa das Risiko eines wahrgenommenen Datenmissbrauchs zunehmen, je komplexer die Datennutzung ist und je weniger der Verbraucher die Datenverwendung nachvollziehen kann. Etwaige Effekte können je nach Signifikanz der Finanzdienstleister im Markt und abhängig von der Häufigkeit möglicher Datenvorfälle auch die Reputation der gesamten Branche beeinträchtigen.

3. Bigtechs bieten Dienstleistungen traditioneller Finanzdienstleister an

Sollten Bigtechs künftig Finanzdienstleistungen anbieten, werden sie prüfen müssen, wie sie den Vertrauensrückstand gegenüber traditionellen Finanzdienstleistern ausgleichen können. Laut Umfragen zeigen Verbraucher – insbesondere in Deutschland – nur geringe Bereitschaft, ihre Bankgeschäfte über Bigtech-Unternehmen abzuwickeln.⁸⁵ Darüber hinaus hätten diese neuen Anbieter dieselben aufsichtlichen und regulatorischen Anforderungen zu erfüllen wie etablierte Unternehmen des Finanzsektors. Hieraus könnte – bei Etablierung einer entsprechenden Praxis der zweckgebundenen Datennutzung – eine Stärkung des Kunden- bzw. Verbrauchervertrauens erwachsen.

⁸⁵ Laut einer Umfrage des Bundesverbands deutscher Banken wären nur drei Prozent der Befragten bereit, mit ihren Bankgeschäften zu Unternehmen wie Google, Amazon oder Facebook zu wechseln, falls diese Bankdienstleistungen anbieten würden. Quelle: Bankenverband, 2017, Bank der Zukunft: Die Kunden auf dem Weg zur Digitalisierung mitnehmen! Online verfügbar: <https://bankenverband.de/newsroom/meinungsumfragen/bank-der-zukunft-die-kunden-auf-dem-weg-zur-digitalisierung-mitnehmen/>, abgerufen am 17.11.2017.

Unabhängig von der strategischen Ausrichtung stehen alle Anbieter entlang der drei skizzierten Szenarien vor der Herausforderung, ein ausreichendes Vertrauen der Kunden in die Datennutzung aufzubauen. Ein aktiver Umgang mit der EU-DSGVO, der im Kundeninteresse über die dort geregelten Mindeststandards hinausgeht und keine Grenzbereiche auslotet, könnte hierbei ein Wettbewerbsvorteil sein. Ferner könnten künftig neben datenintensiven Angeboten auch bewusst datensparsamere bzw. konventionelle Angebote wettbewerbsdifferenzierend wirken. Darüber hinaus wäre es zur Bildung von Vertrauen in die Datennutzung auch denkbar, dass Unternehmen freiwillig zusichern, personenbezogene Daten nur für eine kurze, für die konkrete Produkterstellung nötige Zeitdauer zu speichern bzw. zu verarbeiten und danach komplett zu löschen.

4.1.4 Schlussfolgerung: Souveränität des Verbrauchers zur Vertrauensbildung

Neue Anbieter und etablierte Banken, Versicherungsunternehmen und Finanzdienstleister müssen sich die zentrale Frage stellen, welche vertrauensbildenden bzw. -erhaltenden Maßnahmen sie mit Blick auf BDAI und Datennutzung und angesichts eines noch nicht gesicherten regulatorischen und wettbewerblichen Umfelds ergreifen sollten. Dabei geht es nicht nur um Vertrauen als wertschöpfenden Faktor, sondern um Rechtspositionen, die – etwa in Gestalt der informationellen Selbstbestimmung – in der Bundesrepublik Deutschland Verfassungsrang genießen⁸⁶ und die als Merkmale, welche die Wertordnung prägen, auch in die Ausgestaltung von Rechtsverhältnissen Privater einfließen.⁸⁷ Auch die EU-DSGVO verdeutlicht, dass Anbieter bei der Nutzung von BDAI gefordert sind, im Verhältnis zu ihren Vertragspartnern adäquate Rahmenbedingungen für den Einsatz von BDAI zu schaffen. Im Folgenden soll daher beispielhaft der Ansatz der Datensouveränität skizziert werden.

Datensouveränität könnte verstanden werden als die Fähigkeit des Einzelnen, Transparenz und Kontrolle über den Besitz, die Verwendung oder die Löschung seiner persönlichen Daten zu wahren.⁸⁸ Ziel dieses Ansatzes wäre es, dass der Verbraucher seine potenzielle Eigenverantwortung souverän ausübt. Der Verbraucher kann jedoch nur selbstbestimmt entscheiden, wenn er transparent, leicht verständlich und durch eine schnell zu erfassende Darstellung über die BDAI-Datennutzung informiert wird. Hierbei wäre auch darauf zu achten, dass die – jeweils zweckgebundene – Zustimmung des Verbrauchers zur Datennutzung revidierbar ist, dass er auch über die mittelbaren Konsequenzen informiert wird und eine echte Wahlfreiheit hat. Entsprechende Voraussetzungen hierfür müssen die Anbieter gewährleisten. So kann der Verbraucher eine freie, aufgeklärte, bewusste und nachhaltige Entscheidung über die BDAI-Nutzung treffen und muss sich künftig nicht allein auf Selbstbeschränkungen verlassen, welche sich die datenverarbeitenden Unternehmen auferlegen.

⁸⁶ BVerfG, Urteil vom 15. 1. 1958 - 1 BvR 400/57; BVerfGE.

⁸⁷ BeckOK DatenschutzR/Brink BDSG Rn. 141f.

⁸⁸ Beispielsweise hat die Bertelsmann Stiftung mit ihrem Konzept zur Datensouveränität im Kontext von Big Data einen umfassenden Policy-Rahmen entworfen, der sowohl die individuelle als auch die unternehmerische und kollektive Verantwortung für die Herstellung von Kontrolle über die Datennutzung integriert. Siehe Bertelsmann Foundation, 2017, Datensouveränität in Zeiten von Big Data, S. 24 – 32. Online verfügbar: <https://www.bertelsmann-stiftung.de/de/unsere-projekte/teilhabe-in-einer-digitalisierten-welt/projektnachrichten/datensouveraenitaet-in-zeiten-von-big-data/>, abgerufen am 13.11.2017.

Verbraucher über Datennutzung aufklären und angemessen informieren

Datenschutzbestimmungen, insbesondere in ihrer heute bei Online-Dienstleistungen weit verbreiteten Form, können oft nicht dazu beitragen, Verbraucher angemessen zu informieren. Sie werden faktisch nicht gelesen. So sagen laut einer Umfrage der Boston Consulting Group (BCG) zwei Drittel der Verbraucher, dass sie Datenschutzbestimmungen aufgrund von deren Länge und Komplexität nicht lesen. Mehr als die Hälfte der befragten Verbraucher in ausgewählten Ländern der EU und den USA geben zudem an, dass Datenschutzbestimmungen zu viel „juristische Sprache“ enthielten und daher nicht nachvollziehbar seien.⁸⁹ Eine Sonderausgabe des Eurobarometers zum Datenschutz kommt ebenfalls zu dem Ergebnis, dass zwei Drittel der Befragten (67 Prozent) Datenschutzbestimmungen als zu lang und 38 Prozent diese als zu unklar und zu schwierig empfinden.⁹⁰ Eine für den Verbraucher verständliche und der spezifischen Entscheidungssituation angepasste Darstellung von Datenschutzbestimmungen könnte auch bei der Nutzung von BDAI helfen, diesen Umstand zu beheben. Denkbar wäre eine verkürzte und adressatengerecht formulierte Aufklärung, die zugleich bewirkt, dass sich der Verbraucher bewusst mit den Konsequenzen einer entsprechenden Datennutzung auseinandersetzt. Finanzdienstleister könnten selbst Lösungen entwickeln und dazu beitragen, dass Verbraucher besser informiert werden.

In seinem Bericht „Smart Data – Smart Privacy?“ schlägt das Forschungszentrum Informatik (FZI) beispielsweise vor, dem Verbraucher die Ergebnisse der Datenschutzfolgenabschätzung (vgl. Art. 35 EU-DSGVO) zusätzlich in vereinfachter Form als Entscheidungsgrundlage für eine Datenpreisgabe zur Verfügung zu stellen. Darüber hinaus merkt das FZI an, dass sich die Transparenz auch mit einem einheitlichen, einfach verständlichen Skalen- oder intuitiven Ampelsystem verbessern ließe, aus dem hervorgeht, mit welchen Risiken die Datennutzung verbunden ist.⁹¹

Verbrauchern Kontrolle über Datennutzung ermöglichen

Auch der deutsche Sachverständigenrat für Verbraucherfragen hat sich in einem Gutachten mit der Souveränität im Kontext der Digitalisierung befasst.⁹² Er schlägt z.B. eine Datenschutzerklärung als One-Pager und die Schaffung eines verbraucherzentrierten Datenportals vor. Ein solches Portal könne Verbrauchern mehr Kontrolle über die Nutzung (Umfang und Inhalt) ihrer individuellen Daten durch unterschiedliche Anbieter geben. Ziel sei es, dass der Verbraucher in einem solchen Portal seine Daten zentral löschen und ändern und dass er Zugriffsrechte verwalten könne.

⁸⁹ Vgl. Rose et al., 2016, Bridging the Trust Gap: Data Misuse and Stewardship by the Numbers. Online verfügbar: <https://www.bcg.com/de-de/publications/2016/big-data-technology-digital-bridging-trust-gap-data-misuse.aspx>, abgerufen am 21.02.2018.

⁹⁰ European Commission, 2015, Special Eurobarometer 431.

⁹¹ FZI Forschungszentrum Informatik, 2015, Smart Data – Smart Privacy? Impulse für eine interdisziplinär rechtlich-technische Evaluation, S. 13 f. Online verfügbar: https://www.digitale-technologien.de/DT/Redaktion/DE/Downloads/Publikation/SmartData_Thesenpapier_smart_Privacy.pdf?__blob=publicationFile&v=7, abgerufen am 08.01.2018.

⁹² Vgl. Sachverständigenrat für Verbraucherfragen, 2017, Digitale Souveränität – Gutachten des Sachverständigenrats für Verbraucherfragen. Online verfügbar: http://www.svr-verbraucherfragen.de/wp-content/uploads/Gutachten_Digitale_Souver%C3%A4nit%C3%A4t.pdf, abgerufen am 14.11.2017.

Einen solchen Ansatz verfolgt beispielsweise die Datenallianz „verimi“, die in einer Kooperation verschiedener privater Akteure in Deutschland aktiv wird.^{93,94} Verimi soll einen „bequemen, sicheren und selbstbestimmten Umgang mit Identitäten und Daten im Netz“⁹⁵ ermöglichen. Die Plattform soll Verbrauchern erlauben, ihre digitalen Identitäten und Daten sicher für die Wiederverwendung bei Unternehmen und Behörden im Internet zu verwahren. Für Unternehmen soll die Plattform zudem mit Blick auf die EU-DSGVO Rechtssicherheit bieten und helfen, „Angebote unabhängig von internationalen Plattform-Anbietern abgesichert in lokalen wie globalen Märkten zu platzieren.“^{96,97}

4.2 IT-strategische Erfolgsfaktoren

Neben dem in Kapitel 4.1 beschriebenen Erfolgsfaktor „Verbrauchervertrauen“ gibt es weitere – eher technologische – Voraussetzungen für die erfolgreiche Anwendung von BDAI. So sind Finanzdienstleister bereits heute gefordert, eine aus der Geschäftsstrategie abgeleitete nachhaltige IT-Strategie festzulegen, in der Ziele und Maßnahmen zu ihrer Erreichung definiert werden⁹⁸. IT-Strategien werden beim Einsatz von BDAI jedoch eine noch bedeutendere Rolle einnehmen, wenn die im folgenden Kapitel beschriebenen Marktveränderungen eintreten. Denn BDAI dürfte z.B. Auswirkungen auf Daten- und IT-Architektur, (IT-)Aufbau- und Ablauforganisation, Kompetenzen (auf Mitarbeiter- und Leitungsebene), Arbeitsmethoden, Informationssicherheit und Outsourcing haben. In den nachfolgenden Abschnitten werden diese technologischen Erfolgsfaktoren näher ausgeführt.

4.2.1 Datenqualität und -umfang, IT-Architektur und Cloud-Computing als Erfolgsfaktoren für die Nutzung von BDAI

Datenqualität und -umfang

Datenqualität soll sicherstellen, dass die Inputvariablen einer BDAI-Anwendung eine vernünftige und effektive Grundlage⁹⁹ für die Ergebnisse darstellen. Hierzu sind Verfahren und Kriterien bereitzuhalten, welche die angemessene Datenqualität im jeweiligen Anwendungsfall gewährleisten können. Die konkreten Kriterien variieren je nach Anwendungsfall. Typische Kriterien sind z.B. Vollständigkeit, Konsistenz, Wahrhaftigkeit und/oder Aktualität.¹⁰⁰ Darüber hinaus kann der Umfang, also Volumen und Vielfalt, der Daten (Variety) helfen, repräsentative und aussagekräftige BDAI-Modelle zu erzeugen.

⁹³ Beteiligt sind unter anderem Allianz, Axel Springer, Bundesdruckerei, Daimler, Deutsche Bank, Lufthansa und Deutsche Telekom.

⁹⁴ Eine weitere Plattform dieser Art ist die „Log-in-Allianz“. Drei Medien- und Internetunternehmen haben sich zu einer Allianz zusammengesetzt und ein übergreifendes Anmeldeverfahren im Internet entwickelt (Single Sign-on). Damit wollen die Unternehmen ihre Plattformen frühzeitig an die neuen europäischen Datenschutzbestimmungen anpassen, die im Mai 2018 in Kraft treten. Mitglieder der „Log-in-Allianz“ sind die Mediengruppe RTL, ProSiebenSat.1 sowie United Internet (GMX, Web.de). Vgl. Berger, 2017, Medien- und Internet-Unternehmen gründen Log-in-Allianz. <https://www.heise.de/newsticker/meldung/Medien-und-Internet-Unternehmen-gruenden-Log-in-Allianz-3784989.html>, abgerufen am 12.02.2018.

⁹⁵ Siehe Verimi, 2017, verimi-Website. Online verfügbar: <https://www.verimi.com/>, abgerufen am 29.11.2017.

⁹⁶ Ebd.

⁹⁷ Vgl. Industrial Data Space als ein Ansatz für Datensouveränität, bei dem die Daten bei Bedarf dezentral bei ihren Eigentümern erlebbar können, siehe Kapitel 3.5.4 Infrastrukturen für Datensouveränität.

⁹⁸ Für Banken vgl. §25a KWG, MaRisk, BAIT.

⁹⁹ Zum Beispiel in Anlehnung an Artikel 174(a) Verordnung (EU) Nr. 575/2013.

¹⁰⁰ Siehe European Banking Authority, 2016, Final Draft Regulatory Technical Standards on the specification of the assessment methodology for competent authorities regarding compliance of an institution with the requirements to use the IRB Approach in accordance with Articles 144(2), 173(3) and 180(3)(b) of Regulation (EU) No 575/2013, Artikel 76.

So sind beispielsweise (gesetzliche) Ansprüche an das Ergebnis einer Datenauswertung für Anwendungsfälle im Compliance-Umfeld (z.B. bei der Geldwäscheprävention) grundsätzlich höher als in der gezielten Kundenansprache (siehe Anwendungsbeispiele in Kapitel 5.2). Bei der Kundenansprache überwiegt gegebenenfalls der Nutzen, mehr Kunden ansprechen zu können, das Risiko, dass einige falsche Kunden darunter sind. Hieraus leiten sich unterschiedliche Kriterien zur Bewertung der Datenqualität ab. Grundsätzlich sind Anbieter in der Verantwortung, dem Risiko von Fehlentscheidungen durch einen Datenbias vorzubeugen, der aus unzureichender Datenqualität und zu geringem Datenumfang resultiert (vgl. Kapitel 3.3).

Datenmanagement

Typischerweise wird zwischen strukturierten und unstrukturierten Daten unterschieden, die entweder bei den Anbietern erzeugt werden bzw. vorliegen oder von externen Quellen bezogen werden. Abbildung 10 gibt hierzu einen Überblick.

Abbildung 10: Beispiele für Datentypen entlang von zwei Dimensionen

| | Interne Daten | Externe Daten |
|-----------------------|--|--|
| Strukturierte Daten | <ul style="list-style-type: none"> • Daten aus bestandsführenden Kontosystemen (bspw. Transaktionsdaten) | <ul style="list-style-type: none"> • Externe Marktdaten (bspw. Preise von Finanzinstrumenten, Informationen zu Emissionen und Übernahmen) |
| Unstrukturierte Daten | <ul style="list-style-type: none"> • E-Mails, Chatprotokolle im Handel • Callcenter-Telefonate • Bilder von Schadenfällen in der Versicherung | <ul style="list-style-type: none"> • Öffentlich verfügbare Daten zu Kunden wie Geschäftsberichte, Ad-hoc-Mitteilungen • Blogs, Newsfeeds, Social-Media-Streams |

Strukturierte Daten liegen oft in vergleichsweise guter Qualität und ausreichendem Umfang vor, beispielsweise Transaktionsdaten im Zahlungsverkehr. Jedoch sind die Daten vieler Finanzdienstleister fragmentiert: Anbieter haben in vielen Fällen keine konsolidierte Sicht auf ihre Daten, und die Vielzahl direkter Verbindungen zwischen datenerzeugenden Systemen, wie beispielsweise bestandsführenden Anwendungen und Zahlungsverkehrssystemen, sowie datenabnehmenden Systemen erhöht die Komplexität. So berichten 65 Prozent der untersuchten Banken in einer BCG-Studie, dass sie keine bzw. nur eine teilweise definierte Zieldatenlandschaft¹⁰¹ hätten; und lediglich 25 Prozent der untersuchten Banken haben eine Datenstrategie auf Unternehmensebene definiert.¹⁰² Der digitale Reifegrad von Versicherungsunternehmen in Deutschland ist darüber hinaus laut einer BCG-Studie im Durchschnitt niedriger als der von Banken.¹⁰³

¹⁰¹ Unter Zieldatenlandschaft soll in diesem Zusammenhang der Zielzustand für die Gesamtheit der operativ und analytisch genutzten, datenführenden oder -speichernden IT-Systeme verstanden werden.

¹⁰² BCG, 2017, European IT Benchmarking in Banking.

¹⁰³ BCG, 2017, IT-Benchmarking in deutschen Versicherungen 2017 – Digitaler Reifegrad-Index.

Daneben ist in den vergangenen Jahren vor allem der Umfang externer und hierbei insbesondere unstrukturierter Daten rapide gewachsen.¹⁰⁴ Die Verarbeitbarkeit dieser unstrukturierten Daten (beispielsweise durch Fortschritte in der Spracherkennung) ermöglicht wiederum neue Anwendungsbeispiele wie z.B. autonome Chatbots an der Kundenschnittstelle¹⁰⁵

Neben der Nutzung in operativen Geschäftsprozessen kann BDAI auch dazu beitragen, die Datenqualität zu erhöhen. Einzelne große Versicherungsunternehmen haben bereits begonnen, BDAI-Lösungen zur Verbesserung der Qualität elektronisch verarbeitbarer Daten zu verwenden. Beispielsweise können Informationen aus unstrukturierten Quellen in strukturierte Daten überführt werden, wie die Vorsortierung bzw. Klassifizierung des Posteingangs und das Auslesen von Vertragsinformationen aus papierbasierten Verträgen. Ein weiteres Beispiel ist die Migration von Versicherungspolicen aus Legacy-IT-Systemen, die mit Hilfe von BDAI-Lösungen auf neue Policenstrukturen im Zielsystem überführt werden können (vgl. Kapitel 5.3).

IT-Architektur

Die Nutzung von BDAI-Anwendungen wird durch die Bereitstellung von Daten in einer Datenplattform ermöglicht, die Teil der IT-Architektur eines Marktteilnehmers ist. Unter einer Datenplattform versteht man die Kombination mehrerer Schichten¹⁰⁶, welche in Abbildung 11 vereinfacht dargestellt sind:

1. Integrationsschicht zum Laden von Daten aus diversen (internen und externen) Quellen und zur semantischen Datenintegration
2. Datenhaltungsschicht (z.B. Data Lakes zum Ablegen von unterschiedlichen Datenformaten in unterschiedlicher Granularität, Format, Qualität etc.)
3. Datenmanagement-Schicht (Data Dictionary, Data Security, Data Lineage, Zugriffsberechtigung)
4. API (Application Programming Interface)-Schicht, welche die Schnittstellen für die Weiterverwendung der Daten zur Verfügung stellt


Zusätzlich können einzelne Data-Processing-Anwendungen Teil der Datenplattform sein, um hohe Sicherheit und Schnelligkeit zu gewährleisten (nicht abgebildet).

¹⁰⁴ Vgl. IBM, 2013, Analytics: The real-world use of big data in financial services, S. 2. Online verfügbar: https://www-935.ibm.com/services/multimedia/Analytics_The_real_world_use_of_big_data_in_Financial_services_Mai_2013.pdf, abgerufen am 18.12.2017.

¹⁰⁵ Nadella, 2016, Remarks by Satya Nadella: Worldwide Partner Conference 2016. Online verfügbar: <https://news.microsoft.com/speeches/satya-nadella-worldwide-partner-conference-2016/>, abgerufen am 18.12.2017.

¹⁰⁶ Vgl. SAS, 2015, Erkenntnisse vom BITKOM Big Data Summit. Online verfügbar: <https://blogs.sas.com/content/sasdach/2015/03/02/big-data-ist-in-deutschen-unternehmen-angekommen-erkenntnisse-vom-bitkom-big-data-summit-2015/>, abgerufen am 18.12.2017.

Abbildung 11: Mögliche Zielarchitektur einer Datenplattform



Dabei sind unterschiedliche Ausprägungen der Zentralisierung möglich: Datenplattformen können einerseits auf Ebene des Gesamtunternehmens, einzelner Segmente oder Bereiche aufgebaut werden. Andererseits sind auch Stand-alone-BDAI-Anwendungen mit lokalen Datenhaushalten möglich (z.B. bieten integrierte, vorkonfigurierte Datenplattform-Lösungen eine Kombination aus Hardware, Datenbank-Software, Analytics-Anwendungen etc. und damit eine vergleichsweise einfache Installation und Verwendung). Außerdem ist zu unterscheiden, ob Daten in der Datenplattform lediglich gespiegelt werden, die operative Datenhaltung also weiterhin separat in bestandsführenden Systemen erfolgt, oder ob bestandsführende Systeme und Analytics-Anwendungen denselben Datenhaushalt verwenden.

Die konkrete Ausgestaltung der Daten- und IT-Architektur und die Maßnahmen zur Umsetzung muss jedes Unternehmen individuell definieren. In jedem Fall müssen diese Ziele und Maßnahmen als Teil der IT-Strategie den aufsichtlich-regulatorischen Anforderungen¹⁰⁷ genügen und sich an der Geschäftsstrategie der Finanzdienstleister orientieren.

Nutzung von Cloud-Computing

Cloud-Computing und darauf basierende Dienstleistungen sind ein weiterer technischer Erfolgsfaktor für die Anwendung von BDAI. Sie bieten die Möglichkeit, Rechen- und Speicherkapazitäten flexibel zu nutzen, was insbesondere aufgrund der unterschiedlichen Anforderungen an die Infrastruktur von Entwicklungs- und Produktionszyklen relevant ist. Entwicklungszyklen stellen meist deutlich höhere Anforderungen, ihre dauerhafte interne Bereitstellung ist daher gegebenenfalls ökonomisch nicht sinnvoll. Darüber hinaus lassen sich auch AI-Anwendungen wie beispielsweise Spracherkennung, Bild-, Video- und Textanalyse cloudbasiert beziehen.

¹⁰⁷ Vgl. Bundesanstalt für Finanzdienstleistungsaufsicht, 2017, Rundschreiben 10/2017 (BA) - Bankaufsichtliche Anforderungen an die IT (BAIT), siehe Tz. 1 und 2. Online verfügbar: https://www.bafin.de/SharedDocs/Downloads/DE/Rundschreiben/dl_rs_1710_ba_BAIT.html, abgerufen am 07.02.2018.

4.2.2 Technologische Veränderungen erfordern neue Kompetenzen, Strukturen sowie agile Arbeitsmethoden

Die beschriebenen Veränderungen haben unter anderem zur Folge, dass der Bedarf an Mitarbeitern mit mathematisch-analytischen Fähigkeiten steigt, da für die Entwicklung von BDAI-Modellen Fähigkeiten auf dem Gebiet der Datenanalyse und Softwareentwicklung erforderlich sind (Data Scientists).¹⁰⁸

Marktteilnehmer benötigen demzufolge eine klare Personalstrategie (inkl. Bedarfsanalyse, interner Weiterentwicklungsmaßnahmen und Recruiting). Neue Wettbewerber im Bigtech-Umfeld sind dabei meist in einer besseren Ausgangsposition, da sie bereits über viele Mitarbeiter mit mathematisch-analytischem Hintergrund verfügen und attraktive Arbeitgeber für potenzielle Kandidaten sind.¹⁰⁹ Etablierte Marktteilnehmer in der Finanzdienstleistungsbranche stehen daher bei der Suche nach neuen Mitarbeitern mit diesen Profilen in einem harten Wettbewerb um Talente. In Deutschland liegt beispielsweise die MINT¹¹⁰-Arbeitskräftelücke per Ende September 2017 bei rd. 300.000.¹¹¹ Neben mathematisch-analytischen Fähigkeiten benötigen Marktteilnehmer Mitarbeiter mit Kenntnissen in der Identifikation und Entwicklung von neuen Geschäftsmodellen, um das Potential von BDAI-Anwendungen zu erschließen und im Wettbewerb zu bestehen.

Weiterhin könnten agile Arbeitsmethoden die Adressierung einer hohen Veränderungsgeschwindigkeit im Geschäftsumfeld unterstützen. Diese wird sich, wie in Kapitel V detailliert beschrieben, durch BDAI voraussichtlich erhöhen. Agile Methoden könnten die schnellere Umsetzung von neuen Anforderungen ermöglichen und führen üblicherweise zu einer engen Abstimmung zwischen Fachabteilung und IT, weil von der ersten Projektphase an gemeinsame Teams bestehen. Dies ist vor allem bei sich schnell ändernden fachlichen Anforderungen von Vorteil, wie sie bei der Nutzung von BDAI oftmals zu beobachten sind.¹¹² BAIT bzw. VAIT¹¹³ setzen bestimmte Rahmenbedingungen, die methodenübergreifend zu erfüllen sind, beispielsweise fordern sie die Entwicklung neuer Funktionalitäten in einer dedizierten Umgebung. Marktteilnehmer sind gefordert, ihre Geschäftsorganisation, wo notwendig, an solche Methoden anzupassen. Neue Wettbewerber wie Fintechs oder Bigtechs sind auch hierbei üblicherweise in einer guten Startposition, da solche Methoden dort bereits heute weit verbreitet sind.¹¹⁴

¹⁰⁸ Siehe IBM, 2017, The Quant Crunch: How the demand for data science skills is disrupting the job market, S. 3. Online verfügbar: <https://www-01.ibm.com/common/ssi/cgi-bin/ssialias?htmlfid=IML14576USEN>, abgerufen am 18.12.2017.

¹⁰⁹ BCG-Analyse der Angaben zum Studium auf LinkedIn mit Fokus auf mathematisch-analytische Studiengänge.

¹¹⁰ Mathematik, Informatik, Naturwissenschaft und Technik.

¹¹¹ Institut der deutschen Wirtschaft Köln (IW), 2017, MINT-Herbstreport 2017 – Herausforderungen in Deutschland meistern, S. 34. Online verfügbar: <https://www.iwkoeln.de/studien/gutachten/beitrag/christina-anger-sarah-berger-oliver-koppel-axel-pluennecke-mint-herbstreport-2017-368955>, abgerufen am 18.01.2018.

¹¹² Vgl. BCG, 2015, Building a cutting-edge banking IT function. Online verfügbar: <https://www.bcgperspectives.com/content/interviews/technology-digital-financial-institutions-ron-van-kemenade-building-cutting-edge-banking-it-function/>, abgerufen am 18.12.2017.

¹¹³ Versicherungsaufsichtliche Anforderungen an die IT. Vgl. Bundesanstalt für Finanzdienstleistungsaufsicht, 2017, BaFin Journal Dezember 2017, S. 17.

¹¹⁴ Vgl. Kaufman et al., 2015, The Power of People in Digital Banking Transformation. Online verfügbar: https://www.bcgperspectives.com/Images/BCG-Power-People-Digital-Banking-Transformation-Nov-2015_tcm80-199721.pdf, abgerufen am 18.12.2017.

Über neue Kompetenzen und Methodenwissen müssen nicht nur die einzelnen Mitarbeiter verfügen. Das Phänomen BDAI stellt auch neue Anforderungen an die Geschäftsführung von Banken und Versicherungsunternehmen. Marktteilnehmer sind gefordert, diese neuen Kompetenzen und Arbeitsmethoden in ihre aufbau- und ablauforganisatorischen Strukturen einfließen zu lassen. Aufsichtsbehörden wie die BaFin legen daher verstärkt Wert auf adäquate IT-Kompetenzen und erleichtern die Bestellung von IT-Fachleuten in den Vorstand.¹¹⁵

4.2.3 Die Bedeutung von Informationssicherheit im Kontext von BDAI

Informationssicherheit gewinnt grundsätzlich an Bedeutung. Risiken müssen daher systematisch betrachtet und verstanden werden.

Informationssicherheit soll unter anderem Vertraulichkeit, Integrität und Verfügbarkeit von Informationen sicherstellen.¹¹⁶ Ein Mangel an Informationssicherheit kann deshalb erhebliche Auswirkungen auf Finanzdienstleister haben: Halten sie regulatorische Anforderungen (beispielsweise EU-DSGVO) nicht ein, resultieren daraus möglicherweise Geldbußen.¹¹⁷ Es können sich aber auch negative Auswirkungen auf die Funktionsfähigkeit der Institute (beispielsweise durch Unterbrechung des Geschäftsbetriebs) und das Vertrauen der Verbraucher ergeben (vgl. Kapitel 4.1). In Extremfällen könnten die ökonomischen Schäden sogar die Lebensfähigkeit der Unternehmen gefährden.

Es ist absehbar, dass insbesondere das Ausmaß von Informationssicherheitsbrüchen in den nächsten Jahren zunehmen wird. Die weltweit aus Cyberkriminalität resultierenden Kosten für Unternehmen werden Schätzungen zufolge von 445 Milliarden USD im Jahr 2015 auf 2,1 Billionen USD bis 2019 steigen.^{118, 119} Zusätzlich ist von einer hohen Dunkelziffer auszugehen.¹²⁰ In den großen Volkswirtschaften (USA, Japan, Deutschland und Großbritannien) gehören laut Global Risk Report 2017 des World Economic Forum Cyberangriffe bzw. Datenbetrug und Datendiebstahl zu den bedeutendsten Risiken für Unternehmen.¹²¹ Entsprechend beschäftigen sich auch Regulatoren und Aufsichtsbehörden mit dem Thema.¹²²

¹¹⁵ Siehe Bundesanstalt für Finanzdienstleistungsaufsicht, 2017, IT-Kompetenz in der Geschäftsleitung. In: BaFinJournal, S. 15 ff. Online verfügbar:

https://www.bafin.de/SharedDocs/Downloads/DE/BaFinJournal/2017/bj_1712.pdf;jsessionid=677DC922154CC5480E4AA4C656A124592_cid363?__blob=publicationFile&v=3, abgerufen am 18.12.2017;

European Banking Authority und European Securities and Markets Authority, 2017, Joint ESMA und EBA Guidelines on the assessment of the suitability of members of the management body and key function holders, S. 34. Online verfügbar:

<https://www.eba.europa.eu/documents/10180/1972984/Joint+ESMA+and+EBA+Guidelines+on+the+assessment+of+suitability+of+members+of+the+management+body+and+key+function+holders+%28EBA-GL-2017-12%29.pdf>, abgerufen am 18.12.2017.

¹¹⁶ BCG, 2014, Cybersecurity Meets IT Risk Management. A Corporate Immune and Defense System. Online verfügbar:

https://www.bcgperspectives.com/content/articles/technology_strategy_technology_organization_cybersecurity_meets_it_risk_management/, abgerufen am 10.01.2018.

¹¹⁷ Vgl. Art. 83 EU-DSGVO, Allgemeine Bedingungen für die Verhängung von Geldbußen.

¹¹⁸ Juniper Research, 2016, Cybercrime will Cost Businesses Over \$2 Trillion by 2019. Online verfügbar:

<https://www.juniperresearch.com/press/press-releases/cybercrime-cost-businesses-over-2trillion>, abgerufen am 30.10.2017.

¹¹⁹ Vgl. B20 Germany 2017, Taskforce Digitalization Policy Paper 2017. Online verfügbar:

https://www.b20germany.org/fileadmin/user_upload/documents/B20/B20_Digitalization_Policy_Paper_2017.pdf, abgerufen am 30.10.2017.

¹²⁰ Aufgrund der strategischen Relevanz von Informationssicherheitsrisiken besteht eine Zurückhaltung, Informationssicherheitsvorfälle öffentlich bekanntzugeben.

¹²¹ Vgl. World Economic Forum, 2017, Global Risks of Highest Concern for Doing Business. Online verfügbar:

<http://reports.weforum.org/global-risks-2017/global-risks-of-highest-concern-for-doing-business-2017/#>, abgerufen am 21.11.2017.


¹²² Siehe Financial Stability Board, 2017, Stocktake of Publicly Released Cybersecurity Regulations, Guidance and Supervisory Practices. Online verfügbar: <http://www.fsb.org/wp-content/uploads/P131017-2.pdf>, abgerufen am 16.01.2018. Vgl. auch Kapitel 7.2.

Gefahren für die Informationssicherheit drohen nicht nur von außen, etwa durch Hackerangriffe, sondern auch in den Unternehmen: durch unzureichende Präventions- und Schutzmaßnahmen in der Organisation, in den Prozessen und auf Seiten der Mitarbeiter.¹²³ Im Rahmen dieser Studie werden grundsätzlich zwei Kategorien von Informationssicherheitsrisiken betrachtet (vgl. Abbildung 12):


- Daten- und Systemrisiken, welche die Verlässlichkeit von IT-Systemen und –Hardware gefährden. Sie umfassen auch Anwendungsfehler und damit interne Sicherheitsrisiken.
- Cyberrisiken, die kriminelle Aktivitäten umfassen, deren Zweck darin besteht, der Funktionsfähigkeit eines Finanzdienstleisters zu schaden und/oder aus diesen Aktivitäten (nicht-)finanzielle Vorteile zu ziehen. Hierzu gehören auch externe Gefahren aus Hackerangriffen.


Abbildung 12: Übersicht Informationssicherheitsrisiken

Daten- und Systemrisiken


 **Ausfall- bzw. Unterbrechungsrisiko**
Betriebsunterbrechungen aufgrund externer Faktoren (bspw. Naturereignissen) oder fehlender wichtiger Ressourcen (z. B. Strom, Mitarbeiter)


 **Risiko des Systemversagens**
Betriebsunterbrechungen durch kompromittierte oder fehlerhafte Systeme (z. B. fehlerhaftes Systemdesign)


 **Datensicherheitsrisiko**
Gefährdung der Authentizität, Integrität und Vertraulichkeit der Daten (z. B. fehlerhafte, nicht-beabsichtigte Modifikation oder Datenverlust durch Mitarbeiter)

 **Risiko durch/in Zusammenarbeit mit Dritten**
Schäden und/oder Betriebsstörungen aufgrund des fehlerhaften Umgangs mit Daten außerhalb der (eigenen) sicheren Unternehmensnetzwerke (z. B. im Zusammenhang mit Outsourcing)

Cyberrisiken

 **Risiko durch unberechtigten Zugriff**
Schäden durch unberechtigten Zugriff ohne die Verwendung von Schadsoftware (z. B. Identitätsdiebstahl oder Phishing, unsichere Passwörter der Mitarbeiter)

 **Hackerrisiko**
Schäden durch die Verwendung von Schadsoftware (z. B. Denial of Service, Manipulation von Software und Hardware)

 **Risiko durch/in Zusammenarbeit mit Dritten**
Schäden und/oder Betriebsstörungen aufgrund nicht autorisierter Aktivitäten durch Systeme von Drittanbietern

Durch BDAI nehmen Vernetzungsgrad und Datennutzung zu – und damit auch das Informationssicherheitsrisiko. Zugleich können BDAI-Anwendungen helfen, die Informationssicherheit zu erhöhen.

Neben dem steigenden Risiko durch stärkere Vernetzung von Marktteilnehmern und vermehrte Nutzung von Daten können sich aus der Nutzung von BDAI auch neue Risiken ergeben. Ein Beispiel hierfür sind Adversarial Attacks. Hierbei ändern Angreifer gezielt den Input für Algorithmen des maschinellen Lernens, um einen bestimmten Output zu erhalten. Diese Manipulation kann z.B. auf unstrukturierte Daten wie Bilder abzielen und eine fehlerhafte Klassifizierung durch das AI-System auslösen. Die Änderung des Inputs (Bilder) kann jedoch so subtil erfolgen, dass sie für das menschliche Auge kaum wahrnehmbar ist.¹²⁴ Dies verdeutlicht, dass beim Einsatz neuer komplexer Methoden wie etwa des Deep Learnings zusätzliche Anstrengungen zur Gewährleistung der Informationssicherheit notwendig sein dürften.

¹²³ Deutscher et al., 2017, Building a Cyberresilient Organization, S. 3. Online verfügbar: <https://www.bcgperspectives.com/content/articles/technology-digital-building-a-cyberresilient-organization/>, abgerufen am 10.01.2018.


¹²⁴ Vgl. Kurakin et al., Adversarial Examples in the Physical World. Online verfügbar: <https://arxiv.org/pdf/1607.02533.pdf>, abgerufen am 21.02.2018.

Grundlage für die Adressierung von Informationssicherheitsrisiken ist ein differenziertes Verständnis der besonders zu schützenden Vermögenswerte des jeweiligen Unternehmens. Durch die Nutzung von BDAI entstehen auch neue zu schützende Vermögenswerte.¹²⁵ Neben Daten zählen hierzu Algorithmen. Diese können sowohl einen Vermögenswert als auch ein Informationssicherheitsrisiko in Form einer potenziellen Schwachstelle darstellen. Ihre mögliche Manipulierbarkeit könnte insbesondere im Fall von schwer nachvollziehbaren Analyseverfahren zu einem erhöhten Informationssicherheitsrisiko werden (vgl. Kapitel III).

- Durch die Nutzung von BDAI entstehen und ändern sich Risiken besonders schnell. Informationssicherheitsrisiken können daher nur bedingt analog zu anderen operationellen Risiken adressiert werden. Mit Blick auf BDAI sind eine höhere Flexibilität und häufigere Anpassungen von internen Richtlinien und Kontrollen gefordert. Zudem haben sich Unternehmen in der Vergangenheit eher auf Präventionsmaßnahmen konzentriert. Vor dem Hintergrund bislang unbekannter Gefahren der BDAI-Nutzung und einer dynamischen Veränderung der Risikobewertung werden künftig jedoch Erkennungs- und Reaktionsfähigkeiten an Bedeutung gewinnen. Das Gleiche gilt für die Kompetenzen und Fähigkeiten der Mitarbeiter.¹²⁶

Folglich sollten Unternehmen auch eine klare Risikotoleranz für die Informationssicherheit festlegen. Zur Abwendung und Minderung von Informationssicherheitsrisiken (jenseits der Risikotoleranz) sind Finanzdienstleister gefordert, Vorkehrungen in mehreren Bereichen ihres Geschäftsmodells zu treffen. Als Bausteine könnten etwa die von den G7-Mitgliedsstaaten verabschiedeten acht Grundelemente der Cybersicherheit für die Finanzdienstleistungsbranche herangezogen werden (vgl. Abbildung 13).¹²⁷ Auf deren Basis könnte ein Unternehmen unter Berücksichtigung des eigenen Ansatzes für die Risikosteuerung und -kultur eine Cybersicherheitsstrategie und einen operativen Handlungsrahmen entwickeln und umsetzen. Die Elemente stellen einzelne Schritte in einem dynamischen Prozess dar, in dem Unternehmen ihre Cybersicherheitsstrategie und ihren Handlungsrahmen systematisch neu ausrichten können, wenn sich das operative Umfeld und die Bedrohungslage ändern.

Abbildung 13: G7 Grundelemente der Cybersicherheit für die Finanzdienstleistungsbranche



¹²⁵ Europäische Agentur für Netz- und Informationssicherheit, 2016, Big Data Threat Landscape, S. 12. Online verfügbar: <https://www.enisa.europa.eu/publications/bigdata-threat-landscape>, abgerufen am 10.11.2017.

¹²⁶ Vgl. Dreischmeier, 2017, Digital Without Cybersecurity Is a Train Wreck Waiting to Happen. Online verfügbar: <https://www.linkedin.com/pulse/digital-without-cybersecurity-train-wreck-waiting-ralf-dreischmeier/>, abgerufen am 10.01.2018.

¹²⁷ G7, 2016, G7 Fundamental Elements of Cybersecurity for the Financial Sector. Online verfügbar: https://www.ecb.europa.eu/paym/pol/shared/pdf/G7_Fundamental_Elements_Oct_2016.pdf?69e99441d6f2f131719a9cada3ca56a5, abgerufen am 09.02.2018.

Auf der anderen Seite bietet BDAI auch Potential für die bessere Erkennung von Informationssicherheitsrisiken. Mögliche Anwendungsbeispiele sind z.B. die Anomalieerkennung als Möglichkeit zur Identifikation der Abweichung von wahrscheinlichen Mustern, etwa bei der Verwendung von Login-Daten und der Identifikation von Angriffsmustern.¹²⁸ BDAI kann auch zu einem besseren Verständnis möglicher Cybergefahren und so zur Threat Intelligence beitragen.¹²⁹ Zudem könnte BDAI durch intelligente Automatisierung auch den Anteil notwendiger manueller Bearbeitung in der Cybersicherheit signifikant reduzieren. Insgesamt könnte so die Qualität und Geschwindigkeit der Gefahrenabwehr erhöht werden.¹³⁰

¹²⁸ Vgl. Europäische Agentur für Netz- und Informationssicherheit, 2016, Big Data Threat Landscape, S. 56 – 59. Online verfügbar: <https://www.enisa.europa.eu/publications/bigdata-threat-landscape>, abgerufen am 10.11.2017. Unter Botnets wird eine Gruppe automatisierter Schadprogramme, die über vernetzte Rechner ablaufen, verstanden.

¹²⁹ Vgl. Samtani et al., 2018, Exploring Emerging Hacker Assets and Key Hackers for Proactive Cyber Threat Intelligence. In: Journal of Management Information Systems.

¹³⁰ Vgl. Gartner, 2017, Top 10 Strategic Technology Trends for 2017: Adaptive Security Architecture, S. 10. Online verfügbar: <https://www.gartner.com/doc/3645329/top--strategic-technology-trends>, abgerufen am 16.01.2018.

V. Perspektive des Marktes

5.1 Einordnung

Betrachtung von Effekten aus Big Data und Artificial Intelligence im weiteren Sinne

In den folgenden Abschnitten dieses Kapitels werden mögliche Auswirkungen von BDAI auf die Banken- und die Versicherungsbranche sowie den Kapitalmarkt betrachtet. Diese Auswirkungen lassen sich in der Regel nicht immer sauber von Effekten der allgemeinen Digitalisierung des Finanzsystems abgrenzen. Daher wird BDAI im Folgenden in einem erweiterten Sinne verstanden. Dies schließt die Berücksichtigung von Elementen der Digitalisierung ein, welche sowohl Voraussetzung für die Anwendung von BDAI sein können (wie die Digitalisierung von Informationen), als auch Folge von deren Nutzung (etwa die Digitalisierung von Prozessen).

Es zeigt sich in den Marktbetrachtungen eine duale Natur: BDAI ermöglicht es zum einen, Prozesse, die bislang wegen ihrer Heterogenität noch größtenteils manuell geprägt waren, zu digitalisieren und zu automatisieren und somit effizienter zu gestalten. Ein Beispiel dafür ist die Erkennung relevanter Inhalte von gescannten Dokumenten und die Ableitung von Handlungen daraus. Zum anderen kann BDAI dazu beitragen, Schätzer- und Vorhersagemodelle – etwa für Kreditausfallwahrscheinlichkeiten und die Optimierung des Produktangebots entlang des prognostizierten Kundenbedarfs – zu verbessern und so die Effektivität zu steigern.

Die Betrachtungen der folgenden Abschnitte beschreiben aktuell bereits am Markt zu beobachtende Prozesse, Produkte und Anbieter, berücksichtigen relevante Literatur und die Ergebnisse der begleitenden Expertengespräche. Die nun folgenden Vorhersagen sind – wie alle in die Zukunft gerichteten Aussagen – mit Unsicherheit behaftet.

Nachfolgende Darstellungen zu Banken und Versicherungsunternehmen unterscheiden sich strukturell von der Art der Betrachtung des Kapitalmarkts

Die Abschnitte zur Betrachtung der Banken und Versicherungsunternehmen sind grundsätzlich stärker prognostizierend, da sich in diesen beiden Branchen die BDAI-Nutzung größtenteils noch im Anfangsstadium befindet. Prozesse sind dort zwar stark von regelbasierten und automatisierten Abläufen bestimmt, allerdings beginnen Banken und Versicherer erst jetzt, Daten anhand von BDAI-Anwendungen in größerem Umfang zu nutzen. Im Kapitalmarkt hingegen sind aufgrund der langjährigen Verwendung großer Datenbestände, etwa im Handel mit Volumina im Petabyte-Bereich, und Algorithmen bereits deutlich mehr Anwendungen von BDAI zu beobachten. Im Kapitalmarkt kam die Beschäftigung mit Informationen per se und deren Verwertung bereits sehr kurz nach Entstehen der Informationstheorie auf, sodass hier konzeptionell andere Wege beschritten worden sind als bei den eher prozessorientierten Banken oder Versicherern.

Zudem folgen die Abschnitte zu Banken und Versicherern einer Marktstruktur aus Kunden auf der einen und (Finanz-)Dienstleistern auf der anderen Seite. Daher fokussiert sich die Betrachtung dieser Branchen insbesondere auf die Kundenschnittstelle, auf interne Kernprozesse und mögliche neue Geschäftsmodelle. Im Vergleich dazu ist der Kapitalmarkt durch eine Interaktionsstruktur aus einer Vielzahl meist professioneller Akteure gekennzeichnet. Deshalb erfolgt seine Betrachtung entlang wesentlicher Trends.

Drei wichtige Gruppen von Anbietern im Finanzsystem

Die Marktbetrachtungen beschreiben u.a. mögliche Handlungsszenarien von Akteuren im Finanzsystem. Diese lassen sich in drei Gruppen aufteilen.

- **Incumbents**, d.h. traditionelle Unternehmen der Branchen, also im Markt aktive Banken, Versicherungsunternehmen und Kapitalmarktakteure¹³¹, die in der Regel über eine vollumfängliche Geschäftserlaubnis der Aufsichtsbehörden verfügen.
- **Fintechs/Insurtechs/Regtechs/Legaltechs**, d.h. im Markt aktive, vergleichsweise junge, technologieorientierte, kleinere Anbieter, die selektive Funktionen an der Kundenschnittstelle oder in einem Kernprozess für eines oder mehrere Produkte anbieten (teilweise in Kooperation mit einem oder mehreren Incumbents).
- **Bigtechs**, d.h. große, global agierende Technologieunternehmen, die einen Wettbewerbsvorteil aus der Nutzung digitaler Anwendungen ziehen. Sie fokussieren sich vorwiegend auf Online-Dienstleistungen, (IT-)Plattformen oder die Bereitstellung digitaler Infrastrukturen, über die sie und andere Anbieter Produkte und Dienstleistungen zur Verfügung stellen können.¹³² Einige Bigtechs verfügen bereits über eine Geschäftserlaubnis zur Erbringung einzelner Finanzdienstleistungen.¹³³ Im kontinentaleuropäischen Finanzmarkt sind sie bislang nicht oder nur eingeschränkt aktiv.

5.2 Marktbetrachtung Banken

5.2.1 Einleitung und Status quo

In der Bankenbranche trifft eine veränderte Kundenerwartungshaltung auf Kosten- und Margendruck sowie Legacy-IT-Systeme traditioneller Finanzinstitute.

Im Zuge der Digitalisierung verändern sich die Erwartungen der Kunden an die Customer Experience in vielen Branchen. Heute setzen große Technologieunternehmen Maßstäbe in puncto Schnelligkeit von Prozessen und Entscheidungen, reibungsloser Interaktion zwischen Dienstleister und Kunde, intuitiver Bedienbarkeit von Nutzeroberflächen¹³⁴ und Individualisierung/Personalisierung¹³⁵ der Dienstleistung und des Angebots. Durch solche Erfahrungen aus anderen Branchen sinkt bei vielen Bankkunden die Toleranz, wenn Anbieter auf Anfragen oder Anträge erst nach längerer Zeit reagieren. Viele Kunden übertragen ihre Erwartungen auch auf die Produkte und Dienstleistungen der Bankenbranche. Viele Finanzdienstleister könnten verstärkt BDAI-Anwendungen nutzen, um diesen neuen Maßstäben und Kundenerwartungen gerecht zu werden, also eine verbesserte Customer Experience anzubieten.

¹³¹ Im Kapitalmarkt umfassen die Incumbents mehrere Gruppen (z.B. Banken, Assetmanager, Handelsplätze, Clearinghäuser, gegebenenfalls auch Daten- oder Analyticsanbieter) und sind weniger statisch in der tatsächlichen Zusammensetzung, z.B. entstehen beinahe kontinuierlich neue Hedge-Fonds.

¹³² Vgl. Bank for International Settlements, 2018, Sound Practices. Implications of fintech developments for banks and bank supervisors. Basel Committee on Banking Supervision, S. 15.


¹³³ Beispielsweise Amazon mit AmazonPay, Google mit Google Pay oder Alibaba mit Ant Financial.

¹³⁴ Beispiele sind Sprachassistenten für zu Hause bzw. Mobiltelefone und die Sprachsteuerung von Navigationssystemen in Autos. In der Bankenbranche gibt es nun auch Angebote, die eine Kundenidentifikation oder Steuerung der mobilen App per Spracherkennung ermöglichen.

¹³⁵ Dieses Konzept, auch unter den Begriffen „Segment-of-one“ bzw. „Mass Customization“ bekannt, kann als weitere Verfeinerung gesehen werden, da nun jeder Kunde ein für sich passendes Produkt erhält.

Das hohe Volumen von Investitionen in Fintechs verdeutlicht, dass die Anpassung an diese veränderte Erwartungshaltung bereits stattfindet. So sind die weltweiten Investitionen in Fintechs, die BDAI nutzen, zwischen 2014 und 2016 um 62 Prozent auf 2,3 Milliarden USD angewachsen (vgl. Abbildung 14). Zudem ist zu beobachten, dass auch Bigtechs – wenngleich in geringerem Maße – bereits Finanzdienstleistungen anbieten. Beide Entwicklungen führen wiederum dazu, dass BDAI-Dienstleistungen und -Anwendungen in der Bankenbranche präsenter werden könnten.

Abbildung 14: Entwicklung des globalen Investitionsvolumens in BDAI-Fintechs¹³⁶



Die traditionelle europäische Bankenbranche ist mit zwei Herausforderungen konfrontiert, die derzeit eine verbreiterte Nutzung von BDAI – und somit eine angemessene Reaktion auf veränderte Kundenerwartungen – hemmen könnten: Zum einen steht der europäische Bankenmarkt seit der Finanzkrise unter einem hohen Kosten- und Margendruck. Das anhaltend niedrige Zinsniveau, der Rückgang der Bilanzsummen europäischer Banken und niedrige Margen erschweren es den Instituten, nachhaltige Erträge zu erwirtschaften. Insgesamt haben Incumbents, die unter Kostendruck leiden, deshalb einen begrenzten Spielraum, um in neue Technologien zu investieren. Solche Investitionen könnten aber geboten sein, damit die etablierten Institute veränderten Kundenerwartungen gerecht werden können.

Zum anderen könnten eine über Jahre gewachsene IT-Architektur (Legacy-IT) und ihre in Teilen funktional redundanten Anwendungen ein Grund für hohe Betriebskosten und somit ein Hindernis für die Umsetzung von Änderungen sein.¹³⁷ Mögliche Innovationen an der Kundenschnittstelle und in der technologiebasierten Optimierung von Kernprozessen können deshalb nur vergleichsweise langsam und kostspielig implementiert werden. Trotz dieses hohen Aufwands könnte eine solche Transformation für Incumbents sinnvoll sein, nämlich wenn BDAI einen nachhaltigen Beitrag zur Kostensenkung leistet. Durch ihre Legacy-IT und deren geringere Fähigkeit, neue Anwendungen zu integrieren, sind Incumbents gegenüber neuen Anbietern oft strukturell benachteiligt.¹³⁸ Diese haben entweder bereits eine State-of-the-Art-IT-Architektur oder können neue Anwendungslandschaften aufbauen, ohne die Integration einer Legacy-IT

¹³⁶ BCG FinTech Control Tower. Anmerkung: 2015 Zuwachs in BDAI Fintech Funding insbesondere durch Palantir's 880 Millionen USD Runde.

¹³⁷ Siehe Grebe et al., 2016, Simplifying IT to Accelerate Digital Transformation. Online verfügbar: http://image-src.bcg.com/Images/BCG-Simplifying-IT-to-Accelerate-Digital-Transformation-Apr-2016_tcm9-87515.pdf, abgerufen am 30.01.2018.

¹³⁸ Siehe Saleh et al., 2017, Why Aren't Banks Getting More from Digital? Online verfügbar: http://image-src.bcg.com/Images/BCG-Why-Arent-Banks-Getting-More-from-Digital-Dec-2017_tcm9-179412.pdf, abgerufen am 30.01.18.

berücksichtigen zu müssen. Verschiedene Banken fördern daher den Aufbau paralleler Digitalbanken und gehen dazu über, Fintechs zu übernehmen oder mit ihnen zu kooperieren.¹³⁹

Im Folgenden werden mögliche Effekte von BDAI auf den Gesamtmarkt, die Kundenschnittstelle, die Kernprozesse und neue Geschäftsmodelle betrachtet. Dazu werden vereinfachend drei Gruppen von Bankprodukten (Anlagen/Sparen, Kredit, Zahlungsverkehr/Kontoführung) und drei Kundengruppen (Privatkunden, kleine Firmenkunden, große Firmenkunden) unterschieden. Außerdem sollen die drei in Kapitel 5.1 eingeführten Gruppen von Anbietern betrachtet werden: Incumbents (traditionelle Banken), Bigtechs und Fintechs.

5.2.2 Auswirkungen von BDAI auf den Bankenmarkt

Eine wesentliche Veränderung im Zuge der Disaggregation der Wertschöpfungskette im Bankenmarkt kann die Trennung der Kundenschnittstelle und der Produktplattform¹⁴⁰ sein.

Die Ausweitung von BDAI-Anwendungen verstärkt die bereits bestehende Tendenz zur Disaggregation von Wertschöpfungsketten im Bankenmarkt, indem neue Wettbewerber mit BDAI-getriebenen Geschäftsmodellen oder BDAI-Anwendungen Teile der Wertschöpfungskette besetzen.¹⁴¹ Unterstützt wird der Trend zur Disaggregation durch zwei weitere Entwicklungen: Zum einen beschleunigen geänderte regulatorische Vorgaben (z.B. PSD 2)¹⁴² die Schaffung möglichst standardisierter Schnittstellen,¹⁴³ welche die Aufspaltung der Wertschöpfungsketten weiter vorantreiben könnten. Zum anderen fördern spezifische technologische Entwicklungen wie der Trend zum Open Banking¹⁴⁴ und die damit einhergehende breite Verfügbarkeit von API-basierten Anwendungen¹⁴⁵ die technische Integration einzelner, bisher isolierter Angebote entlang der Wertschöpfungskette.¹⁴⁶

¹³⁹ Während 2010 lediglich sechs Prozent (über alle Segmente) bzw. ein Prozent (Retailbanking) der Investitionen in Fintechs durch Banken getätigt wurden (der Rest durch Venture Capital oder Ähnliche), hat sich dieser Anteil in 2016 auf 49 Prozent (alle Segmente) bzw. 71 Prozent (Retailbanking) erhöht; BCG FinTech Control Tower.

¹⁴⁰ Als Produktplattform sollen im Folgenden solche Funktionen und Prozesse im Middle- und Backoffice zusammengefasst werden, die notwendig sind, um Produkte und Dienstleistungen herzustellen, die an der Kundenschnittstelle (Frontoffice) angeboten, aber nicht von den Kunden wahrgenommen werden.

¹⁴¹ So bieten einige Anbieter sehr spezialisierte Produkte und Dienstleistungen, beispielsweise Robo-Advisors, für eine verbesserte Kundeninteraktion an.

¹⁴² So erlaubt die PSD 2 im Kontext des Zahlungsverkehrs künftig unter anderem, dass Account Information Service Provider (AISPs) über dedizierte APIs (Application Programming Interfaces, vgl. Fußnote 145) Kontoinformationen von Kunden anfragen und dann darauf basierend neue Informationsdienstleistungen für den Kunden anbieten, ohne dass die Kundenkonten zwangsläufig bei diesen AISPs geführt werden. Beispiele für solche neuen Dienstleistungen sind Anwendungen, die Kunden einen Gesamtüberblick über mehrere Konten bieten (Personal Finance Manager). Hierbei werden Transaktionsdaten von mehreren Konten abgerufen und aggregiert dargestellt. (EU) 2015/2366, Payment Services Directive.

¹⁴³ Siehe Cortet et al., 2016, PSD2: The digital transformation accelerator for banks. In: Journal of Payments Strategy & Systems, Volume 10 (1). Online verfügbar: <https://www.innopay.com/assets/Publications/JPSS-Spring-PSD2-digital-transformation-for-banks-Innopay.pdf>, abgerufen am 30.01.2018.

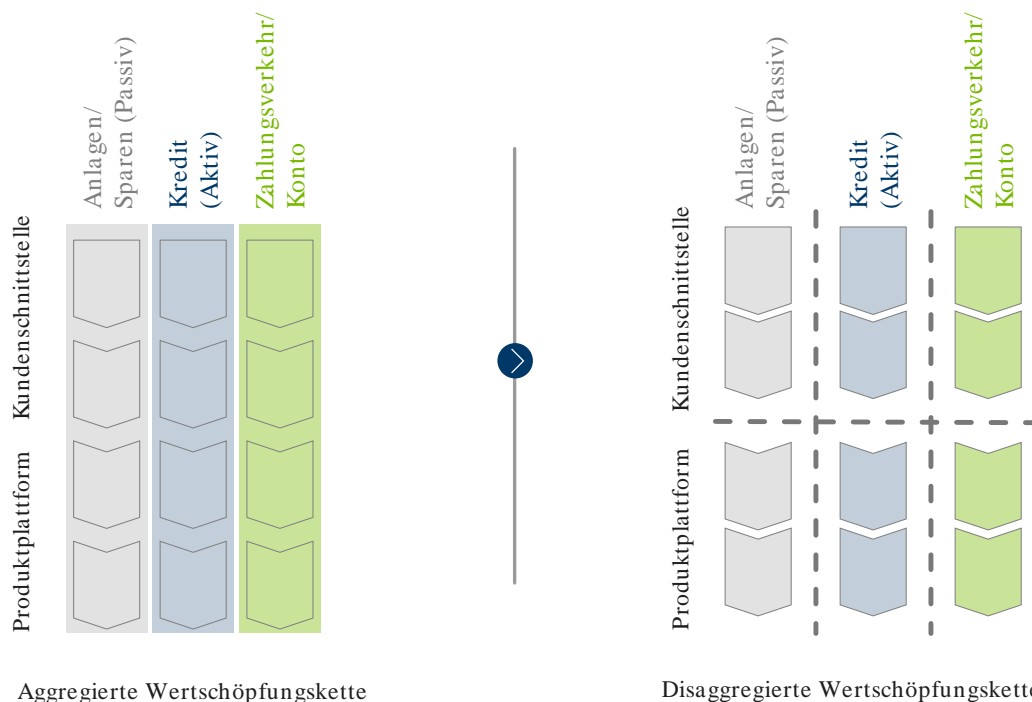
¹⁴⁴ Unterschiedliche technologische Trends wie die zunehmende Standardisierung, Modularisierung und Kapselung von Systemen und Anwendungen (u.a. durch die Verbreitung von APIs) sollen in diesem Zusammenhang unter dem Begriff „Open Banking“ zusammengefasst werden (vgl. Kapitel 4.2).

¹⁴⁵ Application Programming Interfaces (API) sind Anwendungsprogrammierschnittstellen, die die einfache Nutzung komplexer Funktionalitäten ermöglichen, siehe dazu auch detaillierte Ausführungen im Kapitel 4.2; siehe auch Zachariadis et al., 2017, The API Economy and Digital Transformation in Financial Services: The Case of Open Banking. Online verfügbar: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2975199, abgerufen am 30.01.2018.

¹⁴⁶ Vgl. Kapitel 4.2.

Die Wertschöpfungskette kann sich dabei sowohl entlang der Geschäftsprozesse von Banken als auch entlang der Bankprodukte disaggregieren (vgl. Abbildung 15).¹⁴⁷

Abbildung 15: Schematische Darstellung des Übergangs von einer aggregierten zu einer disaggregierten Wertschöpfungskette



Der Trend zur horizontalen Disaggregation der Wertschöpfungskette führt dazu, dass die Zahl der Anbieter steigt und diese sich auf ein oder wenige Produkte spezialisieren. Vor allem im Zahlungsverkehr treten vermehrt neue Anbieter in den Markt ein (vgl. Kapitel 5.2.3).¹⁴⁸

Vertikal disaggregierte Wertschöpfungsketten weisen eine stärkere Trennung zwischen Aktivitäten mit direktem Kundenkontakt an der Kundenschnittstelle und solchen im Middle- und Backoffice (Produktplattform) auf, als dies bisher der Fall war. Kunden nehmen dabei regelmäßig den Anbieter als Hersteller des Produktes wahr, der mit ihnen in die direkte Interaktion tritt und damit die Kundenschnittstelle besetzt. Dieser Anbieter hält die direkte Kundenbeziehung und bindet andere Anbieter auf der Wertschöpfungskette als Zulieferer ein. Somit erreicht er eine vergleichsweise stärkere Wettbewerbsposition als diese.¹⁴⁹

¹⁴⁷ Eine vergleichbare Unterteilung findet sich auch in einem Konsultationsdokument des Basel Committee on Banking Supervision; vgl. Bank for International Settlements, 2017, Sound Practices: Implications of fintech developments for banks and bank supervisors. Basel Committee on Banking Supervision. Online verfügbar: <https://www.bis.org/bcbs/publ/d415.pdf>, abgerufen am 23.01.2018.

¹⁴⁸ Siehe Dorfleitner et al., 2016, The Fintech Market in Germany. Bericht im Auftrag des Bundesministeriums für Finanzen, S.15. Online verfügbar: <https://ssrn.com/abstract=2885931>, abgerufen am 30.01.2018; vgl. European Banking Authority, 2017, Discussion Paper on the EBA's approach to financial technology (FinTech), S. 22. Online verfügbar: <https://www.eba.europa.eu/documents/10180/1919160/EBA+Discussion+Paper+on+Fintech+%28EBA-DP-2017-02%29.pdf>, abgerufen am 30.01.2018.

¹⁴⁹ So kann es prinzipiell möglich sein, dass ein Anbieter nur den reinen Zugang zur Dienstleistung bereitstellt und sich für alle anderen Tätigkeiten eines weiteren Anbieters bedient, der regulatorische und technologische Anforderungen abdeckt. Für den Kunden wäre diese Trennung jedoch nicht auf den ersten Blick zu erkennen.

Als Produktplattform sollen im Folgenden die Funktionen und Prozesse im Middle- und Backoffice zusammengefasst werden, die notwendig sind, um Produkte und Dienstleistungen herzustellen, die an der Kundenschnittstelle (Frontoffice) angeboten werden. Hierzu zählen Vertragsabschluss, Kontoanlage, detaillierte Analysen zur Beantwortung von Kundenanfragen und manuelle Buchungsschritte bzw. die Behandlung von Fehlern bei Zahlungsverkehrstransaktionen. Hierfür ist eine technologische Plattform vonnöten, beispielsweise der bestandsführenden Systeme und der Systeme zur Abwicklung von Transaktionen. Zudem kann es, je nach Position auf der Wertschöpfungskette, bestimmter Fähigkeiten und Kapazitäten bedürfen, um regulatorische Anforderungen zu erfüllen¹⁵⁰, etwa zur Kapitalausstattung, zum Risikomanagement und um Meldungen und Berichte für die Aufsichtsbehörden zu verfassen. Schließlich ist auch spezifisches Know-how zur Entwicklung von Finanzprodukten erforderlich.¹⁵¹

Die stärkere Trennung von Aktivitäten an der Kundenschnittstelle und solchen im Middle- und Backoffice könnte außerdem Veränderungen in der Ausgestaltung von Kompetenzen innerhalb der Institute zur Folge haben: Bislang war die Produktgestaltung oft in Form individueller Vereinbarungen mit einzelnen Kunden im Frontoffice/Vertrieb verortet. Mit der Einführung von dedizierten Produktplattformen und deren Nutzung auf Basis klar definierter Schnittstellen könnte sich die Initiative für neue Produkte und deren Ausgestaltung in Richtung der Produktplattform verlagern. Dort könnte, ausgehend von standardisierten Produkten, die Möglichkeit zur Anpassung an die jeweiligen Bedürfnisse an der Kundenschnittstelle angeboten werden.

Durch die Disaggregation der Wertschöpfungskette kann die Landschaft der Anbieter heterogener werden. Bereits heute findet sich unter den Anbietern neben den etablierten Banken auch eine Vielzahl junger Unternehmen wie Fintechs¹⁵² und vereinzelt Bigtechs¹⁵³. Sie alle könnten sich – unter Beachtung der regulatorischen Vorgaben für Auslagerungen – auf bestimmte Teile der Wertschöpfungskette konzentrieren. In einem solchen Szenario ist es wahrscheinlich, dass sich einige Anbieter auf die Kundenschnittstelle fokussieren und die für die Wertschöpfung notwendige Produktplattform von einem Dritten beziehen werden. Das Ziel wäre, die vergleichsweise attraktive Kundenbeziehung zu übernehmen und zugleich die mit dem Angebot der Produktplattform verbundene Komplexität und die Kosten dafür zu minimieren. Die Bereitstellung der Produktplattform für Dritte dagegen könnte entweder aktiv geschehen – als Teil des Geschäftsmodells (White Labeling) der Produktplattform – oder passiv, nämlich als Konsequenz aus der oben beschriebenen Strategie neuer Anbieter, die Kundenschnittstelle zu übernehmen. Beispiele für Produktplattformstrategien sind vor allem bei Fintechs zu finden, die sich typischerweise auf bestimmte Produkte und Dienstleistungen spezialisieren. Andererseits wäre dies eine Strategie für Incumbents, die sich entscheiden könnten, ihr Front- und Backoffice zu entkoppeln und verschiedene Teile der Wertschöpfungskette unter einem Dach anzubieten, allerdings organisatorisch und technisch getrennt.

Daneben kann es Anbieter geben, die sowohl die Kundenschnittstelle besetzen als auch die Produktplattform dazu anbieten.¹⁵⁴ Diese Anbieter decken sämtliche Produkte und Funktionen im Sinne einer Vollbank ab.

¹⁵⁰ In Kapitel VI wird auf die aufsichtlich-regulatorischen Implikationen der Disaggregation der Wertschöpfungskette eingegangen.

¹⁵¹ Siehe für die vertikale Disaggregation der Wertschöpfungskette exemplarisch am Beispiel des Zahlungsverkehrs Badi et al., 2017, *Global Payments 2017: Deepening the Customer Relationship*. Online verfügbar: <https://www.bcg.com/publications/2017/transaction-banking-financial-institutions-global-payments-2017-deepening-customer-relationship.aspx>, abgerufen am 30.01.2018.

¹⁵² So ist die Zahl der aktiven Fintechs von ca. 4.900 in 2010 auf ca. 10.350 in 2017 gestiegen; BCG FinTech Control Tower.

¹⁵³ Bigtechs sind vor allem im Zahlungsverkehr bzw. in der Bereitstellung von Cloud-Dienstleistungen aktiv (vgl. die Ausführungen im Abschnitt „Kundenschnittstelle“ und in Kapitel 4.2).

¹⁵⁴ Dies kann entweder dediziert für ein Produkt (im Sinne der horizontal disaggregierten Wertschöpfungskette als Spezialanbieter) oder aber über mehrere Bankprodukte als klassische Vollbank geschehen. Weitere Substrategien sind denkbar, werden an dieser Stelle aber nicht ausgeführt. Vergleichbare Ansätze hat auch das Basel Committee on Banking Supervision verfolgt; vgl. *Bank for International Settlements, 2017, Sound Practices: Implications of fintech developments for banks and bank supervisors*. Basel Committee on Banking Supervision. Online verfügbar: <https://www.bis.org/bcbs/publ/d415.pdf>, abgerufen am 23.01.2018.

Incumbents, Fintechs und Bigtechs haben in relevanten Wettbewerbsdimensionen unterschiedliche Stärken.

Für ein erfolgreiches Agieren sind vier verschiedene Wettbewerbsdimensionen mit BDAI-Bezug zu betrachten, deren Relevanz je nach strategischer Ausrichtung der Anbieter variiert:¹⁵⁵

- **Vertrauen der Verbraucher.** Hierunter kann das Vertrauen in die Sicherheit und den Umgang mit persönlichen Daten verstanden werden (vgl. Kapitel 4.1).¹⁵⁶
- **Technologische BDAI-Plattform.** Darunter versteht man u.a. eine flexible und moderne Systemarchitektur, die schnelle Reaktionen auf neue Anforderungen zulässt (Transformationsfähigkeit), eine geeignete Datenarchitektur und Tools für die Anwendung von BDAI. Darüber hinaus gehören dazu die entsprechenden Fähigkeiten und Erfahrungen der Mitarbeiter sowie die Fähigkeit der Organisation, unternehmensweit agil zu arbeiten (vgl. Kapitel 4.2).
- **Customer Reach.** Dies bezeichnet die Zahl der Kunden, die ein Anbieter tatsächlich erreichen kann. Ein hoher Customer Reach erlaubt es unter entsprechenden Umständen, Geschäftstätigkeiten sehr schnell an eine hohe Zahl von Kunden auszurollen und damit möglicherweise einen First-Mover-Vorteil zu erzielen.
- **Regulatorische Kompetenz und Branchenkenntnis.** Darunter werden zu etablierende Prozesse, Methoden und Tools sowie Mitarbeiter mit spezifischem Regulierungswissen und Branchenkenntnissen zusammengefasst. Insbesondere die regulatorische Kompetenz ist im Vergleich zu anderen Branchen relevant, da es sich bei Banken um eine stark regulierte Branche handelt. Sowohl Prozesse als auch Expertise unterliegen somit einem ständigen Anpassungsdruck. Außerdem sind Banklizenzen die Voraussetzung für viele Dienstleistungen.¹⁵⁷


Die hier betrachteten Gruppen von Anbietern – Incumbents, Bigtechs und Fintechs – haben, was diese vier Dimensionen angeht, unterschiedliche Marktpositionen. Abbildung 16 gibt einen schematischen und stark vereinfachten Überblick über die relativen Ausprägungen der Wettbewerbsdimensionen. Zugleich haben diese Anbieter unterschiedliche Geschäftsziele und verfolgen daher unterschiedliche Strategien bezüglich ihrer Positionierung im Markt.

¹⁵⁵ Insgesamt verfolgen die Anbieter auch unterschiedliche Strategien in Bezug auf die Positionierung auf der Wertschöpfungskette. Es ist zu erwarten, dass die jeweilige strategische Positionierung nicht eindeutig einer Gruppe von Anbietern zugeordnet werden kann. Vielmehr wird es mehrere Varianten und Zwischenstufen geben. Auch können sich die Positionierungen mit der Zeit ändern, wenn sich die Rahmenbedingungen und Präferenzen/Ziele wandeln.

¹⁵⁶ Diese Einschätzung beruht auf Erhebungen zum Thema Datenschutz und Umgang mit persönlichen Daten; vgl. Special Eurobarometer 431 zum Vertrauen in den Schutz persönlicher Informationen durch Behörden und Privatunternehmen, Juni 2015, Frage: „Verschiedene Behörden (Ministerien, Kommunen, Behörden) und Privatunternehmen sammeln und speichern persönliche Informationen über Sie. Inwieweit vertrauen Sie darauf, dass die folgenden Behörden und Privatunternehmen Ihre persönlichen Informationen schützen?“; vgl. auch die Umfrage: Die Kunden auf dem Weg zur Digitalisierung mitnehmen, März 2017, im Auftrag des Bundesverbandes deutscher Banken, Frage: „Die Kundendaten sind vor Zugriffen Dritter geschützt bei folgenden Anbietern: Banken, BigTechs, FinTechs.“

¹⁵⁷ Die Lizenzanforderungen sollen nicht im Detail aufgegriffen werden.

Abbildung 16: Schematische Darstellung der relativen Ausprägungen von Wettbewerbsdimensionen für Incumbents, Bigtechs und Fintechs



Traditionelle Banken/Incumbents genießen vergleichsweise hohes Vertrauen bei Verbrauchern (vgl. Kapitel 4.1) und verfügen über regulatorische Kompetenz, da sie bereits seit Jahren oder Jahrzehnten die Erfüllung zahlreicher, auch sich wandelnder regulatorischer Anforderungen sicherstellen mussten und auf langjährige Interaktionen mit Aufsichtsbehörden aufbauen können. Zudem haben sie einen hohen Customer Reach und können neue Geschäftsmodelle deshalb potenziell an eine hohe Zahl von Bestandskunden ausrollen. Neben einem hohen Customer Reach haben Banken den Vorteil, dass sie über umfangreiche Transaktionsdaten ihrer Kunden verfügen – dazu gehört insbesondere die Gesamtsicht auf die Transaktionen aller Kunden in ihrem Bestand (Kundenportfolio). Dieser Vorteil wird durch die Einführung von PSD 2 möglicherweise kleiner, da Transaktionsdaten mit Zustimmung des Kunden Drittanbietern zugänglich gemacht werden müssen. Drittanbieter könnten dann sukzessive ebenfalls eine Kundenportfoliosicht aufbauen bzw. erweitern. Die technologische Plattform und vor allem die Verfügbarkeit von Fähigkeiten in den für BDAI notwendigen Bereichen stellen für Incumbents heute oftmals noch eine Herausforderung dar. Investitionen in eine technologische Plattform müssen aufgrund historisch gewachsener IT-Architekturen regelmäßig höher ausfallen als bei Fintechs oder Bigtechs.

Bigtechs haben im Vergleich zu Incumbents typischerweise gegensätzliche Ausprägungen der vier Wettbewerbsdimensionen: Sie haben eine moderne technologische Plattform für ihre Kerngeschäftsfelder, nutzen verbreitet BDAI und verfügen über die erforderlichen Mitarbeiter und Methoden, um neue technologische Kapazitäten schnell und effizient aufzubauen. Sie können außerdem ihre besonders breite Kundenbasis und ihre flexiblen Plattformen nutzen, um schnell zu skalieren, und sind damit in der Lage, in neuen Geschäftsfeldern rasch eine starke bzw. dominierende Marktposition zu erlangen.¹⁵⁸ In den Märkten, in denen Bigtechs vorzugsweise agieren, ist dies von entscheidender Bedeutung.¹⁵⁹ Bigtechs sind außerdem in der Lage, hohe Investitionen in die Entwicklung ihrer Technologie und in neue Geschäftsfelder zu tätigen. Diese Investitionen können sowohl durch eigene Forschung und Entwicklung als auch durch Investitionen in Fintechs erfolgen.¹⁶⁰ Außerdem sind Bigtechs bei ihren Investitionen in der Lage, größere Risiken bei neuen

¹⁵⁸ Beispielsweise konnten sich die Musikstreaming-Angebote von Amazon (Prime Music, 2014) und Apple (Apple Music, 2015) sehr schnell zu Marktführern hinter Spotify entwickeln, was vor allem an ihrem großen Kundenstamm und ihrer Plattform liegt; vgl. MIDIA, 2017, Amazon Is Now The 3rd Biggest Music Subscription Service. Online verfügbar: <https://musicindustryblog.wordpress.com/2017/07/14/amazon-is-now-the-3rd-biggest-music-subscription-service/>, abgerufen am 30.01.2018.

¹⁵⁹ Diese Märkte können prinzipiell als Winner-takes-all-Märkte gesehen werden, in denen die Großen immer größer werden, siehe die Ausführungen zu „Centralized Production“ im Kontext von digitalen bzw. Informationsgütern in Loebbecke et al., 2015, Reflections on societal and business model transformation arising from digitization and big data analytics: A research agenda. In: The Journal of Strategic Information Systems. Online verfügbar: <http://dx.doi.org/10.1016/j.jsis.2015.08.002>, abgerufen am 30.02.2018.

¹⁶⁰ So waren die Bigtechs seit 2007 an über 100 Funding-Runden für Fintechs beteiligt, vgl. BCG FinTech Control Tower.

Geschäftsmodellen oder Produkten einzugehen, als traditionelle Banken dies wollen oder können.¹⁶¹ Im Hinblick auf das Verbrauchervertrauen stehen Bigtechs derzeit vor der Herausforderung, dass Verbraucher ihnen vor allem beim Umgang mit persönlichen und Finanzdaten weniger Vertrauen entgegenbringen als anderen Anbietern (vgl. Kapitel 4.1). Außerdem verfügen Bigtechs nicht über die gleiche umfassende Erfahrung mit der Regulierung und Entwicklung von Finanzprodukten wie traditionelle Banken und haben in der Vergangenheit vergleichsweise wenig mit Aufsichtsbehörden bzw. Regulatoren zu tun gehabt. Bisher hat diese Gruppe keine Vollbanklizenzen in Europa erworben.¹⁶²

Fintechs verfügen typischerweise ebenfalls über eine moderne und flexible technologische Plattform, da sie nicht auf eine existierende IT-Architektur aufsetzen müssen. Komplexität und IT-Wartungsaufwand fallen daher typischerweise geringer aus als bei traditionellen Banken – auch aufgrund der oft zu beobachtenden Konzentration auf vergleichsweise wenige Produkte bzw. Dienstleistungen. Auf der anderen Seite können Fintechs aufgrund eines geringen Customer Reach ihre neuen Geschäftsmodelle vergleichsweise weniger schnell ausrollen, da sie in der Regel ihren Kundenstamm neu aufbauen müssen. Daneben lässt sich beobachten, dass Verbraucher Fintechs derzeit weniger Vertrauen entgegenbringen als traditionellen Banken. Was ihre regulatorische Kompetenz angeht, ist die Gruppe der Fintechs eher heterogen. Viele Anbieter konzentrieren sich auf die Kundenschnittstelle und beziehen die Produktplattform von dritten Anbietern mit den entsprechenden Lizenzen. Ihre regulatorische Kompetenz ist daher weniger stark ausgeprägt. Andere Fintechs konzentrieren sich auf Angebote aus der Produktplattform und haben die dafür notwendige regulatorische Kompetenz aufgebaut. Einigen wenigen Fintechs in Deutschland hat die BaFin bereits eine Lizenz als Kredit- oder Finanzdienstleistungsinstitut (Vollbanklizenz) erteilt.

Regtechs als Sonderfall der Fintechs haben eine ausgeprägte regulatorische Kompetenz, da sie BDAI-Anwendungen insbesondere dazu nutzen, Prozesse wie beispielsweise den Compliance-Prozess von Banken effektiver und effizienter zu gestalten.

5.2.3 Auswirkungen von BDAI auf die Kundenschnittstelle

An der Kundenschnittstelle werden sich voraussichtlich die Anbieter durchsetzen, welche die beste Customer Experience für die jeweiligen Kundensegmente bieten. Daher ist eine Umverteilung von Erträgen möglich.

BDAI ist für die Kundenschnittstelle von großer Bedeutung, da es helfen kann, die geänderten Erwartungen der Kunden zu erfüllen. Viele Kunden erwarten nun auch von Banken effiziente Prozesse, die Kommunikation und Vertragsabschluss in Echtzeit und vollständig online ermöglichen. BDAI kann dabei die schrittweise Optimierung und im Idealfall die vollständige Automatisierung von Kernprozessen unterstützen (vgl. dazu den nächsten Abschnitt). So könnten z.B. Kreditentscheidungen für Kunden in Echtzeit auf Basis der vorliegenden (Transaktions-)Daten getroffen werden, und dadurch könnte die Customer Experience verbessert werden. Auch kann BDAI beispielsweise die 24/7-Erreichbarkeit von Banken durch Chatbots in

¹⁶¹ Exemplarisch lässt sich die Aussage von Scott Galloway (Professor an der NYU Stern School of Business) lesen: „They’re fantastic at taking big risk. Putting metrics on them and just as importantly pulling the plug and performing infanticide on projects that aren’t working and then moving on to the next thing. Whether it was auctions or the phone with Amazon or Facebook and some of their targeting, all of these companies have had huge missteps, but it just doesn’t matter because they on average win.“ Online verfügbar: <http://www.businessinsider.com/scott-galloway-amazon-facebook-apple-google-failure-success-tech-2017-10?IR=T>, abgerufen am 22.01.2018.

¹⁶² Amazon, Facebook und Google haben jeweils eine Zahlungsdienstleistungslizenz gemäß dem jeweiligen nationalen Umsetzungsgesetz der PSD-Richtlinie. Facebook besitzt seit 2016 eine E-Money-Lizenz in Irland, Amazon seit 2011 in Luxemburg, Google seit 2007 in Großbritannien. Amazon EU verfügt darüber hinaus seit 2015 in Großbritannien über eine Lizenz als Credit Broker. Allerdings verfügen diese Unternehmen in Deutschland über keine Einlagen- und Kreditlizenzen (Vollbanklizenz). PayPal besitzt allerdings seit 2007 eine Lizenz als Kreditinstitut in Luxemburg.

Callcentern oder im Onlineangebot der Institute ermöglichen.¹⁶³ Denkbare Beispiele wären direkte Antworten auf Fragen beim Vertragsabschluss – auch außerhalb von Banköffnungszeiten – und auf Fragen während der Vertragsbeziehung, beispielsweise zu Zahlungsmitteln, Ausgabenübersichten bzw. Kontobewegungen und Überweisungen. Weiterhin erwarten einige Kunden einfache, auf ihre individuellen Präferenzen zugeschnittene Nutzeroberflächen und Interaktionsmöglichkeiten, wie etwa die Möglichkeit der Sprachsteuerung oder Identifikation durch Sprache anstelle von Passwörtern oder Ähnlichem.¹⁶⁴ Darüber hinaus ist es vorstellbar, dass Banken ihren Kunden passgenaue Angebote unterbreiten, die basierend auf verfügbaren Informationen exakt die Produkte oder Dienstleistungen beinhalten, die in der aktuellen Situation für sie relevant sind. Auch wenn viele Banken bereits Angebote für die jeweilige Lebenssituation machen (beispielsweise bei Studienabschluss, Heirat) bestünde hier weiteres Potential zur Individualisierung. Auch im Segment der großen Firmenkunden sind Verbesserungen der Customer Experience wichtig und könnten wettbewerbsentscheidend sein, da viele Endanwender bei großen Kunden die Standards aus ihrem privaten Umfeld auch im beruflichen Umfeld erwarten dürften.

Fintechs und Bigtechs könnten die Kundenschnittstelle gezielt adressieren, da sie dort eine ihrer Kernkompetenzen besonders gut ausspielen können. Mit ihren stark datengetriebenen Geschäftsmodellen gehen sie innovative Wege, beispielsweise bei der Nutzung von extern verfügbaren Daten wie dem in Frankreich elektronisch verfügbaren „Infogreffe“¹⁶⁵. Insbesondere für Bigtechs spielt an der Kundenschnittstelle außerdem die Erhebung weiterer Kundendaten eine wichtige Rolle, da sie diese Daten für ihre Kerngeschäfte außerhalb der Bankdienstleistungen verwenden können. Ein möglicher Ansatz dafür wäre die Bereitstellung kostenloser Finanzdienstleistungen.

Für Incumbents steht dagegen oft die Sicherung der Kundenbeziehung im Vordergrund. Daneben sind traditionelle Banken – auch aufgrund der erforderlichen hohen Investitionen in die Transformation der technologischen Plattform – vergleichsweise stärker auf die Profitabilität ihrer originären Geschäftstätigkeit angewiesen. Viele Incumbents kooperieren bereits mit Fintechs, um ihr Angebot an der Kundenschnittstelle zu ergänzen. Zugleich sind solche Kooperationen auch aus Sicht der Fintechs attraktiv, da diese so Zugang zu einer breiten bestehenden Kundenbasis erhalten. Typische Beispiele für Angebote von Fintechs an der Kundenschnittstelle können Zahlungsverkehr, Anlageberatung, beispielsweise durch Robo-Advisors, und Crowdfunding sein. Fintechs sind langfristig in erster Linie auf die Profitabilität ihres originären Geschäftsmodells angewiesen. Allerdings konzentrieren sie sich zu Beginn ihrer Geschäftstätigkeit häufig vor allem auf Wachstum und weniger auf Profitabilität. Daneben kann die Monetarisierung von Daten mittelfristig ebenfalls eine Rolle spielen.

Daneben etablieren sich insbesondere Fintechs als Aggregator- oder Plattformanbieter an der Kundenschnittstelle. Die Geschäftsmodelle dieser Anbieter nutzen die relativ einfache Produktportabilität mancher Finanzprodukte aus. Dies gilt beispielsweise für Geschäftsmodelle, die die Optimierung von Tagesgeldanlagen anbieten. Solche Zinsplattformen arbeiten in der Regel als Tagesgeldaggregatoren mit einer Partnerbank zusammen, um ihren Kunden die Anlage von Tagesgeld bei verschiedenen Banken zu ermöglichen. Die Partnerbank der Zinsplattform legt für den Kunden Tagesgeld bei verschiedenen Banken an, ohne dass die Kunden selbst dafür ein zusätzliches Konto eröffnen müssen. Der Kunde muss sich lediglich einmal bei der Partnerbank der Zinsplattform identifizieren. Für Incumbents besteht somit das Risiko, Kunden zu verlieren.

¹⁶³ Die zunehmende Verbreitung solcher Chatbots greift u.a. auch das Financial Stability Board auf, siehe Financial Stability Board, 2017, Artificial intelligence and machine learning in financial services. Online verfügbar: <http://www.fsb.org/wp-content/uploads/P011117.pdf>, abgerufen am 23.01.2018.

¹⁶⁴ Ein weiteres Beispiel für die Personalisierung der Kundeninteraktion ist ein Fintech, das auf datenbasierte und dynamische Ansprache der Schuldner im Fall von Zahlungsverzug setzt, indem auf Basis eines automatisch generierten Kundenprofils bestimmte Satzformulierungen, der Stil der Ansprache oder der Kommunikationskanal ausgewählt werden. Auf Basis der Kundenreaktionen wird diese Ansprache angepasst.

¹⁶⁵ Infogreffe bietet als Äquivalent zum deutschen Handelsregister bzw. Bundesanzeiger die Möglichkeit, online zahlreiche Informationen über Unternehmen zu erhalten.

Trotz der Potentiale von BDAI an der Kundenschnittstelle ist kurzfristig nicht zu erwarten, dass BDAI den Gesamtmarkt und die Gesamterträge für Bankdienstleistungen wachsen lassen wird. Vielmehr könnte es durch den verstärkten Wettbewerb an der Kundenschnittstelle zu einer Umverteilung von Erträgen kommen.

Daten aus dem Zahlungsverkehr und der Kontoführung können besonders für Incumbents und Bigtechs wertvoll sein. Für Fintechs stehen die Erträge aus dem Zahlungsverkehr im Vordergrund.

Der Zahlungsverkehr spielt eine wichtige Rolle in der Generierung von Erträgen.¹⁶⁶ Darüber hinaus macht er einen wesentlichen Teil der Kundenbeziehungen aus, da die Zahl der Kundeninteraktionen im Vergleich zu anderen Finanzdienstleistungen relativ hoch ist. Der Zahlungsverkehr trägt so zum Ausbau qualitativ hochwertiger Daten bei. So ist insbesondere die Zahl der Transaktionen mit Karten in den vergangenen Jahren in Europa stark gewachsen, wobei allerdings große regionale Unterschiede zu beobachten sind.¹⁶⁷ Transaktionsdaten können Anbietern als Basis für personalisierte und individualisierte Angebote auch über Bankdienstleistungen hinaus dienen. Der Zugriff der Anbietergruppen auf diese Daten ist gegenwärtig noch unterschiedlich stark.

Traditionelle Banken sind in ihrer Rolle als Hausbanken grundsätzlich in einer guten Position, Transaktionsdaten an der Kundenschnittstelle zu nutzen. Sie haben bereits einen umfassenden Überblick über die Transaktionsdaten der gesamten Kunden in ihrem Bestand.¹⁶⁸ Im Gegensatz zu anderen Anbietern, die keinen historischen Datenbestand haben, können traditionelle Banken neben Querschnitt- auch Längsschnittanalysen auf Basis der Transaktionsdaten durchführen.¹⁶⁹ Daraus ergeben sich weiterreichende Möglichkeiten zur Optimierung der Kundenschnittstelle. Personalisierung und die Adressierung individueller Kundenbedürfnisse, etwa in Form von Next-Best Offer auf Basis vergleichbarer Kundenprofile,¹⁷⁰ können so noch effektiver erfolgen. Insbesondere wenn die Zahlungsfähigkeit des Kunden bekannt ist und ihm dadurch höherwertige Produkte und Dienstleistungen verkauft werden können, wären über diesen Weg auch Ertragssteigerungen denkbar.

Darüber hinaus wäre vorstellbar, dass Banken im Segment der kleinen und mittleren Unternehmen mit Hilfe von BDAI Transaktionsdaten analysieren, um mögliche neue Firmenkunden zu identifizieren. Dies wäre beispielsweise durch eine Netzwerkanalyse von Kundenbeziehungen oder eine Rückwärtssuche möglich. So könnten etwa potenzielle Neukunden identifiziert werden, die strukturell besonders profitablen bestehenden Kunden ähneln.

Für Bigtechs könnten Transaktions-/Zahlungsdaten zur Stärkung ihres Kerngeschäfts wertvoll sein. Sie könnten damit ihre bestehenden Daten über Präferenzen der Kunden um Wissen über deren Zahlungsfähigkeit und Zahlungsbereitschaft erweitern. So könnten Bigtechs diese Informationen innerhalb ihres eigenen Geschäftsmodells monetarisieren.

¹⁶⁶ Der Zahlungsverkehr erzeugte 2016 weltweit Einkünfte in Höhe von 1,2 Billionen USD und wird in den kommenden zehn Jahren voraussichtlich jährlich um sechs Prozent weltweit wachsen; vgl. Badi et al., 2017, Global Payments 2017: Deepening the Customer Relationship, S. 5. Online verfügbar: <https://www.bcg.com/publications/2017/transaction-banking-financial-institutions-global-payments-2017-deepening-customer-relationship.aspx>, abgerufen am 30.01.2018.

¹⁶⁷ In der EU ist die Zahl der Kartentransaktionen allein 2016 um 12,2 Prozent auf 59,6 Milliarden gestiegen. Dabei existierte allerdings eine Spannweite für den Anteil an Kartentransaktionen von unter 20 Prozent bis hin zu 81 Prozent zwischen den Ländern; siehe Europäische Zentralbank, 2017, Payments statistics for 2016. Online verfügbar: <https://www.ecb.europa.eu/press/pdf/pis/pis2016.pdf>, abgerufen am 23.01.2018.

¹⁶⁸ Wie bereits ausgeführt, ist zu erwarten, dass dieser Wettbewerbsvorteil durch die Auswirkungen von PSD 2 in absehbarer Zeit abschmelzen könnte.

¹⁶⁹ Voraussetzung dafür ist ein hinreichend großer Kundenstamm.

¹⁷⁰ Die Bank ermittelt das für den jeweiligen Kunden am besten passende Angebot. Dieses basiert auf den vorliegenden Kundendaten und berücksichtigt die daraus abgeleiteten Interessen und Bedürfnisse des Kunden.

Auch für Fintechs sind Zahlungsverkehrsdienstleistungen ein attraktives Geschäftsfeld. Dies wird u.a. in den Investitionen in Fintechs deutlich, die Zahlungsdienstleistungen anbieten: Seit 2011 adressierten jedes Jahr 20 Prozent oder mehr aller Fintechs Investitionsrunden in Zahlungsdienstleistungsgeschäftsmodelle. Fintechs könnten die aus diesem Geschäft abfallenden Daten zusätzlich monetarisieren.

BDAI kann dazu eingesetzt werden, die Zahlungsbereitschaft der Kunden noch genauer zu analysieren. Für den Kunden entsteht dadurch das Risiko, dass einzelne Anbieter versuchen könnten, durch bessere Kenntnis ihrer Zahlungsbereitschaft und -fähigkeit die Konsumentenrente¹⁷¹ übermäßig stark abzuschöpfen. Eine Abschöpfung der Konsumentenrente wird insbesondere auch für Anbieter mit plattformbasierten Geschäftsmodellen möglich, die nicht hauptsächlich Finanzdienstleistungen anbieten. Andererseits könnten Kunden über eine verbesserte Angebotstransparenz ihre Konsumentenrente erhöhen, beispielsweise durch Nutzung von Tagesgeldaggregatoren oder Kreditvergleichsportalen, wenn diese Portale tatsächlich unabhängig sind.

Automatisierungspotentiale durch BDAI können an der Kundenschnittstelle die Customer Experience verbessern und zugleich Effizienzpotentiale heben.

BDAI erlaubt es, bereits automatisierte Prozesse zu optimieren und entsprechende Anwendungsfelder zu erweitern. Beispielsweise können BDAI-optimierte Robo-Advisors an der Kundenschnittstelle im Produktbereich Anlage/Sparen neben automatisierten Anlageempfehlungen auch automatisiert dynamische Portfolioverwaltung auf Basis von Kundenpräferenzen anbieten. Dies kann zugleich die operativen Kosten senken. Ähnliche Effekte können sich durch den Einsatz von Chatbots ergeben: Beispielsweise können bei einigen nichteuropäischen Banken bereits bis zu 80 Prozent aller Kundenanfragen durch Chatbots beantwortet und damit kosteneffizienter bearbeitet werden. Zugleich ergeben sich für den Kunden Vorteile durch eine jederzeitige Verfügbarkeit des Serviceangebots.¹⁷² Daneben könnten regulatorische Anforderungen an der Kundenschnittstelle (z.B. MiFID¹⁷³ II) durch den Einsatz von BDAI-Anwendungen effizienter abgebildet werden.

Im bereits weitgehend automatisierten Kreditgeschäft für Privatkunden könnte BDAI insbesondere bei komplexeren Kreditprodukten wie beispielsweise der Baufinanzierung den Prozess vereinfachen und damit zu einer schnelleren Verfügbarkeit der Leistung beitragen. So existieren beispielsweise erste Angebote, die es erlauben, Finanzierungsanfragen u.a. durch den Einsatz von BDAI zu beschleunigen und kanalübergreifende, teilweise vorausgefüllte Anträge zu erstellen, um den Prozess deutlich zu beschleunigen. Zum Beispiel gibt es mobile Anwendungen, die zusätzliche Informationen zur jeweiligen Immobilie zusammentragen. Auch kann der Prozess zur Verarbeitung von notwendigen Dokumenten, wie Gehaltsnachweisen, deutlich vereinfacht bzw. automatisiert werden.

Für kleine und mittlere Firmenkunden, insbesondere in den Kundensegmenten der freien Berufe und kleinen Betriebe, wären die größten Effekte vermutlich bei den Standardkreditprodukten (siehe Anwendungsbeispiel „Kreditentscheidung“) und bei den Anlage- und Sparprodukten zu erwarten. In diesen Segmenten ist wie im Privatkundengeschäft typischerweise die Zahl der Transaktionen vergleichsweise hoch, und die Vorgänge sind eher standardisiert, sodass eine stärkere Automatisierung sowohl zur Verbesserung der Effizienz als zur Customer Experience beitragen kann. Produkt- und segmentübergreifend besteht Potential für die Automatisierung administrativer Tätigkeiten wie etwa der manuellen Übertragung von Informationen aus Formularen und Kundenbelegen, sofern diese heute noch im Frontoffice/Vertrieb bearbeitet werden (vgl.

¹⁷¹ Vgl. Erläuterungen in Fußnote 63.

¹⁷² Siehe z.B. Crossman, 2017, Chatbots to humans: Move aside, I got this. Online verfügbar:

<https://www.americanbanker.com/news/chatbots-to-humans-move-aside-i-got-this>, abgerufen am 23.01.2019. Darüber hinaus stellte Juniper in einem Report fest, dass die durchschnittliche Kundeninteraktion im Vergleich zu einem üblichen Callcenter vier Minuten kürzer ist, siehe Juniper, 2017, Chatbot Conversations to deliver \$8 billion in Cost savings by 2022. Online verfügbar: <https://www.juniperresearch.com/analytsexpress/july-2017/chatbot-conversations-to-deliver-8bn-cost-saving>, abgerufen am 23.01.2018.

¹⁷³ Markets in Financial Instruments Directive.

Abschnitt „Kernprozesse“ zum Automatisierungspotential von administrativen Prozessen in der Produktplattform). Die dargestellten Möglichkeiten, durch BDAI im Frontoffice effizienter zu agieren, würden zum ohnehin bestehenden Trend beitragen, die Struktur im Frontoffice zu ändern (z.B. Neuaufstellung der Kanalausammensetzung aus Filiale, Mobile, Online und Telefon inkl. Hybridansätzen).¹⁷⁴

5.2.4 Auswirkungen von BDAI auf die Kernprozesse der Produktplattform

Bei der Produktplattform haben Anbieter mit effizienten Kernprozessen oder von Dienstleistungen mit hohem Wertbeitrag einen Wettbewerbsvorteil.

Bei der Bereitstellung der Produktplattform kann Profitabilität typischerweise durch hohe Standardisierung und Skalierung erreicht werden. Alternativ gelingt dies durch die Bereitstellung von Dienstleistungen mit einem außerordentlich hohen Wertbeitrag, der nur durch spezielles Know-how beim Anbieter generiert werden kann. Andere Anbieter wiederum konzentrieren sich auf einzelne Teile der Wertschöpfungskette, an denen sie skalierbar tätig sein können. In Anbetracht ihrer Skalierungsfähigkeiten wäre es denkbar, dass Bigtechs als Produktplattformanbieter in Erscheinung treten. Allerdings sprechen sowohl die oben beschriebenen typischen Ziele der Bigtechs als auch ihre aktuelle Positionierung im Markt im Moment noch nicht für ein solches Angebot.

In (Kern-)Prozessen mit hohen Stückzahlen und standardisierten Vorgängen könnte die Nutzung von BDAI nachhaltige Effizienzpotentiale realisieren. Diese ergeben sich vor allem bei Abwicklungs- und Compliance-Prozessen.

Potentiale für Effizienzgewinne sind typischerweise in solchen Bereichen besonders hoch, in denen eine hohe Zahl hinreichend ähnlicher Vorgänge zu beobachten ist. Diese Struktur findet sich üblicherweise im Privatkundensegment und bei kleinen und mittleren Firmenkunden mit vergleichsweise standardisierten Produkten. Im Folgenden werden einige Anwendungsbereiche dargestellt, in denen unterschiedlich große Effizienzpotentiale durch die Nutzung von BDAI-Anwendungen liegen können.

Signifikante Potentiale könnten sich vor allem in den Abwicklungsprozessen verschiedener Produkte und Kundensegmente im Middle- und Backoffice ergeben, da diese Prozesse bei hohen Stückzahlen vergleichsweise homogen sind. Hier entstehen Potentiale insbesondere dann, wenn durch den Einsatz von BDAI-Anwendungen Prozesse automatisiert werden können. Beispielsweise sind bereits heute in vielen Bereichen Robotic Process Automation (RPA)-Anwendungen im Einsatz. Diese sind allerdings oft auf stark regelbasierte Fälle limitiert, bei denen sowohl Input als auch Output in vergleichsweise strukturierter Form vorliegen. Dies reduziert die Zahl der adressierbaren Prozesse. Durch den Einsatz von BDAI ließe sich der Anwendungsbereich von RPA insofern vergrößern, als auch weniger strukturierter Input verarbeitet werden könnte, indem er durch BDAI-Anwendungen für den RPA-Einsatz vorbereitet würde. So gibt es beispielsweise die Möglichkeit, mit Hilfe von BDAI-Anwendungen digitale/gescannte Daten zuerst mit Optical Character Recognition (OCR)-Anwendungen maschinell lesbar zu machen und, darauf basierend, automatisch zu klassifizieren (z.B. Geburtsurkunde, Gehaltsnachweis, Kreditberichte).¹⁷⁵ Darauf kann dann ein RPA-basierter Prozess aufsetzen. Beispiele für derartige Prozesse sind u.a. der Antragsprozess,¹⁷⁶ die Vertrags- und Kontoanlage.

¹⁷⁴ So zeigen die Werte der Europäischen Zentralbank, dass die Zahl der Filialen in der Eurozone zwischen 2012 und 2016 um 13 Prozent gesunken ist; Europäische Zentralbank, 2017, EU structural financial indicators. Stand 29.12.2017. Online verfügbar: <http://sdw.ecb.europa.eu/reports.do?node=1000002869>, abgerufen am 22.01.2018.

¹⁷⁶ Hier der Middle- und Backoffice-Teil in Abgrenzung zum Frontoffice-Teil, der im Abschnitt „Kundenschnittstelle“ adressiert wird.

Weitere Effizienzgewinne können bei der Kontoabstimmung von kleinen und mittleren Kunden entstehen.¹⁷⁷ Diese könnte durch BDAI noch stärker automatisiert werden, beispielsweise bei der Zuordnung von Einzahlungen ohne direkten Bezug zu Forderungen, bei Überweisungen ohne eindeutige Referenz, Teilüberweisungen und Überweisungen, die sich auf mehrere Rechnungen beziehen. Außerdem könnte die Kontoabstimmung über mehrere Konten oder sogar Banken hinweg automatisiert erfolgen.

Produktseitig könnte die Abwicklung von Privatkrediten wie Konsumenten- und Autokrediten sowie (mittelfristig, da komplexer) Baufinanzierungen die größten Effizienzpotentiale bieten.¹⁷⁸ Ähnliche Potentiale könnten in der Abwicklung von einfachen Firmenkrediten bestehen. In vielen Fällen werden Effizienzgewinne durch Kooperationen mit spezialisierten Unternehmen erzielt. Die Middle- und Backoffice-Prozesse im Zahlungsverkehr sind typischerweise schon sehr stark automatisiert, sodass auch hier die Effizienzpotentiale durch BDAI-Anwendungen eher als gering eingestuft werden können.

Des Weiteren bietet BDAI Effizienzpotentiale bei Compliance-Prozessen. Zentrale Anwendungsbereiche sind die Geldwäscheprävention sowie die Sicherstellung der Einhaltung von Sanktionen. BDAI-Anwendungen könnten bei der Analyse von Transaktions- und Kommunikationsdaten unterstützen, um irreguläre Muster als potenzielle Verdachtsfälle zu identifizieren (siehe Anwendungsbeispiel „Compliance“). So kooperiert beispielsweise eine große Universalbank mit einem Fintech, um mit Hilfe von BDAI-Anwendungen ihre Compliance-Prozesse insbesondere in der Geldwäschebekämpfung schlanker und dadurch zeitsparend zu gestalten.

Weitere Compliance-Prozesse, bei denen BDAI-Anwendungen Effizienzpotentiale heben könnten, bestehen rund um den Zahlungsverkehr, insbesondere im Kreditkartengeschäft. In diesem Produktsegment werden schon seit geraumer Zeit BDAI-Anwendungen genutzt, um betrügerisches Verhalten zu identifizieren. Beispielsweise können Daten von Kreditkartenkunden und Transaktionsdaten aus dem Handel mit bestehenden Betrugs- und Nicht-Betrugsfällen kombiniert werden, um das Betrugsrisiko der Kartennutzer ständig neu zu evaluieren. Dies führt dazu, dass die Trefferqualität erhöht wird und eventuell mehr Betrugsfälle bei den Strafverfolgungsbehörden angezeigt werden.

Neben diesen beiden großen Bereichen, in denen mit Hilfe von BDAI die Effizienz gesteigert werden könnte, gibt es diverse weitere Anwendungsbereiche, beispielsweise die Auswertung von Kreditverträgen und die Migration von Daten in neue Datenformate und -strukturen. Zusätzlich könnten BDAI-Anwendungen für diverse produkt- und segmentübergreifende analytische Prozesse helfen, Daten und Informationen automatisch statt manuell aufzubereiten. Beispielsweise könnten Kreditnehmereinheiten und Gruppen verbundener Kunden mit Hilfe von BDAI entwickelt bzw. validiert werden.

BDAI-Anwendungen könnten vor allem in den Bereichen Compliance und Risikobewertung Potential zur Steigerung der Effektivität bieten.

Es ist zu erwarten, dass die oben beschriebenen Effizienzpotentiale die Auswirkungen aus der Steigerung der Effektivität übersteigen. Dies hängt zum einen damit zusammen, dass die heute eingesetzten Modelle der Risikobewertung schon sehr weit fortgeschritten sind, zum anderen damit, dass in Compliance-Prozessen bereits heute eine große Zahl an Verdachtsfällen identifiziert wird. Trotzdem gilt für beide Anwendungsbereiche, dass bei großen Transaktionen die Identifikation von Risiken wichtiger ist als deren effiziente Bearbeitung – mögliche BDAI-Anwendungsbereiche sind also grundsätzlich relevant.

¹⁷⁷ Im Anwendungsbeispiel „Automatisierte Kreditentscheidung im Firmenkundengeschäft“ wird die Anwendung von BDAI in der Vergabe von Firmenkrediten genauer beleuchtet. Im Folgenden werden an dieser Stelle deshalb exemplarisch Beispiele für die Kooperation von Anbietern an der Kundenschnittstelle mit Anbietern an der Produktplattform dargestellt.

¹⁷⁸ Vergleiche zur Bewertung illiquider Assets Kapitel 5.4.3.

Im Compliance-Prozess sind neben den oben beschriebenen Effizienz- auch Effektivitätssteigerungen denkbar. Die Anwendung von BDAI könnte die Qualität der Treffer voraussichtlich noch einmal erhöhen: Es entstünden weniger falsche Treffer, und bisher unentdeckte Muster könnten erkannt und verfolgt werden. Außerdem könnten Netzwerkansätze helfen, die Prozesse sowohl zwischen einzelnen Banken als auch über eine zentrale Instanz zu optimieren.¹⁷⁹ Wenn Institute sich über mögliche Verdachtsfälle oder beobachtetes Betrugsverhalten austauschen, könnten sie von den Erkenntnissen anderer profitieren. Darüber hinaus könnte für manche Betrugsmuster der Blick auf das Einzelinstitut nicht ausreichen, durch eine konsolidierte Sicht könnten sie aber identifiziert werden.

Die Nutzung von BDAI birgt auch mit Blick auf Risikobewertungsmodelle für Aktivprodukte Effektivitätspotentiale. So könnte die Kreditausfallwahrscheinlichkeit eines Kunden, beispielsweise auf Basis seiner Transaktionsdaten, genauer vorhergesagt werden. Allerdings wurden auf diesem Feld in den vergangenen Jahrzehnten bereits erhebliche analytische und datenbasierte Optimierungsmaßnahmen vorgenommen, sodass bereits heute eine relativ hohe Qualität von Schätzungen erreicht wird. BDAI-Anwendungen könnten diese Modelle weiter präzisieren. Wird die Qualität von Schätzungen verbessert, könnte dies Auswirkungen auf die Kapitalunterlegung haben. Durch eine präzisere Schätzung könnten mitunter einzelne risikoreichere Geschäfte, die heute gegebenenfalls nicht abschlussfähig sind, kontrahiert werden, sodass eine zusätzliche Kapitalunterlegung erforderlich würde. Zugleich könnte es dazu kommen, dass im Bestandsportfolio die Risikobewertung von Einzeladressen geändert wird. Wobei hier auf der Portfolioebene keine Tendenzaussage zu einer Erhöhung oder Reduzierung der Kapitalunterlegung gemacht werden kann.

5.2.5 Neue Geschäftsmodelle durch BDAI

Die Monetarisierung von Daten ist ein neues potenzielles Geschäftsmodell, das Erträge aus dem traditionellen Bankgeschäft zwar nicht ersetzen, aber ergänzen könnte.

Über die bisher beschriebenen Auswirkungen von BDAI auf den Bankenmarkt hinaus sind – vor allem für traditionelle Banken – einzelne neue Geschäftsmodelle auf Basis von BDAI denkbar. Dies gilt insbesondere für die Monetarisierung von Daten als zusätzliche Ertragsquelle. Dabei lassen sich verschiedene Ansätze unterscheiden, die rechtliche Zulässigkeit und das Einverständnis des Kunden jeweils vorausgesetzt (vgl. Kapitel 4.1): Erstens könnten Anbieter aggregierte, anonymisierte Informationen zu bestimmten Transaktions- und Stammdaten monetarisieren, beispielsweise Zahlungsverkehrsinformationen (Zahl und Höhe der Transaktionen).¹⁸⁰ Zweitens könnte ein Anbieter nach expliziter Zustimmung und auf Wunsch des Kunden z.B. eine einmal erfolgte Legitimationsprüfung auch Dritten in anderen Branchen zur Verfügung stellen. Drittens ist das Angebot von Datensätzen mit anonymisierten Kundenprofilen aus Transaktions- und Stammdaten denkbar. Diese könnten um Informationen zu Kreditwürdigkeit oder Ähnlichem ergänzt werden. Für alle drei Typen von Geschäftsmodellen existieren erste Beispiele im Bankenmarkt in unterschiedlichen Reifegraden.

Die Monetarisierung von Daten stellt zwar eine mögliche zusätzliche Ertragsquelle für Banken dar, es ist allerdings nicht zu erwarten, dass die Erträge daraus kurzfristig die klassischen Erträge im Bankgeschäft ersetzen können. Auch müssen Anbieter zwischen dem Zusatznutzen durch die Monetarisierung und einer potenziellen Beeinträchtigung des Verbrauchervertrauens abwägen (vgl. Kapitel 4.1). Wobei eine Verletzung des Vertrauens durch einzelne Marktteilnehmer auf die gesamte Branche ausstrahlen könnte. Incumbents

¹⁷⁹ Beispielsweise sind in einigen Ländern schon Utility-Ansätze zu beobachten, bei denen eine zentrale Instanz Dienstleistungen rund um Compliance-Prozesse übernimmt, siehe hierzu zum Beispiel Pulley, 2016, Know Your Customer. Banks place trust in KYC as a Service. Online verfügbar: <https://blogs.thomsonreuters.com/financial-risk/know-your-customer/banks-place-trust-kyc-managed-services/>, abgerufen am 30.01.2018.

¹⁸⁰ Darauf basierend ließen sich beispielsweise Aussagen über geeignete Standorte für unterschiedliche Unternehmen tätigen, der Erfolg von Werbekampagnen bestimmen oder die Frequentierung von Geschäften zu verschiedenen Tageszeiten nachvollziehen.

bietet sich dabei möglicherweise eine Chance, ihren Vertrauensvorsprung dahingehend auszuspielen, dass sie eine aus Sicht des Verbrauchers kontrollierte Nutzung der Daten unter dem Dach einer vertrauenswürdigen Instanz anbieten könnten (siehe Anwendungsbeispiel „Monetarisierung Banken“).

Über die Monetarisierung von Daten hinaus könnten Marktteilnehmer als neues Geschäftsmodell einzelne Teile der Wertschöpfungskette für Dritte anbieten. Wie weiter oben bereits dargestellt, könnten traditionelle Banken ihre regulatorische Kompetenz und Branchenkenntnis sowie ihren Customer Reach nutzen, um für andere Anbieter an der Kundenschnittstelle White-Label-Produkte zur Verfügung zu stellen.

5.2.6 Anwendungsbeispiele in der Bankenbranche

Bankfachliche Prozesse sind zwar verhältnismäßig stark von regelbasierten und automatisierten Abläufen geprägt, und der Einsatz von Informationstechnologie hat bereits in der Vergangenheit dazu geführt, dass viele Daten erzeugt werden, aber erst jetzt beginnen Banken, diese Daten mit Hilfe von BDAI-Anwendungen in größerem Umfang zu nutzen. So sind beispielsweise bei der Kreditentscheidung größere Effizienzpotentiale zu erwarten. Ebenso können, wie oben erwähnt, im Compliance-Prozess BDAI-Anwendungen helfen, insbesondere die Geldwäscheprüfung effizienter und effektiver zu gestalten. Darüber hinaus gibt es Möglichkeiten der Monetarisierung von Daten.

In den Kapiteln 5.2.6.1, 5.2.6.2 und 5.2.6.3 werden diese drei Anwendungsbeispiele detailliert dargestellt:

Automatisierte Kreditentscheidung im Firmenkundengeschäft. Das erste Anwendungsbeispiel untersucht, wie mit Hilfe von BDAI-Anwendungen die bereits im Privatkundengeschäft bestehende Automatisierung in der Kreditentscheidung auf einfache Firmenkunden ausgeweitet werden könnte. So könnte mit Hilfe von BDAI in vergleichsweise wenig komplexen Fällen im Firmenkundengeschäft die Bearbeitung des Kreditantrags bis hin zur Kreditentscheidung automatisiert werden.

Optimierung der Compliance am Beispiel der Geldwäscheprüfung. Dieses Anwendungsbeispiel verdeutlicht das Potential von BDAI-Nutzung in den bankfachlichen Kernprozessen. Oft erweist sich nach einer manuellen Prüfung der automatisch erzeugte Hinweis auf einen Geldwäscheverdachtsfall als nicht vertiefungswürdig. Es ist denkbar, dass BDAI-Verfahren helfen, die Qualität der Treffer zu erhöhen, bisher unerkannte Muster selbstständig zu erkennen und die Zahl der Falschmeldungen deutlich zu reduzieren.

Monetarisierung von Kundendaten durch Banken. Dieses Anwendungsbeispiel verdeutlicht, wie Transaktionsdaten als neue Ertragsquellen genutzt werden und somit insbesondere Banken neue Geschäftsfelder eröffnen können. Mit Hilfe von BDAI-Anwendungen können die Banken die vorliegenden Daten intern auswerten, um personalisierte Angebote zu entwickeln. Auf diese Weise können die Institute sich als Mittler zwischen Kunden und Einzelhändlern positionieren. Hierbei könnte ein Ausgleich zwischen Datenschutz und der Generierung zusätzlicher Erträge gelingen, indem man die Kundendaten bei der Bank belässt und dem Händler aggregierte und anonymisierte Daten übermittelt.

5.2.6.1 Automatisierte Kreditentscheidung im Firmenkundengeschäft

1. Einleitung

Die Automatisierung der Kreditentscheidung ist nicht neu. Die Autoren des Buches „Zukunft der Universalbank“ haben bereits 1997 über einen Geldautomaten in Washington berichtet, der innerhalb weniger Minuten kleinere Kredite vergibt. Auch die Autorisierung von Kreditkartenumsätzen lief zu diesem Zeitpunkt bereits automatisiert.¹⁸¹ BDAI ermöglicht nun die Fortentwicklung dieser eher deterministischen Automatisierung im einfachen, granulareren und homogeneren Konsumkreditgeschäft auf das komplexere, jedoch immer noch vergleichsweise kleinteilige Firmenkreditgeschäft.¹⁸²

Die Automatisierung der Kreditentscheidung bedeutet, dass eine Maschine unter Berücksichtigung von Eingangsparametern und Entscheidungsmodellen abschließend über die Gewährung eines Kredites entscheidet. Sofern dies rechtlich nicht vollständig möglich ist, wird zumindest der Kredit(entscheidungs-)prozess so weit wie möglich automatisiert. Unbenommen ist dabei, dass es stets Sonderfälle geben wird, die ausgesteuert werden und von Menschen in manuellen Prozessen bearbeitet werden müssen.

BDAI wird dabei genutzt, um eine bessere und einfachere cash-flow-basierte Analyse, etwa auf Basis transaktionaler Daten, zu ermöglichen. Damit können prozessual tendenziell eher aufwändigere Bilanzanalysen vermieden werden. Die Zahl der notwendigen Unterlagen und Datenpunkte im Antragsprozess sowie dessen Bearbeitungsdauer sinken. Zugleich erlaubt das bessere Bild von Cash-Flows, die Abhängigkeit von komplexen Sicherheitenanalysen zu reduzieren.

Eine Interaktion mit einem Kundenberater ist dann nicht mehr zwingend erforderlich und die Zusage (oder Absage) wird nach kurzer Zeit über einen digitalen Kanal übermittelt. Neben der Geschwindigkeit des Kreditprozesses kann durch die strukturierte Verwendung von bekannten oder zusätzlichen internen oder externen Daten und AI auch die Risikodifferenzierung verbessert werden.

Treiber dieser Entwicklung ist neben einer Prozessbeschleunigung im Interesse des Kunden insbesondere die Reduktion interner Prozesskosten, vor allem im kleinteiligen, aber stückzahlgetriebenen KMU¹⁸³-Geschäft. Auf echte asset-basierte Finanzierungen, zum Beispiel im großvolumigen gewerblichen Immobilienfinanzierungsgeschäft, ist dieser Prozess aktuell daher noch nicht anwendbar.

2. Anwendung

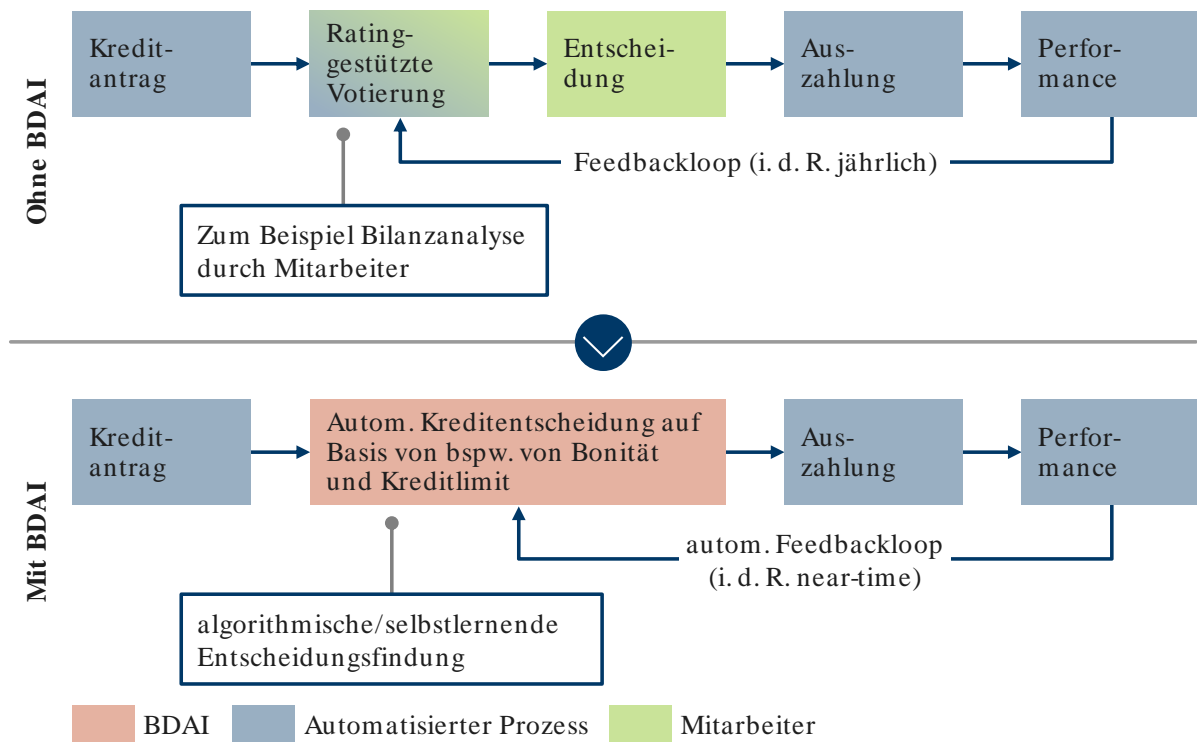
Mit Hilfe von BDAI wird für weniger komplexe Fälle im Firmenkundengeschäft die Bearbeitung des Kreditantrages bis hin zur Kreditentscheidung automatisiert. Der Algorithmus berechnet dazu in einem verschlankten Kreditprozess, basierend auf den verfügbaren Kundendaten, dynamisch und adaptiv die Bonität des Kunden sowie ein maximales Kreditlimit.

¹⁸¹ Vgl. Böhme, 1997, Die Zukunft der Universalbank. Strategie, Organisation und Shareholder Value im Informationszeitalter. Wiesbaden: Deutscher Universitätsverlag, S. 118.

¹⁸² Davon abzugrenzen sind regulatorische Risikomodelle, die zwar mit der Kapitalunterlegung, aber nur mittelbar mit der Kreditentscheidung zu tun haben. Diese sind nicht Gegenstand des Anwendungsbeispiels. Bisher setzen Modelle, die von der Aufsicht genehmigt werden müssen (Interne Modelle bei Instituten, die den Internal Ratings Based Approach – IRB – nutzen) noch nicht auf die Paarung von Big Data und Artificial Intelligence. Sollte es aber künftig zu einer aufsichtlich relevanten Nutzung von BDAI kommen, ergäben sich verschiedene Fragen, die über diese Anwendungsbeispiele hinausgehen.

¹⁸³ Kleine und mittlere Unternehmen.

Abbildung 17: Anwendung von BDAI in der Kreditentscheidung



Die Analyse basiert auf der Berücksichtigung eines breiten Sets transaktionaler Daten eines Kunden. Dazu zählen die Buchungshistorie auf dessen Konten, die Soll- und Habenstände, die Buchungstypen sowie die Gründe für einzelne Buchungen (z.B. Gehalts- und Dividendeneingänge auf der einen sowie Mahngebühren und Lastschriftrückläufer auf der anderen Seite).

Wesentliche Parameter für die Anwendbarkeit von BDAI sind:

- die Datengrundlage: Je breiter die Datengrundlage, die der Kunde zur Verfügung stellt, desto besser ist der Einblick in die Zahlungsströme bzw. das Verhaltensmuster des Kunden und desto belastbarere Ergebnisse kann BDAI erzielen, bzw. umso eher kann ein Kreditantrag rein cash-flow basiert bearbeitet werden. Hierbei sind aktuell noch die Hausbanken im Vorteil. Dies könnte sich jedoch durch die Einführung der PSD 2 ändern.
- der Standardisierungsgrad der Sicherheitenstrukturen¹⁸⁴: Nur wenn hier eine hinreichende Standardisierung erfolgt, kann BDAI effizient angewendet werden. Soll der Prozess voll automatisiert ablaufen, können nur Sicherheiten eingebunden werden, die zu dem Zeitpunkt nicht manuell geprüft werden müssen. Dies beschränkt das Anwendungsfeld aber keinesfalls auf Blanko-, Cash-besicherte- bzw. verbürgte Kredite oder standardisiert bewertbare Sachsicherheiten wie etwa Kraftfahrzeuge und Baumaschinen. Sollten Sachsicherheiten vorliegen, die bereits bewertet wurden, können diese durchaus durch eine automatisierte Adjustierung des Sicherheitenwerts Berücksichtigung finden.
- der Standardisierungsgrad der Vertragsstrukturen: Hierbei zeigt sich bereits seit längerem der Trend zur Standardisierung. Insbesondere in den Vertragsstrukturen sind individuelle Bedingungen (z.B. Zusicherungen des Kreditnehmers) rückläufig. Dies ist in der Regel einfach durchzusetzen, da komplexe vertragliche Verkläuterung in vielen Fällen nur auf Betreiben der Bank Vertragsbestandteil wurde.

¹⁸⁴ Durch weitere Fortschreitung von BDAI kann dieser Treiber der Komplexität vsl. reduziert werden.

Dynamisch und adaptiv bedeutet, dass der Algorithmus nicht darauf angewiesen ist, dass ein definierter Datensatz vollständig vorliegt, sondern mit digital verfügbaren Daten arbeiten kann – auch wenn diese nicht vollständig sind. Wenn die bereits vorhandenen Informationen ausreichen, müssen keine neuen – manuellen – Erhebungen vorgenommen werden. Abhängig von der Art, Aktualität und Vollständigkeit wird eine Schätzgüte berechnet. Bei geringer Schätzgüte wird das maximale Kreditlimit um einen Sicherheitsabschlag reduziert. In der Folge könnte der Kunde, auf Anforderung der Bank, weitere Daten zuliefern, beispielsweise Transaktionsdaten, und dadurch den Abschlag reduzieren und gegebenenfalls sein Kreditlimit erhöhen. Die zusätzlich übermittelten Daten können die Kreditwürdigkeit sowohl erhöhen als auch senken.

Was den Umfang der angeforderten Daten angeht, kann die Bank den Aufwand bei sich selbst und beim Kunden reduzieren, indem sie Daten nur dann zusätzlich anfordert, wenn die auf den vorhandenen Daten berechnete Beurteilungskonfidenz für die gewünschte Kredithöhe nicht ausreicht.

Dieses Prinzip der Fokussierung auf eine cash-flow basierte Analyse kann in Zukunft durch Nutzung weiterer, heute noch nicht genutzter BDAI-Bausteine ergänzt werden. Dies betrifft insbesondere die Hinzuziehung weiterer relevanter, teilweise auch unstrukturierter Merkmale wie zum Beispiel:

- Text-Mining in Geschäftsberichten und Jahresabschlüssen sowie geschäftlicher Korrespondenz
- Analyse angebotener Sicherheiten entlang extern verfügbarer Daten wie etwa der Verkehrsfrequenz in bestimmten Lagen und der Wertbeurteilung von eher illiquiden Vermögenswerten
- Verhaltensmuster im Rahmen des Onlineantrages wie etwa Sorgfalt bei der Prüfung von Unterlagen/AGBs und Testeingaben

Durch diese Maßnahmen könnte die Informationsbreite stark erhöht werden. Das Textmining könnte z.B. darin bestehen, dass pro Dokument die Häufigkeit von einigen Zehntausend bis zu einigen Hunderttausend Wörtern und Wortkombinationen ausgezählt wird. Wörter wie „Inkasso“ könnten bei Soll-Umsätzen negativ, „Mieteinnahmen“ oder „Dividendenzahlung“ bei Haben-Umsätzen positiv wirken.

Damit könnten nicht nur bereits automatisierte Bestandteile wie die Bilanzanalyse und die Berechnung von Entscheidungsparametern (z.B. Loan-to-Value) abgedeckt werden, sondern auch komplexere Sachverhalte, beispielsweise eine einfache Prüfung gewährter Sicherheiten (Grundschuld, Fahrzeuge etc.) und die Analyse einer wirtschaftlichen Unternehmensstruktur im Sinne einer Kreditnehmereinheit bzw. von Gruppen verbundener Kunden.

3. Technologische Funktionsweise und Datenbasis

Auswertung von Transaktionsdaten auf der Ebene einzelner Buchungen

Zentrale Basis dafür ist die Auswertung der bei jeder Bank vorliegenden granularen Transaktionsdaten der Kunden bis auf die Ebene einzelner Buchungen inklusive der Verwendungstexte (sofern gesetzlich erlaubt), der Kontonummern der Gegenparteien und des zeitlichen Ablaufs (und der darin sichtbaren Veränderungen über die Zeit). Die daraus gewonnenen Informationen haben eine hohe Vorhersagekraft für Bonitätsveränderungen und sind den traditionell für die Kreditentscheidung verwendeten Datenquellen, wie zum Beispiel der Bilanz und GuV, in Aktualität, Granularität und digitaler Verfügbarkeit überlegen. Viele Sonderthemen, die bei den traditionellen Kreditentscheidungsprozessen abgeprüft werden, wie etwa die Abhängigkeit von einzelnen Lieferanten, Kunden und Währungsrisiken, können automatisiert überwacht werden. In vielen Fällen ist eine volle Bilanzanalyse kreditmateriell nur noch in deutlich längeren Zeitintervallen erforderlich. Die Automatisierung des Kreditprozesses ist daher im Geschäft mit kleinen Firmenkunden bereits weit verbreitet. Interne Testrechnungen einzelner Institute zeigen, dass ein Einsatz auch für mittlere und große Firmenkunden möglich ist.

Auswirkungen von PSD 2

Je größer der zur Verfügung stehende Anteil aller Transaktionsdaten des Kunden ist, desto zuverlässiger sind die Ergebnisse und damit die Risikodifferenzierung. Vor diesem Hintergrund ist vor allem das Inkrafttreten der PSD 2 und ihre Umsetzung in nationales Recht relevant. Diese Richtlinie erlaubt es den Kreditinstituten, im Einverständnis mit dem Kunden, die Transaktionsdaten von anderen Banken auszuwerten und damit die Datenverfügbarkeit weiter zu erhöhen. Wenngleich die PSD 2 somit die Automatisierung in den Banken erleichtert, schafft ihre weit über den Banksektor hinausgehende Gültigkeit aber auch zusätzliche Konkurrenz durch Fintechs und Nicht-Banken.

Neben den Daten aus Transaktionen wird auch aus anderen verfügbaren internen und externen Quellen eine möglichst breite, dynamische Datenbasis angelegt. Auch öffentliche Verzeichnisse erlangen, abhängig von der jeweiligen nationalen Verfügbarkeit, zunehmend Bedeutung. Hierzu ist stets eine Zustimmung des Kunden einzuholen, wobei insbesondere die Anforderungen der EU-DSGVO etwa zu Transparenz und Verständlichkeit zu beachten sind.

Dass diese externen Daten zusätzlich hinzugezogen werden, sollte dem Antragsteller in einer transparenten und leicht verständlichen Weise mitgeteilt werden und von seinem Einverständnis abhängig gemacht werden (vgl. auch Kapitel IV und VI). Führt die Verweigerung des Einverständnisses dazu, dass der Zinssatz aufgrund von Risikozuschlägen höher ausfällt, ist dies dem Kunden ebenfalls mitzuteilen.

Aber auch Anreize für den Kunden zur Datenoffenlegung durch Mehrwertleistungen (z.B. automatisierte Kontoausgleichsfunktionen, Transaktionsanalysetools) oder Konditionsvorteile kommen zum Einsatz, um die Datenbasis zu verbreitern. Die Motivation ist zum einen, dass eine möglichst vollständige Datenbasis die Prognosegüte der eingesetzten Algorithmen steigert, zum anderen, dass die laufende Plausibilisierung der vorhandenen Daten gegeneinander die Modellgüte verbessert.

Da die so erreichte Risikodifferenzierung aufgrund der Vielzahl von Datenpunkten und -quellen und der so erreichbaren Mehrdimensionalität der Analyse meist deutlich objektiver ist als die individuelle subjektive Einschätzung des Kundenberaters, kann auf dessen kostenintensiven Input zunehmend verzichtet werden. Vergleichsrechnungen zeigen deutliche Vorteile in Trennschärfe und Vorwarnzeit.

Zur Datenanalyse werden verschiedene analytische Methoden verwendet. Banken nutzen sich selbstständig weiterentwickelnde Algorithmen heute jedoch noch nicht in Produktivsystemen. Der Grund hierfür liegt häufig in der komplexeren Replizierbarkeit und den Compliance Anforderungen hierzu. Allerdings finden sich bereits heute – parallel zu den in Produktivsystemen verwendeten analytischen, linearen Modellen – in Testsystemen oft Algorithmen in Challenger-Rollen, die sich selbstständig weiterentwickeln. Das Ziel ist, die Leistungsfähigkeit der Produktivsysteme laufend zu überprüfen.

4. Chancen

Für die überwiegende Mehrheit der Kunden reduzieren sich durch die automatisierte Kreditentscheidung der bürokratische Aufwand und die Wartezeit bis zur verbindlichen Zu- oder Absage des Kredites erheblich, wodurch die Qualität der Kundenschnittstelle stark verbessert wird. Zudem führt die bessere Risikodifferenzierung zu einer besseren Identifizierung von Kunden mit der Gefahr einer Überschuldung, die Verweigerung des Kredites kann in diesem Fall vor einer Überschuldung schützen.

Effizienz- und Effektivitätssteigerungen bei der Kreditvergabe

Aus Sicht der Kreditinstitute wird durch die Automatisierung des Prozesses vom Kreditantrag bis hin zur Kreditentscheidung der Kernprozess der Kreditvergabe effizienter und effektiver. Für die Firmenkunden geringer Komplexität wird dazu auf digital verfügbare Daten abgestellt, und die manuelle Arbeit im Kreditantrag bis hin zur Entscheidung wird stark reduziert.

Daneben verbessern die tiefere Analyse der Transaktionsdaten und deren höhere Aktualität die Risikodifferenzierung und die Frühwarnfunktionen, also den Schutz vor Kreditausfall. Negative Entwicklungen, welche sich in der Bilanz oder der GuV entweder aufgrund der dort nicht vorhandenen Granularität oder der mit der Bilanzerstellung verbundenen zeitlichen Verzögerung nicht oder verspätet zeigen, werden sichtbar und können in die Entscheidung einbezogen werden.

Aus Sicht des Marktes erhöht sich die Markttransparenz. Da der Aufwand pro Antrag aus Sicht des Kunden wie auch der Bank deutlich sinkt, wird es für Kunden sehr viel weniger aufwändig, realistische, also bereits relativ weit geprüfte Angebote einzuholen und diese zu vergleichen.

5. Risiken

Auf Seiten der Kunden besteht bei breitem Einsatz der Methode vor allem das Risiko der Diskriminierung. Fehlt bei weiteren Teilen des Kreditprozesses die manuelle Betrachtung, kann es bei Anwendung von BDAI passieren, dass bestimmte Kundengruppen nur erschwert Zugang zu klassischen Bankkrediten finden oder diese nur zu vergleichsweise höheren Kosten angeboten bekommen. So sehr Algorithmen auch zu objektiveren Prozessen und Entscheidungen beitragen können, müssen doch alle Fälle, die in den Datengrundlagen wenig repräsentiert sind, in der Ablehnung eines Kreditgesuchs münden – oder in einen stärker manuell bearbeiteten und damit aus Sicht der Kreditinstitute kostspieligeren Prozess. Das Risiko einer solchen Diskriminierung besteht zwar auch in einem manuellen Kreditantragsprozess. Im automatisierten Kreditantrag entfällt aber die Möglichkeit, einem Bankberater Umstände zu schildern, die trotz gegenteilig indizierender Parameter doch dazu führen könnten, dass der Kredit gewährt wird.

Zugleich kann der subjektive (preisgetriebene) bzw. objektive (Zugang zum Produkt überhaupt) Druck auf den Kunden steigen, als privat bzw. geschäftlich besonders vertrauenswürdig eingestufte Daten offenzulegen, um Zugang zu einem Kredit zu erhalten. Entscheidet sich der Kunde für die Offenlegung, sollte sichergestellt werden, dass die sensiblen Daten auch tatsächlich ausschließlich für den Kreditvergabeprozess verwandt werden.

Markteintrittsbarrieren im Kreditgeschäft sinken durch BDAI

Für die Kreditinstitute erhöht sich der Wettbewerbsdruck durch Eintritt neuer Marktteilnehmer ins Kreditgeschäft, da die Markteintrittsbarrieren mit BDAI sinken – algorithmische Kreditprozesse sind einfacher übertragbar. Im traditionellen Kreditprozess ohne BDAI war Krediterfahrung in Form von Anweisungen, Kreditrisikostراتيجien sowie Erfahrung und Beurteilungsfähigkeit der Mitarbeiter stark in der DNA der Institute verankert. Mit BDAI wird Krediterfahrung ein technisch erzeugbarer Wert. Verschärft wird dies weiter durch die PSD 2 und den damit verbundenen Zugang zu Transaktionsdaten, wenn das Einverständnis des Kunden dazu vorliegt. Damit geht einher, dass das bestehende Vertrauensverhältnis zwischen Kunde und Bank nicht in Mitleidenschaft gezogen werden darf, etwa durch einen Missbrauch von Daten oder eine Datenverwendung, die vom Kunden lediglich als Missbrauch wahrgenommen wird.

Daneben wirken sich durch die Automatisierung im Mengengeschäft Modellfehler schneller bzw. vergleichsweise stärker aus, als dies bei menschlichen Fehlentscheidungen der Fall ist. Falsche Annahmen, Datenqualitätsmängel, Überschreitung der Modellgrenzen oder unsachgemäße Verwendung des Modells können schnell negative Konsequenzen in Form ungewollter Kreditentscheidungen haben. Dies unterscheidet sich per se nicht vom manuellen Status quo, bei dem eine unsachgemäße Kreditrisikostategie das Portfolio negativ beeinflussen kann. Jedoch kann durch BDAI zum einen eine schnellere Prozessgeschwindigkeit die Anforderungen an die Reaktionszeit erhöhen. Zum anderen entfällt die natürliche Streuung von Entscheidungen, da bei der Anwendung von BDAI alle Entscheidungen von einer Instanz getroffen werden – und nicht von verschiedenen Kreditsachbearbeitern. Dem kann durch Umsetzung einer stringenten Governance entgegengewirkt werden, die beispielsweise eine einfache, robuste Erklärbarkeit der Entscheidungen ermöglicht (vgl. hierzu insbesondere Kapitel III).

Der nachfolgende Exkurs zeigt anhand eines spieltheoretischen Ansatzes auf, wie sich kleine Unterschiede in der Risikodifferenzierung auf die Wettbewerbsfähigkeit auswirken können.

Exkurs: Risikodifferenzierung und Wettbewerbsfähigkeit durch Bonitätsmodelle

Wir betrachten ein hypothetisches Antrags-Portfolio von Konsumentenkrediten. Die durchschnittliche Ausfallrate nach einem Jahr beträgt drei Prozent. Die Höhe der Einzelkredite wird der Einfachheit halber – ebenso wie der Verlust bei Ausfall – mit 1 angenommen. Zwei Wettbewerber konkurrieren mit unterschiedlichen Preismodellen um Kunden aus diesem Portfolio.

Im Folgenden betrachten wir zwei Bonitätsmodelle, mit denen Wettbewerber die Ausfallwahrscheinlichkeiten einzelner Kunden schätzen: Modell A ist das Basismodell mit einem AUC¹⁸⁵ von 0,8625. Modell B ist leicht verbessert und hat einen AUC von 0,87. Der Unterschied in der Modellgüte ist moderat und kann z.B. durch die Umstellung der Modellierung von einem linearen Verfahren auf ein nicht-lineares Verfahren wie Gradient Boosted Trees oder neuronale Netze erzielt werden.

Wir betrachten nun die Auswirkungen im direkten Wettbewerb zweier Anbieter – zum Beispiel bei Angeboten auf Kreditvergleichsportalen. In jeder Phase berechnen die beiden Anbieter die Ausfallwahrscheinlichkeiten für jeden Kunden in zwei Schritten neu. Zunächst berechnen sie den Modellscore, mit dem eine Rangreihung der Kunden festgelegt wird. Dann wird auf Basis der in der vorhergehenden Phase gewonnen Kunden die Ausfallwahrscheinlichkeit in Abhängigkeit des Scores neu berechnet.

Die Spielregeln für das Gedankenexperiment sind:

- Die Preise der Anbieter unterscheiden sich im Gedankenexperiment nur durch die unterschiedlichen Prämien für den erwarteten Verlust, der proportional zur Ausfallwahrscheinlichkeit ist.
- Kunden wählen immer den niedrigsten angebotenen Zinssatz.
- Nur Kunden mit einer Ausfallwahrscheinlichkeit kleiner als zehn Prozent erhalten Angebote.

In Phase 1 verwenden beide Anbieter das Modell A auf Basis einer konstanten Historie. Dies führt zu gleichen Preissetzungen, und beide Banken teilen sich den Markt. Die erwarteten Ausfallraten (PD – Probability of Default) und die realisierten Ausfallraten (AR) stimmen exakt überein.

| | Marktanteil | PD | AR |
|------------------|--------------------|-----------|-----------|
| Abgelehnt | 7,95 % | 20,76 % | 20,34 % |
| Modell A | 46,02 % | 1,50 % | 1,50 % |
| Modell B | 46,02 % | 1,50 % | 1,50 % |

¹⁸⁵ Der AUC (Area Under Curve) ist ein typisches Gütemaß, das in diesem Beispiel angibt, wie gut die ausfallenden von den nicht ausfallenden Kunden unterschieden werden können. Hierbei wird die Fläche unterhalb einer Grenzwertoptimierungskurve (Receiver Operating Characteristic Curve) berechnet. Diese stellt bei Klassifikationsproblemen den Zusammenhang zwischen True-Positives- und False-Positives-Raten dar.

In Phase 2 wechselt Anbieter 2 zum leicht verbesserten Modell B. In der direkten Wettbewerbssituation unterschätzt das Modell A die Ausfallrate auf den gewonnenen Kunden um mehr als ein Prozent, Modell B hingegen überschätzt die Ausfallrate. Zugleich verschieben sich die Marktanteile stark. Modell B gewinnt – relativ – 38 Prozent mehr Kunden. Das Institut mit Modell A erhält so die schlechtesten Kunden.

| | Marktanteil | PD | AR |
|------------------|--------------------|-----------|-----------|
| Abgelehnt | 6,68 % | 22,91 % | 22,91 % |
| Modell A | 29,53 % | 2,11 % | 3,14 % |
| Modell B | 63,78 % | 1,24 % | 0,85 % |

In Phase 3 bemerken beide Institute, dass ihre Modelle nicht richtig kalibriert sind, und adjustieren die Ausfallraten, ohne das zu Grunde liegende Score-Modell anzupassen. Beiden ist bewusst, dass sie nicht rein auf den in Phase 2 gewonnenen Kunden kalibrieren können. Sie wählen daher den konservativen Ansatz, dass sie die maximale Ausfallwahrscheinlichkeit aus den Kalibrierungen aus Phase 1 und Phase 2 verwenden. Im Resultat wächst der Marktanteil von Modell B nochmals deutlich. Modell B überschätzt die Ausfallrate nur noch leicht. Bei Modell A liegt die Unterschätzung der Ausfallrate immer noch bei 0,5 Prozent.

| | Marktanteil | PD | AR |
|---------------------------|--------------------|-----------|-----------|
| Abgelehnt | 6,68 % | 22,14 % | 22,91 % |
| Modell A – Phase 2 | 11,93 % | 1,61 % | 2,11 % |
| Modell B – Phase 2 | 81,39 % | 1,58 % | 1,50 % |

Die Beispielrechnung zeigt:

- Die Güte des Bonitätsmodells kann – insbesondere in hoch kompetitiven Märkten – entscheidend für die Wettbewerbsfähigkeit eines Instituts sein.
 - Das Institut mit dem besseren Modell gewinnt deutlich Marktanteile.
 - Das Institut mit dem schlechteren Modell unterschätzt die Verluste deutlich, wodurch die Gewinnmarge pro Kunde sinkt oder sogar negativ wird.
- Ein neues Modell eines Wettbewerbers kann Ergebnisse der anderen Modelle am Markt beeinflussen, da die Daten der Vergangenheit nicht mehr repräsentativ sind.

Insbesondere der letzte Punkt stellt klassische Modelle in Frage, die rein auf der Auswertung historischer Daten basieren und Marktdynamiken und spieltheoretische Ansätzen nicht berücksichtigen.

Notabene: De facto entscheiden Kunden nicht rein rational, und Faktoren wie Marketing, Vertrieb und Loyalität spielen eine große Rolle. Hinzu kommt, dass Institute bei Bestandskunden aufgrund des Informationsvorsprungs durch die bereits gesammelten Daten zu Zahlungsströmen und Verhalten einen inhärenten Wettbewerbsvorteil haben. Zudem wissen Marktteilnehmer zumindest teilweise von den Aktivitäten ihrer Konkurrenten.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte haben verschiedene aufsichtliche und regulatorische Implikationen.

BDAI-Modelle können für regulatorisch relevante Sachverhalte herangezogen werden, daher stellt sich die Frage der Zulassung und Überwachung dieser Modelle.

Zugleich wird die Standardisierung des Kreditprüfungsprozesses die Barrieren für den Eintritt neuer Marktteilnehmer in den Bankensektor senken und so gegebenenfalls zu mehr Wettbewerb, aber auch zu mehr Vernetzung und Disaggregation der Wertschöpfungskette führen.

Aus der Automatisierung der Kreditentscheidung mittels BDAI ergeben sich zudem Implikationen für den Verbraucherschutz, was die Diskriminierung von Einzelnen bzw. Randgruppen angeht. Ferner können sich Verbraucher oder auch Firmenkunden faktisch dazu genötigt sehen, sensible Daten zu offenbaren, um überhaupt eine Chance auf eine positive Kreditentscheidung zu haben oder um bereits angebotene Kreditkonditionen verbessern zu können.

Bei vermehrter Nutzung von BDAI-Modellen stellen sich darüber hinaus Fragen zur Modelltransparenz/Erklärbarkeit, welche schon in Kapitel III angesprochen wurden.

In Kapitel VI dieser Studie wird auf die aufsichtlich-regulatorischen Implikationen der genannten Punkte detailliert eingegangen.

5.2.6.2 Optimierung der Compliance am Beispiel Geldwäscheverdachtsprüfung

1. Einleitung

Geldwäsche ist ein weltweites, sehr großvolumiges Problem. Allein für Deutschland wird das jährliche Volumen an Geldwäsche beispielsweise auf 50 Mrd. bis 100 Mrd. Euro geschätzt¹⁸⁶. Banken wickeln den nationalen und internationalen Zahlungsverkehr ab. Deshalb kommt ihnen in der Bekämpfung von Geldwäsche eine herausgehobene Bedeutung zu. Sie sind gesetzlich verpflichtet, verdächtige Zahlungsströme im Rahmen der Geldwäscheverdachtsprüfung zu erkennen und an die Behörden zu melden. Verfahren mit Nutzung von BDAI können auch hierbei Effektivität und Effizienz steigern.

Aktuell werden in Banken jeden Tag Tausende automatisierter Hinweise auf Basis der expertenbasierten Erkennungsregeln generiert. In der anschließenden manuellen Bearbeitung erweist sich häufig nur ein geringer Anteil dieser Hinweise als vertiefungswürdig. Einer der Gründe hierfür ist, dass einzelne Erkennungsregeln oft nur Ansätze verdächtiger Transaktionen erkennen können, die jedoch auch auf eine Vielzahl von normalen Transaktionen zutreffen. Da sich die Methoden professioneller Geldwäscher ständig weiter entwickeln und die Erkennungsregeln oft nur mit Verzögerung angepasst werden, besteht die Gefahr, dass eine Vielzahl tatsächlicher Geldwäschetransaktionen unerkant bleibt.

¹⁸⁶ Vgl. Bussmann, 2015, Dark figure study on the prevalence of money laundering in Germany and the risks of money laundering in individual economic sectors, S. 4.

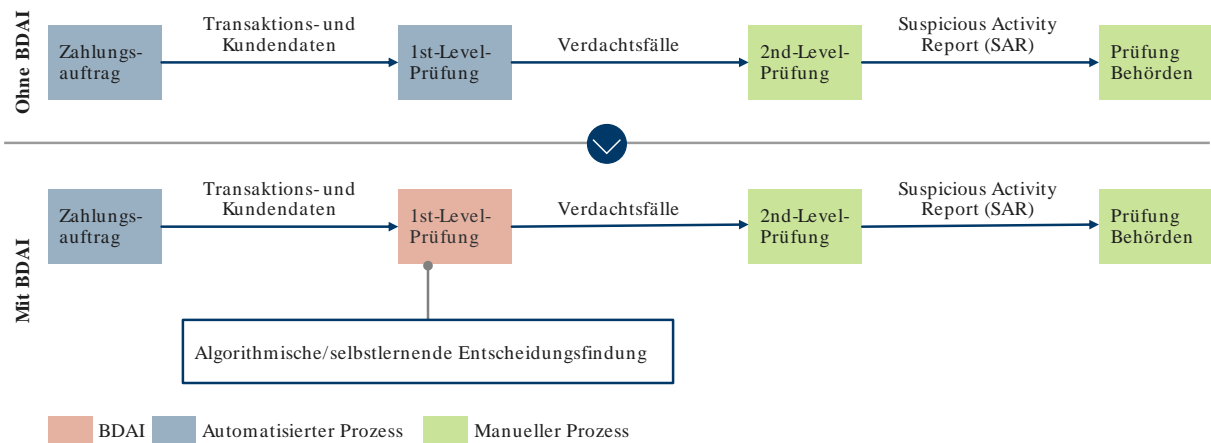
Bei der Geldwäscheverdachtsprüfung müssen große Datenmengen aus den Transaktionen der Kunden auf Verhaltensauffälligkeiten analysiert werden. BDAI-Verfahren könnten helfen, beispielsweise bisher unerkannte Muster wie Zahlenanomalien und regelmäßige Transaktionen unterhalb der Schwellenwerte selbstständig im Sinne des Selbstlernens zu erkennen sowie die Effektivität bestehender Erkennungsregeln durch Rückkopplungsschleifen zu erhöhen. Erste Banken erproben derzeit solche Anwendungen, d.h. sie nutzen sie meist noch parallel zum bestehenden, teilweise manuellen Prozess. Erste Versuche am Markt zeigen, dass auf diese Weise die Zahl der Falschmeldungen reduziert und zugleich die Qualität der verbleibenden Treffer erheblich verbessert werden kann.

2. Anwendung

Üblicherweise gibt es in der automatisierten Unterstützung bei der Bekämpfung von Geldwäsche eine Vielzahl von Regeln zur Geldwäscheidentifikation, die auf Expertenmeinungen basieren und zur Überwachung in einer 1st-Level-Prüfung auf die Transaktionsdaten – in Verbindung mit weiteren bekannten Eigenschaften des Kunden – angewendet werden. Sobald aufgrund dieser Regeln eine Transaktion als möglicherweise verdächtig eingestuft wird, muss ein Bankmitarbeiter diesen Verdacht bei einer 2nd-Level-Prüfung manuell bearbeiten und entscheiden, ob der Verdacht begründet ist und somit eine offizielle Verdachtsmitteilung (Suspicious Activity Report – SAR) zur weiteren Abklärung an die Behörden gerichtet wird.

Dieser 2nd-Level-Prozess kann für die Bank höchst arbeitsintensiv sein, insbesondere wenn in der automatischen Überwachung der 1st-Level-Prüfung eine große Zahl letztendlich falscher Verdachtsmitteilungen generiert wird, die somit in der darauffolgenden manuellen 2nd-Level Prüfung eigentlich unnötige Arbeit verursachen (siehe Abbildung 18 zur schematischen Darstellung des Einsatzes von BDAI).

Abbildung 18: Optimierung der Geldwäscheverdachtsprüfung durch Einsatz von BDAI



Bei den Erkennungsregeln wird üblicherweise zwischen absoluten und profilbezogenen unterschieden. Absolute Erkennungsregeln basieren beispielsweise auf Betragsschwellen, Zahlungsdestinationen und Verwendungszwecken, während Profilabweichungen auf der Grundlage von Abweichungen zum historischen Profil des Kunden und Abweichungen gegenüber einer Vergleichsgruppe generiert werden.

Die absoluten Erkennungsregeln können leicht umgangen werden und insbesondere bei großvolumigen Geschäftsbeziehungen zu unbegründeten technischen Hinweisen führen. Die profilbasierten Erkennungsregeln sind insbesondere anfällig für saisonale Effekte, einen Mangel an Vergleichbarkeit bzw. Repräsentativität von Vergleichsgruppen sowie abweichende Geschäftsallokationen zwischen den Hausbanken.

BDAI kann helfen, die Effektivität von Betragsschwellen durch Sensitivitätsanalysen zu verbessern, trennschärfere, gegebenenfalls mehrperiodige Profilanalysen zu generieren und bisher unerkannte Muster (Zahlenanomalien, regelmäßige Transaktionen zwischen auf den ersten Blick voneinander unabhängigen Zahlungsauftraggebern und -empfängern) zu erkennen.

Hierdurch kann nicht nur die Zahl der unbegründeten Verdachtsfälle reduziert, sondern auch die Qualität der verbleibenden Treffer auf dem 1st-Level gesteigert werden. Aufgrund der gezielten Herausfilterung von Verdachtsfällen kann die verfügbare Bearbeitungszeit pro Verdacht auf dem 2nd-Level erhöht werden. Dies kann die Trefferqualität auf dem 2nd-Level abermals verbessern.

3. Technologische Funktionsweise und Datenbasis

Um den Prozess der Erkennung und Meldung von Geldwäscheverdachtsfällen zu standardisieren und effizienter zu machen, werden zunächst verschiedene Daten aufbereitet. Dazu zählen Kundendaten und -charakteristika, Transaktionsdaten, Daten zu individuellem Zahlungsverhalten, zum Zahlungsverhalten der Vergleichsgruppe oder zu Änderungen im Zahlungsverhalten (der Vergleichsgruppe oder des eigenen) sowie historische Daten von begründetem Geldwäscheverdacht.

In der Praxis werden dazu in einem ersten Schritt die Transaktionsdaten klassifiziert – etwa nach den Kriterien „Bar-Einzahlung“ und „Überweisung in ein Hochrisikoland“. Diese werden dann in Variablen übersetzt wie z.B. „Summe der Einzahlungen der letzten 30 Tage“ und „Verhältnis Cash-Einzahlungen in den letzten 30 zu den letzten 360 Tagen“.

In einem zweiten Schritt können sowohl Algorithmen des überwachten als auch des unüberwachten Lernens genutzt werden. Die erstgenannten, um insbesondere bekannte Muster aus Erfahrungswerten der Vergangenheit in den aktuellen Datensätzen zu identifizieren; die letztgenannten, um insbesondere bislang noch nicht aufgetretene Muster/Anomalien in den Datensätzen zu identifizieren (vgl. Kapitel III). Dabei stellt das unüberwachte Lernen einen besonderen Fortschritt gegenüber rein regelbasierten Modellen dar, da es Indizien für bislang noch nicht aufgetretene Betrugs- oder Geldwäskemuster aufzeigen kann.

Daraus resultierende Verdachtsfälle werden dann von darauf spezialisierten Mitarbeitern manuell weiter untersucht, und bei Bestätigung des Verdachts wird ein SAR an die Behörden zur weiteren Abklärung und Verfolgung des Verdachts geschickt.

Die Optimierung der Mustererkennung von Geldwäsche beim überwachten Lernen erfolgt anhand historischer begründeter Verdachtsmitteilungen (SARs), auf deren Basis der Algorithmus trainiert wird. Für die Qualität der automatischen Prüfung ist es daher von zentraler Bedeutung, den Algorithmus mit möglichst aktuellen Fällen von Geldwäsche bzw. begründeten Verdachtsfällen versorgen zu können, damit er die entsprechenden Muster erlernt und später erkennt. Die Maschine lernt gewissermaßen von vielen unterschiedlichen Mitarbeitern, wie man Geldwäskemuster in den Daten erkennt. Die Algorithmen sind dabei in der Lage, Muster in kompletten Kontohistorien und den damit über Transaktionen verbundenen Konten zu erkennen.

4. Chancen

Die Chancen des skizzierten Verfahrens zur Anwendung von BDAI bei der Transaktionsüberwachung liegen darin, Geldwäsche besser zu erkennen, und damit in einer höheren Aufklärungsquote. Kriminelle haben durch die verbesserten Verfahren einen höheren Aufwand und laufen deutlich eher Gefahr, aufgedeckt zu werden.

Aus Sicht der nichtkriminellen Kunden machen bessere Systeme der Überwachung von Geldwäsche es weniger wahrscheinlich, fälschlicherweise in den Fokus der Geldwäscheüberwachung zu geraten. Für Kunden ist eine Untersuchung wegen Geldwäscheverdachts mühsam, da sie oft Auskünfte und Dokumente vorlegen müssen, um den Verdacht zu falsifizieren.

Aus Sicht der Finanzinstitute führen die höhere Trefferquote der automatisierten Verfahren und die dadurch reduzierte Zahl manuell zu überprüfender Verdachtsfälle zu einer signifikanten Kostensenkung im Überwachungsprozess. Die Reduzierung der fälschlich gemeldeten Verdachtsfälle ist zudem aus Reputationsgründen wichtig für die Institute, da durch eine eingeleitete Strafverfolgung eines Kunden die Kundenbeziehung erheblich gestört wird. Darüber hinaus ist eine stetige Verbesserung der Verfahren zur Geldwäscheprävention für Institute auch essentiell, weil unter Umständen hohe Geldbußen verhängt werden, wenn Institute systematische Fehler in ihren Verfahren begehen.

Die regelmäßige Aktualisierung der Erkennungsregeln durch BDAI schränkt die Möglichkeiten Krimineller ein, im Markt bekannte Regeln zu Erkennung von Geldwäsche bewusst zu umgehen.

5. Risiken

Ein Risiko besteht in der komplexeren Nachvollziehbarkeit bzw. aufwändigeren Erklärbarkeit der verwendeten BDAI-Modelle. Das Ausmaß dieses Problems ist dabei abhängig vom verwendeten Algorithmus. Während bei den klassischen regelbasierten Verfahren eine höhere Transparenz bezüglich der definierten Regeln und Ableitungen herrscht, ist die Nachvollziehbarkeit der Ergebnisse bei anderen, fortschrittlicheren Verfahren von BDAI, insbesondere beim unüberwachten Lernen, aufwändiger, was speziell für den fälschlich Beschuldigten ein Problem darstellt.¹⁸⁷ Daneben muss sichergestellt werden, dass das Erlernete auch sachlich richtig ist.

Darüber hinaus besteht die Gefahr, dass durch erhebliche Fortschritte in der Erkennungsqualität bei der Anwendung von BDAI Straftäter künftig primär auf die Institute ausweichen, die in diesem Bereich einen Entwicklungsrückstand aufweisen. Dieser Effekt kann noch dadurch verstärkt werden, dass der Mensch als Hinweisgeber an der Kundenschnittstelle durch eine flächendeckende Digitalisierung an Bedeutung verliert.

Daneben gibt es mit Blick auf die Wahrung des Verbrauchervertrauens zwei potenzielle Herausforderungen: Erstens ist sicherzustellen, dass im Rahmen des gesetzlichen Auftrags der Geldwäscheprüfung genutzte und gewonnene Daten/Profile nicht anderweitig verwendet werden. Zweitens muss gewährleistet werden, dass die Banken nicht auf Daten außerhalb ihres Verantwortungsbereiches zurückgreifen.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel zur Überwachung von Geldwäsche dargestellten Aspekte haben verschiedene aufsichtliche und regulatorische Implikationen, die es künftig zu adressieren gilt.

Beispielsweise lassen sich mittels BDAI die Prozesse zur Erkennung von (strafbewehrten) Geldwäsche-Verstößen deutlich verbessern. Dies ermöglichte insbesondere eine Konzentration der vorhandenen Ressourcen auf tatsächlich relevante Verdachtsfälle. In Kapitel VI dieser Studie wird auf die genannten Punkte in der Ableitung von themenübergreifenden aufsichtlich-regulatorischen Implikationen detailliert eingegangen.

¹⁸⁷ Dies kann jedoch auch eine Chance sein, da dadurch für potenzielle Straftäter die Transparenz und damit das Umgehungspotential geringer werden.

5.2.6.3 Monetarisierung von Kundendaten durch Banken

1. Einleitung

Wie bereits erwähnt, verfügen Banken über sehr sensible und zugleich wertvolle Kundendaten, insbesondere durch transaktionale Geschäfte wie den Zahlungsverkehr. Der Wert solcher Daten, beispielsweise Buchungsdaten auf Konten, ergibt sich sowohl aus ihrer Aktualität – Buchungen erfolgen in der Regel near-time – als auch aus ihrem Wahrheitsgehalt, wenn es etwa darum geht, wie viel ein Verbraucher für ein Produkt oder eine Dienstleistung maximal zahlen will. Daher sind derartige Daten für das Unternehmen deutlich wertvoller als reine Interessenbekundungen von Kunden, z.B. durch den Besuch von Websites.

Für die Hausbank¹⁸⁸ bietet sich dadurch die Möglichkeit, das für Konsum bzw. Investitionen verfügbare Einkommen ihrer Kunden sehr präzise festzustellen und Rückschlüsse auf die künftige Zahlungsbereitschaft und -fähigkeit zu ziehen.

BDAI ermöglicht eine genauere Kundensegmentierung

So lassen sich Privatkunden anhand von Einkommensanteilen segmentieren, die beispielsweise auf Versicherungen, Fahrzeug, Reisen, Ausbildung und Spenden an Wohltätigkeitsorganisationen entfallen. Daneben könnten die Transaktionsart selbst, d.h. Lastschrift oder Überweisung, Kreditkarten- oder Point-of-Sale-Zahlungen, Aufschluss über Kundentypologien geben. Diese Segmentierung könnte nicht nur eine wertvolle Information für das Marketing und die Kundenklassifizierung der Bank sein, sondern auch für Dritte, die Produkte oder Dienstleistungen anbieten. Möglich wäre z.B. die Ermittlung von produktspezifischen Kaufwahrscheinlichkeiten, etwa für bestimmte Automarken, Versicherungen, Strom-, Telefon- und Gasanbieter sowie Transportdienstleister auf aggregierter und anonymisierter Ebene.

Für Banken bieten derartige Daten theoretisch das Potential, die eigene Vertriebssteuerung und – gegen Gebühr – vertriebliche Aktivitäten von Drittanbietern zu optimieren.

Diesem Optimierungspotential für den Vertrieb und die Ertragslage der Banken steht jedoch das Risiko gegenüber, dass Banken durch unautorisierte bzw. unreflektierte Weitergabe höchst sensibler Finanzdaten (vgl. Kapitel 4.1) das bislang hohe Vertrauen der Kunden nachhaltig schädigen. Dieses Risiko ergibt sich insbesondere daraus, dass viele Kunden diese Transaktionsdaten als sehr privat empfinden (vgl. Kapitel 4.1).

Wahrung des Verbrauchervertrauens

Die Wahrung des Verbrauchervertrauens wird die eigentliche technologische und kommunikative Herausforderung bei der Monetarisierung von Kundendaten durch Banken sein. Da der Kunde gewissermaßen Urheber der über ihn und von ihm erzeugten Daten ist und das Recht auf informationelle Selbstbestimmung in Europa einen sehr hohen Stellenwert hat (z.B. in Deutschland Verfassungsrang), wird sich stets die Frage stellen, ob der Kunde die Monetarisierung seiner Transaktionsdaten tatsächlich befürwortet. Stimmt er dem zu, stellt sich zudem die Frage, wie er angemessen an einer Wertschöpfung aus diesen Daten partizipieren kann.

Es ist derzeit nicht absehbar, dass die zusätzlichen Gebühreneinnahmen aus der Monetarisierung von Kundentransaktionsdaten für Banken eine Größenordnung erreichen könnten, die den Erträgen aus dem originären Bankgeschäft auch nur ansatzweise entsprechen würden. Eine mögliche Ursache hierfür könnte der Umstand sein, dass Banken, was das Vertrauen der Verbraucher angeht, höheren Erwartungen entsprechen müssen als beispielsweise Bigtechs. Die Monetarisierung von Daten kann die Solvenz einer Bank daher nicht signifikant verbessern, wohl aber einen Beitrag dazu leisten bzw. ein differenzierendes Merkmal im Wettbewerb der Banken sein, indem z.B. die Gebühreneinnahmen zur Quersubventionierung von kleinstmöglichen Dienstleistungen genutzt werden.

¹⁸⁸ Auch für andere Banken/Nicht-Banken mit Einführung von PSD 2.

Die in der Vergangenheit beobachteten Kaufpreise bzw. Erlöse aus dem Geschäft mit Daten in anderen Branchen resultieren in der Regel aus andersartigen Geschäftsmodellen, beispielsweise

- dem Verkauf vollständiger Kundendatensätze, wie dies etwa beim Verkauf von datengetriebenen Plattformen der Fall ist,¹⁸⁹ und
- der Monetarisierung von Kundendatensätzen ohne Bankbezug, jedoch mit sehr breiter Offenlegung von nicht-bankbezogenen Daten.¹⁹⁰

Als Maßstab für Banken lassen sich diese Transaktionen daher nicht heranziehen.

Erste Geschäftsmodelle aus den USA – außerhalb des Bankensektors –, die auf einer umfassenden Datenoffenlegung durch den Verbraucher basieren (z.B. Daten aus Finanztransaktionen und anderen Sachverhalten, Kommunikationsdaten, digitale Profile, Gesundheitsdaten), bieten dem Verbraucher dafür einen niedrigen einstelligen Dollarbetrag pro Monat als Vergütung. Der auf bankbezogene Daten entfallende Anteil dürfte sehr gering ausfallen.

Erste Banken aus dem europäischen bzw. asiatisch-pazifischen Raum haben die Monetarisierung von Kundendaten auf eine Weise realisiert, die versucht, den Zielkonflikt zwischen Wahrung des Verbrauchervertrauens und Mehreinnahmen bzw. Stärkung der Kundenbindung für die Bank sowie Mehrwert für Drittanbieter zu lösen.

Dazu ist anzumerken, dass in der internationalen bankfachlichen Praxis in der Regel Wege beschritten wurden, die nur auf die Offenlegung anonymisierter Daten gegenüber Drittanbietern abzielen. Möglichkeiten dazu bietet entweder die Nutzung von Kundengruppen mit ähnlichen Profilen – vgl. Kapitel III – oder der Verzicht auf die Offenlegung von personenbezogenen Einzelkundendaten, da alle kundenbezogenen Daten die Systeme der Bank nicht verlassen. Ein Beispiel wird im folgenden Abschnitt dargestellt.

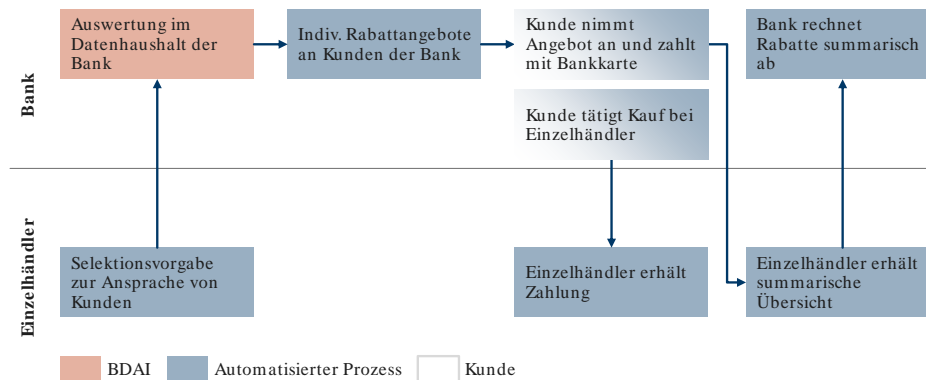
2. Anwendung

Eine Bank bietet Einzelhändlern die Möglichkeit, gezielt Kunden der Bank – etwa mit rabattierten Produktangeboten – anzusprechen, deren Profile sie zuvor definiert haben. Derartige Profile können etwa auf einer räumlichen Zuordnung, auf Zahlungstransaktionen mit bestimmten Adressen in der Vergangenheit oder auf einer bestimmten freien Liquidität basieren.

¹⁸⁹ Zum Vergleich: Sowohl beim Verkauf von WhatsApp an Facebook als auch bei dem von Instagram an Facebook wurden rund 30 USD pro Nutzer gezahlt, vgl. Glikman et al., 2015, What's The Value Of Your Data? Online verfügbar: <https://techcrunch.com/2015/10/13/whats-the-value-of-your-data/>, abgerufen am 30.01.2018.

¹⁹⁰ Zum Vergleich: Facebook hat beispielsweise pro Nutzer in den USA und Kanada im dritten Quartal 2017 rund 21 USD Erlöse erzielt, in Europa rund 7 USD, vgl. Facebook, 2017, Facebook Q3 2017 Results, S. 8. Online verfügbar: https://s21.q4cdn.com/399680738/files/doc_financials/2017/Q3/Q3-'17-Earnings-Presentation.pdf, abgerufen am 30.01.2018.

Abbildung 19: Zweigeteilte Prozessstruktur des Anwendungsbeispiels



Beispiel: Funktionsweise der Monetarisierung von Kundendaten

Nachdem der Einzelhändler die Selektionsvorgabe erstellt und der Bank übergeben hat, wertet die Bank ihre Datensätze vor dem Hintergrund der Selektionsvorgaben und unter Nutzung der Algorithmen für den Einzelhändler aus. Die identifizierten Kunden der Bank erhalten über die Plattform der Bank – z.B. eine App – ein spezielles Rabattangebot des Einzelhändlers.

Der Bankkunde kann dieses Angebot annehmen, indem er bei dem Einzelhändler – ohne Vorlage der App oder des konkreten Angebots – mit der Karte der Bank bzw. über sein Konto bei der Bank bezahlt. Der Einzelhändler kann dabei nicht erkennen, dass dieser Kunde den Geschäftsabschluss aufgrund dieser Marketingmaßnahmen getätigt hat.

Die Bank verrechnet den Rabatt bei der Abrechnung der Transaktion in Form einer Gutschrift zugunsten des Kunden.

Zum Ende einer Periode erhält der Einzelhändler von der Bank einen summarischen Report über die anhand der Selektionskriterien identifizierten Kunden, die tatsächlich eine Transaktion getätigt haben, jedoch ohne den Namen der Kunden offenzulegen (vgl. dazu beispielsweise auch Privacy-preserving Data Mining in Kapitel III). Zugleich vergütet der Einzelhändler die Bank durch Rückerstattung der gewährten Rabatte und eine Gebühr.

Zustimmung des Kunden erforderlich

Kunden müssen dabei aktiv der Nutzung ihrer Daten für diese Zusatzfunktion zustimmen. Sie können die Dienstleistung auch beispielsweise auf die Einzelhändler beschränken, mit denen sie bereits in der Vergangenheit in Geschäftsbeziehung standen.

In einer Erweiterung kann dieses Modell auch mit Bankprodukten, etwa mit Konsumentenkrediten für größere Anschaffungen und Autokrediten, kombiniert werden, um so auch den Zins- bzw. Gebührenertrag der Bank zu erhöhen.

Dieser Fall zeigt exemplarisch den Wert transaktionaler Kundendaten von Banken. Anzumerken ist jedoch, dass mit Blick auf die PSD 2 dieser Wettbewerbsvorteil von Banken gegenüber Nichtbanken reduziert werden kann, da mit der Richtlinie auch Drittanbieter Zugriff auf die transaktionalen Daten erhalten können, sofern der Kunde ihnen die Erlaubnis dazu erteilt.

3. Technologische Funktionsweise und Datenbasis

Die technologische Grundlage dieses Falles besteht in der Nutzung der großen Datenhaushalte der Banken. Dazu gehören beispielsweise die strukturierte Zahlungshistorie zu Vertragspartnern, Zahlungskanälen, -standorten und -beträgen über mehrere vergangene Perioden hinweg sowie die Limiteinschätzung der Bank, die Kundenstammdaten und andere bankfachliche Merkmale wie etwa die Risikoeinstufungen bei Anlageprodukten. Natürlich kann dieser Datenhaushalt um weitere bankfachliche Merkmale erweitert oder verkleinert werden.

Algorithmisch kann dabei ein klassischer deterministischer Prozess als Grundlage dienen. Zielführender ist jedoch der Einsatz von selbstlernenden Algorithmen, die beispielsweise das individuelle Verhalten der Kunden in Reaktion auf einzelne Vertriebsmaßnahmen der Einzelhändler in der Vergangenheit berücksichtigen.

Die Feedbackschleife kann nicht nur rabattierte Einkäufe einschließen, sondern auch künftige Verhaltensänderungen des Kunden, wie etwa den vermehrten Besuch des jeweiligen Einzelhändlers.

4. Chancen

Der Verbraucher erhält als Kunde der Bank von dieser eine personalisiertere Ansprache und Angebote, die gegebenenfalls mit Rabatten gekoppelt sind. Der Einzelhändler kann als Kunde der Bank seine Kundenbindung und sein Marketing individualisieren, ohne eine eigene Datenbasis und Analytik aufbauen zu müssen.

Verbesserte Kundenbindung

Die Bank kann ihre Position als Vertragspartner sowohl des Verbrauchers als auch des Einzelhändlers nutzen, um ihre Ertragslage zu verbessern. Dies kann intern durch eine bessere Vermarktung eigener Bankprodukte, aber auch extern bzw. indirekt durch die Verbesserung der Angebote von Einzelhändlern geschehen. Darüber hinaus bedingt die anonyme Einlösung des Rabatts in dem Beispiel die Verwendung der Bankkarte bzw. des Bankkontos. Dies erhöht die Kundenbindung – objektiv in Form von zusätzlichen Transaktionen und subjektiv – etwa bei sehr digitalisierungsaffinen Kunden – durch ein Differenzierungsmerkmal gegenüber Wettbewerbern.

Aus Gesamtmarktsicht resultiert hieraus zudem ein Vorteil von Banken im Vergleich zu Bigtechs. Banken verfügen neben elektronisch dokumentierten und geprüften Kundendaten auch über Transaktionsdaten und in der Regel auch weiter zurückreichende Datenbasen, die ein maschinelles Lernen ermöglichen. Dies kann Instituten helfen, sich mit individualisierten Bankdienstleistungen gegenüber anderen, datengetriebenen Anbietern, beispielsweise Bigtechs, im Wettbewerb zu behaupten.

5. Risiken

Für den Verbraucher besteht bei der Teilnahme an solchen Bindungs- und Rabattprogrammen die Gefahr der mangelnden Wahlfreiheit und der mangelnden Aufklärung und Kontrolle über die Verarbeitung persönlicher bankbezogener Daten. Dies gilt umso mehr, wenn die Bereitstellung gewöhnlicher Bankdienstleistungen mit der Teilhabe an derartigen Programmen in Form einer Take-it-or-leave-it-Entscheidungssituation verknüpft würde. Wer der Teilnahme an solchen Bindungs- und Rabattprogrammen nicht zustimmt, könnte folglich ungerechtfertigt vom Angebot der Bank ausgeschlossen werden – etwa vom Einlagengeschäft und vom Zahlungsverkehr. Durch die mangelnde oder unzureichende Aufklärung und Kontrolle im Rahmen solcher Programme kann es zudem passieren, dass private Daten und Informationen offengelegt oder für Zwecke außerhalb der gewöhnlichen Bankdienstleistungen verwendet oder sogar doch an Dritte weitergereicht werden, ohne dass der Kunde dies wünscht.

Möglicher Vertrauensverlust bei intransparenter Datennutzung durch die Banken

Aus Sicht der Banken gilt es, einen hieraus möglicherweise resultierenden Vertrauensverlust bestehender und potenzieller neuer Kunden zu vermeiden, indem die Teilnahme an solchen Programmen für Verbraucher transparent, nachvollziehbar und kontrollierbar ausgestaltet wird. Obwohl Kunden – wie im oben beschriebenen Modell – eine Wahlfreiheit haben, besteht für die Bank die Gefahr eines öffentlichen Imageschadens, wenn es zu einer missbräuchlichen Verwendung von Daten kommt oder zu einer Datenverwendung, die der Kunden lediglich als Missbrauch wahrnimmt. Zudem könnten Kunden ihre Unzufriedenheit über beworbene Dienstleister, Händler und deren Produkte auch auf die Bank übertragen. Hilfreich wäre in diesem Zusammenhang, wenn die Banken von sich aus und vorab ihren teilnehmenden Kunden mitteilen, welche Information über sie an den Dritten weitergegeben wird, um volle Transparenz herzustellen.

Eine unangemessen starke Bewerbung von Bankkunden mit Konsumangeboten kann außerdem dazu führen, dass Kunden über ihre eigentliche Zahlungsfähigkeit hinaus zu Kaufentscheidungen animiert werden, die ohne ein solches Angebot nicht zu Stande gekommen wären. Aus Sicht der Bank kann damit die Bonität des Schuldners leiden. Aus Sicht des Verbrauchers wäre die eigene Liquidität gefährdet bzw. die Verschuldung könnte bei besonders starkem Konsum steigen.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte haben verschiedene aufsichtliche und regulatorische Implikationen.

Aus der Monetarisierung von Daten mittels BDAI resultieren insbesondere Implikationen für den Verbraucherschutz, sowohl hinsichtlich der Prinzipien zur Datensparsamkeit bzw. Datenminimierung und Zweckbindung von Daten als auch hinsichtlich der Kontrolle der Datenverwendung. Darüber hinaus kann sich eine negative Diskriminierung einzelner Kunden ergeben – bei bankbezogenen und bei nicht-bankbezogenen Produkten.

In Kapitel VI dieser Studie wird auf die aufsichtlich-regulatorischen Implikationen der genannten Punkte in detailliert eingegangen.

5.3 Marktbetrachtung Versicherer

5.3.1 Einleitung und Status quo

Der Einsatz von BDAI in der Versicherungsbranche befindet sich grundsätzlich noch im Anfangsstadium.

Traditionell werden in der Versicherungsbranche große Volumina strukturierter Daten für aktuarielle Aufgaben genutzt.¹⁹¹ Eine flächendeckende Nutzung von BDAI-Technologie im Sinne dieser Studie, also der Anwendung beispielsweise von Methoden des überwachten Lernens, ist auf dem globalen Versicherungsmarkt¹⁹² derzeit jedoch nicht zu beobachten. Dennoch wenden einige Anbieter weltweit BDAI-Technologien entlang der klassischen Wertschöpfungskette bereits an oder testen sie. Große Versicherungsunternehmen sind dabei häufig weiter fortgeschritten als kleinere Wettbewerber. So haben in Deutschland einzelne Versicherungsunternehmen erste BDAI-Initiativen gestartet und vor allem in der Kraftfahrt-, in der Hausrat- und in der Krankenversicherung bereits testweise implementiert.

Zwei Herausforderungen haben die Marktdurchdringung von BDAI bislang verzögert.

Im Folgenden werden zwei Herausforderungen dargestellt, die eine schnellere Marktdurchdringung von BDAI-Technologien in der Versicherungsbranche bislang verzögert haben. Es wird zudem untersucht, warum die Bedeutung von BDAI in der Versicherungsbranche dennoch zugenommen hat und wahrscheinlich weiter zunehmen wird.

Vergleichsweise geringe Erfahrung im Umgang mit neuen Datenquellen und (selbstlernenden) Algorithmen

Im Vergleich zu anderen Branchen fehlt es Versicherungsunternehmen nach eigener Aussage teilweise noch an Expertise und Erfahrung im Umgang mit den in Kapitel III dargestellten Technologien und an einer hinreichenden Anzahl von Experten. Rekrutierung und Aufbau geeigneter Fachkräfte stellen zentrale Herausforderungen für viele Versicherungsunternehmen dar, die BDAI-Anwendungen umsetzen möchten.¹⁹³

Derzeitige Datenerfassung ist häufig nicht auf verhaltensbezogene Daten ausgerichtet, teilweise keine Nutzung dieser im BDAI-Kontext möglich

¹⁹¹ Vgl. Feilmeier, 2016, Digitalisierung, Big Data und andere digitale Techniken in der Versicherungswirtschaft. In: Fakten & Meinungen zur DAV/DGVFM-Jahrestagung 2016.

¹⁹² Rückversicherungsunternehmen, Pensionskassen sowie auf multinationale Versicherungs- und Vorsorgelösungen spezialisierte Versicherungsunternehmen werden im Rahmen dieser Studie nicht berücksichtigt. Des Weiteren erfolgt eine Fokussierung auf Endverbraucher (Privat- und Firmenkunden). Die Kunden von Rückversicherern sind Erstversicherer und damit weder Privat- noch Firmenkunden im engeren Sinne. Im Rahmen dieser Studie werden zudem nur die privaten, nicht jedoch die gesetzlichen Krankenversicherer betrachtet, denn der Einsatz von BDAI z.B. zur Differenzierung von Prämien ist dort derzeit nicht absehbar.

¹⁹³ Vgl. Silverberg et al., 2016, Innovation in Insurance: How technology is changing the industry. In: Institute of International Finance, S. 18f.

Die derzeitige Erfassung von Daten fokussiert sich in aller Regel auf traditionelle Stamm- und Schadendaten, wohingegen die für den Einsatz von BDAI-Anwendungen u.a. wertvollen individuellen Verhaltensdaten der Kunden oftmals noch nicht erfasst werden.¹⁹⁴ Des Weiteren sehen sich Versicherungsunternehmen innerhalb einzelner Sparten¹⁹⁵ häufig noch mit Datensilos konfrontiert, z.B. bei Datenerfassung in Customer-Relationship-Management-, Policen-, Schadenmanagement- und Abrechnungssystemen. Infolgedessen ist die Nutzbarkeit des Datenhaushalts für die Anwendung von BDAI meist noch nicht hinreichend¹⁹⁶ (vgl. auch Kapitel 4.2).

BDAI-Potentiale lassen sich nur innerhalb einer geeigneten IT-Architektur vollständig umsetzen.¹⁹⁷ Dies erfordert eine Harmonisierung von Kernsystemen. Die hierfür häufig notwendigen Datenmigrationen sind jedoch mit Projektrisiken und erheblichen Investitionskosten verbunden. Für viele Versicherungsunternehmer waren diese Risiken in der Vergangenheit der Hauptgrund, Migrationen nicht durchzuführen.¹⁹⁸ In jüngster Zeit jedoch zeigen marktweit verschiedene Versicherungsunternehmen größeres Interesse daran, moderne IT-Architekturen zu implementieren. Dies wird bei Zugrundelegung öffentlich verfügbarer Informationen deutlich: Insbesondere die deutsche Versicherungsbranche investiert hohe Beträge in die Digitalisierung – vor allem zur Harmonisierung von Kernsystemen. Im Durchschnitt nannten deutsche Versicherer Einzelbudgets zwischen 100 Millionen und 500 Millionen Euro für den Gesamtzeitraum von 2017 bis 2021.

Für diese Entwicklung können zwei Aspekte maßgeblich sein: Zum einen ist der Kostendruck vor allem für Kranken- und Lebensversicherer durch die anhaltend niedrigen Zinsen gestiegen. Zum anderen gibt es erste Anzeichen dafür, dass neue Wettbewerber – viele davon mit hoher Technologieexpertise – mit datengetriebenen Geschäftsmodellen und entsprechenden BDAI-Technologien in den Versicherungsmarkt eintreten könnten.¹⁹⁹

¹⁹⁴ Bei einigen Versicherungsunternehmen beschränkt sich die Interaktion mit Versicherungsnehmern – insbesondere bei Schadenfreiheit – auf eine „jährliche Mitteilung“, wodurch nur begrenzt Daten erfasst werden.

¹⁹⁵ In Deutschland gilt gemäß § 8 Abs. 4 VAG das Prinzip der Spartenrennung. Demnach kann ein Versicherungsunternehmen beispielsweise nur eine Erlaubnis zum Betrieb entweder der Lebensversicherung, der Krankenversicherung oder anderer Versicherungssparten erhalten. Auch ein Rückversicherungsunternehmen wird nur zum Betrieb der Rückversicherung zugelassen. Oftmals tritt eine Versicherungsgruppe gegenüber den Kunden jedoch unter dem gleichen Branding auf. Ferner werden Kunden im Rahmen eines Vertragsabschlusses oftmals um ihr Einverständnis gebeten, dass bestimmte Kundendaten auch von anderen Versicherungsunternehmen der Gruppe genutzt werden können (z.B. für Cross-Selling-Kampagnen).

¹⁹⁶ Siehe Jung et al., 2017, Die Last der Altsysteme. In: Zeitschrift für Versicherungswesen 03/2017, S. 86 – 89.

¹⁹⁷ Zu weiteren Erfolgsfaktoren für BDAI-Anwendung vgl. Kapitel 4.2.

¹⁹⁸ Ergebnis der Auswertung von begleitenden Expertengesprächen.

¹⁹⁹ Fromme, 2018, Versichert von Amazon. In: Süddeutsche Zeitung 14.11.2017.


The Wall Street Journal, 2018, Amazon, Berkshire Hathaway, JPMorgan Join Forces to Pare Health-Care Costs. Online verfügbar: <https://www.wsj.com/articles/amazon-berkshire-hathaway-jpmorgan-to-partner-on-health-care-1517315659>, abgerufen am 30.01.2018.

5.3.2 Auswirkungen von BDAI auf den Versicherungsmarkt

Die vielfältigen Möglichkeiten, BDAI in der Versicherungsbranche einzusetzen, wie die gezielte Kundenansprache anhand von identifizierten Next-Best Products basierend auf den ausgewerteten Daten eines Versicherungsnehmers, sind grundsätzlich nicht nur für konventionelle Versicherungsunternehmen interessant. Sie könnten auch Wettbewerber motivieren, sich stärker im Versicherungsmarkt zu positionieren oder neu in den Markt einzutreten. Im folgenden Kapitel werden – analog zum vorangehenden Kapitel – Marktszenarien für drei Unternehmenstypen unterschieden: Incumbents (traditionelle Versicherungsunternehmen), Bigtechs²⁰⁰, die bislang nur vereinzelt Aktivitäten bezogen auf den Versicherungsmarkt zeigen, und Insurtechs. In diesem Zusammenhang werden insbesondere deren jeweilige Stärken, Schwächen, Möglichkeiten und Herausforderungen skizziert.

Die derzeitigen Marktpositionen der drei genannten Unternehmenstypen können vereinfacht anhand der in Kapitel 5.2 hergeleiteten Wettbewerbsdimensionen dargestellt werden: Vertrauen der Verbraucher, technologische BDAI-Plattform²⁰¹, Customer Reach und regulatorische Kompetenz/Branchenkenntnis²⁰². Dies wird in Abbildung 20 verdeutlicht.

Abbildung 20: Schematische Darstellung der relativen Ausprägungen von Wettbewerbsdimensionen für Incumbents, Bigtechs und Insurtechs



Traditionelle Versicherungsunternehmen können durch Investitionen in BDAI-Technologien neue werthaltige Daten erfassen, welche die standardmäßig erfassten Daten der Versicherten und deren Schadendaten komplementieren könnten.

²⁰⁰ Zum Beispiel Google (Alphabet), Amazon, Facebook, Apple.

²⁰¹ Hierbei sind insbesondere die technische Innovationsfähigkeit, die Umsetzungsgeschwindigkeit von BDAI-Anwendungen sowie eine agile Unternehmenskultur relevant.

²⁰² Hierbei sind insbesondere die Hoheit über proprietäre Versicherungsdaten und die Expertise in der Entwicklung von Versicherungsprodukten relevant.

Durch ihre längere Existenz am Markt haben traditionelle Versicherungsunternehmen in der Regel – im Vergleich zu Insurtechs und Bigtechs – deutlich mehr Expertise, was die Berücksichtigung regulatorischer Anforderungen angeht. Sie haben zudem eine vertiefte Branchenkenntnis. Zugleich genießen sie ein potenziell höheres Vertrauen der Verbraucher, was den Umgang mit sensiblen Daten anbelangt (vgl. Kapitel 4.1). Sofern sie diese Wettbewerbsvorteile wahren und zugleich ihre BDAI-Technologien und -Kompetenzen stärken, könnten sich traditionelle Versicherungsunternehmen in einer guten Position befinden, um ihre aktuelle Marktposition insbesondere an der Schnittstelle zu den Kunden zu sichern. BDAI-Anwendungen könnten für Versicherungsunternehmen auch in Kernprozessen von zentraler Bedeutung sein, da sie erwartungsgemäß mit Effizienzgewinnen in der Verwaltung einhergehen (vgl. Kapitel 5.3.3).²⁰³ Dazu müssten die Unternehmen in BDAI-Technologie investieren und entsprechende Prozesse umsetzen (vgl. Investitionsbudgets zur Digitalisierung in Kapitel 5.3.1).

Ein anderes denkbare Szenario bestünde darin, dass sich traditionelle Versicherungsunternehmen mittel- bis langfristig bewusst aus den Kundenschnittstellen zurückziehen bzw. aus ihnen verdrängt werden. Eine Verdrängung wäre u.a. dann denkbar, wenn neue Wettbewerber den Versicherungsnehmern eine nachhaltig bessere Customer Experience anbieten könnten.²⁰⁴ In diesem Szenario könnte sich ein traditionelles Versicherungsunternehmen dann auf seine versicherungsfachlichen Kernfunktionen wie die Risikoträgerschaft fokussieren. Dies würde eine stärkere Zusammenarbeit mit Insurtechs und/oder Bigtechs implizieren.

Bigtechs könnten versuchen, die Schnittstelle zu den Versicherten zu dominieren, um Zugang zu (Versicherungsnehmer-)Daten zu erhalten und selbst Produkte zu entwickeln.

Derzeit haben Bigtechs – besonders im Vergleich zu traditionellen Versicherungsunternehmen – eine höhere Expertise im täglichen Umgang mit BDAI-Technologien. So verwendet ein großes Social-Media-Unternehmen beispielsweise seit 2010 Gesichtserkennungssoftware, um Menschen auf Bildern zu identifizieren, die andere Nutzer hochgeladen haben.²⁰⁵ Zudem verfügen Bigtechs in aller Regel über eine breitere Kundenbasis sowie einen festen Kundenstamm, der sich an die meist einfache Bedienbarkeit der von Bigtechs angebotenen Dienstleistungen gewöhnt hat, und können somit neue Geschäftsmodelle schneller skalieren (vgl. Ausführungen zu Banken in Kapitel 5.2). Sofern sie in den Versicherungsmarkt eintreten wollten, müssten sie aufgrund der regulatorischen Anforderungen in der Versicherungsbranche und dem Mangel an Branchenkenntnissen entsprechende Expertise extern erwerben bzw. intern aufbauen (vgl. Abbildung 20, Mitte).

Daher könnte eine mögliche Strategie von Bigtechs darin bestehen, zumindest vorerst nur an der Kundenschnittstelle in den Versicherungsmarkt einzutreten und selbst keine Versicherungsprodukte zu entwickeln. In der Konsequenz könnten Bigtechs über ihre Plattformen Versicherungsprodukte von Versicherungsunternehmen vertreiben, die über eine entsprechende Erlaubnis zum Betrieb des Versicherungsgeschäfts verfügen. Hierdurch würde dann wie im Bankenmarkt (vgl. Kapitel 5.2) eine Disaggregation der Wertschöpfungskette im Versicherungsmarkt weiter begünstigt, d.h. eine zunehmende Trennung von Unternehmen, die Versicherungsprodukte vertreiben, und denen, die die mit Versicherungsverträgen verbundenen Risiken tragen.

²⁰³ BDAI-basierte Homogenisierung bisher heterogener Arbeitsschritte dürfte künftig die Automatisierung (nahezu) aller noch (teil-)manuellen Geschäftsprozesse in einem Versicherungsunternehmen ermöglichen.

²⁰⁴ Zur Definition von „Customer Experience“ vgl. Kapitel 5.2.1.

²⁰⁵ Vgl. Fast Company, 2017, How Apple, Facebook, Amazon And Google Use AI To Best Each Other. Online verfügbar: <https://www.fastcompany.com/40474585/how-apple-facebook-amazon-and-google-use-ai-to-best-each-other>, abgerufen am 30.01.2018.

In einem nächsten Schritt wäre es denkbar, dass Bigtechs selbst BDAI-basierte Versicherungsprodukte entwickeln und vertreiben. Sofern sie jedoch keine eigene Erlaubnis zum Betrieb des Versicherungsgeschäfts hätten, wären sie hierbei auf die Zusammenarbeit mit bzw. die Beauftragung durch lizenzierte Versicherungsunternehmen angewiesen. Bigtechs könnten also in diesem Szenario als Dienstleister konventionelle Versicherungsunternehmen bei der Produktentwicklung beraten. Die tatsächlichen Machtverhältnisse zwischen Bigtechs und konventionellen Versicherungsunternehmen könnten sich allerdings dahingehend verlagern, dass Versicherer in gewisser Weise gezwungen sind, mit Bigtechs zusammenzuarbeiten, da diese z.B.

- den direkten Kontakt zu den Versicherungsnehmern derart dominieren, dass der Versicherer Interessenten kaum noch über andere Kanäle/das eigene Branding erfolgreich ansprechen und akquirieren könnte, oder
- Prozesse derart kosteneffizient durchführen, dass der Versicherer bei einer Durchführung dieser Prozesse in Eigenregie nicht mehr wettbewerbsfähig wäre.

Die Erlaubnis zum Betrieb des Versicherungsgeschäfts läge in diesem Fall weiterhin bei den traditionellen Versicherungsunternehmen, sofern das Bigtech keine eigene Erlaubnis beantragt und erhalten hätte. Denkbar wäre, dass traditionelle Versicherungsunternehmen künftig nur noch als Träger des Risikos agieren, das den Versicherungsverträgen innewohnt. Alle mit dem Betrieb des Versicherungsgeschäfts verbundenen Prozesse (Produktentwicklung, Underwriting, Schadenbearbeitung, Kapitalanlage etc.) würden dann auf ein oder mehrere Tech-Unternehmen ausgegliedert, die auf die Durchführung des jeweiligen Prozesses spezialisiert sind.

Ein etwaiger Markteintritt von Bigtechs in einzelne Versicherungssegmente könnte mit hoher Wahrscheinlichkeit davon abhängen, wie nah ein Versicherungsprodukt am Kerngeschäft eines Bigtechs ist. Ein großes Online-Warenhaus bereitet beispielsweise derzeit das Angebot produktbezogener Versicherungen für höherwertige Geräte (Notebooks, Kameras etc.) vor.²⁰⁶

Eine fundamentale Veränderung am Markt durch den Eintritt neuer bzw. bestehender Insurtechs²⁰⁷ ist derzeit aufgrund von deren leichter Integrierbarkeit in Strukturen traditioneller Versicherungsunternehmen nicht absehbar.

Zurzeit agiert im Versicherungsmarkt eine große Zahl verschiedener Insurtechs insbesondere an der Schnittstelle zu den Kunden aber auch als Unterstützer von Kernprozessen. Diese Unternehmen sind in aller Regel auf einzelne Versicherungsfunktionen spezialisiert. Beispielsweise bieten einzelne Insurtechs unterstützende Leistungen in den Bereichen Vertrieb (z.B. Vergleichsportale), Vertragsmanagement oder Schaden-/Leistungsmanagement an.²⁰⁸ Sofern ein Insurtech Versicherungsprodukte vertreibt und über keine eigene Lizenz zum Betrieb des Versicherungsgeschäfts verfügt (z.B. Versicherungsvermittler), muss es mit einem oder mehreren etablierten Versicherungsunternehmen kooperieren, die Inhaber der erforderlichen Lizenz zum Betrieb des Versicherungsgeschäfts sind und das dem Versicherungsvertrag innewohnende Risiko übernehmen.²⁰⁹

²⁰⁶ Vgl. Fromme, 2018, Versichert von Amazon. In: Süddeutsche Zeitung 14.11.2017.

²⁰⁷ Unter dem Begriff Insurtechs werden im Rahmen dieser Studie – über die Definition in Kapitel 5.1 hinaus – sowohl solche Unternehmen verstanden, die über eine Erlaubnis zum Betreiben von Versicherungsgeschäft gemäß § 8 Abs. 1 VAG verfügen, als auch solche, die nicht über die entsprechende Erlaubnis verfügen, die jedoch versuchen, sich als vergleichsweise junge technologieorientierte Unternehmen entlang der Wertschöpfungskette von Versicherungsunternehmen anzusiedeln.

²⁰⁸ Offermatt, 2017, Fintechs und Insurtechs. Die Disruption kommt (?). In: Max. 99, Deutsche Aktuar-Akademie GmbH, Versicherungsforen Leipzig.

²⁰⁹ Ebd.

Ungeachtet der Präsenz von Insurtechs im Markt hat dieser sich bislang nicht stark verändert. Auch in den nächsten Jahren ist eine solche Änderung durch Insurtechs nicht absehbar²¹⁰, denn es mangelt dem Großteil der Insurtechs an einer breiten Kundenbasis. Die Kosten der Neukundengewinnung können zudem auch für Insurtechs erheblich sein. Eine plausible Strategie vieler Insurtechs könnte daher auch weiterhin darin bestehen, ihre Expertise im Umgang mit BDAI-Technologien und ihren digitalisierten Zugang zu Versicherungsnehmern für Kooperationen mit konventionellen Versicherungsunternehmen zu nutzen bzw. ihre BDAI-Kompetenz in die Wertschöpfungskette einzelner Incumbents zu integrieren und so ihren Mangel an Customer Reach auszugleichen. So hat beispielsweise ein großer deutscher Finanzdienstleister²¹¹ im Jahr 2017 einen digitalen Finanzassistenten übernommen, der – zur Schaffung von Transparenz – Konten, Kapitalanlagen und Versicherungen in einer plattformübergreifenden Mobilapplikation darstellen kann.

Die im vorangehenden Abschnitt beschriebenen Veränderungen für die unterschiedlichen Unternehmenstypen könnten diverse Auswirkungen auf den Versicherungsmarkt haben. In den nächsten Absätzen wird über einige dieser möglichen Auswirkungen eingehender diskutiert.

BDAI-induzierte Effizienzgewinne könnten die Profitabilität von Versicherungsunternehmen kurzfristig steigern.

Die verbesserte Profitabilität würde jedoch voraussichtlich kein langfristig anhaltender Effekt sein, da der Marktmechanismus bei funktionierendem Wettbewerb die Marktpreise der Versicherungsunternehmen an die neue Kostensituation anpassen würde. Denn sobald mehrere Anbieter durch die Realisierung von Effizienzgewinnen Kosten einsparen könnten, könnte die Strategie einzelner Versicherungsunternehmen darin bestehen, ihre Preise zu senken, um ihre Wettbewerber zu unterbieten und sich so zusätzliche Marktanteile zu sichern sowie den Versicherungsmarkt zu bereinigen. Die Folge dieses Marktmechanismus könnte sein, dass BDAI-bedingte Effizienzgewinne durch preisgünstigere Versicherungsprodukte im Mittel an die Versicherungsnehmer weitergegeben werden.²¹²

Abschöpfung von Konsumentenrenten²¹³ möglich.

Unbenommen der Tatsache, dass Versicherungsnehmer – wie im vorangehenden Absatz beschrieben – von den Effizienzgewinnen der Versicherungsunternehmen profitieren könnten, gilt jedoch, dass langfristig auch eine Abschöpfung von Konsumentenrenten möglich ist. Durch eine gezielte BDAI-unterstützte Vertriebssteuerung könnten Versicherungsunternehmen die Konsumentenrente abschöpfen, indem sie Versicherungsnehmern Angebote zu einem Preis unterbreiten, der ihrer individuellen Zahlungsbereitschaft entspricht und sich nicht auf ihr jeweiliges Risiko bezieht (vgl. ebenso Kapitel 6.2.3). Die ebenfalls mit BDAI einhergehende Möglichkeit einer höheren Individualisierung von Versicherungsprodukten kann zudem deren Vergleichbarkeit verringern, so dass es dem Kunden schwerfallen könnte, Leistung und Preise mit einander zu vergleichen, um sich für die günstigere Variante bei guter Leistung entscheiden zu können. Vergleichsportale könnten hierbei gegebenenfalls nur bedingt Abhilfe schaffen, insbesondere, wenn die Art des Angebots die Intention des Konsumenten zum shop around verringert.²¹⁴

²¹⁰ „Im Vertrieb seien Insurtechs am aktivsten. Gleichzeitig führe der hohe Wettbewerb bei Online-Maklern bereits zu Marktvereinigungen bei diesen selbst.“ GVNW-Symposium 2017 des Gesamtverbandes der versicherungsnehmenden Wirtschaft e. V., 2017, Marktberingung bei Insurtechs hat begonnen. In: VersicherungsJournal.de 12.09.2017.

²¹¹ Das Geschäftsfeld „Versicherung“ ist eine wesentliche Säule des Gesamtunternehmens.

²¹² Ergebnis der Auswertung von begleitenden Expertengesprächen.

²¹³ Vgl. Erläuterungen in Fußnote 63.

²¹⁴ FCA, 2016, Price discrimination and cross-subsidy in financial services, Occasional Paper No. 22, S. 7 ff. Online verfügbar: <https://www.fca.org.uk/publication/occasional-papers/op16-22.pdf>, abgerufen am 09.03.2018.

Der Einsatz von BDAI könnte zu stärkerem Verdrängungswettbewerb führen.

Traditionelle Versicherungsunternehmen mit hohen Investitionsbudgets könnten als Vorreiter bei der Anwendung neuer BDAI-Technologien First-Mover-Vorteile im Versicherungsmarkt erzielen. Sie könnten diese nutzen, um sich durch günstigere Tarife von Wettbewerbern mit geringeren Budgets abzugrenzen und in weitere technische Innovationen zu investieren. Auf diese Weise könnten sie versuchen, ihre Stellung im Markt zu verbessern.

Bigtechs und vereinzelte Insurtechs könnten vergleichbare First-Mover-Vorteile nutzen, da sie bereits umfangreiche Erfahrungen in der Anwendung von BDAI-Technologie haben. Sie könnten sogar konventionelle Versicherungsunternehmen mit hohen Investitionsbudgets durch günstigere Tarife unterbieten. Denn der Grad der Digitalisierung versicherungsfachlicher Prozesse wäre bei diesen Unternehmen erwartungsgemäß hoch. Bigtechs und Insurtechs könnten zudem frei von Altlasten wie etwa Legacy-IT-Systemen Kostenvorteile in der Entwicklung und dem Angebot von Versicherungsprodukten erzeugen. Voraussetzung dafür wäre jedoch, dass sie über eine Erlaubnis zum Betrieb von Versicherungsgeschäften verfügen.

Die traditionellen Versicherungsunternehmen, die als Second-Mover eventuell versuchen, die durch BDAI induzierten Vorteile zu adaptieren, könnten durch die Vorreiter verdrängt werden. Es sei denn, sie könnten – etwa durch eine Verlagerung auf Nischenprodukte – ebenfalls einen Wettbewerbsvorteil erzielen. Vor allem für kleinere Versicherungsunternehmen (und Insurtechs) mit vergleichsweise geringeren Investitionsbudgets könnte durch diesen Verdrängungswettbewerb ein gewisser Konsolidierungsdruck entstehen, insbesondere um Zugang zum erforderlichen BDAI-Know-how zu erhalten.²¹⁵

Derzeit ist keine quantitative Aussage zu den BDAI-induzierten Markteffekten möglich.

Ebenso wenig ist absehbar, ob der Versicherungsmarkt insgesamt wüchse oder kleiner würde, denn durch den Einsatz von BDAI könnten sich saldierende Effekte ergeben, nämlich die Besetzung von Marktnischen versus die Reduktion des gesamtwirtschaftlichen Schadens. Hinzu kommt, dass sich etwaige BDAI-induzierte Markteffekte mit weiteren großen Trends wie der Entwicklung selbstfahrender Kraftfahrzeuge und dem gesteigerten Interesse an Cyberversicherungen überlagern könnten.

Im Folgenden wird beschrieben, wie sich die beiden genannten BDAI-induzierten Effekte und die beiden eher nicht BDAI-induzierten Trends auf die Größe des Versicherungsmarktes auswirken könnten:

- **Marktnischen.** Durch das kosteneffizientere Erfassen und Auswerten von mehr Daten wie z.B. Verhaltensdaten könnten neue Risiken versicherbar werden. Dies ist in erster Linie durch einen Preiseffekt begründet, denn gewisse Risiken wären ohne BDAI-Technologie mit sehr hohen Fixkosten verbunden, sodass sich ihre Versicherung aus rein ökonomischer Perspektive nicht rentiert hätte oder Produkte zu derart hohen Preisen hätten angeboten werden müssen, dass die Nachfrage am Markt sehr gering ausgefallen wäre. Mit Hilfe einer BDAI-basierten Produktentwicklung könnten die Fixkosten deutlich reduziert und (neue) Versicherungsprodukte zu bezahlbaren Preisen angeboten werden. Beispielsweise wäre es durch maschinelle Auswertung von komplexen, hochvolumigen Datenbeständen zu Krankheitsverläufen denkbar, auch HIV-Infizierten schneller und günstiger bzw. überhaupt eine Lebensversicherung anbieten zu können.²¹⁶ Gleiches gilt bezogen auf die Wohngebäudeversicherung für Gebäude in überschwemmungsgefährdeten Gebieten. Durch die Berücksichtigung von Satellitenbildern und Geodaten können Versicherungsunternehmen die Gefährdungsgebiete genauer abgrenzen. Folglich könnte der Versicherungsmarkt durch das Abdecken von Marktnischen wachsen.

²¹⁵ Es ist gegenwärtig nicht absehbar, dass es im Zuge dessen zu einer signifikanten Reduktion der Anbieter am Markt kommt.

²¹⁶ Ein amerikanisches Versicherungsunternehmen bietet beispielsweise seit Anfang 2016 Lebensversicherungen für HIV-infizierte Menschen an. Die Produktentwicklung basierte u.a. auf der Auswertung von Datensets mehrerer zehntausend HIV-Infizierter und fand in Zusammenarbeit mit einem deutschen Rückversicherer statt.

- **Schaden- und Prämienreduktion.** Ein Effekt auf die Marktgröße, welcher der Abdeckung (noch) nicht bedienter Marktsegmente entgegenstehen könnte, ist unter Umständen die Reduktion des gesamtwirtschaftlichen Schadens durch verbesserte Betrugserkennung und Schadenprävention (z.B. bedachteres Fahren bei Einsatz von Telematik-Tarifen und dadurch gesamtwirtschaftliche Reduzierung von Autounfällen/Schadenszahlungen). BDAI könnte zur gezielten Vermeidung von Wertvernichtung eingesetzt werden, wodurch es unter Umständen möglich wäre, Versicherungsprämien und damit Beiträge zu senken.²¹⁷ Ein Rückgang der eingezahlten Beiträge würde zu einer Verkleinerung des Versicherungsmarktes gemessen an den gezahlten Bruttobeiträgen führen.

- **Wandel im Kraftfahrzeug-Markt.** Die Entwicklung selbstfahrender Autos könnte die Bedeutung von Kraftfahrtversicherungen für die Versicherungsbranche dauerhaft reduzieren, da die Zahl der Unfälle zurückgehen dürfte.²¹⁸ Im Jahr 2016 machten z.B. in Deutschland die für Kraftfahrtversicherungen gezahlten Beiträge noch 13 Prozent der insgesamt im deutschen Versicherungsmarkt gezahlten Beiträge aus.²¹⁹ Schätzungen zufolge könnten sich die Bruttobeiträge im Kraftfahrtversicherungsmarkt bis 2040 – im Vergleich zum Jahr 2016 – um bis zu 80 Prozent reduzieren.²²⁰ Zugleich könnte der gesamte Versicherungsmarkt (unabhängig von möglichen BDAI-induzierten Markteffekten) signifikant kleiner werden.

- **Informationssicherheitsrisiken.** Die Versicherung von Informationssicherheitsrisiken könnte ein neues Massenprodukt im Versicherungsmarkt werden, da Privat- und Firmenkunden zunehmend an einer Absicherung beispielsweise gegen Datenverluste, Beschädigung von Hard- und Software, Betriebsunterbrechungen aufgrund von IT-Störungen und die Verletzung geistiger Eigentumsrechte interessiert sind. Durch die Etablierung dieses Marktsegments könnten sich dann gegebenenfalls Umsatzsteigerungen durch höhere Beitragseinnahmen und damit Marktwachstum ergeben. Aufgrund der wachsenden Nachfrage wurden in den vergangenen Jahren nationale wie internationale Initiativen und Arbeitsgruppen zu dieser neuen Produktart ins Leben gerufen, u.a. von der OECD, der IAIS und von EIOPA. Ziel ist es, diese Produkte und ihre Risiken besser zu verstehen, um Handlungsempfehlungen für die Aufsicht entwickeln zu können.²²¹

²¹⁷ Dieser aus volkswirtschaftlicher Perspektive positive Effekt ginge nicht zwingend mit einer Reduktion der Gewinne der Versicherungsunternehmen einher. Denn eine mögliche Weitergabe der Kostenvorteile an die Versicherungsnehmer erfolgte erwartungsgemäß nur proportional zur Reduktion der Schadenkosten. Gleichzeitig könnten sich für einzelne Versicherungsnehmer, z.B. die nichttechnologieaffinen, höhere Prämien ergeben (vgl. Vermeidung möglicher Diskriminierung in Kapitel 6.2.3).

²¹⁸ Die Entwicklung hängt u.a. auch davon ab, inwieweit Verbraucher und Gesellschaft selbstfahrende Kraftfahrzeuge akzeptieren.

²¹⁹ BaFin Jahresbericht 2016. Online verfügbar:

https://www.bafin.de/DE/PublikationenDaten/Jahresbericht/jahresbericht_node.html, abgerufen am 20.04.2018.

²²⁰ Morgan Stanley and The Boston Consulting Group, 2016, Motor Insurance 2.0, S. 3. Online verfügbar:

<https://www.bcg.com/publications/2016/automotive-motor-insurance-2-0.aspx>, abgerufen am 15.01.2018. Es bestehen Unterschiede in dem Grad des Rückgangs je nach Staat. Neben selbstfahrenden Kraftfahrzeugen wurden weitere Trends wie Car-Sharing berücksichtigt.

²²¹ Derzeit ist noch nicht geklärt, ob und wie BDAI dabei unterstützen könnte, relevante Daten über die Schadeneintrittswahrscheinlichkeiten und Schadenhöhen von Informationssicherheitsrisiken zu erfassen und zu analysieren, um diese Risiken besser bewerten zu können.

5.3.3 Auswirkungen von BDAI auf die Kundenschnittstelle

Für Kunden könnte die Interaktion mit Versicherungsunternehmen durch den Einsatz von BDAI einfacher, schneller und individueller werden.

Der Einsatz von BDAI-Technologie in Versicherungsunternehmen wirkt an der Kundenschnittstelle auf zweierlei Weise: zum einen im Hinblick auf die fortlaufende Interaktion mit Versicherungsnehmern und deren stetige Information über neue auf den Kunden zugeschnittene Produkte zwecks Bindung an das Versicherungsunternehmen (gezielter Vertrieb), zum anderen hinsichtlich des Erlebnisses in der persönlichen Interaktion mit einem Versicherungsunternehmen (Kundenerlebnis).

Der Vertrieb könnte sich dergestalt verändern, dass für jeden Versicherungsnehmer auf Grundlage der Nutzung von BDAI kontinuierlich ein individualisiertes Marketing²²² (Lead Generation, Cross-Selling) entwickelt wird, welches das Angebot zugeschnittener Produkte unter Berücksichtigung der jeweiligen Lebenssituation ermöglicht. Dies umfasste auch das Angebot kurzfristiger, situativer Versicherungen, wie eines Probefahrt-, eines Busreise- und eines temporären Skifahr-Schutzes. Derart individualisierte und auf die jeweilige Situation zugeschnittene Angebote setzen voraus, dass ein Versicherungsunternehmen Kenntnis davon hat, welches Produkt bzw. welche Dienstleistung ein Versicherungsnehmer gerade benötigen könnte. Anders als bislang könnte dem Versicherungsnehmer ein individuelles Angebot nicht mehr nur auf Nachfrage, sondern automatisch unterbreitet werden – z.B. wenn er sich in einem Autohaus aufhält, eine Busreise antreten und in den Skiurlaub fahren will. In Deutschland beispielsweise haben sich bereits erste Anbieter derartiger situativer Versicherungen etabliert. Allerdings erfolgt das Angebot dieser situativen Versicherungen derzeit häufig zu Preisen, die oberhalb ganzzähriger Versicherung für das gleiche Risiko liegen.²²³

Das Potential zum gezielten Vertrieb könnte vor allem im Privatkundensegment der Kompositversicherungen sowie in den Zusatzversicherungen der privaten Kranken- und Lebensversicherungen liegen. Dabei könnten Versicherungssegmente mit hoher Marktdurchdringung (hier gemessen an der Zahl der Verträge bzw. Versicherten) besonders einträglich sein. Aus diesem Grund könnte es künftig z.B. im Segment der Kompositversicherungen individuell zugeschnittene Produkte geben, zunächst bei der Kraftfahrt- und dann bei der Hausrat-/Wohngebäude-, der Haftpflicht- und der Unfallversicherung.²²⁴

Bei zahlreichen Versicherern sind durch die Digitalisierung bereits heute viele aus Kundensicht aufwändige Prozessschritte etwa beim Vertragsabschluss (Antragstellung, Dokumentation, Unterschriften etc.), bei der Bestandsverwaltung (Adress- und Namensänderungen etc.) und der Schadenregulierung (Schadenmeldung inklusive Dokumentation des Schadens etc.) weniger manuell und somit schneller und bequemer geworden (vgl. auch Beispiele für BDAI-basierte Schadenregulierung in der Kraftfahrtversicherung in Kapitel 5.3.7.1). Durch Nutzung von BDAI könnten künftig einige Prozesse aus Sicht der Versicherten weiter vereinfacht und noch stärker auf ihre Bedürfnisse zugeschnitten werden. BDAI-Anwendungen wie Bot-Systeme und digitale Assistenten könnten in einigen Jahren für Versicherungsunternehmen marktreif und dann zur weiteren Automatisierung bestehender Prozesse an der Kundenschnittstelle eingesetzt werden.²²⁵

²²² Konkret ist hiermit die Lead Generation gemeint. Leads sind in diesem Zusammenhang Personen, die Interesse an bestimmten Versicherungsprodukten haben und ihre persönlichen Daten dem Versicherungsunternehmen überlassen, um etwa zusätzliche Informationen zu entsprechenden Gütern zu erhalten (z.B. Anmeldung zu einem Newsletter).

²²³ FAZ, 2015, Spontan per Handy versichert. Online verfügbar: <http://www.faz.net/aktuell/finanzen/meine-finanzen/versicherer-und-schuetzen/mini-versicherungen-spontan-per-handly-versichert-13309963.html>, abgerufen am 09.03.2018.

²²⁴ BaFin Statistik, Schaden- und Unfallversicherungen 2016. Online verfügbar: https://www.bafin.de/DE/PublikationenDaten/Statistiken/Erstversicherung/erstversicherung_artikel.html?nn=8228488, abgerufen am 20.04.2018.

²²⁵ Erste Anbieter intelligenter Kundenserviceassistenten haben sich, zum Beispiel in Spanien, zwar etabliert, jedoch noch keine breite Kundenbasis im Versicherungsmarkt aufgebaut.

Potential für die weitere Verbesserung des Kundenerlebnisses durch BDAI-Technologie besteht grundsätzlich in allen Versicherungssegmenten. Je häufiger die Versicherungsnehmer mit ihrem Versicherer interagieren, desto höher könnte das Potential in diesem Segment ausfallen. Konsequenterweise sollte dann bei Lebensversicherungen das geringste Potential bestehen, da bei diesen ein Versicherer in aller Regel weniger mit seinen Versicherungsnehmern interagiert als in anderen Segmenten.²²⁶

5.3.4 Auswirkungen von BDAI auf die Kernprozesse

BDAI könnte das Verständnis des individuellen versicherten Risikos verbessern und Kernprozesse über alle Versicherungssparten hinweg effizienter machen.

Der Einsatz von BDAI in Versicherungsunternehmen könnte zu einer Veränderung der Kernprozesse (z.B. Produktentwicklung, Schadenregulierung) führen und erwartungsgemäß sowohl deren Effektivität als auch deren Effizienz erhöhen, insbesondere durch differenziertere Risikobewertung, die Reduktion der Risiko- und Verwaltungskosten sowie eine verbesserte Schadenprävention und Betrugserkennung.

In Bezug auf die Effektivität könnte der wesentliche Zugewinn durch BDAI in der Möglichkeit einer differenzierteren Preisgestaltung von Versicherungsprodukten bestehen.²²⁷ Denn durch die Verfügbarkeit neuer Daten könnte die Menge der relevanten Prädiktoren für eine granularere Bewertung von Risiken – und damit die Festlegung der Prämie – neu definiert werden. Grundsätzlich könnten dabei hohe Risiken höher und niedrige Risiken niedriger bepreist werden als vor dem Einsatz von BDAI. Folglich könnte BDAI die adverse Selektion in der Versicherungsbranche reduzieren.²²⁸

Die hierdurch mögliche Bildung homogenerer Segmente²²⁹ könnte sich positiv auf die Schwankung um den erwarteten Schadenaufwand und somit die Risikokosten eines jeden Segmentes auswirken²³⁰. Ein Anreiz zu risikobewusstem Verhalten (siehe Anwendungsbeispiel „Produktentwicklung“ in Kapitel 5.3.7.2) könnte die Risikokosten darüber hinaus zusätzlich senken. Ein derartiger Anreiz könnte zudem zwei weitere Vorteile für Versicherungsunternehmen mit sich bringen. Zum einen könnten sich Versicherungsnehmer selbst selektieren: Die Tatsache, dass eine Person z.B. dem Tragen eines Wearables zustimmt oder einen Telematik-Tarif wählt, könnte ein möglicher erster Indikator für ein niedrigeres Risiko sein. Zum anderen könnten dadurch weitere Daten erfasst werden, wodurch Versicherungsprodukte unter Umständen noch weiter differenziert werden könnten. Auf die Risiken einer solchen Entwicklung aus Sicht der Versicherungsnehmer wird u.a. in dem Anwendungsbeispiel „Produktentwicklung“ in Kapitel 5.3.7.2 und in Kapitel VI im Zusammenhang mit potenziellen aufsichtlich-regulatorischen Implikationen und Leitfragen eingegangen.

²²⁶ Lebensversicherungen haben im Vergleich zu anderen Versicherungen eine höhere Fristigkeit. Regelmäßige Interaktion mit Versicherungsnehmern ist in aller Regel nicht erforderlich. Konträr ergeben sich z.B. bei der privaten Krankenversicherung allein aufgrund regelmäßiger Arztbesuche (inkl. Vorsorgeuntersuchungen etc.) deutlich mehr unterjährige Interaktionen zwischen Versicherungsnehmern und Krankenversicherungsunternehmen.

²²⁷ Allerdings nur unter der Voraussetzung, dass nach heutigem Kenntnisstand homogene Segmente (im Rahmen der Studie wird unter einem Segment ein Versicherungstarif verstanden) tatsächlich noch inhomogen sind und sich mit Hilfe externer Daten und neuer Auswertungstechnologien in mehrere Untersegmente aufteilen lassen.

²²⁸ Durch Differenzierung von Versicherungsnehmern wird ein Risikokollektiv (im Rahmen der Studie wird unter einem Risikokollektiv die Gesamtheit aller Versicherten in einer Versicherungssparte in einem Versicherungsunternehmen verstanden) kleinteiliger, d.h. alle Versicherten werden mehr (und damit feineren) Segmenten zugeteilt bis hin zum Segment-of-one. In einem solchen Segment-of-one würde ein Versicherter seinen individuellen geschätzten Erwartungsschaden als Prämie bezahlen.

²²⁹ Gleichzeitig Bildung einer größeren Anzahl an Segmenten/Tarifen innerhalb eines Risikokollektivs.

²³⁰ Durch geringere Schwankungen um den Erwartungsschaden wäre weniger Risikokapital anzusetzen, und somit wären die Risikokosten geringer.

Das Potential für derart differenzierte Versicherungsprodukte könnte segmentübergreifend sowohl für Privat- als auch für Firmenkunden bestehen. Insgesamt ist jedoch vorab zu klären, ob solche Daten einen hinreichenden Erklärungsbeitrag etwa zur Risikobeurteilung leisten können.²³¹ Aus wirtschaftlicher Perspektive wird BDAI zur Preisdifferenzierung wahrscheinlich zunächst in umsatzstarken Segmenten eingesetzt. Demnach wird z.B. im Segment der Kompositversicherungen eine stärkere Differenzierung zunächst bei der Kraftfahrt-, dann bei der Wohngebäude-/Hausrat-/Industrie-/Gewerbe- und dann bei der Haftpflichtversicherung vermutet.²³²

Die Effizienz könnte u.a. durch eine BDAI-unterstützte Reduktion des Verwaltungsaufwands verbessert werden. Beispielsweise könnten durch eine auf BDAI-Technologie basierende Automatisierung von Versicherungsabschlüssen (z.B. durch Automated Underwriting in der Lebensversicherung²³³), in der Bestandsverwaltung inklusive der Stornoprävention und bei der Schadenregulierung Effizienzen gehoben werden. In diesen Beispielen werden von Versicherungsunternehmen bereits heutzutage vereinzelt BDAI-Anwendungen eingesetzt bzw. getestet.

Das BDAI-Potential für die Aufwandsreduktion kann annäherungsweise mit Hilfe der beiden Indikatoren „Zahl Geschäftsvorfälle“²³⁴ und „Homogenisierbarkeit von Prozessschritten“²³⁵ erfolgen. Dabei gilt, dass das BDAI-Potential in einem bestimmten Versicherungssegment umso größer ausfallen könnte, je mehr Vorfälle anfallen und/oder je homogenisierbarer und damit automatisierbarer die betroffenen Prozessschritte sind. Entsprechend dieser Logik ergibt sich, dass dem Privatkundengeschäft hinsichtlich der Zahl an Geschäftsvorfällen ein signifikant größeres BDAI-Potential zugeschrieben werden könnte. Bei Betrachtung der Produktdimension innerhalb des Privatkundengeschäfts zeigt sich, dass die Kompositsparte aufgrund der vergleichsweise größeren Zahl von Geschäftsvorfällen und der größeren Zahl automatisierbarer Prozessschritte ein signifikant höheres BDAI-Potential aufweisen könnte als die Kranken- und Lebenssparte. Beim Vergleich von Kranken- und Lebensversicherungen wird gemäß der beschriebenen Logik vermutet, dass die Krankensparte ein geringfügig höheres BDAI-Potenzial aufweisen könnte. Innerhalb der Kompositsparte könnten Kraftfahrtversicherungen das größte BDAI-Potenzial aufweisen, gefolgt von den Hausrat- und Wohngebäudeversicherungen, Haftpflichtversicherungen, Unfallversicherungen, Rechtsschutzversicherungen und weitere Schaden-/Unfallversicherungen.

Langfristig werden Versicherungsunternehmen voraussichtlich versuchen, nicht nur punktuell an einzelnen Prozessschritten BDAI-Anwendungen zu implementieren, sondern neue BDAI-Technologien zu nutzen, um ihr Unternehmen umfänglich zu transformieren und damit Prozesse zunehmend End-to-End zu automatisieren. Denkbar wäre beispielsweise, den Neuaufnahmeprozess bei Krankenversicherungen vollständig zu automatisieren – vom ersten Kontakt mit einem Interessenten bis zur Ausstellung des Versicherungsscheins. Dann müsste kein Beschäftigter diesen Prozess mehr begleiten. Im Zuge dessen wird sich das operationelle Risiko für Versicherungsunternehmen verändern. Es kommt zu einer Verschiebung des Risikos hin zu Modellrisiken. Inwiefern sich das Risiko in Summe erhöht oder reduziert, lässt sich jedoch nicht exakt einschätzen: Das operationelle Risiko könnte potenziell größer werden, da aufgrund schnellerer

²³¹ Etwa hinsichtlich der Bedeutung von Wearables gibt es auch kritische Stimmen: „Das sind nur Gimmicks, durch Sport und Bewegung kann man maximal eineinhalb Prozent der Gesundheitskosten beeinflussen.“, Zitat O. Bäte, Vorstandsvorsitzender der Allianz SE. In: „Wir brauchen Waffengleichheit“, Der Spiegel, 16.01.2016.

²³² BaFin Jahresbericht 2016. Online verfügbar: https://www.bafin.de/DE/PublikationenDaten/Jahresbericht/jahresbericht_node.html, abgerufen am 20.04.2018.

²³³ Hierfür sind derzeit bereits Software-Tools großer Rückversicherer am Markt erhältlich.

²³⁴ Indikator gemessen an der Zahl von Neupolicen pro Jahr und Sparte geteilt durch die mittlere Vertragslaufzeit je Sparte multipliziert mit der mittleren Anzahl an Geschäftsvorfällen pro Jahr und Sparte. Quelle für Neupolicen: Hoppenstedt Versicherungsdatenbank 2017. Ø Vertragslaufzeit 50 Jahre (Kranken), 30 Jahre (Leben), 1 Jahre (Komposit). Ø Anzahl Geschäftsvorfälle p. a. 2,5 (Kranken), 1 (Leben), 0,2 (Komposit). Erfahrungswerte.

²³⁵ Indikator gemessen an der Personalkostenquote je Sparte: d.h. Aufwendungen für Löhne und Gehälter geteilt durch verdiente Nettoprämien (= verdiente Beiträge für eigene Rechnung). Angewandte Logik: Je höher diese Quote, desto manueller der Prozess, desto höher das BDAI-Potential. Quelle für Löhne und Gehälter sowie Nettoprämien: Hoppenstedt Versicherungsdatenbank 2017.

Durchlaufzeiten weniger Zeit für die Detektion von maschinellen Fehlern und Einleitung von Korrekturmaßnahmen zur Verfügung stünde. Ebenso könnte das operationelle Risiko insgesamt kleiner werden, da sich durch den Einsatz von Algorithmen zugleich auch die Kontrollmechanismen verbessern könnten.²³⁶ Das operationelle Risiko verändert sich darüber hinaus, da durch den Einsatz von BDAI-Anwendungen bzw. die damit einhergehende stärkere Vernetzung zwischen den einzelnen Geschäftsprozessen sowie die stärkere Abhängigkeit von digitalen Anwendungen tendenziell auch die Informationssicherheitsrisiken steigen (vgl. Kapitel 4.2).

Des Weiteren könnten BDAI-Anwendungen traditionelle aktuarielle Aufgaben unterstützen bzw. perspektivisch sogar übernehmen, wodurch sich der Verwaltungsaufwand ebenfalls reduzieren ließe. Insbesondere könnte sich durch Nutzung von AI die Möglichkeit ergeben, Legacy-IT-Systeme innerhalb kürzerer Zeit und zu deutlich geringeren Kosten automatisiert zu migrieren. Ein Beispiel hierfür ist die BDAI-unterstützte Migration von Lebensversicherungspolicen.²³⁷

Weiterhin könnte die Effizienz von Versicherungsunternehmen durch BDAI-unterstützte Schadenprävention und Betrugserkennung verbessert werden. Beides zusammen könnte potenziell einen Rückgang der Schadenkosten ermöglichen (vgl. Beispiele zur Schadenprävention und Betrugserkennung im Anwendungsbeispiel „Schadenmanagement“ in Kapitel 5.3.7.1). Zudem könnte BDAI auch zur Minimierung der Auswirkungen bereits eingetretener Schäden eingesetzt werden; darüber wird insbesondere bei Industrieversicherungen diskutiert.

5.3.5 Neue Geschäftsmodelle durch BDAI

Versicherungsunternehmen könnten auf Basis von BDAI neue Geschäftsmodelle entwickeln.

Im Rahmen dieser Studie wird unter einem neuen BDAI-induzierten Geschäftsmodell in der Versicherungsbranche die Schaffung einer neuen Ertragsquelle verstanden, die vom traditionellen Versicherungsgeschäft abzugrenzen ist.²³⁸ Ein mögliches neues Geschäftsmodell auch für Versicherer ist die Monetarisierung von Daten, d.h. deren Verwendung zum Angebot von Produkten, die über traditionelle Versicherungsprodukte hinausgehen, bzw. ein Verkauf von hinreichend anonymisierten Datensätzen an andere Versicherungsunternehmen oder andere Unternehmen.²³⁹ Zu den Risiken einer potenziellen Monetarisierung von Daten vgl. das Anwendungsbeispiel „Monetarisierung von Kundendaten“ in Kapitel 5.2.6.3, zum Verbrauchervertrauen vgl. Kapitel 4.1 und zu möglichen aufsichtlich-regulatorischen Implikationen und Leitfragen vgl. Kapitel VI.

Bislang ist keine nennenswerte Monetarisierung von Daten durch Versicherungsunternehmen zu beobachten. Grundsätzlich schätzen einige Marktteilnehmer, dass traditionelle Daten über Risiken allein nur schwer zu monetarisieren wären. Die Monetarisierung von Daten ist, wie im Folgenden dargelegt, in zweierlei Hinsicht denkbar:

²³⁶ Bedingung dafür ist eine fehlerfreie Programmierung der eingesetzten Algorithmen. Zudem kann erwartet werden, dass Algorithmen grundsätzlich objektivere Entscheidungen treffen, als es Menschen manchmal möglich ist.

²³⁷ Hierbei handelt es sich um eine BDAI-Methode zur effizienteren Strukturierung des Datenhaushalts einer Lebensversicherung. Das sekundäre Ziel besteht in der Reduktion der Zahl unterschiedlicher Produkte im Unternehmen bei gleichzeitiger Sicherstellung, dass kein Versicherungsnehmer durch die Migration schlechter gestellt wird.

²³⁸ Es bestehen länderspezifische Unterschiede, inwiefern versicherungsfremdes Geschäft in ein Tochterunternehmen ausgelagert werden müsste. In Deutschland beispielsweise ist die Durchführung von versicherungsfremdem Geschäft für Versicherungsunternehmen verboten, vgl. § 15 Abs. 1 VAG.

²³⁹ Diese Unternehmen könnten gerade in Branchen außerhalb der Finanzdienstleistungsbranche beheimatet sein.

Traditionelle, proprietäre und neue, externe Daten (z.B. erfasst aus Telematik- und/oder Wearables-Anwendungen) könnten zusammen zur Schadenprävention und damit zur Senkung des Risikos genutzt werden (vgl. auch Kapitel 5.3.7.1). Dies impliziert eine Entwicklung von einem reinen Schadenregulierer hin zu einem Risikomanager, wodurch eine Ertragsquelle neben dem Versicherungskerngeschäft geschaffen werden könnte.²⁴⁰ Ferner könnte diese Art der Monetarisierung von Daten den Versicherern im Rahmen des Internet of Things (IoT) die Möglichkeit eröffnen, erweiterte, regelmäßige Dienstleistungen anzubieten. Als Beispiele wären etwa die frühzeitige Warnung vor Hagelschauern bei der Kraftfahrtversicherung zu nennen und – im Fall der Haushalts- bzw. Gebäudeversicherung – die Information darüber, welche Haushaltsgeräte oder gewerblichen Maschinen wann gewartet werden müssten, um Kurzschlüsse oder Brandgefahren zu vermeiden bzw. zu mitigieren. Dabei könnte durch häufigeren, für den Versicherungsnehmer nutzbringenden Kontakt die Kundenbindung erhöht werden. Ein amerikanisches Versicherungsunternehmen beispielsweise bietet seinen Versicherungsnehmern an, über „Alexa“²⁴¹ z.B. Anweisungen zur Reduktion von Hurrikan-Schäden zu erhalten.²⁴²

Ebenso könnten neu erhobene Daten als hinreichend anonymisierte Datenpakete direkt an interessierte Unternehmen, z.B. an Kraftfahrzeughändler (Telematikdaten) und an Betreiber von Fitnesscentern (Wearables-Daten) veräußert werden, vorausgesetzt das Versicherungsunternehmen selbst verfügt über diese Daten, was derzeit zumindest in Deutschland regelmäßig (noch) nicht der Fall ist.²⁴³

Zum jetzigen Zeitpunkt ist nicht absehbar, in welcher Höhe Versicherungsunternehmen durch die genannten neuen Geschäftsmodelle Erträge generieren könnten bzw. inwiefern diese Erträge nachhaltig wären. Insbesondere stellt sich die Frage, inwiefern derartige Geschäfte mit den daten- und verbraucherrechtlichen Anforderungen sowie mit den Anforderungen einzelner Länder an die Durchführung versicherungsfremder Geschäfte vereinbar wären. Die Art, wie Versicherungsunternehmen bei derartigen neuen Geschäftsmodellen personenbezogene Informationen nutzen, kann zudem Auswirkungen auf das Vertrauen der Verbraucher haben.

5.3.6 Erklärungskraft externer Daten

Der Markteintritt von Nicht-Versicherungsunternehmen²⁴⁴ würde erleichtert, wenn diese für die Risikobewertung relevante, externe Daten besäßen und zielgerichtet auswerten könnten. Die tatsächliche Erklärungskraft externer Daten ist allerdings noch nicht ausreichend belegt.

Der systematische Einsatz von BDAI an der Kundenschnittstelle könnte in der Versicherungsbranche an Bedeutung gewinnen. Denn die hier erfassbaren externen Daten (d.h. nicht die originären Daten aus der Schadenhistorie eines Versicherungsunternehmens) könnten nicht nur zum digitalen Ausbau der Kundenschnittstellen dienen, sondern darüber hinaus dafür verwendet werden, auf Basis neuer Prädiktoren Risiken differenzierter zu bewerten.

²⁴⁰ Siehe Bauer, 2017, Cognitive IoT – Trends & Auswirkungen auf Prozesse der Versicherungswirtschaft. In: DAV/DGVFM-Jahrestagung 2017 – Actuarial Data Science.

²⁴¹ Ein internetbasierter, persönlicher Assistent mit Lautsprecherfunktion des amerikanischen Unternehmens Amazon. Es bleibt abzuwarten, welchen Einfluss solche smarten Assistenten im Haushalt auf die Wahrung der Privatsphäre haben und welche Anwendungs- und Nutzungsform sich durchsetzen.

²⁴² Vgl. Mutchler, 2017, Insurance Companies Increase Alexa Skill Offerings. Online verfügbar: <https://www.voicebot.ai/2017/03/06/insurance-companies-increase-alexa-skill-offerings/>, abgerufen am 30.01.2018.

²⁴⁴ Im Rahmen dieser Studie sind mit Nicht-Versicherungsunternehmen solche Unternehmen gemeint, die in der Vergangenheit zwar kein Versicherungsgeschäft betrieben haben, künftig aber Zugang zu relevanten Daten zur Bestimmung des versicherungstechnischen Risikos erlangen könnten.

Der technische Zugang zu relevanten externen Daten (für eine Beschreibung neuer relevanter Datentypen und -quellen vgl. Kapitel 5.3.7.2) wäre jedoch nicht nur traditionellen Versicherungsunternehmen vorbehalten. Dritte (Nicht-Versicherungsunternehmen) könnten diese Daten künftig ebenso erfassen und monetarisieren.²⁴⁵ Eine Möglichkeit der Monetarisierung bestünde in der Nutzung für das Versicherungsgeschäft. Zum heutigen Zeitpunkt reicht die Erklärungskraft der externen Daten allein allerdings nicht aus, um das versicherte Risiko zu charakterisieren. Nur in Verbindung mit traditionellen, proprietären Versicherungsdaten (Schadenhistorie, allgemeine Versichertendaten etc.) könnte die Risikobewertung gegebenenfalls verfeinert werden. Die traditionellen Daten würden dabei in erster Linie zum Zweck des Backtestings verwendet.

De facto ist der Zugewinn an Erklärungskraft einzelner – im Sinne dieser Studie – neuer Prädiktoren (z.B. Beschleunigungsverhalten von Kraftfahrzeugführern) zur Bewertung von Risiken bislang nicht abschließend belegt.²⁴⁶ Dass die Bestimmung neuer Prädiktoren für Versicherungsunternehmen grundsätzlich interessant sein kann, wurde in der Vergangenheit bereits empirisch bestätigt. Eine Studie zeigt beispielsweise für die Kraftfahrtversicherung einen statistischen Zusammenhang zwischen Bonitätsbewertungen²⁴⁷ und Erwartungsschäden.²⁴⁸ Es stellt sich also die Frage, ob in Zukunft die Erklärungskraft der angesprochenen Daten für Nicht-Versicherungsunternehmen ausreichen könnte, um Versicherungsgeschäft effektiv betreiben zu können, und ob die damit möglicherweise genauere Charakterisierung des versicherten Risikos wesentlich wäre. Wären diese beiden Voraussetzungen erfüllt, dann könnte dies den Eintritt neuer Wettbewerber in den Versicherungsmarkt erleichtern, vorausgesetzt, sie erfüllten die regulatorischen Anforderungen an Versicherungsunternehmen.

5.3.7 Anwendungsbeispiele in der Versicherungsbranche

Eine flächendeckende Nutzung von BDAI ist im globalen Versicherungsmarkt derzeit auch aufgrund der oben genannten Herausforderungen noch nicht zu beobachten. Dennoch haben Versicherer weltweit bereits erste BDAI-Technologien angewendet bzw. getestet. Unter anderem wird versucht, die Prämien auf Basis unterschiedlicher, heterogener Datenquellen differenzierter zu gestalten. Ebenso soll die Zahl der Verträge je Versicherungsnehmer durch das Angebot von Next-Best Products erhöht und damit das Cross-Selling optimiert werden.²⁴⁹ Darüber hinaus kommt BDAI in der Schadenregulierung und in der Betrugserkennung (sowohl beim Abschluss als auch in laufenden Versicherungsverträgen) zum Einsatz – und zwar durch maschinell unterstützte Foto- und Videoanalysen.²⁵⁰

In den Kapiteln 5.3.7.1 und 5.3.7.2 werden zwei dieser Anwendungen detailliert dargestellt:

- **Datenauswertung zur Unterstützung des Schadenmanagements.** Das erste Anwendungsbeispiel untersucht, wie Versicherungsunternehmen BDAI zur Reduktion von Verwaltungskosten in der Schadenregulierung, zur Betrugserkennung und zur Schadenprävention einsetzen bzw. künftig einsetzen könnten. Ferner wird dargelegt, inwiefern für die Versicherungsnehmer insbesondere die Schadenregulierung deutlich einfacher werden könnte.

²⁴⁵ Unter Beachtung rechtlicher Anforderungen wie der EU-DSGVO.

²⁴⁶ Für eine Einschätzung der derzeitigen Bedeutung externer Telematik-Daten in der Kraftfahrtversicherung vgl. Morawetz, 2016, Der telematische Irrweg der Kfz-Versicherung. In: Zeitschrift für Versicherungswirtschaft 04/2016, S. 5 f.

²⁴⁷ Gemeint sind an dieser Stelle Kreditscores.

²⁴⁸ Vgl. Monaghan, 2000, The Impact of Personal Credit History on Loss Performance in Personal Lines. In: Casualty Actuarial Society.

²⁴⁹ Gerbert et al., 2017, Putting Artificial Intelligence to Work. In: The Boston Consulting Group, S. 10.

²⁵⁰ Ergebnis der Auswertung von begleitenden Expertengesprächen.

- **Produktentwicklung durch Hinzunahme externer Daten.** Das zweite Anwendungsbeispiel erläutert das Potential, versicherungstechnische Risiken mittels BDAI differenzierter zu bepreisen. Ferner wird gezeigt, dass sich dadurch der Selektionsdruck im Markt erhöhen könnte, verbunden mit dem Risiko, dass einzelne Kundensegmente wesentlich höhere Prämien zahlen müssten, wohingegen andere Kundensegmente von wesentlich niedrigeren Prämien profitieren könnten.

Ein drittes Anwendungsbeispiel (vgl. Kapitel 5.3.7.3) behandelt ein vom derzeitigen rechtlichen Rahmen losgelöstes, potenziell disruptives Versicherungssystem, das sich im nächsten Jahrzehnt etablieren könnte:

- **Homogene Gruppen von Versicherten auf Basis von BDAI.** Ein besseres Verständnis des versicherungstechnischen Risikos könnte die Bildung großer, länderübergreifender, homogenerer Gruppen ermöglichen. Diese könnten bei einer von den Versicherungsnehmern selbst bestimmten Organisationsform Kostenvorteile und Aufsichtsarbitrage nutzen.²⁵¹ An dieser Stelle sei jedoch darauf hingewiesen, dass eine mögliche Aushebelung lokaler Versicherungsangebote durch länderübergreifende Plattformen aus heutiger Sicht nicht absehbar ist.

Die Auswahl dieser Anwendungsbeispiele erfolgte auf Basis einer indikativen Abschätzung des ökonomischen BDAI-Potentials²⁵² – wobei das größte BDAI-Potential derzeit im Schadenmanagement und in der Produktentwicklung/Preisgestaltung gesehen wird – sowie auf Grundlage möglicher disruptiver Entwicklungen im Versicherungsmarkt.

5.3.7.1 Datenauswertung zur Unterstützung des Schadenmanagements

1. Einleitung

In der Wertschöpfungskette aller Versicherer nimmt das Schadenmanagement einen großen Teil der Ressourcen in Anspruch. Wenngleich die Regulierung vieler Schäden zügig erfolgen kann, so entstehen teilweise komplexe Sachverhalte, bei denen die manuelle Bewertung von Ansprüchen und zu zahlenden Versicherungsleistungen langwierig ist.²⁵³ Im vorliegenden Anwendungsbeispiel wird für mehrere Versicherungssparten im Segment der privaten Kompositversicherungen²⁵⁴ dargestellt, wie durch den Einsatz von BDAI das Schadenmanagement maschinell unterstützt und dadurch verbessert und beschleunigt werden kann.

BDAI wird über die maschinelle Vorerfassung gemeldeter Schadenfälle in Antrags- und Leistungssystemen von Versicherungsunternehmen hinausgehen. BDAI könnte Sachbearbeiter dadurch entlasten, dass gewisse Sachverhalts- bzw. Schadenhöhenüberprüfungen oder -plausibilisierungen maschinell auf Basis zusätzlicher Datenquellen durchgeführt werden. Darüber hinaus könnte BDAI künftig sogar dazu eingesetzt werden, das Schadenmanagement für eine Teilmenge der Schäden vollständig zu automatisieren.

Die Unterstützung des Schadenmanagements durch die Analyse externer Datenquellen ist heute in einzelnen Unternehmen bereits Praxis für ausgesuchte Anwendungen, welche im Folgenden dargestellt werden.

²⁵¹ Die Genehmigungspflicht und der Umgang mit auf Basis von BDAI zusammengestellten Risikokollektiven zur Realisierung einer P2P-Versicherung, in der sich Mitglieder entsprechend dem Teambrella-Konzept (Online abrufbar: <https://teambrella.com/>.) organisieren könnten, unterliegt stets der Einzelfallprüfung des jeweiligen Geschäftsmodells. Pauschalaussagen sind nicht möglich.

²⁵² Ergebnis der Auswertung von begleitenden Expertengesprächen.

²⁵³ Aufgrund ihrer Komplexität kann die Schadenregulierung nicht nur die Zulieferung von Dokumenten seitens der Versicherungsnehmer einfordern, sondern auch Einschätzungen von Gutachtern wie Juristen und Medizinern einholen.

²⁵⁴ Beim vorliegenden Anwendungsbeispiel werden Kraftfahrt-Kasko- und Kraftfahrt-Haftpflichtversicherungen sowie Hausrat- und Gebäudeversicherungen adressiert.

2. Anwendung

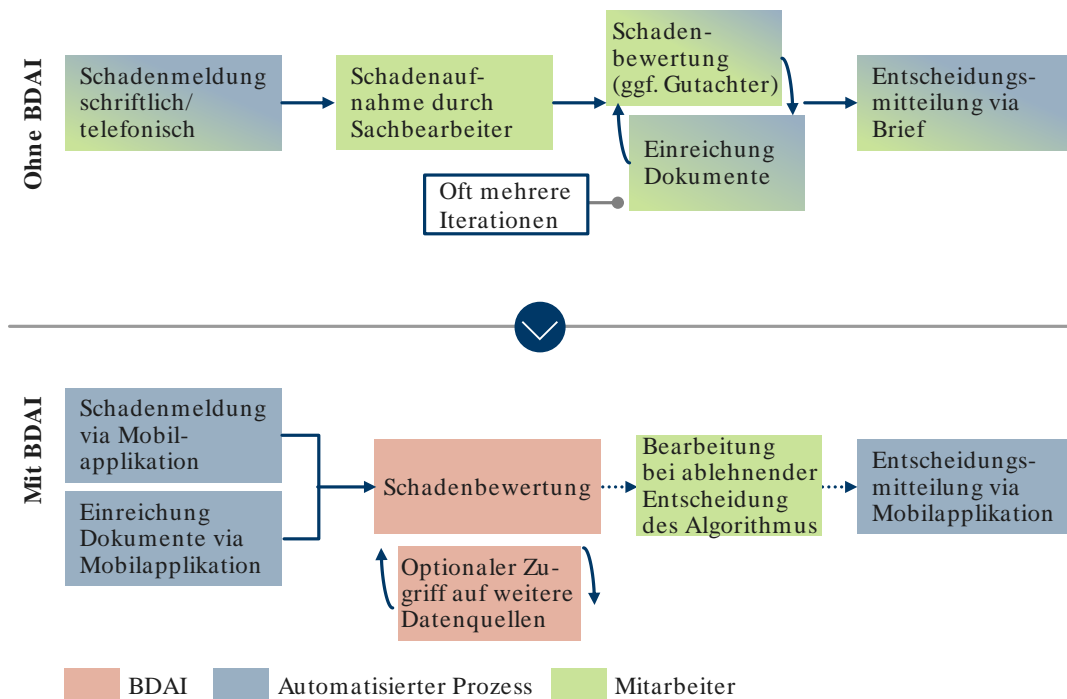
Durch den Einsatz von BDAI – genauer gesagt durch das maschinell unterstützte Auswerten öffentlich verfügbarer (z.B. Datenbanken mit Preisen für Ersatzteile) sowie privater Datenquellen (z.B. eingereichte Bild- oder Videoaufnahmen von Versicherten) – kann das Schadenmanagement in dreierlei Hinsicht unterstützt werden:

- verbesserte Schadenregulierungsprozesse durch (teil-)automatische Bewertungen und Zusagen oder Absagen²⁵⁵ von Leistungen im Schadenfall,
- effizientere und effektivere Identifikation von Betrugsfällen durch präzisere Schadenserkenkung sowie
- Schadenprävention.

Verbesserte Schadenregulierung

Im Segment der Kompositversicherungen können Schadenregulierungsprozesse insofern durch BDAI-Anwendungen optimiert werden, als Schäden anhand von Bild- und/oder Videoaufnahmen vom Unfallort sowie weiteren Datenquellen automatisiert ausgewertet werden können. Dadurch verändert sich der gesamte Schadenregulierungsprozess, wie in der vereinfachten Darstellung in Abbildung 21 gezeigt wird.

Abbildung 21: Vergleich vereinfachter Schadenregulierungsprozess ohne vs. mit Einsatz von BDAI



Beispielsweise bieten schon Kraftfahrtversicherer in Deutschland und den USA ihren Versicherungsnehmern eine Schaden-App an, mit der diese bei einer Beschädigung ihres Kraftfahrzeugs Aufnahmen des Schadens in die Mobilapplikation einfügen und dem Versicherer übermitteln können. Der Standort²⁵⁶ sowie Datum und Uhrzeit werden dabei automatisch ermittelt und dem Datensatz hinzugefügt.

²⁵⁵ Gemäß Verhaltensregeln des GDV (Gesamtverband der Deutschen Versicherungswirtschaft e. V.) dürfen automatisiert nur Entscheidungen zugunsten eines Versicherungsnehmers erfolgen, d.h. nur die Annahme eines Antrags bzw. die Anerkennung der Leistungspflicht kann auf diese Weise beschieden werden.

²⁵⁶ Beispielsweise per Global Positioning System (GPS).

Mittlerweile haben sich auch spezialisierte Dienstleister etabliert, die mit Hilfe von Drohnen hochauflösende Bilder von Schäden (z.B. an Kraftfahrzeugen oder Gebäuden) erfassen und auf Basis von BDAI Erkenntnisse für Versicherungsunternehmen ableiten. Es existiert beispielsweise ein US-amerikanisches Start-up, das als Plattformanbieter vor allem in den USA, aber inzwischen auch in Europa und Australien Versicherungsunternehmen derartige Dienstleistungen offeriert.

Beispiel: Weitgehende Automatisierung der Schadenregulierung bei Hausratversicherungen

Das folgende Praxisbeispiel zeigt, dass es mit Hilfe von BDAI im Schadenfall unter bestimmten Voraussetzungen ausreichen kann, wenn der Versicherungsnehmer seinen Schaden lediglich meldet, ohne einen Nachweis zu erbringen. Ein niederländischer Versicherungskonzern hat 2016 damit begonnen, seinen Schadenregulierungsprozess in der Hausratversicherungssparte weitgehend zu automatisieren. Zunächst wurde mit Hilfe der Schadenhistorie von Versicherungsnehmern mit abgeschlossenen Hausratversicherungen (mit einer Laufzeit von mehr als sechs Monaten) ein Algorithmus angelehrt. Bei Schadenmeldung kann dieser auf Basis des versicherten Risikos (das Haus/der Hausrat), der Art des eingereichten Schadens (z.B. Brandschaden) und der gemeldeten Schadenhöhe in einem Großteil der Fälle vollautomatisch entscheiden, ob der Schaden reguliert werden muss oder nicht (überwachtes Lernen, vgl. Kapitel 3.2.1). Dazu wägt der Algorithmus das Risiko ab, dass es sich um eine betrügerische Schadenmeldung handelt. In strittigen Fällen überprüft ein Mitarbeiter den Sachverhalt manuell.

Beispiel: Betrugserkennung bei einem Kraftfahrtversicherer durch prädiktive Analytik

Ein amerikanischer Kraftfahrtversicherer verwendet beispielsweise prädiktive Analytik in einem zweistufigen Prozess zur Erkennung betrügerischer Schadenmeldungen und kombiniert dabei automatische und manuelle Arbeitsschritte. Zuerst werden alle Schadenmeldungen automatisiert auf der Basis eines durch verschiedene Datenquellen definierten Musters auf Betrugsverdacht geprüft. Im zweiten Schritt wird über Verdachtsfälle innerhalb einer speziellen Untersuchungseinheit (manuell) entschieden, um unbegründete Beschuldigungen durch automatisiert fehlerhaft identifizierte Betrugsfälle zu verhindern.

Einbeziehung von Wetterdaten und Daten vernetzter Geräte zur Schadenprävention

Um Schäden in der Kraftfahrtversicherung zu vermeiden bzw. zumindest zu mitigieren, können Versicherungsnehmern an ihrem jeweiligen Standort²⁵⁷ beispielsweise Wettervorhersagen und Hinweise zu Hagel-, Gewitter-, Sturm- oder Glatteisgefahren übermittelt werden, sodass sie etwa ihr Auto rechtzeitig vor Hagelschäden schützen können. Der Kontakt kann dabei über eine Mobilapplikation (via Push-Mitteilung), Kurznachricht oder E-Mail erfolgen. In mehreren Ländern (z.B. Deutschland, USA) bieten einzelne Kraftfahrtversicherer derartige Dienstleistungen bereits an. Diese Entwicklung wirft die Frage auf, welche Konsequenzen Versicherungsnehmern entstehen könnten, wenn sie die Hinweise nicht beachteten. Es ist jedoch zu erwarten, dass der Versicherungsnehmer einem risikoreicheren Kollektiv zugeteilt würde, wodurch sich seine Prämie erhöhen könnte.

Auch bei Hausrat- und Gebäudeversicherungen ist Schadenprävention möglich – einerseits durch Auswertung von Wetterdaten zur frühzeitigen Übermittlung von Prognosen und/oder Hinweisen, etwa den Keller mit Sandsäcken gegen Hochwasser zu schützen, andererseits durch Auswertung von kontinuierlichen Datenströmen vernetzter Geräte (IoT). Ein Versicherungsunternehmen könnte sich mit Zustimmung interessierter Versicherter mit deren Geräten verbinden, um beispielsweise den baldigen Ausfall oder Kurzschluss eines Toasters und damit Brandrisiken²⁵⁸ frühzeitig zu erkennen und zu kommunizieren. Des Weiteren könnte es interessierte Versicherte mit sonstigen erweiterten Dienstleistungen unterstützen – etwa mit der Information darüber, wie defekte Geräte sicher entsorgt werden können. Ein amerikanisches Start-up für Smart-Home-Sensoren kooperiert mit großen US-Versicherungsunternehmen, wodurch

²⁵⁷ Ermittelt per Global Positioning System (GPS).

²⁵⁸ Oder etwa Wasserschäden bei defekten Waschmaschinen.

Versicherungsnehmern „Smart Sensors“²⁵⁹ für deren Wohnungen und/oder Häuser angeboten werden können. Schäden im Haushalt werden dabei automatisiert dem Versicherer mitgeteilt. Zugleich ermöglichen diese Sensoren Versicherern, auch bei Abwesenheit der Versicherungsnehmer direkt über Schäden (z.B. Vandalismus) informiert zu werden und entsprechende Gegenmaßnahmen einzuleiten (z.B. die Polizei zu informieren) und den Schadenregulierungsprozess anzustoßen.

3. Technologische Funktionsweise und Datenbasis

Die (voll-)maschinelle Erfassung und Bewertung von Versicherungsschäden wird künftig durch die Verfügbarkeit neuer Daten sowie den Einsatz von BDAI-Technologie ermöglicht. Zu den neuen Daten zählen insbesondere digitalisierte Bilder und Videos vom geschädigten Objekt bzw. Unfallort, öffentliche Wetterdaten sowie Marktdaten zu lokalen Preisen von Ersatzteilen oder Reparaturdienstleistungen. Zu den BDAI-Technologien gehören die Bild-, Video- und Spracherkennung zum automatisierten Auslesen etwa von digitalisierten Beschreibungen von Unfallhergängen und beschädigten Objekten sowie Sensorik zur fortlaufenden Sammlung von Daten, die beispielsweise in Smartphones und Kraftfahrzeugen eingebaut wird. Darüber hinaus ermöglicht die AI-basierte Dokumentenanalyse den systematischen Abgleich von Versicherungsbedingungen in Vertragswerken mit schriftlich eingereichten Forderungen und Stellungnahmen von Versicherungsnehmern und deren Anwälten. Die mit Hilfe der genannten Technologien aus den Daten gewonnenen Informationen unterstützen die Entscheidung, ob ein Schaden reguliert wird, und fließen in statische oder dynamische Modelle zum Festlegen der Höhe der Einzelschadenreserven ein.²⁶⁰

Die für eine stärker automatisierte Schadenregulierung erforderlichen Daten können Versicherer aus unterschiedlichen Quellen beziehen. Wetter- und Preisdaten können sie von spezialisierten Anbietern einkaufen. Bild- und/oder Videomaterial können sie direkt vom Versicherungsnehmer (oder einem Bevollmächtigten) erhalten – durch Fotografie und Zusendung der (Unfall-)Bilder etwa über eine Mobilapplikation. Oder sie setzen Drohnen ein, die die erforderlichen Beweisbilder (z.B. von Hurrikan-Schäden) zur Schadenregulierung aus der Luft aufnehmen und zur Auswertung an Versicherungsunternehmen übermitteln.

Dreistufige Analyse zur BDAI-basierten Betrugsaufdeckung

Zur BDAI-basierten Betrugsaufdeckung können grundsätzlich drei automatisierte Analysen kombiniert werden: die Analyse des Schadens/der Schadenmeldung, die Analyse des Versicherungsnehmers sowie eine Netzwerkanalyse. Ziel der Schadenanalyse ist die automatische Indikation verdächtiger Schadenmuster. Auf Basis der internen Schadenhistorie, von Daten zu früheren Schäden bei anderen Versicherungsunternehmen und allgemeinen Unfallstatistiken können Algorithmen Fragen wie „Passt die Schadenhöhe zum Unfall?“ oder „Passt die medizinische Diagnose zum Unfall?“ prüfen. Ziel der Versicherungsnehmeranalyse ist die automatische Erkennung betrügerischen Verhaltens. Anhand der internen Schadenhistorie, von Daten zu früheren Schäden bei anderen Versicherungsunternehmen und der Kreditauskunftei²⁶¹ können Algorithmen Vorfragen wie „Ist die finanzielle Situation des Versicherungsnehmers angespannt?“ prüfen.²⁶² Ziel der Netzwerkanalyse ist die Erkennung von Verbindungen zu betrügerischen Netzwerken. Mit den bei der Versicherungsnehmeranalyse verwendeten Daten können Algorithmen Fragen wie „Bestehen verdächtige Beziehungen zu anderen Schäden?“ oder „Bestehen verdächtige Beziehungen eines Versicherungsnehmers zu kriminellen Netzwerken?“ analysieren.

²⁵⁹ Sensoren zur Überprüfung von z.B. Temperatur, Luftfeuchtigkeit, Bewegung und Geräuschen.

²⁶⁰ Die Einzelschadenreserve erfasst den Aufwand für den Schaden buchhalterisch und wird bei Auszahlung aufgelöst. „Dynamisch“ bedeutet in diesem Zusammenhang, dass die Algorithmen der Bewertungsmodelle sich auf Basis neuer Daten fortlaufend selbst modifizieren und ihre Prognosegüte verbessern.

²⁶¹ Zugriffe für Versicherungsunternehmen sind je nach Staat unterschiedlich geregelt.

²⁶² Technisch gesehen können auch die sozialen Medien hinzugezogen werden, um die Analyse eines Versicherungsnehmers weiter zu differenzieren.

4. Chancen

Die dargestellten Ansätze zur Unterstützung des Schadenmanagements bei Kompositversicherungen sind mit einer Reihe von Chancen für Versicherungsnehmer und Versicherungsunternehmen verbunden. Zusammengefasst könnten Versicherungsnehmer von einem verbesserten Kundenerlebnis, niedrigeren Prämien, zusätzlichen Dienstleistungen und sogar von weniger Schadenfällen profitieren. Versicherungsunternehmen wiederum könnten die Bindung zu ihren Versicherungsnehmern durch ein verbessertes Kundenerlebnis stärken, Verwaltungskosten einsparen, betrügerische Ansprüche früher und besser identifizieren und eine häufigere, positive Interaktion mit den Versicherten pflegen.

Perspektive der Versicherungsnehmer

In den kommenden Jahren werden sich das Verhalten der Versicherungsnehmer und ihre Erwartungen an Geschäftsprozesse weiter verändern. Zunehmen werden vor allem der Anteil digitalisierungsaffiner Versicherungsnehmer und deren Erwartung, mit dem Versicherer vermehrt digital zu interagieren, also z.B. via Mobilapplikation. Der Einsatz von BDAI im Schadenmanagement könnte sich anbieten, um dem adäquat Rechnung zu tragen.

Das Kundenerlebnis bei der Schadenregulierung könnte sich durch zwei Effekte verbessern: Zum einen könnte die Schadenbearbeitungszeit verkürzt werden. Gerade in komplexen Schadenfällen, insbesondere in der privaten Krankenversicherung, in der Versicherungsnehmer für Leistungen in Vorkasse treten, käme dies den Versicherungsnehmern zugute, weil sie früher Gewissheit über die Entscheidung zur Schadenübernahme hätten. Zudem könnte die Schadenleistung schneller ausgezahlt werden. In einfachen Schadenfällen könnte die Entscheidung über die Schadenübernahme sogar innerhalb von Minuten nach Schadenmeldung erfolgen.²⁶³

Zum anderen könnte die Schadenregulierung aus Sicht der Versicherungsnehmer vereinfacht werden, weil die zeitintensive schriftliche Schadendokumentation entfällt oder zumindest weniger aufwändig ist, weil der Versicherungsnehmer im Idealfall physische Rechnungen nicht aufbewahren²⁶⁴ und – im Fall von Kraftfahrtschäden – weil er keine Kostenvoranschläge in Reparaturwerkstätten einholen muss.

Gibt es durch eine verbesserte Betrugserkennung und Schadenprävention weniger Schadenfälle und dadurch geringere Schadenkosten, erweitert dies den Raum für niedrigere Beiträge. Vor allem eine verbesserte Betrugserkennung könnte positive Effekte haben, denn sie deckt systematische Betrugssysteme auf, die ehrliche Versicherungsnehmer durch erhöhte Prämien schädigen.

Im Rahmen verbesserter Schadenprävention könnten Versicherungsnehmern neuartige Dienstleistungen angeboten werden. Ihnen könnten beispielsweise (nach Zustimmung) anhand von Aufnahmen ihrer Häuser Vorschläge für einen besseren Gebäudeschutz unterbreitet werden.

Außerdem könnten Versicherungsunternehmen durch Schadenprävention versuchen, die Wahrscheinlichkeit des Eintritts von Schadenfällen zu reduzieren und damit einhergehende Aufwände für Versicherungsnehmer zu vermeiden.

²⁶³ Ergebnis der Auswertung von Interviews mit Anbietern. Die Verbesserung des Kundenerlebnisses durch Rückmeldung per Mobilapplikation nach ein paar Minuten anstatt per Post nach (je nach Fall) wenigen Tagen bewerten Versicherungsnehmer erwartungsgemäß unterschiedlich stark.

²⁶⁴ Künftig könnten sämtliche Rechnungen in digitaler Form in einer Mobilapplikation des Versicherers abgespeichert werden.

Perspektive der Versicherungsunternehmen

Ein wesentliches Ziel von Versicherungsunternehmen beim Einsatz von BDAI im Schadenmanagement besteht darin, einen Mehrwert für alle Versicherungsnehmer zu erzielen. Die Schadenregulierung ist der Teil der Wertschöpfungskette, an dem sich Versicherungsnehmer in aller Regel entscheiden, ob sie mit der Leistung ihres Versicherers zufrieden sind. Ein beschleunigter und bequemer Schadenregulierungsprozess ist somit ein zentraler Faktor, um die Kundenzufriedenheit und – damit einhergehend – die Bindung der Versicherungsnehmer an den Versicherer nachhaltig weiter zu stärken.

Durch den Einsatz der u.a. oben genannten Technologien könnten Versicherer Kosteneinsparungen aus stärker automatisierten Schadenregulierungsprozessen, einer effizienteren Erkennung von Betrugsfällen und einer verbesserten Schadenprävention durch intensivere Interaktion mit Versicherungsnehmern erzielen.

Zum einen könnten sich mit Hilfe von BDAI die internen Schadenregulierungskosten (d.h. im Wesentlichen die Kosten der Schadenabteilung) reduzieren lassen. Hierbei kommen zwei Effekte zum Tragen: Eine größere Zahl von Schäden könnte als „einfach zu regulieren“ eingestuft und maschinell unterstützt bzw. vollmaschinell abgewickelt werden.²⁶⁵ Zudem könnten sich die durchschnittlichen Schadenregulierungszeiten insgesamt verkürzen. Insbesondere komplexe Schadenfälle, die weiterhin manuell geprüft werden müssten, könnten durch BDAI unterstützt und dadurch effizienter bearbeitet werden. Zum anderen könnten sich die externen Schadenregulierungskosten (z.B. Kosten für Gutachter) reduzieren lassen, da sich in einer höheren Zahl von Schadenfällen die Dienstleistungen von Gutachtern durch Bild- und Videoanalysen ersetzen ließen.²⁶⁶ Das Kosteneinsparpotential durch BDAI im Schadenmanagement dürfte allerdings unternehmensspezifisch sein und von bereits erfolgten Automatisierungen und Investitionen abhängen.

Durch eine BDAI-basierte Automatisierung der Erkennung von Betrugsfällen könnten alle Schadenmeldungen zügiger auf Auffälligkeiten geprüft werden, wodurch Schadenauszahlungen für betrügerische Schadenmeldungen, die bislang nicht identifizierbar waren bzw. sind, vermieden werden könnten. Auf Basis von Schätzungen des Gesamtverbands der deutschen Versicherungswirtschaft belaufen sich die Schäden durch Versicherungsbetrug derzeit jährlich auf ca. vier Milliarden Euro.²⁶⁷ Auch kleinteilige Schäden, die bisher aufgrund des hohen manuellen Bearbeitungsaufwands nicht untersuchungswürdig waren, könnten schnell und effizient auf Betrug geprüft werden.

Könnte eine durchgängigere Schadenprävention gewährleistet werden, sollten weniger Schadenfälle eintreten, was zur Reduzierung der Schadenkosten führen würde. Gleichzeitig würde es Versicherungsunternehmen möglich, häufiger mit ihren Versicherungsnehmern zu interagieren und dadurch eine bessere Bindung zu diesen zu erreichen.

Bislang bestand – bei Schadenfreiheit – die Interaktion mit Versicherungsnehmern oftmals nur aus der Übermittlung z.B. der Beitragsrechnung, wohingegen mit Hilfe von BDAI Versicherungsnehmer kostenschonend zu jeder Zeit und an jedem Ort betreut werden könnten. Auf Basis neuer Daten bzw. Datenauswertung entstehen somit neue Dienstleistungsmöglichkeiten, die Versicherte und Versicherer enger zusammenbringen. Insbesondere der Mehrwert einer Versicherung würde durch die Dienstleistung „Prävention“ für Versicherungsnehmer transparenter: Ein Versicherungsunternehmen könnte seinen Versicherungsnehmern überzeugend das Gefühl vermitteln, sich permanent um sie zu kümmern, selbst wenn kein akuter Schadenfall vorliegt.

²⁶⁵ Bereits ohne BDAI können viele Schäden mit geringem manuellem Aufwand reguliert werden.

²⁶⁶ Inwiefern BDAI-basierte Bild- und Videoanalysen gerichtsfest wären, ist im Rahmen dieser Studie nicht absehbar.

²⁶⁷ Insurance Europe, 2013, The impact of insurance fraud, S. 11.

Für den Versicherungsmarkt in Großbritannien wird vermutet, dass ein Schaden von ca. 2,2 Milliarden Euro durch Versicherungsbetrug jährlich unentdeckt bleibt, vgl. Insurance Europe, 2013, The impact of insurance fraud, S. 9.

5. Risiken

Die dargestellten Ansätze zur Unterstützung des Schadenmanagements sind aber auch mit Risiken verbunden.

Perspektive der Versicherungsnehmer

Für Versicherungsnehmer besteht ein gewisses Risiko, dass die verwendeten Einzelschadenbewertungsmodelle dazu führen, dass Schadenfälle systematisch unberechtigterweise abgelehnt werden. Insbesondere könnten BDAI-unterstützte Netzwerkanalysen dazu führen, dass Versicherungsnehmer bei Schadenmeldung unwissentlich und fälschlicherweise einer bestimmten Kategorie (z.B. „Beziehung zu kriminellem Netzwerk“) zugeordnet werden. Dadurch könnten Versicherungsnehmern vermeidbare (auch zeitliche) Aufwände entstehen, um vor Gericht ihre Ansprüche durchzusetzen. Es könnte zudem das Risiko bestehen, dass Versicherer die Regulierung eines Schadens bei Nicht-Beachtung von Präventionshinweisen auch ausschließen und somit im Einzelfall Schadenfälle nicht oder zumindest nicht in voller Höhe beglichen werden.

Die Digitalisierung von Schadenregulierungsprozessen wirft die Frage auf, inwiefern damit einhergehende Veränderungen langfristig bestimmte Versicherungsnehmer in ihrer Interaktion mit Versicherern einschränken könnten. Sofern beim Ausbau des Online-Kanals, also der Möglichkeit, Schäden z.B. via Mobilapplikation zu melden, einzelne Personen wie etwa die weniger technologieaffinen Versicherungsnehmer²⁶⁸ benachteiligt werden würden, wäre aus aufsichtlicher Sicht sicherzustellen, dass die Interessen aller Versicherungsnehmer auch weiterhin ausreichend gewahrt werden. Ferner ist hierbei sicherzustellen, dass sich auch weniger technologieaffine Versicherungsnehmer weiterhin zu vertretbaren Konditionen versichern können.

Des Weiteren könnte es durch den Einsatz von BDAI im Schadenmanagement aus Sicht eines Versicherten potenziell noch komplizierter werden nachzuvollziehen, was das Versicherungsunternehmen durch Auswertungen seiner Daten konkret über ihn weiß und welchen Einfluss diese Erkenntnisse wiederum auf die Bearbeitung seiner Schadenfälle und die Zusammensetzung seiner Prämien hat.

Je nach Ausgestaltung einzelner Präventionsmaßnahmen werden Versicherer über recht genaue Bewegungsmuster ihrer Versicherungsnehmer verfügen. Sofern dies künftig rechtlich zulässig sein sollte, müssen die Versicherer sicherstellen, dass diese Informationen nicht zweckentfremdet werden können. Mit Blick auf die angesprochenen Smart Sensors ist zudem die IT-Sicherheit zu berücksichtigen. Dabei steht eine Frage im Mittelpunkt: Sind die Zugriffswege der Versicherer auf derartige Geräte genügend abgesichert, um Datenangriffe zu unterbinden und Manipulationen vorzubeugen?

Zum Zweck einer stärkeren Automatisierung der Bewertung eines Schadenfalls würden Versicherungsnehmer ihren Versicherern gegebenenfalls sensibles Beweismaterial übermitteln müssen. Bei den Kompositversicherungen dürfte der Grad der Sensibilität des eingereichten Beweismaterials im Vergleich z.B. zu Gesundheitsdaten und Arztberichten in den meisten Fällen weniger hoch sein. Gleichwohl setzen sich Versicherungsnehmer auch bei Kompositversicherungen dem grundsätzlichen Risiko aus, dass ihre Daten missbraucht und zweckentfremdet werden. Durch angemessene Marktstandards zur Gewährleistung transparenter Datenverarbeitung könnte dieses Risiko zukünftig mitigiert werden. Es gilt retrospektiv zu prüfen, ob mit Inkrafttreten der EU-DSGVO im Mai 2018 bereits ausreichende Marktstandards gesetzt worden sind.²⁶⁹

²⁶⁸ Beispielsweise Versicherungsnehmer, die es gewohnt sind, handschriftlich verfasste/ausgefüllte Schriftstücke per Post einzureichen oder die eine digitale Kommunikation bewusst nicht wünschen. Ein Versicherungsnehmer muss immer eine echte Wahl haben, wie er kommunizieren möchte.

²⁶⁹ Verbraucher haben durch die EU-DSGVO beispielsweise das Recht, jederzeit Auskunft darüber zu erhalten, wofür welche ihrer personenbezogenen Daten verwendet werden. Zudem haben sie u.a. das Recht auf Berichtigung, Löschung und Einschränkung der Verarbeitung ihrer Daten.

Perspektive der Versicherungsunternehmen

Um BDAI-Potentiale in Versicherungsunternehmen zu heben, bedarf es für die meisten Unternehmen – in Abhängigkeit von der Ausgangssituation – der Investition in entsprechende IT-Architektur und qualifiziertes Personal. Da Versicherungsunternehmen bislang teilweise nur begrenzt Erfahrungswerte im Umgang mit BDAI sammeln konnten, können derartige Investitionen mit einem beachtlichen Projektrisiko verbunden sein. In der Erprobungsphase des Einsatzes von BDAI im Schadenmanagement könnte es passieren, dass Schäden systembedingt fehlerhaft reguliert werden, etwa weil Algorithmen fälschlicherweise Schäden annehmen. Ein solches Szenario könnte zu hohen Schadenauszahlungen und damit Profitabilitätseinbußen führen. Große Versicherer könnten dieses Risiko unter Umständen besser mitigieren als kleinere Versicherer, die BDAI-Technologie nur im Zuge stärkeren Wettbewerbsdrucks implementierten und gegebenenfalls nicht über hinreichende Daten verfügen, um den Algorithmus selber anzulernen, sondern die Daten extern erwerben mussten. So könnten große Versicherer beispielsweise die Reichweite der Algorithmen im Unternehmen zunächst beschränken und anschließend sukzessive ausbauen.

Es könnte auch der Fall eintreten, dass Schadenfälle systembedingt fälschlicherweise nicht reguliert werden, wodurch Versicherer das Vertrauen ihrer Versicherungsnehmer verlieren könnten. Zudem könnte negatives Presseecho potenzielle Versicherungsnehmer zu Wettbewerbern treiben. Ferner könnte ein erhöhtes Prozessrisiko entstehen, da bei nicht gerechtfertigten Ablehnungen mehr Klagen seitens der Versicherungsnehmer zu erwarten wären.

Denkbar ist auch, dass Schadenfälle von den eingesetzten Algorithmen zwar korrekterweise als „zu regulieren“ eingestuft werden, die Höhen der zu bildenden Einzelschadenreserven aber systematisch zu niedrig oder zu hoch berechnet werden. Die Ergebnisse BDAI-basierter Einzelschadenbewertungsmodelle dienen als Input für aktuarielle Verfahren zur Bewertung von IBNR²⁷⁰-/Spätschäden und für weitere Folgeprozesse z.B. der Risikokapitalberechnung. Somit besteht das Risiko, dass BDAI-induzierte Fehlbewertungen von Einzelschadenreserven die Auskömmlichkeit der Gesamtschadenreserven (versicherungstechnische Rückstellungen) beeinflussen und zur Unterreservierung führen. Insbesondere könnten Modellanpassungen und die Neukalibrierung dieser Modelle eine zeitliche Instabilität der Einzelschadenreserven bewirken und damit mögliche Strukturbrüche in den Eingangsdaten für die aktuariellen Bewertungsverfahren und Risikokapitalberechnungen zur Folge haben. Hieraus ergibt sich eine besondere Herausforderung für Aktuarer, die auch im Zeitalter von BDAI dafür verantwortlich wären, dass die versicherungstechnischen Rückstellungen den gesetzlichen Anforderungen²⁷¹ genügen.²⁷² Solange die Beschäftigten in der Assekuranz nicht die erforderlichen Qualifikationen erlangen, um (selbstlernende) Algorithmen zu verstehen und zu warten, birgt BDAI demnach das Risiko einer möglichen Unterreservierung und damit der Intransparenz, was die tatsächliche Solvenzsituation angeht. Systematisch fehlerhafte Einzelschadenbewertungen wären insbesondere in den langabwickelnden Versicherungssparten gravierend, da potenzielle Fehlbewertungen unter Umständen erst nach einigen Jahren bei der Auszahlung bekannt würden.

²⁷⁰ Incurred But Not Reported.

²⁷¹ Die gesetzlichen Anforderungen umfassen in Deutschland u.a. die Auskömmlichkeit der Schadenreserven, vgl. z.B. §§ 75ff. VAG i.V.m. Art. 19ff DVO.

²⁷² Dies könnte insbesondere bei den langabwickelnden Versicherungssparten ein Problem darstellen, zumal hier für gewöhnlich auch die von BDAI beeinflussten Aufwandsdaten die dominante Datenbasis sind. Kurzabwickelnde Sparten, bei denen vorwiegend Zahlungsdaten herangezogen werden, dürften sich dagegen relativ robust erweisen, was den Einsatz von BDAI in Einzelschadenbewertungsmodellen angeht.

Die Brisanz dieses operationellen Risikos wird dadurch verdeutlicht, dass Versicherungen gerade bei entsprechendem Wettbewerbsdruck geneigt sein könnten, von Drittanbietern bereitgestellte Algorithmen einzukaufen, um interne Entwicklungskosten einzusparen. Die Erklärbarkeit der Funktionsweise dieser unternehmensfremden Algorithmen sicherzustellen, wäre für die Versicherer eine besondere Herausforderung. Das Thema Erklärbarkeit von Modellen wird in Kapitel 3.5.2 detailliert dargestellt. An dieser Stelle stellt sich darüber hinaus die Frage, inwiefern Versicherungsunternehmen künftig die Qualität von Datensätzen und damit der Entscheidungsgrundlage BDAI-basierter Modelle sicherstellen können, insbesondere wenn Daten externer Dienstleister zugekauft werden.

Ein vergleichbares operationelles Risiko besteht darin, dass möglicherweise Fehlinformationen zur vermeintlichen Schadenprävention verbreitet werden. Verlassen sich Versicherungsnehmer zurecht darauf, vom Versicherer rechtzeitig informiert zu werden, trägt dieser eine besondere Verantwortung gegenüber seinen Versicherten. Fehlinformationen durch maschinelle Fehlinterpretation von Daten könnten Versicherungsnehmer vermeidbaren Gefahren im Straßenverkehr bzw. Haushalt aussetzen. In der Folge gälte das Versicherungsunternehmen möglicherweise nicht mehr als verlässlicher Partner.

6. Aufsichtliche und regulatorische Themen

Das vorliegende Anwendungsbeispiel impliziert verschiedene Fragen, mit denen sich die Aufsicht beschäftigen muss. Diese werden zum Abschluss des Anwendungsbeispiels im nächsten Absatz kurz genannt und in Kapitel VI dieser Studie nochmals aufgegriffen.

Aus der BDAI-basierten Datenauswertung zur Unterstützung des Schadenmanagements resultieren vor allem das aufsichtlich relevante Thema dynamischer Einzelschadenbewertungsmodelle und die Frage der künftigen Anforderungen an deren Güte und Überprüfbarkeit. Daran schließt sich das Thema der Abhängigkeit von externen Datendienstleistern und die Frage nach geeigneten Standards zur Gewährleistung der Datenqualität an. Ein weiteres Thema sind die zweckgemäße Verwendung von Daten durch Versicherungsunternehmen im Sinne des Verbraucherschutzes – zum Erhalt des Verbrauchervertrauens und zur Eindämmung der potenziellen Gefahr eines Missbrauchs sensibler Daten durch kriminelle Netzwerke oder auch Versicherungsunternehmen selbst.

5.3.7.2 Produktentwicklung durch Hinzunahme externer Daten

1. Einleitung

Die Produktentwicklung²⁷³ ist ein weiterer zentraler Prozess in allen Versicherungsunternehmen. Er könnte über alle Sparten hinweg durch den Einsatz von BDAI beschleunigt und stärker als bislang automatisiert werden.

Der Prozess der Entwicklung von Versicherungsprodukten lässt sich in drei Schritte unterteilen. Im ersten Teilschritt werden die Versicherungsbedingungen festgelegt. Es werden sowohl die versicherten Risiken als auch die Ausschlüsse definiert. Vom Versicherungsschutz ausgeschlossen werden bestimmtes Verhalten, bestimmte Risiken oder besondere Umstände. Darüber hinaus können je nach Produkt weitere Optionen in die Versicherungsbedingungen aufgenommen werden.²⁷⁴ Zum zweiten Teilschritt der Produktentwicklung zählt die Festlegung weiterer Nebenbedingungen, z.B. die Bestimmung von Zahlungsvereinbarungen, Vertriebskanälen und sonstigen Vertragsbedingungen.²⁷⁵ Die Preisgestaltung ist der dritte Teilschritt in der Produktentwicklung. Durch Festlegung aller relevanten Versicherungsbedingungen (Risiken, Risikoklassen und Nebenbedingungen) kann ein bestimmter Preis für ein Versicherungsprodukt ermittelt werden. Jedes Risiko ist dabei objektbezogen (z.B. auf ein Kraftfahrzeug einer bestimmten Marke) und liefert relevante Informationen zur Ableitung von Risikoklassen.

Im vorliegenden Anwendungsbeispiel wird sowohl für Kranken- und Lebens- als auch für Kraftfahrt-Haftpflichtversicherungen dargestellt, wie Versicherungsunternehmen BDAI einsetzen könnten, um die Kalkulation risikoadäquater Beiträge – als Teil der Produktentwicklung – durch die Nutzung von zusätzlichen, meist externen Daten weiter zu verbessern, zu individualisieren und zu automatisieren.

2. Anwendung

Differenziertere Bepreisung des Versicherungsschutzes durch Nutzung externer Daten

In den Segmenten der Kranken- und Lebensversicherungen könnten externe Daten erfasst oder erworben und mit Hilfe von Algorithmen analysiert werden, um dadurch den Versicherungsschutz differenzierter zu bepreisen. Kostenintensive, größtenteils manuelle Gesundheitsbewertungen zur A-priori-Einschätzung von Risiken potenzieller Versicherungsnehmer könnten somit in vielen Fällen durch Risikomodelle²⁷⁶ ersetzt werden, von denen man sich mehr Präzision erhofft. Diese datenbasierten Modelle könnten potenzielle Gesundheitsrisiken möglicherweise nicht nur kosteneffizienter und schneller vorhersagen als Blut- und Urintests, sondern auch genauso effektiv.²⁷⁷

Beispiel: BDAI-basierte Bepreisung von Lebensversicherungen

Ein US-amerikanischer Versicherer bietet beispielsweise seit 2015 differenziert bepreiste Lebensversicherungen an, die Versicherungsnehmer zunächst ohne ärztliche Gesundheitsprüfung und innerhalb weniger Minuten online abschließen können.²⁷⁸ Die Risikobewertung basiert auf einer BDAI-

²⁷³ Im Rahmen dieses Berichts wird ein Versicherungsprodukt als ein konditionaler Vertrag verstanden, der für einen bestimmten Preis eindeutige, klar abgegrenzte Risiken abdeckt, also beim Eintritt bestimmter Ereignisse eine vordefinierte Entschädigung auszahlt. In diesem Bericht werden die Begriffe „Produkte“ und „Tarife“ synonym verwendet.

²⁷⁴ Als Beispiel kann hier die optionale, dynamische Anpassung der Invaliditätssumme von Unfallversicherungen an geänderte Lebensumstände angeführt werden.

²⁷⁵ Beispielsweise Kündigungsbedingungen.

²⁷⁶ Basierend auf Daten von Versicherungsnehmern (z.B. auf Bonitätsbewertungen, TV-Nutzungsverhalten, Online-Kaufverhalten, Freizeitbeschäftigungen, Abfragen von medizinischen Datenbanken und Rezeptregistern).

²⁷⁷ Siehe Scism et al., 2010, Insurers Test Data Profiles to Identify Risky Clients. In: The Wall Street Journal.

²⁷⁸ Das Versicherungsunternehmen schließt Gesundheitsprüfungen nicht vollkommen aus, sie bilden aber die Ausnahme.

unterstützten Auswertung von Online-Fragebögen und öffentlichen (Gesundheits-)Datenbanken nahezu in Echtzeit. Nach demselben Prinzip verwendet eine deutsche Start-up-Versicherung eine für den B2B-Bereich entgeltlich bereitgestellte Plattform zum Onlineverkauf BDAI-basierter Lebens- und Berufsunfähigkeitsversicherungen.

Beispiel: Preisgestaltung auf Basis von Bilderkennung bzw. ausgewerteten Verhaltensdaten

Ein anderer US-amerikanischer Lebensversicherer unterbreitet potenziellen Versicherungsnehmern einen Preisvorschlag für eine Lebensversicherung auf Basis digitaler Fotos, die auf seiner Website hochgeladen werden. In Zusammenarbeit mit dem Technologieunternehmen Lapetus extrahiert dieser Versicherer dazu mit Hilfe von AI aus den Fotos Informationen zu Alter, Geschlecht²⁷⁹ und Body-Mass-Index.²⁸⁰

Am Beispiel eines in Südafrika entwickelten und mittlerweile auch von großen Versicherungsunternehmen in Deutschland und Frankreich angebotenen Bonusprogramms, das Kranken- und/oder Lebensversicherungsverträge ergänzt, zeigt sich darüber hinaus, dass BDAI es ermöglicht, neue innovative Geschäftsfelder zu etablieren. Durch die kontinuierliche Erfassung von Verhaltensdaten von Versicherungsnehmern²⁸¹ können detaillierte Profile erstellt werden. Bei risikobewusstem Verhalten werden Versicherungsnehmer dann entweder durch Beitragsrückerstattungen oder durch die Ausgabe von Gratifikationen (Vouchers etc.) belohnt²⁸² und zugleich motiviert, weiterhin risikopräventiv zu leben. Durch anreizbasierte Versicherungsprodukte könnte das Versicherungsgeschäft von Kranken- und Lebensversicherern um den Aspekt der Gesundheitsprävention erweitert werden.

Tarifierung von Kraftfahrtversicherungen auf Basis von Telematik-Daten

Im Segment der Kraftfahrt-Haftpflichtversicherung findet insbesondere die Telematik Anwendung, um externe personen- und fahrzeugbezogene Informationen maschinell zu erfassen und anschließend den Versicherungsschutz differenzierter zu bepreisen. Risiken werden hierbei nicht nur anhand sekundärer Daten (Wohnort etc.), sondern auch mit Hilfe primärer Daten aus dem Fahrverhalten und den Fahrbedingungen (Wetterbedingungen, Verkehrsaufkommen, Baustellensituation etc.) bewertet. Anhand der erfassten Informationen sind eine differenziertere Risikobewertung und Versicherungsprämienberechnung möglich – unter Umständen sogar in Echtzeit. Die Darstellung in Abbildung 22 zeigt illustrativ, wie Versicherungsnehmer innerhalb eines Risikokollektivs mit Hilfe zusätzlicher Risikoprädiktoren neu entwickelten Kfz-Tarifen zugeordnet werden könnten.

²⁷⁹ Die Berücksichtigung von Informationen zum Geschlecht zum Zweck der individuellen Preisfindung ist in der EU verboten.

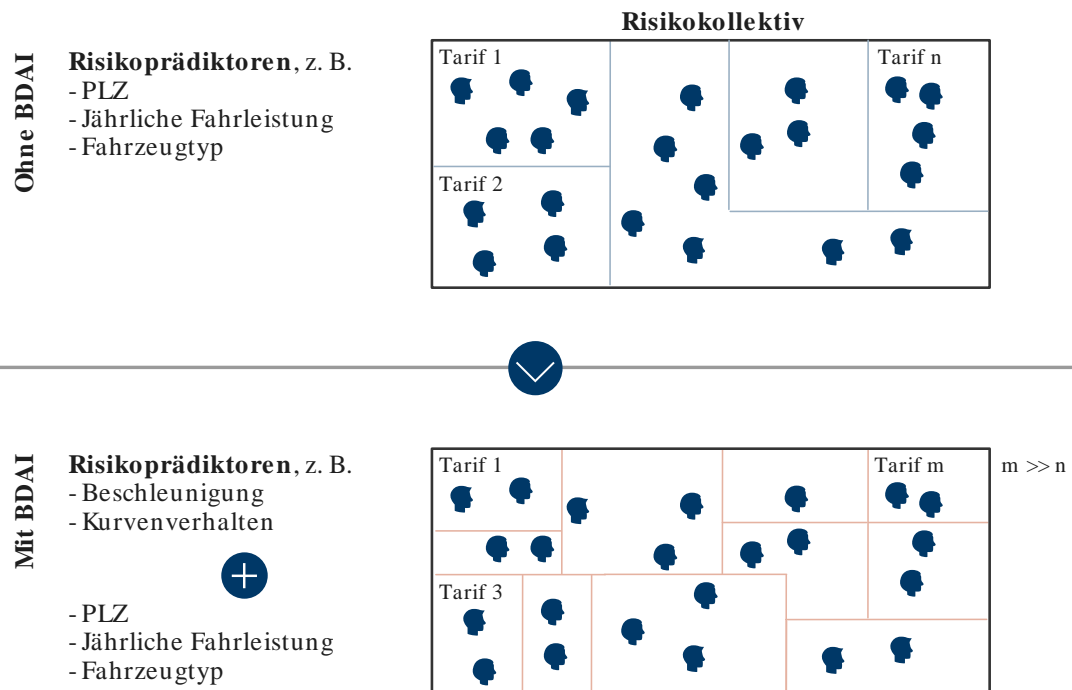
²⁸⁰ BusinessWire, 2017, The Power of a Selfie: Legal & General America Launches SelfieQuote.com. Online verfügbar: <http://www.businesswire.com/news/home/20170731005616/en/Power-Selfie-Legal-General-America-Launches-SelfieQuote.com>, abgerufen am 08.11.2017.

²⁸¹ Mit Hilfe von Fitness- oder Gesundheitstrackern.

²⁸² In Deutschland darf die Tarifeinstufung auf Grundlage einer Gesundheitsprüfung bei Vertragsbeginn durch Umstände, die nach Vertragsschluss beim Versicherten eintreten, nicht geändert werden (vgl. Antwort der Bundesregierung auf die Anfrage der Fraktion BÜNDNIS 90/DIE GRÜNEN vom 09.11.2016, Drs. 18/10259; ebenso Stellungnahme PKV-Verband zu Big Data und Gesundheit vom 31.03.2017).

Nicht ausgeschlossen sind nach Auffassung des PKV-Verbandes Anreizsysteme, bei denen gesundheitsbewusstes Verhalten über Beitragsrückerstattungen honoriert wird, insoweit nachweislich Versicherungsleistungen eingespart werden können (vgl. PKV-Verband, Big Data, Nr. 6). Zudem besteht nach Auffassung des PKV-Verbands versicherungsrechtlich die Möglichkeit, von Beginn an einen Versicherungstarif mit eigener Prämienkalkulation anzubieten, der mit der Bereitschaft zur laufenden Erhebung von gesundheitsrelevanten Daten verbunden ist.

Abbildung 22: Illustrative Zuordnung von Versicherungsnehmern zu Kfz-Tarifen ohne vs. mit BDAI



Ferner kann der Einsatz von Telematik zur effektiven Schadenprävention genutzt werden. So können Versicherungsnehmer motiviert werden, durch Anpassung ihres Fahrverhaltens Beitragserstattungen zu erhalten.

Die Idee, Daten zum Fahrverhalten und zur Fahrsituation in der Risikobewertung zu berücksichtigen, bestand bereits in den 1930er Jahren. Jedoch mangelte es damals noch an den technischen Möglichkeiten, derartige situative Daten zu erfassen.²⁸³ Mittlerweile ist die Nutzung von Telematik-Tarifen sowohl in Nordamerika als auch in Europa stärker etabliert. Schätzungsweise jeweils zehn Millionen Telematik-Policen waren 2016 in Nordamerika und Europa aktiv. Bis 2019 könnte die Zahl dieser Policen auf 33 Millionen in Nordamerika bzw. 27 Millionen in Europa steigen, was jährlichen Wachstumsraten von 40 bis 50 Prozent entspricht.²⁸⁴

In Deutschland werden bislang nur wenige Telematik-Tarife angeboten. Große deutsche Versicherer offerieren Telematik-Tarife bislang nur für Fahrer unter 30 Jahren. Dieses Kundensegment beinhaltet traditionell viele hohe Risiken, sodass hier Telematik besonders geeignet ist, um sicheres, regelkonformes Fahrverhalten zu incentivieren. Ein kleinerer deutscher Kraftfahrtversicherer hatte 2013 einen Telematik-Tarif pilotiert, 2015 jedoch bereits wieder eingestellt. Trotz hoher allgemeiner Kundenzufriedenheit war der Preispunkt (noch) zu hoch angesetzt. Die kritische Menge an Versicherten konnte nicht gewonnen werden. Insbesondere der Betrieb des umfangreichen Angebots (z.B. Feedback zum Fahrverhalten, Notruf bei Unfällen) verursachte hohe Kosten für den Versicherer.

²⁸³ Dorweiler, 1929, Notes on Exposure and Premium Bases. In: Proceedings of the Casualty Actuarial Society XVI, S. 319; Nachdruck: PCAS LVIII, 1972, S. 59.

²⁸⁴ Berg Insight, 2016, Insurance Telematics in Europe and North America. In: M2M Research Series.

3. Technologische Funktionsweise und Datenbasis

Im Folgenden wird die Funktionsweise der BDAI-basierten Produktentwicklung bzw. Preisgestaltung zunächst in den Kranken- und Lebensversicherungssparten und anschließend in der Kraftfahrt-Haftpflichtversicherung dargestellt.

Produktentwicklung bzw. Preisgestaltung in den Kranken- und Lebensversicherungssparten

Für die BDAI-unterstützte Risikobewertung zur Bepreisung eines Kranken- oder Lebensversicherungsvertrags könnte die erforderliche Datenerhebung rein online oder in einem Verkaufsgespräch durch einen Versicherungsvermittler erfolgen. Potenzielle Versicherungsnehmer würden dazu (online oder vor Ort beim Vermittler) interaktive Gesundheitsfragebögen ausfüllen und erhielten anschließend das Ergebnis ihrer Risikobewertung in Form eines differenzierten Preises. Im Hintergrund sammelt, digitalisiert und strukturiert ein Algorithmus die vom Interessenten eingegebenen Daten und überführt sie in ein Risikomodell. Hierbei handelte es sich um ein Modell des überwachten Lernens, wie in Kapitel 3.2.1 erläutert. Je nach Fall benötigte das Risikomodell einen unterschiedlich detaillierten Datensatz. Basierend auf Kosten-Nutzen-Abwägungen würden automatisiert weitere Datenquellen herangezogen, um die Risikobewertung stärker zu differenzieren. Dabei würden preiswertere Datenquellen zuerst verwendet werden. D.h. die erfragten Personendaten würden zunächst mit intern verfügbaren, bereits digitalisierten Datenquellen (z.B. mit bestehenden und/oder früheren Policen, Krankheitsverläufen, Fotos, Laborberichten) angereichert. Darüber hinaus könnten Daten z.B. durch Gesichtsscans oder eine Algorithmen-basierte Auswertung von Social-Media-Profilen generiert werden. Sollten diese Daten keine ausreichend genaue Risikobewertung zulassen, könnten mittels OCR-Lösungen²⁸⁵ unstrukturierte Daten ausgelesen werden. Falls weiterhin keine eindeutige Aussage zum Antrag getroffen werden könnte, würde im nächsten Schritt auf externe (Gesundheits-)Datenbanken zugegriffen, welche bereits digitalisierte und strukturierte Daten gegen Entgelt zur Verfügung stellen. Sollte trotz aller berücksichtigten Informationen keine abschließende Bewertung der Risiken durch den Algorithmus möglich sein, müsste eventuell in einem letzten Schritt eine manuelle Beurteilung erfolgen.

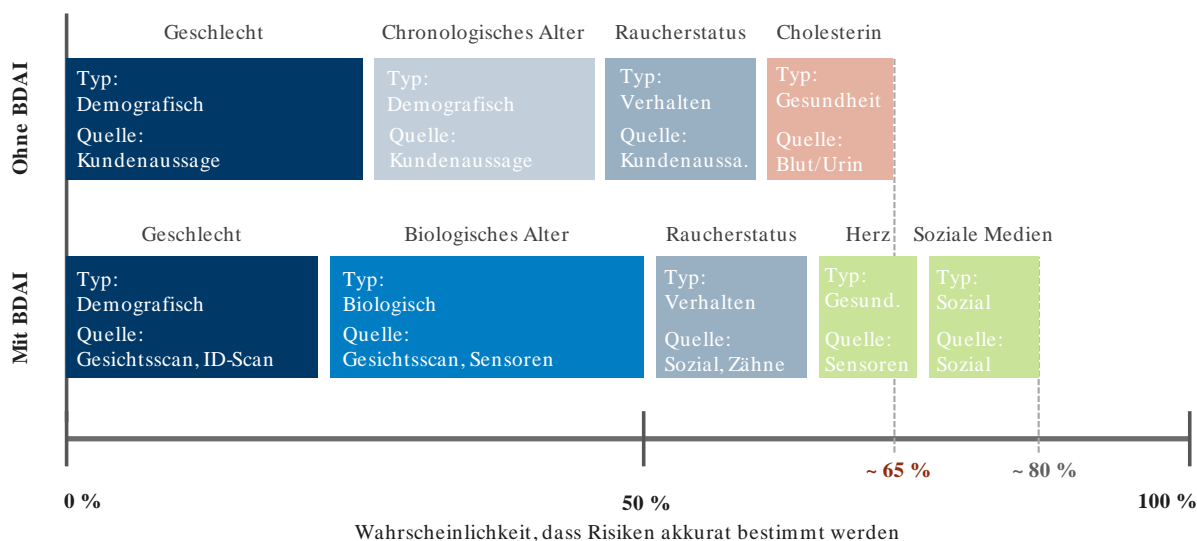
Bei anreiz- bzw. verhaltensbasierten Versicherungstarifen würden Daten mit Hilfe von Sensoren in Wearables oder ähnlichen Geräten fortlaufend gesammelt und gegebenenfalls an das Versicherungsunternehmen selbst oder einen Dienstleister gesendet. Anschließend könnte mittels Algorithmen bewertet werden, inwiefern ein finanzieller Ausgleich gerechtfertigt ist.²⁸⁶

Mögliche zur Auswertung verwendbare Datentypen und -quellen sind in Abbildung 23 dargestellt. Durch den Vergleich der heutigen konventionellen Preisgestaltung mit einer möglichen künftigen BDAI-basierten Preisgestaltung wird deutlich, dass die Risiken von Kranken- und/oder Lebensversicherungsnehmern genauer bestimmt werden könnten: Die durchschnittliche Wahrscheinlichkeit, dass Risiken akkurat bestimmt werden, könnte laut BCG nach ersten Expertenschätzungen von ca. 65 Prozent auf ca. 80 Prozent steigen. Deutlich wird aber auch, dass selbst mit Hilfe von BDAI-Technologie Risiken nicht hundertprozentig genau vorhergesagt werden könnten. Zudem ist bislang noch unklar, welche Auswirkung die Streuung in den verbleibenden ca. 20 Prozent auf den Preis des Risikos hätte.

²⁸⁵ Optical Character Recognition.

²⁸⁶ In Abhängigkeit der Rechtslage im jeweiligen Staat.

Abbildung 23: Vergleich von Datentypen und -quellen zur Preisgestaltung ohne vs. mit BDAI. BCG-Angaben nach ersten Expertenschätzungen.²⁸⁷



Produktentwicklung bzw. Preisgestaltung in der Kraftfahrt-Haftpflichtversicherung

Telematik umfasst die Erhebung aller möglichen Informationen (z.B. Geschwindigkeit) von entfernten, sich bewegenden Objekten (z.B. Kraftfahrzeuge) mit Hilfe des Telekommunikationsnetzwerks.²⁸⁸ Somit ermöglicht Telematik während einer Fahrt die Sammlung und Speicherung zahlreicher Datenbestände. Zur korrekten Ermittlung des situativen Risikos können Daten zum Fahrverhalten (Fahrzeugführer) und zur Fahrsituation (Umgebung) erhoben werden. Konkret umfasst dies soziodemografische und fahrzeugspezifische Vertragsdaten, Telematik-Daten etwa zur Geschwindigkeit, zur Beschleunigung, zum Brems- und Kurvenverhalten, zur Abstandseinhaltung, zu Streckendistanzen, zum Wetter und zum Verkehr und differenziert nach Verkehrsaufkommen, Streckenabschnitt, Datum, Uhrzeit, Wochentag und Jahreszeit.²⁸⁹ Mit Hilfe von BDAI können auf Basis der Daten verschiedene miteinander verbundene Analysen durchgeführt werden. Zum Beispiel könnte maschinell ausgewertet werden, ob ein Fahrer sich an Höchstgeschwindigkeiten hält und ob er vorausschauend und gleichmäßig fährt. Abruptes Beschleunigen und Bremsen könnten auf ein riskanteres Fahrverhalten und entsprechend höhere Unfallrisiken hindeuten. Auch Uhrzeit und Dauer einer Autofahrt könnten mit unterschiedlichen Risiken verbunden sein, beispielsweise sind der Berufsverkehr am Abend und nächtliche Fahrten am Wochenende risikoreicher als Fahrten am Vormittag.²⁹⁰

²⁸⁷ Wie bereits angemerkt, ist die Berücksichtigung von Informationen zum Geschlecht zum Zweck der individuellen Preisfindung in der EU verboten.

²⁸⁸ Berg Insight, 2016, Insurance Telematics in Europe and North America. In: M2M Research Series.

²⁸⁹ Transchel et al., 2016, Telematik: Was KFZ-Versicherer bereits heute nutzen können. In: Zeitschrift für Versicherungswesen, 15 – 16/2016, S. 491 – 496.

²⁹⁰ Transchel et al., 2016, Classification of scale-sensitive telematic observables for risk-individual Pricing. In: European Actuarial Journal 6(1), S. 3 – 24.

Die Datenerhebung erfolgt in der Regel entweder über eine fest installierte Blackbox oder über eine Telematik-App für das Mobiltelefon. Die Blackbox wird in der Regel an der OBD2-Schnittstelle (Fahrzeugdiagnosesystem) eines Autos angeschlossen. So kann die Blackbox während der Autofahrt über Steuergeräte auf Daten zugreifen und diese über Funk an Versicherer oder an Dienstleistungsanbieter versenden, welche die Daten auswerten und anschließend weiterverkaufen. Bei der zweiten Variante erfassen Sensoren eines Smartphones die relevanten Daten. Dazu zählen GPS-Sensoren zur Ortung, Beschleunigungssensoren zur Geschwindigkeitsmessung sowie Gyrosensoren zur Bewertung des Kurvenverhaltens. Über eine Telematik-Applikation werden die Fahrzeugdaten fortlaufend übermittelt und ausgewertet.

Die Entscheidung darüber, welche Daten nach welchen Kriterien zur Berechnung des Risikos verwendet werden, hängt von den einzelnen Anbietern ab. Ebenso variiert je nach Versicherer die Häufigkeit, mit der Prämien von Telematik-Tarifen neu berechnet werden. Beispielsweise hat sich ein deutscher Versicherer für ein Verfahren entschieden, bei dem bereits nach 25 Stunden Datenerhebung der maximal mögliche Nachlass auf die monatlich zu zahlende Versicherungsprämie berechnet wird. Der sich daraus ergebende neue Preis der Kraftfahrtversicherung gilt dann für alle Monate des verbleibenden Jahres. Eine erneute Anpassung der Versicherungsprämie erfolgt im Anschluss immer zu Jahresbeginn und basierend auf allen bis dahin gesammelten Daten. Daten, die älter als zwölf Monate sind, werden mangels Aktualität nicht mehr berücksichtigt.

Gerade die zuverlässige Kalibrierung von Telematik-Modellen ist üblicherweise sehr datenintensiv. Das führte zur Entstehung spezialisierter Telematik-Anbieter, die Versicherungsunternehmen Dienstleistungen wie Datensammlung, -verarbeitung und -modellierung zur Verfügung stellen. Ein globaler Telematik-Anbieter britischer Herkunft kombiniert Fahrverhaltensdaten mit kontextuellen Umgebungsdaten in einen Risikoscore. Dieser Score fließt als Telematik-Faktor (im Prinzip ein prozentualer Auf- oder Abschlag) in die Berechnung der Prämie ein. Das Unternehmen verwendet ein Risikomodell, das fortlaufend mit aktuell gemessenen Schadendaten adjustiert wird. Bei jedem neuen Fahrer oder Fahrzeug wird der initiale Score zunächst anhand konventioneller Differenzierungsfaktoren wie Alter, Fahrzeug und Anzahl unfallfreier Jahre festgelegt (Ex-ante-Risikobewertung). Im Laufe der Zeit werden spezifische Fahrdaten eingespeist und in einem neuen Scoring periodisch ausgewertet (Ex-post-Risikobewertung). Der individuelle Risikoscore wird an das Versicherungsunternehmen übermittelt, welches anschließend die Versicherungsprämien neu beziffern kann.

4. Chancen

Die dargestellten Ansätze zur BDAI-unterstützten Produktentwicklung bzw. Preisgestaltung bei Kranken-, Lebens- und Kraftfahrtversicherungen sind mit einer Reihe von Chancen für Versicherungsunternehmen und Versicherungsnehmer verbunden.²⁹¹ Die Unternehmen könnten von einer stärker differenzierten Segmentierung von Versicherungsnehmern und reduzierten Abschlusskosten profitieren, während einige Versicherungsnehmer an niedrigeren Prämien partizipieren können und möglicherweise motiviert werden, ihr Verhalten positiv zu ändern.

Perspektive der Versicherungsunternehmen

Durch den Zugang zu neuen Datenquellen wie individuellen Verhaltensdaten etwa aus Telematik-Anwendungen könnte Versicherungsunternehmen eine differenziertere Segmentierung ermöglicht werden (vgl. Kapitel 5.3). Das bedeutet: Mit Versicherungsnehmern verbundene Risiken, die in der Vergangenheit gleich bepreist wurden, könnten mit Hilfe von BDAI theoretisch immer stärker differenziert werden. Ein Versicherer könnte sich durch den Einsatz von BDAI in der Produktentwicklung somit einen Informationsvorteil sichern und sich am Markt gegenüber seinen Konkurrenten profilieren sowie seinen Kundenbestand erweitern. Dieser Vorteil bestünde jedoch aller Voraussicht nach nur, bis andere

²⁹¹ Bei der Darstellung der Chancen und Risiken erfolgt keine konsequente Differenzierung nach Sparten, da sie in der Regel spartenübergreifend bestehen. Eine Differenzierung erfolgt im Folgenden nur punktuell, sofern dies erforderlich erscheint.

Wettbewerber mit Hilfe von BDAI-Technologie eine vergleichbar effektive Segmentierung erzielen könnten (vgl. Analogie im Hinblick auf kurzfristige Effizienzgewinne in Kapitel 5.3.2). Bei anreizbasierten Tarifen könnten die fortlaufend erfassten Daten verwendet werden, um eine (automatisierte) kontinuierliche Anpassung der einzelnen Kundensegmente vorzunehmen.

Eine Konsequenz der Spreizung der Preise für Versicherungsprodukte läge darin, dass einzelne Segmente technisch verkleinert würden. Dies stünde jedoch nicht im Widerspruch zu einem Ausgleich von Schadenleistungen im Kollektiv, da dieses weiterhin fortbesteht.

Eine stärkere Konzentration niedrigerer Risiken über alle Tarife eines Versicherungsunternehmens hinweg, ginge mit einer Reduktion der gesamten erwarteten Schadenleistungen einher. Die niedrigeren erwarteten Schadenleistungen könnten sowohl für eine Senkung der Prämien als auch zu einer Erhöhung der Margen genutzt werden. Konkret könnten Versicherungsunternehmen durch eine Verteilung der finanziellen Vorteile der BDAI-induzierten positiven Selektion ihre Ertragslagen verbessern und zugleich Versicherungsnehmern mit geringeren Risiken preiswertere Produkte anbieten.

Des Weiteren kann der Einsatz von BDAI den Prozess der Produktentwicklung/Preisgestaltung durch (Teil-) Automatisierung beschleunigen. Die daraus resultierenden Effizienzvorteile für Versicherer könnten zu einer Senkung der Abschlusskosten führen. Die größte Effizienzsteigerung ließe sich im beratungsfreien Onlinevertrieb erzielen. Dieser würde mit Hilfe von BDAI auch für umfangreichere Antragsprozesse realisierbar, die mit komplexen Risikobewertungen verbunden sind (z.B. bei Lebensversicherungen). Bislang war der Onlinevertrieb tendenziell auf weniger komplexe Sparten bzw. Versicherungsprodukte fokussiert. Auch hier gilt, dass das Kosteneinsparpotential durch BDAI unternehmensspezifisch und abhängig von bereits erfolgten Automatisierungen und Investitionen ist.

Ferner würden durch eine granularere Segmentierung der Versicherten die einzelnen Segmente homogener. Damit könnte eine geringere Schwankung der Schäden einhergehen, wodurch letztendlich weniger Risikokapital benötigt werden sollte. Dadurch könnten folglich auch die aufzubringenden Kapitalkosten sinken.

Dank niedrigerer Abschlusskosten könnten wiederum Versicherungsprodukte mit aus heutiger Sicht noch unlukrativen Margen vertrieben und neue Marktsegmente erschlossen werden. Auf Basis des technologischen Fortschritts könnten sich beispielsweise auch kleinere, situative Versicherungen wie Flug- oder Bahnverspätungsversicherungen am Markt etablieren, die bislang aufgrund zu hoher Stückkosten nicht flächendeckend angeboten wurden (vgl. Kapitel 5.3.2). Auch könnten die schnellere Verfügbarkeit von Daten und besseren Verarbeitungstechnologien²⁹² es ermöglichen, Risiken, die sich bisher aufgrund eines sich schnell und stark ändernden Risikoumfelds nicht adäquat bepreisen ließen, risikogerecht zu bewerten sowie die Bewertung bei Bedarf rasch und flexibel zu adjustieren. Beispielsweise könnten Pay-as-you-drive-Kraffahrt-Haftpflicht- und Kaskoversicherungen angeboten werden, bei denen die kurzfristige Änderung des Risikos durch sich ändernde Straßenverhältnisse (Nebel, Eis etc.) bepreist werden könnte.

Perspektive der Versicherungsnehmer

Versicherungsnehmern könnten durch BDAI-Technologie Vorteile dadurch entstehen, dass denjenigen, die zuvor bestimmte Versicherungen nicht abgeschlossen haben, da sie den Preis in Anbetracht ihres wahrgenommenen Risikos als zu hoch empfanden, risikogerechtere, also individuellere, Produkte zu risikoadäquaten Preisen angeboten werden. Die bereits angesprochene Spreizung der Prämien könnte demnach bestimmten Kundensegmenten in Form von niedrigeren Versicherungskosten zugutekommen.

Durch anreizbasierte Versicherungsprodukte erhalten Versicherungsunternehmen wertvolle Rückmeldungen über das Verhalten ihrer Versicherungsnehmer. Wertvoll sind diese Rückmeldungen insofern, als Versicherer auf Basis der gewonnenen Daten gezielte Informationen über Erwartungen und Bedürfnisse ihrer

²⁹² Vgl. Kapitel II und 0 dieser Studie.

Versicherungsnehmer in deren jeweiligen Lebenssituationen ableiten können. Dies wiederum könnte (potenziellen) Versicherungsnehmern zugutekommen, sobald Versicherungsunternehmen auf Basis dieser neuen Informationen mit entsprechend maßgeschneiderten neuen Produkten und Dienstleistungen auf sie zugehen.

Darüber hinaus könnten Versicherungsnehmer, wie oben beschrieben, durch anreizbasierte Versicherungsprodukte motiviert werden, einen gesünderen Lebensstil zu pflegen bzw. vorausschauender und disziplinierter Auto zu fahren²⁹³, um von niedrigeren Prämien zu profitieren.

5. Risiken

Die dargestellten Ansätze zur BDAI-unterstützten Produktentwicklung bzw. Preisgestaltung bei Kranken-, Lebens- sowie Kraftfahrtversicherungen sind auch mit Risiken verbunden. Auf Unternehmensseite ist hier insbesondere das Risiko des Eigenmittelabriebs zu nennen, das sich daraus ergibt, dass die Ziele der Produktentwicklung verfehlt werden. Für den Versicherungsnehmer bestünde das Risiko steigender Preise in bestimmten Kundensegmenten.

Perspektive der Versicherungsunternehmen

Für Versicherungsunternehmen könnte der Einsatz BDAI-basierter Modelle in der Produktentwicklung dazu führen, dass das Versicherungsrisiko systematisch unter- oder überschätzt wird, was fehlerhafte Versicherungszusagen und Beiträge (negative Selektion) zur Folge haben könnte. Dies wäre bei langfristigen Versicherungen, z.B. Lebens- und Unfallversicherungen, von besonderer Relevanz. Würden Risiken unterschätzt, nähmen die Unternehmen über viele Jahre hinweg zu geringe Prämien ein, was wiederum bei fälliger Auszahlung zunächst zu einem Eigenmittelabrieb führen könnte.²⁹⁴ Für BDAI-basierte Modelle bleibt somit das Risiko bestehen, dass Prämien nicht angemessen kalkuliert werden. Auf Basis selbstlernender Modelle risikogerechtere Prämien festlegen zu wollen, könnte Versicherungsunternehmen²⁹⁵ also vor große Herausforderungen stellen.²⁹⁶ Eventuell müssten sie zur Prävention von Untertarifierung höhere Sicherheitsaufschläge erheben. Versicherer müssten eine Abwägung treffen zwischen erhöhten Sicherheitsaufschlägen und der Preisattraktivität ihrer Produkte.

Wesentlich für die Vermeidung fehlerhafter Prämienkalkulationen ist die verwendete Datengrundlage. Die Qualität selbst erhobener wie extern eingekaufter Daten (v.a. Vollständigkeit, Konsistenz, Wahrheitsgehalt, Aktualität) muss gewährleistet sein. Abgesehen davon ist darauf zu achten, dass die in die Prämienkalkulation einfließenden Daten einen statistischen Zusammenhang mit den Risiken der Versicherungsnehmer haben.²⁹⁷ Es gilt, Scheinkorrelationen zu vermeiden und systematische Fehlbewertungen von Risiken zu mitigieren. Der Nachweis, welche neuen Daten tatsächlich zu einer fundierten, risikogerechteren Differenzierung führen, ist über alle Versicherungssparten hinweg noch zu erbringen. Falsch eingeschätzte Risikotreiber und Abhängigkeiten waren in der Vergangenheit unter anderem ursächlich dafür, dass z.B. Telematik-Tarife vereinzelt wieder eingestellt wurden.²⁹⁸

²⁹³ Der britischen Road Safety Foundation zur Folge ist das Unfallrisiko bei Fahranfängern mit Telematik-Tarifen um etwa 40 Prozent niedriger im Vergleich zu jenen, die traditionelle Kfz-Tarife abgeschlossen haben.

²⁹⁴ Bei anreizbasierten Tarifen müssen Besonderheiten wie die Ausgabe von Gratifikationen berücksichtigt und bereits bei Vertragsabschluss eingepreist werden, um die Auskömmlichkeit der Prämien zu gewährleisten.

²⁹⁵ Vgl. die Ausführungen zur Evaluation von selbstlernenden Modellen in Kapitel 3.3.1.

²⁹⁶ Vgl. die Ausführungen zu Risiken durch BDAI-basierte Modelle im Anwendungsbeispiel in Kapitel 5.3.7.1.

²⁹⁷ Vgl. für z.B. die Lebensversicherung und substitutive Krankenversicherung § 138 Abs. 2 VAG und § 146 VAG sowie Zweckbindung gemäß BDSG.

²⁹⁸ Morawetz, 2016, Der telematische Irrweg der Kfz-Versicherung. In: Zeitschrift für Versicherungswirtschaft, 04/2016, S. 68 ff.

BDAI in der Produktentwicklung ist noch immer relativ neu, die Erfahrungswerte sind gering. Aus diesem Grund ist ein vorsichtiger Umgang mit neuen Daten und Algorithmen wichtig, um eine Untertarifierung zu vermeiden. Dazu gehört auch, dass unternehmensintern ein Lernprozess angestoßen und die erforderliche BDAI-Kompetenz aufgebaut wird.

Es ist gegebenenfalls weiter rechtlich zu konkretisieren, welche erhobenen und welche eingekauften Daten unter welchen Bedingungen zur Auswertung herangezogen werden dürfen, um diskriminierendes Data Mining zu vermeiden²⁹⁹. Ebenso stellt sich die rechtliche Frage, wie der Versicherungsnehmer über die Nutzung einzelner seiner Daten in Kenntnis zu setzen ist. Ginge ein Versicherer insbesondere bei der Nutzung von BDAI nachlässig mit den Daten oder der Einholung der Zustimmung der Versicherungsnehmer um, dürfte dies bei Bekanntwerden mit einem Imageverlust einhergehen. Nicht auszuschließen ist auch ein genereller Vertrauensverlust für die Versicherungsbranche, sofern es an dieser Stelle künftig gehäuft zu missbräuchlichen Verwendungen käme.

Bei Einführung eines neuen BDAI-gestützten Produkts sollte darauf geachtet werden, dass alle zur Steuerung und Überwachung von Versicherungsprodukten zu erfassenden Daten in einer Weise erfasst werden, die ein effektives Produktcontrolling ermöglicht. Ziel des Produktcontrollings ist es, retrospektiv zu prüfen, ob die bei der Produktentwicklung getroffenen versicherungstechnischen Annahmen nach Einführung bestätigt werden können und inwiefern nicht gewünschte Effekte, wie beispielsweise die Adressierung falscher Kundensegmente, eintreten können. Damit einher geht auch die Überprüfung der Profitabilität neuer Produkte. Bei BDAI-basierten Produkten besteht eine wesentliche Herausforderung darin zu überwachen, inwiefern neue Parameter – bei Telematik-Tarifen z.B. das Beschleunigungsverhalten, bei Krankenversicherungen z.B. die Ausprägung roter Äderchen im Bereich der Nase – tatsächlich geeignet sind, risikogerechtere Prämienkalkulationen zu ermöglichen, und ob körperliche Merkmale und Ausprägungen von Versicherungsnehmern überhaupt von Algorithmen zur Tarifierung herangezogen werden dürfen.

Obgleich das Produktcontrolling grundsätzlich eine Kernfunktion von Versicherungsunternehmen ist, hat es in den Versicherungssparten eine unterschiedliche Bedeutung. Dies ist in den spezifischen Fristigkeiten begründet. Je nach Sparte könnte es bei BDAI-basierten Versicherungsprodukten zu einer mehrjährigen Verzögerung zwischen dem Launch des Tarifs und der Gewinnung belastbarer Datenpunkte (z.B. Schadenzahlungen) kommen. Dadurch stünden weniger unternehmensinterne Datenpunkte zur Verfügung, um Annahmen auf Basis echter Daten zu validieren.

Auch im Produktcontrolling könnte es vorkommen, dass gerade bei der Erprobung neuer Produkte unter Umständen mehr Daten von Versicherten erfasst und ausgewertet werden könnten, als ex-post tatsächlich zur Bewertung ihrer Risiken erforderlich sind. Dies stünde dann im Konflikt mit dem Ziel der Datensparsamkeit bzw. Datenminimierung im Sinne des Bundesdatenschutzgesetzes bzw. EU-DSGVO.

Bei Einführung neuer Tarife nutzen Erstversicherer oft Rückversicherungsunternehmen, um Risiken besser zu verteilen. Dies wird voraussichtlich auch bei Einführung BDAI-basierter Tarife der Fall sein. Somit könnten Rückversicherer in gewissem Maße als Enabler von BDAI-basierten Tarifen verstanden werden. Unter der Annahme, dass BDAI-basierte Tarife bei Einführung unprofitabel wären, partizipierten Rückversicherer ebenfalls an der Unprofitabilität. Natürlich werden Rückversicherer langfristig keine defizitären BDAI-basierten Tarife zeichnen.³⁰⁰ Jedoch liegt zwischen der Zeichnung³⁰¹ und der möglichen Erkenntnis, dass ein BDAI-basierter Tarif defizitär ist, unter Umständen ein längerer Zeitraum. Infolgedessen könnten sich in den Bilanzen der Rückversicherer unprofitable BDAI-Tarife konzentrieren.

²⁹⁹ Vgl. Ausführungen zu „Nichtdiskriminierender Datenanalyse“ in Kapitel 3.5.5.

³⁰⁰ Es sei denn, sie erhielten dafür an anderer Stelle einen entsprechenden Ausgleich.

³⁰¹ Gegebenenfalls erfolgte die Zeichnung einzelner Tarife bereits in der Vergangenheit.

Zur Gewährleistung belastbarer Risikobewertungen und Prämienkalkulationen müssen Versicherungsunternehmen, wie bereits angedeutet, die Wahrhaftigkeit und die Aktualität der verwendeten Datengrundlage sicherstellen. Dazu gehört auch, das Risiko der Datenmanipulation etwa durch Versicherungsnehmer zu mitigieren. Bei Kranken-/Lebensversicherungen beispielsweise könnten potenzielle Versicherungsnehmer durch Anlegen sogenannter Fake-Accounts in den Sozialen Medien versuchen, ihre Risikomerkmale gezielt zu manipulieren, um einen günstigeren Preis bei Vertragsabschluss zu erzielen.

Bei Kraftfahrt-Haftpflichtversicherungen besteht ein vergleichbares Risiko. Versicherungsnehmer könnten in der Phase der Festlegung einer möglichen Prämienreduktion bewusst vorbildlich fahren, später aber deutlich riskanter. Diese Gefahr der Datenmanipulation könnte vermieden werden, sobald Prämien von Kraftfahrtversicherungen nur noch situativ, d.h. von Fahrt zu Fahrt, auf Basis des jeweiligen Fahrverhaltens bestimmt würden.

Perspektive der Versicherungsnehmer

Bei anreizbasierten Tarifen könnten für Versicherungsnehmer, die vordergründig ungesündere Lebensstile pflegen, im Vergleich zu nicht-anreizbasierten Tarifen höhere Versicherungskosten entstehen. Denn wenn sehr viele Versicherungsnehmer mit niedrigen Risiken in anreizbasierte Tarife wechseln, könnte der Preis von nicht-anreizbasierten Tarifen steigen, da dort dann überproportional viele Versicherungsnehmer mit hohen Risiken verblieben.³⁰² Diese Entwicklung könnte im Sinne des Verbraucherschutzes als Preisdiskriminierung aufgefasst werden. Vorausgesetzt, anreizbasierte Produkte etablierten sich marktweit als Standard, könnte dies für Versicherungsnehmer negative Folgen haben, da anreizbasierte Tarife dann nicht mehr frei wählbar wären. Besondere Relevanz hat in diesem Zusammenhang, dass ein von außen als ungesund wahrgenommener Lebensstil sich oft der bewussten Entscheidung des Betroffenen entzieht. Das heißt, Versicherungsnehmer, die unverschuldet gesundheitlich beeinträchtigt sind, könnten durch anreizbasierte Krankenversicherungen grundsätzlich diskriminiert werden. Das Argument, der Versicherungsnehmer trage selbst die Verantwortung (Stichwort „Eigenverantwortung“), griffe an dieser Stelle aber nicht.

Infolge der in Kapitel 5.3 angesprochenen möglichen Preisspreizung von Versicherungsprämien könnte der Fall eintreten, dass die Prämie eines Interessenten (z.B. für eine neue Kranken- oder Kraftfahrtversicherung) erheblich höher ausfällt, als wenn dieselbe Person mit Hilfe herkömmlicher Risikomodelle bewertet worden wäre. Im Extremfall könnte diese Preisspreizung dazu führen, dass einzelne Interessenten aufgrund hoher Prämien faktisch nicht mehr versicherbar wären. Es steht zu erwarten, dass der Einsatz von BDAI-Anwendungen in der Produktentwicklung zu mehr Fällen von Nichtversicherbarkeit führen könnte. Bei den Kranken- und Lebensversicherungssparten könnte sich die Absage von Versicherungsverträgen auf Basis neuer Daten als besonders unvorteilhaft für Menschen mit angeborenen oder durch Unfälle erlittenen chronischen Leiden herausstellen. Im Sinne der allgemeinen Gleichbehandlung könnte dies dann als eine sozial-politisch ungewollte Entwicklung aufgefasst werden.

Zur Erfassung der für die differenziertere Bewertung von Risiken erforderlichen Daten müssten Versicherungsnehmer aller Voraussicht nach den verschiedenen Verwendungen ihrer Daten zustimmen. Es könnte sogar erforderlich werden, z.B. einen Social-Media-Account einzurichten, um eine bestimmte Versicherung zum niedrigsten möglichen Preis abschließen zu können. Interessierte, die einen solchen Account nicht hätten bzw. nicht einrichten wollten, müssten entweder einen nicht BDAI-basierten und unter Umständen teureren Tarif abschließen oder aber auf den Versicherungsschutz verzichten. Die Wahlfreiheit der Verbraucher wäre also eingeschränkt.

Es besteht das Risiko, dass trotz formaler Zustimmung zur Datenverwendung den Versicherungsnehmern nicht ausreichend transparent gemacht wird, wozu die – von ihnen zur Verwendung freigegebenen – Daten verwendet werden könnten und dass sie sich der grundsätzlichen Gefahr einer missbräuchlichen Verwendung ihrer Daten aussetzen. Wenn Versicherungsnehmer einer Datenverwendung zustimmen,

³⁰² Der Eintritt einer derartigen Entwicklung dürfte auch von weiteren Aspekten abhängen wie dem Wettbewerbsdruck, der Marktsättigung und/oder der Wechselfreudigkeit der Versicherten.

vertrauen sie darauf, dass ihre Daten sicher sind und das Unternehmen verantwortungsbewusst damit umgeht. Versicherungsunternehmen müssen daher einen vollumfassenden Daten- und Vertrauensschutz gewährleisten: durch eine transparente Aufklärung und indem sie ihren Kunden die Einwilligung zur Datennutzung freistellen. Diese Transparenz wird das Vertrauen in den Versicherer und damit die Kundenbeziehung nachhaltig stärken können. Darüber hinaus ist damit auch gemeint, dass die Versicherer gewährleisten müssen, dass z.B. Algorithmen zur Bewertung von Risiken nur die tatsächlich relevanten Daten, also diejenigen, die in einem direkten Zusammenhang zum zu bewertenden Risiko stehen, hinzuziehen und auswerten (Datensparsamkeit bzw. Datenminimierung bei personenbezogenen Daten). Wichtig wäre auch, dass die erfassten Daten nicht zur Überwachung von Versicherungsnehmern³⁰³ zweckentfremdet bzw. anderweitig genutzt werden.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte haben verschiedene Implikationen, welche die Aufsicht adressieren sollte. Diese werden zum Abschluss des Anwendungsbeispiels im nächsten Absatz kurz genannt und in Kapitel VI dieser Studie eingehend dargestellt.

Was die BDAI-unterstützte Produktentwicklung angeht, ergibt sich zunächst neben der Diskussion über das Schadenmanagement die Frage der Notwendigkeit einer Abnahme/Zertifizierung BDAI-basierter Modelle und des Aufbaus der hierfür relevanten Kompetenzen im Versicherungsunternehmen. Insbesondere selbstlernende Modelle/Algorithmen könnten dabei eine Herausforderung darstellen. Es muss auch darüber diskutiert werden, wie man eine unverhältnismäßige bzw. rechtlich untersagte Diskriminierung einzelner Versicherungsnehmer vermeiden kann. Wenn infolge einer stärkeren Individualisierung von Versicherungsprodukten und insbesondere der Prämien bestimmte Bevölkerungsgruppen faktisch kaum noch Risiken durch Versicherungen absichern können und dies im Extremfall zu Nichtversicherbarkeit führt, so ist dies sozial und politisch relevant. Ebenso wird an diesem Anwendungsbeispiel deutlich, dass dem Schutz der Daten und des Vertrauens der Versicherungsnehmer, dass ihre Daten nicht missbräuchlich verwendet werden, beim Einsatz neuer Technologien und Geschäftsmodelle zunehmend mehr Bedeutung zukommen muss.

5.3.7.3 Homogene Gruppen von Versicherten auf Basis von BDAI

1. Einleitung

Die Einschätzung des versicherungstechnischen Risikos auf Basis von BDAI-Anwendungen wird sich in den nächsten Jahren voraussichtlich dahingehend verändern, dass neue Prädiktoren hinzukommen und/oder die traditionellen ersetzen, sofern hierdurch eine differenziertere Einschätzung des Risikos ermöglicht wird.³⁰⁴ Die für die Risikoeinschätzung erforderlichen Daten werden künftig nicht mehr notwendigerweise im Besitz der Versicherungsunternehmen selbst, sondern möglicherweise in der Verfügungsgewalt von großen Datenanbietern³⁰⁵ sein. Diese könnten ihre Daten und Analysetools dann verwenden oder an Plattformen Dritter weitergeben, um aus ihren Nutzern große, länderübergreifende Gruppen von Versicherten zusammenzustellen, die in Bezug auf ihr versicherungstechnisches Risiko homogen wären (homogene Risikogruppen).

³⁰³ Insbesondere bei verhaltensbasierten Tarifen wäre durch die Erfassung von Lokalisationsdaten via GPS eine derartige Überwachung denkbar.

³⁰⁴ Vgl. vorangehendes Anwendungsbeispiel in Kapitel 5.3.7.2.

³⁰⁵ Beispielsweise Google (Alphabet), Amazon, Facebook, Apple.

Für diese Gruppen könnte es naheliegend sein, sich in einem P2P-Netzwerk³⁰⁶ selbstständig zu organisieren. Derartige Versicherungsnetzwerke würden in erster Linie Privatkunden adressieren, um Komposit- sowie Kranken- und Lebens-Zusatzversicherungen abzuschließen.

Die Größe, die Homogenität und auch die Organisationsform könnten erhebliche Kostenvorteile gegenüber traditionellen Versicherungen bewirken, sodass dies künftig ein potenziell disruptives Geschäftsmodell sein könnte. Gleichzeitig ist das zugrundeliegende Geschäftsmodell jedoch dem eines Versicherungsvereins auf Gegenseitigkeit ähnlich (s. Exkursbox S. 134).

2. Anwendung

Die Bestimmung des versicherungstechnischen Risikos wird sich unter dem Einfluss von BDAI-Technologien verändern. Es werden neue Daten erzeugt, erfasst und analysiert werden, welche Aufschluss über ein versicherungstechnisches Risiko geben könnten. Die bekanntesten Beispiele sind Telematiks und Wearables, die einen Einfluss auf die Einschätzung des Kraftfahrt-Haftpflichtrisikos oder auch des Krankenrisikos haben könnten. Nahezu alle Sparten könnten vom Einsatz der BDAI-Anwendungen profitieren, indem bestehende Daten aus Schadenangaben ergänzt und möglicherweise auch ersetzt werden.

Identifizierung geeigneter Individuen zur Bildung homogener Gruppen von Versicherten

Aus heutiger Perspektive ist die Verwendung alternativer Datenquellen zur Bestimmung des Risikos noch mit einem hohen Lernaufwand verbunden. Innerhalb dieses Gedankenexperiments wird jedoch angenommen, dass dieser Schritt bereits vollzogen ist und die Bestimmung des versicherungstechnischen Risikos auf der Kombination von verschiedenen – auch nicht-traditionellen – Datenquellen beruht, welche je nach Sparte und Risiko unterschiedlich sein können. Weiterhin wäre es künftig möglich, dass nicht mehr die Versicherungsunternehmen selbst es sind, die über die relevanten Informationen zur Bestimmung des versicherungstechnischen Risikos verfügen, sondern eventuell Bigtechs, welche die Schnittstelle zu den Kunden übernommen und entsprechend relevante Datenmengen gesammelt haben. Mit diesen Daten und dem Know-how, das man braucht, um das versicherungstechnische Risiko z.B. auf Basis von unüberwachtem Lernen³⁰⁷ zu bestimmen, wären Bigtechs in der Lage, unter ihren Kunden (oder Nutzern) diejenigen zu identifizieren, die hinsichtlich eines oder mehrerer versicherungstechnischer Risiken vergleichbar sind, um somit große Gruppen homogener Risiken abzubilden.

Unter der Voraussetzung, dass die Versicherungsunternehmen im Besitz dieser relevanten Daten wären, könnten sie in der gleichen Weise verfahren, jedoch beschränkt auf ihren (in der Regel lokalen) Bestand. Bigtechs ihrerseits haben eine wesentlich höhere Zahl von Nutzern und könnten somit größere homogene Gruppen zusammenstellen.

Monetarisierung von Daten als mögliches Geschäftsmodell von Bigtechs

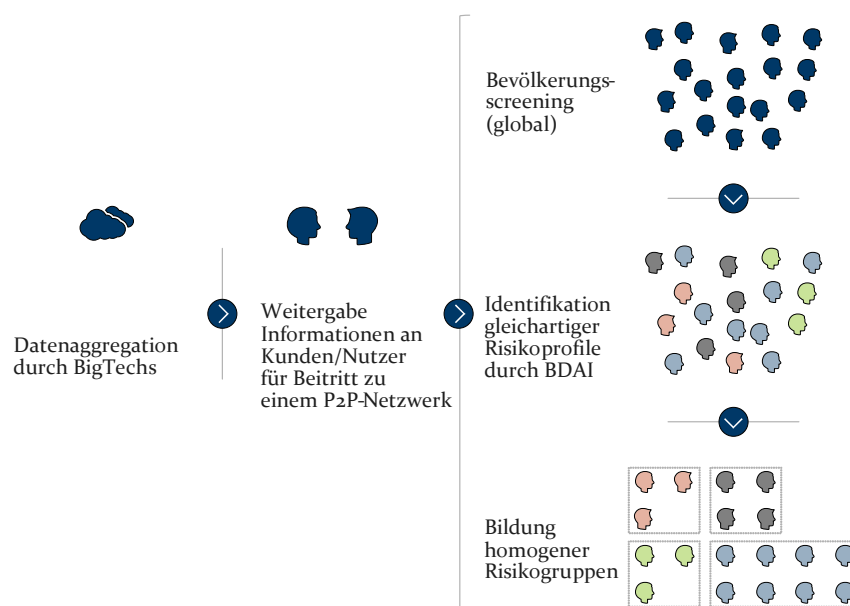
Vermutlich würden Bigtechs versuchen, ihre gewonnenen Erkenntnisse zu monetarisieren. Eine Möglichkeit wäre, dass sie selbst Versicherungsschutz in den angesprochenen Nutzergruppen anbieten. Da dies jedoch sowohl mit Lizenzierungen als auch dauerhaftem regulatorisch bedingtem Aufwand verbunden wäre, ist die Wahrscheinlichkeit dafür tendenziell gering. Eine andere Form der Monetarisierung könnte darin bestehen, die Informationen an traditionelle Versicherungsunternehmen oder digitale Versicherungsplattformen zu verkaufen.³⁰⁸ Alternativ könnten Bigtechs ihren Kunden den Mehrwert der Information, welcher Risikogruppe sie angehören, als zusätzlichen Nutzen kostenfrei oder kostenpflichtig weitergeben (vgl. Abbildung 24). Dadurch könnten sie die Kundenzufriedenheit und damit die Bindung ihrer Kunden an ihr eigentliches Kerngeschäft erhöhen.

³⁰⁶ „P2P-Netzwerk“ ist im Rahmen dieser Studie gleichzusetzen mit „P2P-Versicherung“. P2P-Versicherung wird zudem abgegrenzt von traditionellen Versicherungsunternehmen.

³⁰⁷ Vgl. Ausführungen zu „unüberwachtem Lernen“ in Kapitel 3.2.2.

³⁰⁸ Diese wiederum würden dann innerhalb homogener Gruppen Versicherungen anbieten können.

Abbildung 24: Illustrative und vereinfachte Darstellung der Weitergabe relevanter Informationen an Kunden und Bildung homogener Risikogruppen



Vereinfacht ausgedrückt, könnten alle Kunden (oder Nutzer), die sich beispielsweise auf Basis ihres Suchverhaltens als besonders risikoavers (oder risikofreudig) erwiesen oder durch ihre Online-Einkäufe eine bestimmte Risikoneigung zum Ausdruck gebracht haben, als Teil einer großen und homogenen Risikogruppe verstanden werden. In diesem Gedankenexperiment wird also von folgender Annahme ausgegangen: In Zukunft bestehen die relevanten Informationen für eine optimale Charakterisierung des versicherungstechnischen Risikos nicht in den proprietären Daten der Versicherungsunternehmen, sondern werden durch Bigtechs an deren Kundenschnittstelle erfasst. Ferner wird angenommen, dass Bigtechs ihre Informationen nutzen, um ihre Kunden über ihr versicherungstechnisches Risiko aufzuklären.

Was könnten die Kunden von Bigtechs mit diesen Informationen konkret anfangen? Wie könnte aus dieser Situation heraus Versicherungsschutz entstehen und wie sollten sich die Gruppen organisieren? Im Folgenden werden mögliche Antworten auf diese Fragen skizziert, und anhand eines aktuellen Praxisbeispiels wird zudem eine mögliche Organisationsform für die beschriebenen Risikogruppen illustriert.

3. Technologische Funktionsweise am Beispiel Teambrella

Russische Softwareentwickler bzw. Entrepreneurure haben ein Peer-to-Peer-Versicherungssystem konzipiert (Teambrella), bei dem Mitglieder selbstregulierter Risikogruppen sich gegenseitig versichern können.³⁰⁹ Die Mitglieder einer Gruppe übernehmen dabei die Kontrolle über alle Kernprozesse eines Versicherungsunternehmens, einschließlich der Akquise, der Risikobewertung und der Schadenregulierung. Der Anbieter stellt lediglich die technische Infrastruktur zur Verfügung, leistet aber keine Zahlungen, verwaltet nicht das Vermögen der Mitglieder und bietet selbst auch keinen Versicherungsschutz an. Das Geschäftsmodell beruht auf einer vollständigen Loslösung von traditionellen Versicherungsunternehmen. Versicherungsnehmer werden zu Versicherern. Das System wird seit 2017 in den Niederlanden und in Südamerika pilotiert.

³⁰⁹ Siehe Teambrella. Online verfügbar: <https://teambrella.com/>, abgerufen am 11.12.2017.

Eine Teambrella-Gruppe besteht aus mindestens zwei Mitgliedern. Interessierte können sich für den Beitritt zu einer oder mehreren Gruppen bewerben. Mit der Bewerbung für eine Gruppe entscheidet sich das potenzielle Mitglied für einen bestimmten Versicherungsschutz – der analoge Prozess bei einem traditionellen Versicherer ist die Antragstellung. Teambrella beruht zurzeit auf der Idee, dass neue Mitglieder über Social-Media-Einladungen und Empfehlungen von Freunden akquiriert werden. In unserem Gedankenexperiment wird jedoch angenommen, dass sich die Gruppen auf Basis der Informationen der Bigtechs bilden würden. Jede Teambrella-Gruppe setzt zu Beginn eigene Regeln fest, z.B. darüber, welche Schäden versichert sind und welche Versicherungssummen maximal ausgezahlt werden. Das Gegenstück zum Versicherungsvertrag eines traditionellen Versicherers sind diese durch die Gruppe definierten Regeln. Durch diese Regeln kann jedes Mitglied mitentscheiden, beispielsweise über die Ausweitung des Versicherungsschutzes, den Beitritt neuer Mitglieder und die Höhe von Schadensansprüchen. Die Entscheidungen werden per Abstimmung in der Gruppe getroffen oder können an Experten delegiert werden. Bei diesen Experten kann es sich sowohl um Gruppenmitglieder mit breiterer Versicherungsexpertise als auch um professionelle Versicherungsberater handeln. Die Entwickler von Teambrella empfehlen, dass Gruppenmitglieder Versicherungsberater in Anspruch nehmen, um fundierte und geschulte Entscheidungen zu fördern. Die Bezahlung dieser Berater (erfolgt über einen Prozentsatz der Auszahlungssumme im Schadenfall) soll ein hohes Maß an Professionalität und Effizienz des Versicherungssystems gewährleisten. Jedoch könnte hierin auch ein Konflikt liegen, denn für einen Berater könnte theoretisch ein Anreiz bestehen, gerade Interessenten mit hohen Risiken den Zutritt zur Gruppe zu gewähren oder hohen Schadensansprüchen zuzustimmen.

Schadensansprüche stellen Mitglieder direkt an das Team, und zu Beginn vereinbarte Informationen (z.B. Fotos oder Polizeiberichte) werden bereitgestellt. Im Anschluss kann jedes Mitglied über die Höhe der Schadensumme entscheiden. Wenn die Gruppe einen Schadensanspruch bestätigt, zahlt jedes Mitglied an das begünstigte Mitglied. Der zu zahlende Anteil am Schadensanspruch errechnet sich individuell für jedes Mitglied, abhängig von einem persönlichen Risikokoeffizienten. Der Risikokoeffizient jedes Mitglieds wiederum errechnet sich aus dem Produkt der relativen Schadenwahrscheinlichkeit und der relativen Schadensummenerwartung. Vergleichbarkeit der zu leistenden Schadenzahlungen innerhalb der Gruppe wird dadurch erzielt, dass Mitglieder mit gleichen Risikokoeffizienten im Schadenfall den gleichen Betrag füreinander zahlen, wohingegen Mitglieder mit unterschiedlichen Koeffizienten anteilige Beträge füreinander zahlen. Dies bedeutet, dass Mitglieder mit höheren Risikokoeffizienten höhere Beträge an Mitglieder mit geringeren Risikokoeffizienten zahlen müssen. Im Umkehrschluss wird umso weniger Schadenleistung ausgezahlt, je niedriger die eigene Risikobewertung ist.

Jedes Mitglied zahlt eine bestimmte Summe (analog einer Versicherungsprämie) in ein persönliches E-Wallet ein. Darin bleiben die Beträge so lange, bis Schadensansprüche geltend gemacht werden und Zahlungen erfolgen müssen. Die Entwickler von Teambrella entschieden sich für die Nutzung einer Kryptowährung, um die Transaktionskosten gering zu halten.

Das Teambrella-Konzept ist in erster Linie für Sachschäden gedacht. Unlimitierte Personenschäden können über Teambrella nicht gedeckt werden, da kein Eigenkapital im eigentlichen Sinne existiert und hierfür die Zusammenarbeit mit einem traditionellen Versicherungsunternehmen erforderlich wäre. Ebenso kann das System derzeit nicht bei Versicherungen angewendet werden, die der Gesetzgeber verpflichtend vorschreibt, wie etwa Kraftfahrt-Haftpflichtversicherungen.

Der Erfolg des dargestellten Teambrella-Konzepts kann noch nicht bewertet werden, da es zurzeit noch pilotiert wird. Für unser Gedankenexperiment ist es dennoch geeignet, eine Möglichkeit aufzuzeigen, wie sich bezüglich des Risikos homogene Gruppen von Versicherten künftig selbst organisieren und die Informationen über die Zugehörigkeit zu einer Gruppe nutzen könnten.

Da bei BDAI-basierten P2P-Versicherungen Versicherungsnehmer zugleich Versicherer sind, erfolgt nachstehend eine übergreifende Skizzierung von Chancen und Risiken. Die Perspektive der technischen Plattformen (Infrastrukturanbieter) wird nicht eingenommen.

4. Chancen

Aus Sicht des Mitglieds einer BDAI-basierten P2P-Versicherung gibt es im Wesentlichen zwei Aspekte, die als Chancen betrachtet werden könnten: Der Versicherungsschutz ist voraussichtlich preisgünstiger, und die zugrunde liegenden Prozesse, insbesondere zur Abwicklung von Schäden, sind – da durch die Mitglieder induziert – gegebenenfalls transparenter und selbstbestimmter im Vergleich zu traditionellen Versicherungen.

Ein wesentlicher Vorteil ist die Kostenstruktur einer P2P-Versicherung; er kommt potenziell vollständig den Mitgliedern zugute. Die Abschlusskosten sind pro Abschluss gering und die Verwaltungskosten inklusive der internen Schadenregulierungskosten belaufen sich auf wenige Prozent der Versicherungsprämie.³¹⁰ Die nicht gebrauchten eingezahlten Versicherungsprämien werden wieder an die Mitglieder ausgeschüttet. Hierdurch besteht grundsätzlich die Möglichkeit, dass bei Schadenfreiheit innerhalb eines bestimmten Zeitraums für keines der Gruppenmitglieder Aufwendungen entstehen, abgesehen von geringen Beiträgen an den Infrastrukturanbieter.

Zusätzlich bringt eine Mitgliedschaft den Vorteil mit sich, Versicherungsprozesse innerhalb der eigenen Gruppe dynamisch gestalten und an die speziellen Bedürfnisse der Gruppe anpassen zu können. Dies könnte die Zufriedenheit eines Mitglieds mit dem angebotenen Versicherungsschutz erhöhen. Zugleich sind für Nutzer einer P2P-Versicherung Schadenbewertungen transparenter, da sie die Auszahlungen eigenständig bewerten und autorisieren können. Im Vergleich zu einer traditionellen Versicherung könnte dies das Vertrauen in Versicherungsprozesse weiter erhöhen.

5. Risiken

Nutzen Bigtechs ihre erfassten Kundendaten, um Versicherungsprofile zu erstellen, werden persönliche Daten unter Umständen nicht adäquat geschützt. Dieser Umstand wirft somit Fragen zum Datenschutz der Mitglieder einer P2P-Versicherung auf. Darüber hinaus bedingt die erwünschte Transparenz bei der Berechnung von Risiken und Schadenzahlungen, dass alle Mitglieder einer Gruppe alle Schadenmeldungen und die entsprechenden Details der darin gestellten Ansprüche einsehen können. Vor allem bei sensiblen Daten (z.B. Gesundheitsdaten) könnten sich der unter Umständen schwächere Datenschutz und ein damit einhergehender Verlust an Privatsphäre nachteilig auf die Mitglieder auswirken.

Versicherungsleistungen werden bei P2P-Versicherungen nicht durch ein traditionelles Versicherungsunternehmen garantiert. Der Versicherungsschutz könnte dadurch abnehmen, unabhängig davon, ob die Prämien der Mitglieder auskömmlich kalkuliert sind. Gerade in extremen Schadenjahren (sei es durch wenige nicht erwartete und sehr hohe Einzelschäden oder eine seltene Häufung kleinerer Schadenfälle) könnte es zu Ausfällen der Versicherungssummen kommen. Daraus ergibt sich die Frage, wie dieses Risiko in der Gruppe abgefangen werden könnte. Eine Möglichkeit wäre, eine Nachschusspflicht festzulegen, wie sie bei einigen Versicherungsvereinen auf Gegenseitigkeit vorgesehen ist. Wenn die Versicherungsleistungen in einer Periode die eingezahlten Prämien übersteigen, dann müsste die Gruppe nachschießen um die ausstehenden Verpflichtungen gegenüber den Versicherungsnehmern zu begleichen. Wie diese Pflicht bei P2P-Versicherungen umgesetzt werden könnte, bleibt zunächst offen. Auch eine Rückversicherungslösung wäre denkbar.³¹¹

³¹⁰ Die durchschnittliche Verwaltungskostenquote im deutschen (traditionellen) Kompositversicherungsmarkt liegt bei rund 14 Prozent, im Vergleich zu rund fünf Prozent bei Teambrella (Stand Dezember 2017). Hoppenstedt Versicherungsdatenbank, 2017, Verwaltungsaufwendungen brutto in Prozent der verdienten Bruttoprämien; Teambrella: Online verfügbar: <https://teambrella.com/>, abgerufen am 11.12.2017.

³¹¹ Alternativ könnte die Pflicht zur Bildung von Puffern vergleichbar mit den Schwankungsrückstellungen des deutschen Handelsgesetzbuchs europaweit festgelegt werden.

Ein anders gelagertes Risiko könnte sich daraus ergeben, dass sich gerade bei größeren Gruppen erfahrungsgemäß nur eine kleinere Zahl der Mitglieder intensiver mit den einzelnen Schadenfällen auseinandersetzen wird. In den oben beschriebenen Entscheidungsprozessen bekämen diese Personen ein erhebliches Gewicht. Dies könnte zur Folge haben, dass bei der Schadenregulierung Klientelpolitik betrieben wird, was die Transparenz einer P2P-Versicherung grundsätzlich in Frage stellen würde. In einem solchen Fall spielte bei der Schadenregulierung nicht nur der reine Sachverhalt eine Rolle, sondern auch die Beziehung des Antragstellers zu den genannten Personen.

Ein weiteres Risiko ist, dass die Mitglieder einer Gruppe mit einem erheblich höheren Verwaltungs- und Entscheidungsaufwand konfrontiert werden könnten. Da bei Eintritt in eine Gruppe nicht eindeutig abschätzbar wäre, wie viele einzelne Schadenfälle (gerade bei großen Gruppen) innerhalb bestimmter Zeiträume eintreten und dann durch Mitwirken der Mitglieder bearbeitet werden müssten, wären die Opportunitätskosten für Gruppenmitglieder nicht bewertbar (höherer Zeitaufwand für Schadenfallbearbeitungen gegenüber gegebenenfalls niedrigeren Zahlungen/Kosten im Vergleich zu einem Versicherungsvertrag mit einem traditionellen Versicherungsunternehmen).

Die Abwicklung von Zahlungen zwischen Mitgliedern könnte bei nicht ausreichend vertragsrechtlich gesicherten und institutionalisierten Geschäftsmodellen weitere Risiken für Versicherungsnehmer mit sich bringen. So birgt beispielsweise die Verwendung von Bitcoin als Währung ein gewisses Risiko aufgrund der Volatilität³¹² des Währungskurses³¹³ und der Gefahr von Angriffen aus dem Internet (wodurch einem Mitglied der Zugang zu seiner e-Wallet unwiederbringlich entzogen werden kann).³¹⁴

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte haben verschiedene Implikationen, welche die Aufsicht adressieren sollte. Diese werden zum Abschluss des Anwendungsbeispiels im nächsten Absatz genannt.

Auf Basis von BDAI zusammengestellte Gruppen von Versicherten zur Realisierung einer P2P-Versicherung, in der sich Mitglieder entsprechend dem Teambrella-Konzept organisieren, könnten genehmigungspflichtig sein. Dies gilt es in den einzelnen Staaten zu prüfen. Doch selbst wenn eine Genehmigungspflicht bestünde, so wäre das vorgestellte Geschäftsmodell unter Umständen nicht an jurisdiktionelle Grenzen gebunden. Insofern könnte die lokale Aufsicht in einzelnen Staaten umgangen und aufsichtsrechtliche Arbitrage betrieben werden. Dies beträfe dann auch den Daten- und kollektiven Verbraucherschutz.

³¹² Volatilität ist eine Messgröße dafür, wie sich der Preis eines Vermögenswerts mit der Zeit verändert. Der Wert der Bitcoins ergibt sich aus Angebot und Nachfrage sowie der Akzeptanz im Wirtschaftskreislauf. Der Einstieg von Spekulanten in den Bitcoin-Markt kann zu Kursschwankungen und Blasen führen. Vgl. BaFin-Fachartikel, 2013, Bitcoins: Aufsichtliche Bewertung und Risiken für Nutzer. Online verfügbar: https://www.bafin.de/SharedDocs/Veroeffentlichungen/DE/Fachartikel/2014/fa_bj_1401_bitcoins.html, abgerufen am 08.12.2017.

³¹³ Vgl. Bitcoin-Volatilitätsindex. Online verfügbar: <https://www.buybitcoinworldwide.com/de/volatilitatsindex/>, abgerufen am 07.12.2017.

³¹⁴ Durch Entwendung privater (digitaler) Zugangsschlüssel. Vgl. BaFin-Fachartikel, 2013, Bitcoins: Aufsichtliche Bewertung und Risiken für Nutzer. Online verfügbar: https://www.bafin.de/SharedDocs/Veroeffentlichungen/DE/Fachartikel/2014/fa_bj_1401_bitcoins.html, abgerufen am 08.12.2017.

Exkursbox: P2P-Versicherung

P2P-Versicherungen adressieren das allgemeine Misstrauen von Versicherungsnehmern gegenüber traditionellen Versicherungsunternehmen, was die unkomplizierte Erfüllung von Schadenansprüchen und die in vielen Fällen nur mühsam nachvollziehbare Berechnung von Versicherungsprämien angeht. Interessierte können sich als Peers zu Gruppen zusammenschließen, um sich gegenseitigen – basierend auf personalisierten Versicherungsbedingungen – Versicherungsschutz anzubieten. Das Prinzip von P2P-Versicherungen ist demnach vergleichbar mit dem von Versicherungsvereinen auf Gegenseitigkeit (VVaG). Die Rechtsform des VVaG ist ebenfalls vom Grundsatz der Gegenseitigkeit geprägt: „Alle für einen, einer für alle.“¹ Risiken werden geteilt und Schadenfälle aus einer gemeinsamen Kasse gedeckt.

P2P-Versicherungen könnten auf Basis neuer Technologien in den kommenden Jahren an Bedeutung gewinnen. Denn erst durch die Auswertung von Social-Media-Daten könnten sich nicht orts- bzw. berufsgebundene Gruppen (in der Sprache der P2P-Versicherungen „Gruppen“) mit ähnlichen Risikoprofilen zusammenschließen.

Erste im Markt zu beobachtende P2P-Versicherungen (Insurtechs aus Deutschland, Großbritannien und den USA; allerdings ohne Einsatz von BDAI) sind im Kraftfahrt- und Hausratversicherungssegment zu finden. Die Entwicklung von P2P-Versicherungen erfolgte in drei Wellen: In der ersten Welle traten reine Distributoren in den Markt ein, die einen Pool von Interessenten mit Policen unterschiedlicher Versicherungsunternehmen versorgten. In der zweiten Welle traten Versicherer in den Markt ein, die eigene, personalisierte Versicherungsprodukte über den Onlinekanal an Interessenten vertrieben. In der dritten Welle drängen mittlerweile Anbieter auf den Markt, die nur noch die technische Infrastruktur zur Verfügung stellen und neue Datenquellen zur Identifikation von geeigneten Versicherungsnehmern einsetzen. In einer vierten Welle könnten diese (oder neue) Anbieter ihre technische Infrastruktur mit Hilfe von BDAI weiter ausbauen.

¹ Farny VW 1975, 90 (92); Weigel in: Prölss VAG, § 15, Rn. 10.

5.4 Marktbetrachtung Kapitalmarkt

5.4.1 Einleitung und Status quo

Der Kapitalmarkt ist eine Interaktionsstruktur, in der verschiedene Akteure miteinander handeln. Diese Akteure lassen sich vereinfacht in zwei Gruppen aufteilen: die Sell-Side, z.B. Banken und Broker, sowie die Buy-Side, also Anleger wie Assetmanager oder Versicherer. Über diese beiden Gruppen hinaus gibt es im Kapitalmarkt eine Marktinfrastruktur, die von verschiedenen Anbietern bereitgestellt wird. Hierzu gehören Handelsplätze, Clearinghäuser und Custodians. Des Weiteren gibt es viele Anbieter von Daten-, Analytics- oder IT-Dienstleistungen. Insgesamt ist der Kapitalmarkt also bereits deutlich fragmentiert bzw. spezialisiert. Der größte Anteil der Erträge im Kapitalmarkt (geschätzte 82 Prozent in 2016) entfällt auf die Sell- und die Buy-Side.³¹⁵

Der Kapitalmarkt kann auch in Assetklassen aufgeteilt werden: Die großen Märkte sind der Zins- und Währungsmarkt³¹⁶, der Aktienmarkt und der Rohstoffmarkt³¹⁷, die auch die jeweiligen Derivatmärkte umfassen. Im Zins- und Aktienmarkt gibt es jeweils einen Primärmarkt³¹⁸ für den Handel mit bzw. die Herausgabe von neuen Titeln und einen Sekundärmarkt für den Handel mit existierenden Titeln und/oder OTC-Derivaten³¹⁹. Zum Primärmarkt kann auch der Advisory-Bereich gezählt werden, der sich z.B. mit Mergers & Acquisitions (M&A) befasst.

Daten und Analysemethoden sind bereits ein wesentlicher Bestandteil des Kapitalmarktes. Die Menge generierter und verfügbarer Daten wächst beständig.

Der Kapitalmarkt ist grundsätzlich geprägt von einer hohen Technologisierung und von einer intensiven Nutzung von Daten und Analysemethoden. Klassischerweise werden im Kapitalmarkt strukturierte Daten (z.B. Wertpapierpreise) verwendet. Marktteilnehmer bedienen sich dabei seit langem spezialisierter Daten- und Analytics-Anbieter. Hierbei reicht das Spektrum von klassischen Anbietern wie Bloomberg oder Reuters bis hin zu Spezialanbietern von Satellitenbildern und deren Auswertung³²⁰. Die Nutzung von nachweisbar werthaltigen Daten unterliegt vielfach Restriktionen z.B. durch Regelungen zum Insider Handel und dem dazugehörigen Front Running.

³¹⁵ Vgl. Morel et al., 2017, Global Capital Markets 2017. Mastering the Value Migration, S. 7. Online verfügbar: http://image-src.bcg.com/Images/BCG-Mastering-the-Value-Migration-May-2017_tcm108-153443.pdf, abgerufen am 30.01.2018.

³¹⁶ Zins-, Währungs- und Rohstoffmärkte werden oft auch zusammen als FICC bezeichnet (Fixed Income, Currency und Commodities).

³¹⁷ Hier kann zwischen einem physischen und einem Derivate-Markt (z.B. Futures auf Öl und auf Gas) unterschieden werden.

³¹⁸ Häufig als DCM (Debt Capital Markets) für Zinsinstrumente bzw. ECM (Equity Capital Markets) für Aktieninstrumente bezeichnet.

³¹⁹ Over-the-Counter-Derivate sind außerbörslich gehandelte Derivate.

³²⁰ Siehe Allison, 2017, How Hedge Funds Can Trade on Data Constantly Collected from the Sky. Online verfügbar: <http://www.newsweek.com/how-hedge-funds-can-trade-data-sky-satellite-fintech-562762>, abgerufen am 30.01.2018.

Die Datengenerierung und -verfügbarkeit nimmt weiterhin zu. So steigt das verfügbare Datenvolumen³²¹ u.a. durch die Verlagerung von Geschäften auf Handelsplätze, wodurch die Transaktionen auch für die nicht direkt in den Handel involvierten Akteure transparent werden können. Ebenso können regulatorische Vorgaben zum Wachstum der Datenbestände beitragen bzw. deren Zugänglichkeit erhöhen. Als Beispiele seien hier Pre- und Post-Trade-Transparency-Regeln der MiFID II und das ESEF³²² der ESMA genannt. Ein weiterer Treiber für die wachsende Datenverfügbarkeit und -nutzung im Kapitalmarkt ist der elektronische Handel in einigen Assetklassen und -typen, der durch einen hohen Prozessstandardisierungsgrad ermöglicht wird (sehr hoch beispielsweise im Aktien- und Futuresmarkt, zurzeit eher noch gering in High Yield Anleihen).³²³

Die heutige Nutzung von BDAI am Kapitalmarkt ist unterschiedlich. Sie variiert sowohl zwischen Marktteilnehmern als auch zwischen einzelnen Bereichen eines Marktteilnehmers.

Die Akteure am Kapitalmarkt nutzen BDAI sehr unterschiedlich. Im Vergleich zu anderen Marktteilnehmern nutzen zum Beispiel einige Hedgefonds bereits sehr umfangreich BDAI für Anlageentscheidungen. Auch der Nutzungszweck variiert. Bei aktiven Assetmanagern besteht dieser beispielsweise in der Vorhersage von Preisentwicklungen und in der Portfolioanalyse und -verwaltung³²⁴. Einige Marktteilnehmer sehen den Nutzen von mehr Daten bzw. neuen Analysemethoden jedoch durchaus kritisch.³²⁵ Im Vertrieb einer Investmentbank kann die BDAI-Nutzung in der Darstellung und Erfassung der aktuellen Marktlage oder in der Sales-Lead-Vorhersage bestehen.

Auch bei einzelnen Akteuren wird BDAI sehr unterschiedlich genutzt. So wird BDAI in Teilen des Frontoffice, beispielsweise im algorithmischen Handel, bereits stark genutzt (siehe auch Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung für institutionelle Anleger“), in anderen Frontoffice-Bereichen, beispielsweise der Schuldscheinemission, hingegen deutlich schwächer. Die unterschiedliche Nutzung von BDAI setzt sich in den Bereichen Middleoffice, Backoffice und den Kontrollfunktionen fort und spiegelt sich auch in den entsprechenden Dateninfrastrukturen wider.³²⁶

³²¹ Beispielsweise archivierte die NASDAQ OMX Group 2014 über 0,5 Petabyte Daten pro Jahr; Microsoft, 2014, NASDAQ OMX Group Reduces 2 PB of Data to 500 TB with Microsoft In-Memory Technology. Online verfügbar: <https://customers.microsoft.com/en-us/story/nasdaq-omx-group-reduces-2-pb-of-data-to-500-tb-with-m>, zuletzt abgerufen am 17.02.2018.

³²² European Single Electronic Format.

³²³ Im größten Einzelmarkt, dem Währungsmarkt mit über 5.000 Milliarden USD an täglichem Volumen (net-net) im April 2016 sind über 50 Prozent elektronisch ausgeführt; vgl. Bank for International Settlements, 2016, Triennial Central Bank Survey. Global foreign exchange market turnover in 2016. Bereits für 2010 wurde der Anteil der automatisierten Spot-Handelsgeschäfte auf ca. 25 Prozent geschätzt; Bank for International Settlements, 2011, High-frequency trading in the foreign exchange market. Markets Committee, S.11.

Im US Treasury Markt, der mit ca. 500 Milliarden USD an täglichem Volumen Ende 2017 ein weiterer großer Einzelmarkt ist, wird ebenfalls ein hoher Anteil der Benchmarkanleihen automatisch gehandelt, wobei die Elektronifizierung mit der von Futures vergleichbar ist; vgl. Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee, S. 10; vgl. Sifma, 2018, US Treasury Trading Volume. Online verfügbar: <https://www.sifma.org/resources/research/us-treasury-trading-volume/>, abgerufen am 19.01.2018. Bei Aktien und Futures wurden bereits 2015 80 Prozent bzw. 90 Prozent elektronisch gehandelt, während es bei High Yield Anleihen nur weniger als 30 Prozent waren; Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee, S. 9.

An den Börsen der Federation of European Security Exchanges (plus London Stock Exchange Group und BATS Europe) wurden im Oktober 2017 ca. 77 Prozent des Aktienhandelsvolumens über elektronische Orderbücher durchgeführt; Federation of European Security Exchanges, 2017, European Trading Statistics – European Electronic Order Book Equity Trading.

³²⁴ Siehe auch das Anwendungsbeispiel „Integrierte Analyse- und Portfolioverwaltungsplattformen“.

³²⁵ Siehe Wigglesworth, 2016, Fintech: Search for the super-algo. In: Financial Times. Online verfügbar: <https://www.ft.com/content/5eb91614-bee5-11e5-846f-79b0e3d20eaf>, abgerufen am 21.12.2016.

³²⁶ Die Fokussierung auf Ertragsgenerierung könnte in der Vergangenheit durchaus eine Hürde bei der BDAI-Aufrüstung dieser Bereiche gewesen sein.

Es ist zudem festzustellen, dass viele der existierenden Modelle (z.B. im Hedging) am Kapitalmarkt bereits eine hohe Güte aufweisen. Durch eine vermehrte Nutzung von BDAI könnte sich deren Qualität folglich nur in geringem Maße steigern lassen. Dennoch könnten in einigen Bereichen des Kapitalmarktes die Notwendigkeit der kontinuierlichen Verbesserung und die daraus resultierenden Zugewinne dazu führen, dass BDAI-Methoden vermehrt angewendet werden. So könnten beispielsweise neue oder mit BDAI erweiterte Handels-, Hedge-, Risiko- oder Alpha³²⁷-Modelle sowie Portfolio- und Kapitaloptimierungsmodelle zu Ertragssteigerungen oder besserer Risiko- und Kapitaleffizienz führen.

Der Markt zeichnet sich durch opportunistische und auch „antagonistische“ Geschäftsmodelle der Kapitalmarktteilnehmer aus.

Die opportunistischen und auch antagonistischen Geschäftsmodelle³²⁸ führen zu einem vergleichsweise hohen Anpassungsdruck, schneller Verbreitung von Trends³²⁹ und damit zu hoher Experimentier- und Innovationsbereitschaft. Die damit einhergehende Beweglichkeit wird auch durch die teilweise hohen Margen unterstützt, die notwendige Investitionen in Technologie und Fähigkeiten³³⁰ möglich machen könnten. Beispiele hierfür sind die (in etwa) Versiebenfachung des CDS-Volumens von 2004 bis 2007³³¹ und – BDAI-spezifischer – die knappe Verdoppelung des Volumens von Quant-Hedgefonds auf etwas unter 1.000 Milliarden USD in den vergangenen sieben Jahren.³³² Auf der Buy-Side haben einige große, BDAI nutzende Hedgefonds deutlich zweistellige Milliardenbeträge an verwalteten Vermögenswerten erreicht. Aktuell sind Bitcoin-Futures, -Fonds oder Bitcoin-Analysen ein Beleg für die dynamische Anpassungsfähigkeit der Geschäftstätigkeit an neue Marktopportunitäten.

Da die Marktteilnehmer im Status Quo zahlreiche Stoßrichtungen verfolgen (oder gegebenenfalls mit diesen experimentieren), wird es weitere BDAI-bedingte Veränderungen im Kapitalmarkt geben. Diese werden vermutlich zu – teilweise naheliegenden – Effizienz- und Effektivitätssteigerungen führen. Darüber hinaus sind weiterreichende Veränderungen nicht auszuschließen, denn diese haben sich bereits in der Vergangenheit als branchenimmanent herausgestellt; So sollen beispielsweise Anfang der 2000er Jahre ca. 600 Cash-Equity-Trader bei einer großen Investmentbank in New York tätig gewesen sein, heute sind es – vornehmlich in Folge von Automatisierung – offenbar nur noch zwei (und 200 IT-Experten).³³³

³²⁷ Mit Alpha wird im Allgemeinen der Mehrertrag gegenüber dem Vergleichsmarkt bezeichnet.

³²⁹ Beispielsweise sollen die Prüfungen zum Chartered Financial Analyst ab 2019 Fragen zu AI beinhalten; vgl. Hunnicutt, 2017, CFA exam to add artificial intelligence, 'big data' questions". In: Reuters. Online verfügbar: <https://www.reuters.com/article/us-investment-tech-cfa/cfa-exam-to-add-artificial-intelligence-big-data-questions-idUSKBN18J2R4>, abgerufen am 14.01.2018.

³³⁰ So finden sich große Investmentbanken z.B. unter den Top 10 der beliebtesten Arbeitgeber bei Undergraduates im Business und Engineering weltweit; vgl. Ziegler et al., 2017, World's Top Employers for New Grads. In: CNN Money. Online verfügbar: <http://money.cnn.com/gallery/news/companies/2017/06/30/worlds-top-employers-new-grads/10.html>, abgerufen am 12.01.2018.

³³¹ Bank for International Settlements, 2018, OTC, credit default swaps, by type of position. Stand: H1 2007. Online verfügbar: <http://stats.bis.org/statx/srs/table/d10.1?p=20071&c=>, abgerufen am 12.01.2018.

³³² Vgl. Wigglesworth, 2018, Quant hedge funds set to surpass \$1tn management mark. In: Financial Times. Online verfügbar: <https://www.ft.com/content/ff7528bc-ec16-11e7-8713-513b1d7ca85a>, abgerufen am 30.01.2017.

³³³ Siehe Byrnes, 2017, As Goldman Embraces Automation, Even the Masters of the Universe Are Threatened, In: MIT Technology Review. Online verfügbar: <https://www.technologyreview.com/s/603431/as-goldman-embraces-automation-even-the-masters-of-the-universe-are-threatened/>, abgerufen am 12.01.2018.

Insgesamt könnte eine vermehrte Nutzung von BDAI zu einer Verschiebung der Erträge zugunsten von Daten- und Analytics-Anbietern, Nischenanbietern sowie Marktinfrastrukturanbietern führen.³³⁴ Erträge aus Effizienzgewinnen würden vermutlich nur temporär bei den Akteuren verbleiben und könnten beispielsweise durch weitere Margenkompression³³⁵ aufgebraucht werden.

5.4.2 Naheliegende Entwicklungen: „More of the same, only faster and better“

Vor dem Hintergrund der bereits weit fortgeschrittenen Nutzung von Daten und Analysemethoden im Kapitalmarkt ist es naheliegend, dass es durch die erweiterte Nutzung von BDAI zu einem „More of the same, only faster and better“ kommen könnte. BDAI könnte zu einer Optimierung im Front-, Middle- und Backoffice führen und zu einer weiteren Automatisierung und Algorithmisierung von Handel und Produkten sowie dem Auftreten von Fintechs als verlängerten Werkbänken oder Innovationsgebern in Partnerschaft mit bzw. als Anbieter für Incumbents.

BDAI kann zu einer Optimierung (Effizienz- und Effektivitätssteigerungen) im Front-, Middle- und Backoffice sowie den angrenzenden Bereichen beitragen.

Grundsätzlich zielen BDAI-Anwendungen im Frontoffice sowohl auf Effektivität (z.B. mehr Alpha, Finden von Ertragsquellen) als auch auf Effizienz (z.B. Einsatz von Robotic Process Automation³³⁶) ab. Im Gegensatz zum Middle- und Backoffice könnten die Effektivitätsziele jedoch überwiegen. Für das Middle- und das Backoffice bestehen vermutlich ebenfalls Effizienzpotentiale, die zum Teil mit BDAI-Methoden gehoben werden könnten. Hierzu zählen generelle Anwendungen wie die Erfassung und Auswertung unstrukturierter Daten (z.B. Vertragstexte), aber auch der Einsatz von Predictive Analytics im Trade Processing. Es ist zudem wahrscheinlich, dass durch BDAI eine weitere Automatisierung vorangetrieben werden könnte, beispielsweise durch den Einsatz von RPA entlang aller Touchpoints (Front-/Middle-/Backoffice) inklusive Onboarding/Know Your Customer.³³⁷ Ein Beispiel hierfür wäre das Schließen von Automatisierungslücken im Fixed Income Settlement. All diese Anwendungen haben allerdings auf die Struktur und Verfassung des Kapitalmarkts relativ geringe Auswirkungen.

³³⁴ Siehe Morel et al., 2017, Global Capital Markets 2017. Mastering the Value Migration. Online verfügbar: http://image-src.bcg.com/Images/BCG-Mastering-the-Value-Migration-May-2017_tcm108-153443.pdf, abgerufen am 30.01.2018.

³³⁵ Mögliche Margenzugewinne durch Kostensenkungen könnten durch Wettbewerbsdynamik aufgezehrt werden.

³³⁶ Abseits von spezifischen Modellen zeichnet sich im Frontoffice der vermehrte Einsatz von Robotic Process Automation ab, beispielsweise zur automatischen Erfassung von spezifischen E-Mail-Inhalten und deren Ausführung, siehe Arnold et al., 2017, Robots enter investment banks' trading floors. In: Financial Times online. Online verfügbar: <https://www.ft.com/content/da7e3ec2-6246-11e7-8814-0ac7eb84e5f1>, abgerufen am 30.01.2018.

³³⁷ Research in Investmentbanken wird hier nicht gesondert betrachtet.

Spezifische Anwendungsbereiche im Middle- und Backoffice zeichnen sich hingegen z.B. im Collateral Management/Optimierung³³⁸, der Model Validation³³⁹ und in der Nutzung von Liquiditätsrisikomodellen, speziell für Assetmanager³⁴⁰, ab. Deutliche Änderungen im Collateral Management könnten sich durch die veränderte Nachfrage nach sicheren Assets auch auf den Kapitalmarkt auswirken. Schließlich gibt es auch bei der Vertragserstellung für Derivate Fortschritte in der Automatisierung.

Auch regulatorische Reporting-Pflichten erfordern effektive Prozesse, die durch die Nutzung von BDAI verstärkt und effizienter werden könnten. Hierzu zählen z.B. Real-Time-Reporting, interne Compliance und Überwachung. Für Compliance und Überwachung, etwa Handelsüberwachung und die Auswertung elektronischer Kommunikation wie E-Mail-Verkehr, ist BDAI bereits heute im Einsatz. Die einzelnen Kapitalmarktakteure (insbesondere Banken) können diese Art der Kommunikation auch intern im Bereich Compliance nutzen, beispielsweise durch die Auswertung von unstrukturierten Daten (z.B. Kommunikationsdaten).³⁴¹ Gerade auf diesem Feld lassen sich bereits Aktivitäten von Regtechs beobachten.

Zusammenfassend lässt sich feststellen, dass BDAI-Anwendungen in immer mehr Funktionen zur Unterstützung im Front, Middle- und Backoffice sowie in Compliance-Prozessen Einzug halten.

BDAI erlaubt die weitere Automatisierung und Algorithmisierung und damit eine verstärkte Maschine-Maschine-Interaktion bei Handel, Sales und Produkten. Diese Entwicklung könnte eine entsprechende Beschleunigung von Prozessen bewirken und auch Advisory betreffen.

Bereits heute sind viele Handelsinteraktionen zwischen Kapitalmarktteilnehmern stark standardisiert, digitalisiert, automatisiert und algorithmisiert (siehe auch Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung für institutionelle Anleger“). Daher sind durch BDAI auf diesem Gebiet zunächst keine wesentlichen Veränderungen zu erwarten. Dennoch ist eine Zunahme bzw. ein Ausbau des algorithmischen Handels, welcher nicht notwendigerweise hochfrequent sein muss, über alle Assetklassen hinweg absehbar. Dadurch könnten bestehende Automatisierungs- und Digitalisierungslücken geschlossen werden. Ein Markt mit noch größeren Automatisierungspotentialen bzw. mit deutlichen Nischen ist beispielsweise Fixed Income, also etwa der elektronische Handel mit Unternehmens- oder High Yield Anleihen. Als Treiber hierfür könnte der algorithmische Handel wirken (beispielsweise sich so abzeichnend im Handel mit Unternehmensanleihen³⁴²), der gemeinsame Standards und effiziente Prozesse erforderlich macht. Hierdurch würde der Anteil von Maschine-zu-Maschine Interaktionen im Kapitalmarkt weiter steigen.

³³⁸ Das heißt die Optimierung der zu hinterlegenden Sicherheiten, die auch eine Pricing-Komponente bei Derivaten haben, siehe für mögliche Ansätze z.B. Kondratyev et al., 2017, MVA Optimization with Machine Learning Algorithms. Online verfügbar: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2921822, abgerufen am 31.10.2017.

³³⁹ Model Validation ist das Führen des Nachweises, dass Modelle entsprechend ihrem Design und den Geschäftsanforderungen ihre Aufgabe erwartungsgemäß erfüllen (z.B. Einsatz von maschinellem Lernen, siehe Woodall, Model risk managers eye benefits of machine learning. In: risk.net. Online verfügbar: <https://www.risk.net/risk-management/4646956/model-risk-managers-eye-benefits-of-machine-learning>, abgerufen am 12.1.2018.).

³⁴⁰ Siehe Kilburn, 2017, Firms race to apply machine learning to liquidity risk models. In: risk.net. Online verfügbar: <https://www.risk.net/asset-management/5328636/firms-race-to-apply-machine-learning-to-liquidity-risk-models>, abgerufen am 12.01.2018.

³⁴¹ Siehe van Liebergen, 2017, Machine Learning: A Revolution in Risk Management and Compliance? Institute of International Finance Research Note. Online verfügbar: <https://www.iif.com/publication/research-note/machine-learning-revolution-risk-management-and-compliance>, abgerufen am 30.01.2018.

³⁴² Siehe The Economist, 2017, Digitalisation shakes up corporate-bond markets. Online verfügbar: <https://www.economist.com/news/finance-and-economics/21721208-greater-automation-promises-more-liquidity-investors-digitisation-shakes-up>, abgerufen am 19.11.2017.

Neben der Nutzung von BDAI-Anwendungen im Handel ist auch eine verstärkte Automatisierung und Algorithmisierung im Sales des Assetmanagements feststellbar. Hier ist der Einsatz von BDAI zum einen in Pricing-Strategien³⁴³ zu sehen, zum anderen ist ein Anstieg der Zahl von Robo-Advisors³⁴⁴ zu beobachten.³⁴⁵ Viele davon sind zurzeit allerdings noch von vergleichsweise geringer BDAI-Komplexität. Zurzeit haben derartige Angebote von Incumbents deutlich größere Volumina als die von neuen Fintech-Anbietern,³⁴⁶ und weiterhin halten einige Incumbents Anteile an solchen Fintechs³⁴⁷. Ferner lässt sich im Retailbereich des Assetmanagements ein vermehrter Einsatz von BDAI zur Unterstützung des Cross-Selling beobachten (z.B. von Assetmanagementprodukten an Kunden von Bankprodukten). Auch im Wealth Management ist maschinelles Lernen zur Erzeugung von Vorschlägen für Kunden als Handreichung für die Mitarbeiter (sogenannte Next-Best Action) zu sehen.³⁴⁸

Auch Prozesse und Entscheidungen, die traditionell eher auf menschlicher Interaktion und Begutachtung basieren, wie beispielsweise im Advisory, könnten künftig vermehrt von BDAI-Anwendungen unterstützt werden. BDAI wird z.B. bereits genutzt, um zu untersuchen, wann oder ob ein geeigneter Marktzeitpunkt für ein ECM³⁴⁹- oder DCM-Engagement³⁵⁰ vorliegen könnte. Der Einsatz von BDAI ist zudem in sehr personalintensiven Anwendungen wie der Due Diligence oder anderen Rechtsprozessen erkenn- oder denkbar. So könnten Legaltechs entsprechende Prozesse skalierbar machen. BDAI ließe sich auch zur Meinungsbeeinflussung für bestimmte Ziele am Kapitalmarkt (z.B. im Shareholder Activism) einsetzen, was aus Verbrauchersicht allerdings problematisch wäre.³⁵¹

Letztlich könnte ein bereichsübergreifender BDAI-Einsatz auch in der algorithmischen Produktentwicklung liegen.³⁵² So wäre – vereinfacht ausgedrückt – denkbar, dass durch BDAI automatisiert Marktentwicklungen und -trends in die Gestaltung von Finanzprodukten Einzug halten könnten. Möglicherweise hätten hier Bigtechs einen Vorteil, da, wie bereits erwähnt, die konstante datenbasierte Optimierung von Produkten bereits Teil ihres Geschäfts- und Betriebsmodells ist.³⁵³

Insgesamt könnten aus der weiteren Kopplung von Maschinen und Anwendungen über Marktteilnehmer hinweg höhere Geschwindigkeiten, situativ stärker schwankende Liquidität und Episoden höherer Volatilität resultieren.³⁵⁴ Selbstverstärkende Wechselwirkungen könnten wiederum zu Instabilitäten in Märkten führen.

³⁴³ Zum Beispiel der Einsatz von BDAI zur Ermittlung von optimalen Managementgebühren; Ähnliches gilt auch für Security-Services (z.B. Custodians, Clearinghäuser).

³⁴⁴ (Retail) Assetmanagement- oder Vermittlungsprodukte mit vollautomatisierter Kundenschnittstelle, die auf den Angaben des Kunden aufbauend Portfoliozusammensetzungen algorithmisch ermitteln und gegebenenfalls verwalten. Auch Mischformen (Mensch und Maschine, Cyborg-Advisor) und Advisor-Plattformen sind im (Fintech-)Markt zu beobachten.

³⁴⁵ Siehe auch Kapitel 5.2, Marktbetrachtung Banken.

³⁴⁶ Vgl. World Economic Forum, 2017, Beyond Fintech: A Pragmatic Assessment Of Disruptive Potential In Financial Services, S. 136.

³⁴⁷ Zum Beispiel Jessop et al., 2017, BlackRock takes Scalable Capital stake in Europe "robo-advisor" push. In: Reuters. Online verfügbar: <https://uk.reuters.com/article/us-blackrock-scalablecapital/blackrock-takes-scalable-capital-stake-in-europe-robo-advisor-push-idUKKBN19A322>, abgerufen am 12.01.2018.

³⁴⁸ Siehe Son, 2017, Morgan Stanley's 16,000 Human Brokers Get Algorithmic Makeover. In: Bloomberg. Online verfügbar: <https://www.bloomberg.com/news/articles/2017-05-31/morgan-stanley-s-16-000-human-brokers-get-algorithmic-makeover>, abgerufen am 15.01.2018.

³⁴⁹ Equity Capital Markets.

³⁵⁰ Debt Capital Markets.

³⁵¹ Die Diskussionen über die Beeinflussung von Wählermeinungen in der neueren Zeit legen nahe, dass Methoden dieser Art Wirklichkeit sind.

³⁵² Beispielsweise wird dies im Textilsektor von einigen Start-ups genutzt, siehe z.B. <https://www.fastcodesign.com/90128248/how-stitch-fix-is-using-algorithmic-design-to-become-the-netflix-of-fashion>, abgerufen am 30.01.2018.

³⁵³ Zum Beispiel durch die Nutzung von A/B-Tests zur Identifizierung von vielversprechenden Produktänderungen.

³⁵⁴ Siehe die Diskussion im Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung für institutionelle Anleger“.

Fintechs entfalten sich bislang vor allem in Partnerschaft mit Incumbents auf dem Kapitalmarkt. Häufig fungieren sie als verlängerte Werkbank, Ideengeber oder Spezialanbieter für Prozessänderungen und Effizienzsteigerungen.

Bei Fintechs ist bisher nur ein geringer direkter Einfluss³⁵⁵ auf den Kapitalmarkt als Ganzes zu beobachten.³⁵⁶ Sie treten bislang insbesondere in den Bereichen Data und Analytics sowie der Ausführung (bzw. den Ausführungstechnologien und entsprechenden Infrastrukturen) in Erscheinung. Vereinfacht können drei Ansätze unterschieden werden:

1. Fintechs kooperieren mit oder werden unterstützt von Incumbents bzw. integrieren sich systematisch in deren Prozesse. Fintechs dürften daher weniger unabhängige Verdränger sein, sondern eher als verlängerte Werkbank und Ideenlieferant für die rasche Umsetzung von BDAI-Anwendungen fungieren.
2. Fintechs treten als Spezialanbieter für Finanzdienstleister und andere Incumbents auf dem Kapitalmarkt in Erscheinung. Ein Beispiel sind Anbieter von Programmbibliotheken³⁵⁷ zum schnellen numerischen Differenzieren, wie es in der Beschreibung von Exposures und Risiken bereits in großem Umfang genutzt wird. Hierdurch könnten Effizienzsteigerungen in den entsprechenden Bereichen von Banken oder Assetmanagern ermöglicht werden. Ein weiteres Beispiel ist die Optimierung von Portfolien von (börsengehandelten) Derivaten mit Blick auf verschiedene Markteinschätzungen. Hierbei müssen Milliarden von Kombinationen berücksichtigt werden. Auch die Rechtsauslegung und Vorhersage von Gerichtsurteilen – Stichwort „Legaltech“ – wären ein mögliches Angebot, das helfen könnte, Rechtsunsicherheit zu reduzieren bzw. schneller und effektiver zu entscheiden.³⁵⁸
3. Fintechs treten auch als unabhängige Anbieter von Finanzdienstleistungen (z.B. von Handelsplattformen) in Erscheinung. Dieser Ansatz könnte sich als weniger durchsetzungsfähig herausstellen. So ist beispielsweise für Kernbereiche wie SEFs³⁵⁹ der Marktanteil von dort unabhängig auftretenden Fintechs bislang klein.³⁶⁰ Ein Grund hierfür könnte in der hohen Anpassungsfähigkeit und dem potenziell disruptiven Handeln³⁶¹ der Incumbents liegen. Dadurch könnte das eigenständige Eindringen von Fintechs in (Kern-)Bereiche des Kapitalmarkts erschwert werden.

Was die tatsächliche Entwicklung von Fintechs angeht, ist jedoch folgendes zu beachten: Vor allem Incumbents wie Investmentbanken investieren in regulatorische Projekte oder haben bereits viele Ressourcen darin investiert (z.B. in die Umsetzung der MiFID II). Folglich haben sie als relevante Akteure bislang zur Entwicklung von Fintechs im Sinne der ersten beiden Ansätzen beigetragen. Sollten bei Incumbents die entsprechenden Kapazitäten jedoch wieder frei werden, könnten sie diese – bisher an Fintechs ausgelagerten – Projekte künftig selbst durchführen.

³⁵⁵ Beispielsweise waren 2017 laut einer Erhebung nur circa 36% der AI-basierten Fintechs am Kapitalmarkt disruptiv ausgerichtet. BCG FinTech Control Tower.

³⁵⁶ Vgl. die vorangehenden Beispiele aus einer Studie des World Economic Forum; World Economic Forum, 2017, Beyond Fintech: A Pragmatic Assessment Of Disruptive Potential In Financial Services. Insgesamt ist die Zahl der Fintechs im direkten Kapitalmarkt im Vergleich zum Retail- oder Corporate-Banking klein: von ca. 8000 von BCG 2016 verfolgten Fintechs waren nur ca. 600 im Kapitalmarkt verortet; siehe Morel et al., 2016, Fintechs in Capital Markets: Land of Opportunity. Online verfügbar: <https://www.bcg.com/de-de/publications/2016/financial-institutions-technology-digital-fintech-capital-markets.aspx>, abgerufen am 30.01.2018. Für Principal Trading Firms und Hedgefonds mit Crowdsourcing von Algorithmen siehe nächsten Abschnitt.

³⁵⁷ Eine Sammlung von Funktionen und Routinen zur Nutzung durch Computerprogramme.

³⁵⁸ Diskutiert z.B. in Alarie et al., 2016, Regulation by Machine. In: 30th Conference on Neural Information Processing Systems (NIPS 2016), Barcelona, Spain.

³⁵⁹ Swap Execution Facility, eine Handelsplattform.

³⁶⁰ Vgl. World Economic Forum, 2017, Beyond Fintech: A Pragmatic Assessment Of Disruptive Potential In Financial Service, S. 178.

³⁶¹ Beispielsweise sind nach einer Studie des World Economic Forum Marktinfrastrukturanbieter teilweise sich selbst gegenüber disruptiv, vgl. World Economic Forum, 2017, Beyond Fintech: A Pragmatic Assessment Of Disruptive Potential In Financial Services, S. 170.

5.4.3 Weiterführende Entwicklungen: Höhere Vernetzung und Komplexität

Neben einem „More of the same, only faster and better“ könnte die vermehrte Nutzung von BDAI aber auch weiterreichende und tiefgreifende Folgen haben – etwa Neuordnungen in der Marktlandschaft. Zum anderen könnten BDAI-Anwendungen zu einer erhöhten Transparenz am Kapitalmarkt sowohl für die Interaktion mit Geschäftspartnern als auch für die Erstellung von Produkten beitragen. Mit jeder neuen modell- und datengetriebenen Interaktion oder mit jedem auf diese Weise erzeugten Produkt werden die Verknüpfungen zwischen Akteuren und Märkten verstärkt. Hierdurch könnte es insgesamt zu einer stärkeren Vernetzung und höherer Komplexität am Kapitalmarkt kommen.

5.4.3.1 Neuordnungen in der Marktlandschaft

BDAI erleichtert die Spezialisierung und das Entstehen neuer Marktteilnehmer und kann so zu einer weiteren Fragmentierung der Wertschöpfungsketten im Kapitalmarkt führen.

Da der Kapitalmarkt stark datengetrieben ist, erleichtert BDAI grundsätzlich das Überführen von Wertschöpfungskomponenten in (mehrere) eigenständige Modelle, d.h. eine Fragmentierung durch Spezialisierung³⁶². Bereits jetzt sind Spezialanbieter wie etwa Principal Trading Firms³⁶³ und Anbieter von Post-Trade-Analysewerkzeugen zum Nachweis von Best Execution³⁶⁴ am Markt etabliert. Diese Entwicklung kann zugleich durch das Freiwerden bestimmter Rollen im Kapitalmarkt verstärkt werden, etwa wenn Incumbents ihren Fokus auf den Handel in Agent-Kapazität richten³⁶⁵.

Darüber hinaus ist eine Kombination aus bereits erfolgter Spezialisierung und Fragmentierung in der Wertschöpfung und einem Streben nach höherer Effektivität unter Verwendung von BDAI zu beobachten. Ein Beispiel hierfür sind Versicherungsunternehmen und Altersversorgungseinrichtungen. Diese Akteure beschaffen bereits heute bestimmte BDAI-Kapitalmarktleistungen extern (z.B. im Bereich Alternative Investments). Inzwischen zeichnet sich bei diesen auch der mittelbare Einsatz von BDAI in der Auswahl der Anbieter ab, z.B. von Hedgefonds,

³⁶² Z.B. durch die Möglichkeit, zahlreiche Tätigkeiten mittels BDAI zu automatisieren, und den einfachen Zugang zu mächtigen BDAI-Werkzeugen wie entsprechenden Programmbibliotheken.

³⁶³ Dies sind (Hoch-Frequenz) Handelsfirmen, die unter Übernahme von eigenem Risiko algorithmisch beispielsweise Kundenaufträge abwickeln bzw. Market-Making betreiben und auf eigene Rechnung handeln. Hierbei können sie als Liquiditätsanbieter auftreten.

³⁶⁴ Banken und Finanzdienstleistungsinstitute müssen bei der Ausführung der Aufträge angemessene Vorkehrungen treffen, um im Regelfall das bestmögliche Ergebnis zu erzielen, vgl. Bundesanstalt für Finanzdienstleistungsaufsicht, 2015, Wertpapiergeschäfte – Was Sie als Anleger beachten sollten. Online verfügbar: https://www.bafin.de/DE/Verbraucher/GeldanlageWertpapiere/Wertpapiergeschaeft/wertpapiergeschaeft_artikel.html, abgerufen am 14.01.2018. Die Broschüre wird derzeit überarbeitet.

³⁶⁵ Der Handel ohne Übernahme eigenen Risikos.

Zwar profitieren Bigtechs bereits heute von der BDAI-Nutzung im Kapitalmarkt, da sie als wichtige Infrastrukturanbieter fungieren, indem sie Cloudcomputing anbieten. Vorstellbar ist aber auch, dass Bigtechs ihr Kerngeschäft erweitern und ihre Präsenz im Kapitalmarkt stärken. Hierzu könnte z.B. die Nutzung des vorhandenen Customer-Reach, bestehender Prozessketten und Client-Analytics-Fähigkeiten für den großflächigen (reinen) Vertrieb von Retail-Finanzprodukten gehören. In einigen Bereichen des Kapitalmarktes sind auch neue Geschäftsmodelle denkbar. Beispielsweise könnten Bigtechs als Assetmanager auftreten.³⁶⁶ Dabei dürfte es dann möglicherweise nicht nur um die Vereinnahmung von Gebühren gehen, sondern auch darum, das jeweilige (Daten-)Ökosystem zu vergrößern. So betreibt bereits ein Affiliate von Alibaba den größten Geldmarktfonds der Welt (Yu'E Bao). Vorstellbar ist auch eine direkte Monetarisierung relevanter Daten mit speziellen Angeboten für Finanzdienstleister.

Durch BDAI können neue Akteure auf dem Kapitalmarkt entstehen, wodurch, wie bereits erwähnt, der Grad der Verflechtung und die Komplexität des Marktes zunehmen dürften.

Durch die Nutzung von BDAI könnte die Zahl von Schnittstellen zunehmen und die Standardisierung im Front-, Middle- und Backoffice fortschreiten. Make-or-Buy-Entscheidungen müssen daher möglicherweise neu bewertet werden.

BDAI-Anwendungen profitieren vom leichten und standardisierten Datenzugriff. Folglich kann die Umsetzung von BDAI im Front-, Middle- und Backoffice auch dort zu einer höheren Standardisierung beitragen. Dadurch kann wiederum die Verbreitung und Nutzbarmachung von Schnittstellen am Kapitalmarkt gefördert werden. Beispielsweise wäre ein universelles Middle- und Backoffice-Kommunikationsprotokoll denkbar, sodass Post-Trade-Informationen ähnlich universell zwischen diesen ausgetauscht werden könnten wie Pre-Trade- und Trade-Informationen. Ebenso wäre eine stärkere Nutzung von regulatorischen Schnittstellen möglich. Beispielhaft wäre auch ein Datenaustausch durch Model-Driven Machine Executable Regulatory Reporting zu nennen, also die direkte Maschine-Maschine-Kommunikation im Rahmen des Reportings zwischen Aufsicht und Aufsichtsobjekt.³⁶⁷

Das Entstehen neuer Schnittstellen und die weitere Standardisierung von Prozessen könnten zu einer neuen Bewertung von Make-or-Buy-Entscheidungen führen. So öffnen bereits erste Investmentbanken ihre Risikomanagementsysteme für Kunden.³⁶⁸ Kleinere Anbieter, die ihr Kapitalmarktgeschäft unterkritisch und als Zusatz zum Kerngeschäft betreiben,³⁶⁹ könnten möglicherweise vermehrt White-Labeling nutzen.³⁷⁰ Durch verfügbare Schnittstellen und Standardisierung könnte bei diesen Akteuren der Anreiz bestehen, auf diese Weise fehlende Skaleneffekte im unterkritischen Zusatzgeschäft auszugleichen. Gleichzeitig würden die Marktrisiken dieser Akteure sinken.

³⁶⁶Siehe Mnyanda, 2017, TechFirms Are the Next Threat to Asset Managers, Moody's Says. In: Bloomberg Markets. Online verfügbar: <https://www.bloomberg.com/news/articles/2017-11-14/tech-firms-are-next-big-threat-to-asset-managers-moody-s-says>, abgerufen am 12.01.2018; siehe Takeo et al., 2017, World's Biggest Pension Fund Says AI Will Replace Asset Managers. In: Bloomberg. Online verfügbar: <https://www.bloomberg.com/news/articles/2017-12-14/world-s-biggest-pension-fund-sees-ai-replacing-asset-managers>, abgerufen am 18.12.2017).

³⁶⁷ Siehe Financial Conduct Authority, 2017, Model-driven machine executable regulatory reporting. Online verfügbar: <https://www.fca.org.uk/firms/our-work-programme/model-driven-machine-executable-regulatory-reporting>, abgerufen am 12.01.2018.

³⁶⁸ Zum Beispiel Baer, 2016, Goldman Sachs Has Started Giving Away Its Most Valuable Software. In: The Wall Street Journal. Online verfügbar: <https://www.wsj.com/articles/goldman-sachs-has-started-giving-away-its-most-valuable-software-1473242401>, abgerufen am 12.01.2018. Derartiges hat im Investmentbanking durchaus Tradition: RiskMetrics Group ist beispielsweise eine Ausgründung aus J.P. Morgan & Co. 1998 heraus.

³⁶⁹ D. h. ohne effektive Nutzung von Skaleneffekten.

³⁷⁰ D. h. vereinfacht, dass Anbieter Dienstleistungen von Drittanbietern nutzen und diese unter eigenem Namen anbieten.

Im Extremfall könnte die konsequente Nutzung von Schnittstellen zu einer noch stärkeren Fragmentierung der Wertschöpfung bis hin zu einer vollständigen Digitalisierung der Aufgaben von Akteuren führen. Das Anwendungsbeispiel „Crowdsourcing von Investment-Algorithmen“ zeigt bereits erste Ansätze in diese Richtung.

Die Rolle von Daten-, Analytics- und Prozessanbietern im Kapitalmarkt wird durch die Anwendung von BDAI relevanter. Folglich könnte es zu einer weiteren Konzentrierung innerhalb dieser Anbietergruppen kommen.

Die fortschreitende Algorithmisierung und Automatisierung baut, wie bereits erwähnt, auf Daten- und Algorithmenverfügbarkeit auf. Die Relevanz der Anbieter, welche diese bereitstellen, nimmt dadurch zu. Existierende Anbieter erweitern mitunter ihr Angebot, indem sie weitere neuer Anbieter einbeziehen und eigene Angebote von Daten und Analytics ausbauen. So öffnen die Anbieter von Plattformen für Daten und Informationen ihre Plattformen für Drittanbieter, welche ihre Daten und Anwendungen so einem größeren Abnehmerkreis zur Verfügung stellen können.³⁷¹ Ein prägnantes Beispiel für den Ausbau eigener Angebote ist der Einsatz von maschinellem Lernen in Liquiditätsrisikomodellen für Assetmanager.³⁷²

Beim Aufbrechen der Wertschöpfungsketten könnte es zudem passieren, dass sich Kapitalmarktakteure auf Kernkompetenzen beschränken. Im Gegenzug schließen wenige andere Akteure die nun offenen Schritte in der Wertschöpfungskette durch entsprechende Angebote. Dieser Ansatz ist bei integrierten Analyse- und Portfolioverwaltungsplattformen bereits zu beobachten (siehe Anwendungsbeispiel „Integrierte Analyse- und Portfolioverwaltungsplattformen“).

Im Laufe dieser Entwicklungen könnte es in den Gruppen der Daten-, Analytics- und Prozessanbieter durch Skaleneffekte zu einer weiteren Konzentration auf Incumbents kommen. Vorstellbar wäre auch, dass selbstverstärkende Datenerzeugungsstrukturen eine positive Wirkung auf bestehende Anbieter haben. So könnten Kapitalmarktakteure bereitgestellte Daten zur Erzeugung neuer Daten nutzen, die wiederum von Daten-, Analytics- und Prozessanbietern für ihre Dienstleistungen genutzt würden.

5.4.3.2 Zielgerichtete Transparenzsteigerungen

Die Nutzung von BDAI könnte die Transparenz für Marktteilnehmer erhöhen, die so ihre Wettbewerbspositionen verbessern und neue Produkte herstellen könnten.

In verschiedenen Bereichen des Kapitalmarktes versuchen Akteure mittels BDAI für sich höhere Transparenz herzustellen. Hierbei stechen vor allem die Bereiche Sales, Trading und Assetmanagement heraus. Ferner ist die Möglichkeit zu nennen, durch mehr Transparenz neue Produkte zu entwickeln, z.B. durch Absicherungen gegenüber bisher nicht adressierbaren Ereignissen, und die Finanzialisierung gesellschaftlicher und wirtschaftlicher Bereiche zu erhöhen, also immer mehr Lebensbereiche handelbar zu machen und mit Preisen zu versehen.

Auf dem Gebiet Sales-Optimierung bzw. Situational Awareness/Market Intelligence für Sales und Trading zeigt sich, dass BDAI verstärkt zur Erzeugung von Transparenz eingesetzt wird. Große Datenbestände werden häufig in Echtzeit ausgewertet, und maschinelles Lernen wird zur Unterstützung der Entscheidungsfindung eingesetzt. Transparenzsteigerung im Sales and Trading durch den Einsatz von AI lässt sich auch bei der Preisfindung im Bondhandel beobachten. Entsprechende Ansätze werden sowohl von Incumbents selbst als auch in Partnerschaft mit Fintechs oder von anderen Anbieter umgesetzt.

³⁷¹ Siehe z.B. Bloomberg Application Portal (<https://www.bloomberg.com/professional/product/application-portal-terminal-connect/>, abgerufen am 30.01.2018)

³⁷² Zum Beispiel Bloomberg (<https://www.bloomberg.com/company/announcements/bloomberg-delivers-first-quantitative-model-for-calculating-liquidity-risk/>, abgerufen am 30.01.2018).

Im Assetmanagement ist das Streben nach Transparenz beispielweise anhand der zunehmenden Verwendung neuer – auch unstrukturierter – Daten zu beobachten (z.B. speziell aufbereitete Web und Social Media Daten in Predictive Analytics). Durch die grundsätzlich steigende Datenverfügbarkeit könnten sich neue Möglichkeiten der Transparenz ergeben. So ist es denkbar, dass sich aus der Verknüpfung zunächst marktferner Daten³⁷³, etwa abgeleiteter Informationen aus dem digitalen Nutzungsverhalten von Unternehmensmitarbeitern, neue Möglichkeiten für die Bewertung von Unternehmen ergeben.

BDAI-Methoden können auch für die interne Planung und Steuerung genutzt werden. Möglich wäre zum Beispiel ein BDAI-gestütztes Asset-Liability-Management zur Steuerung der ökonomischen Risikovorsorge bei Banken, Versicherern und Pensionseinrichtungen.³⁷⁴ Dieser Ansatz könnte z.B. helfen, Risikomitigationstechniken wie Zins- oder Longevityhedges³⁷⁵ besser einzusetzen.

Darüber hinaus besteht die Möglichkeit, durch das BDAI-gestützte Plus an Transparenz neue Produkte am Kapitalmarkt zu entwickeln. Bereits jetzt werden Finanzindizes angeboten, die unter Zuhilfenahme von Natural Language Processing erstellt werden. Hierbei werden zum Beispiel Geschäftsberichte ausgewertet, um bestimmte Informationen über Unternehmen zu extrahieren und diese Unternehmen in (neue) Indizes aufzunehmen.

Schließlich erlaubt BDAI, immer kleinteiligere Risiken transparent zu machen. Bei hinreichender Transparenz wäre es möglich, diese kleinteiligen Risiken zu bündeln. Diese Bündelung wiederum könnte es erlauben, mit diesen Risiken Volumengeschäfte zu betreiben. Daraus entstehende Produkte könnten neue Handelsmöglichkeiten eröffnen. Wenn auf diese Weise bislang nicht gehandelte Risiken handelbar werden und man in sie investieren kann, könnten neue Lebens- und Wirtschaftsbereiche finanziert werden. Ein Beispiel für die Finanzierung von Einzelrisiken könnte die großflächige Verbriefung zukünftiger Einkommen nach Universitätsabschlüssen sein.³⁷⁶ Hierbei könnten auch die Daten der Bigtechs eine weitere Verwendung finden. Zudem besteht die Möglichkeit, Financial Services auf virtuelle Wirtschaften auszuweiten bzw. deren Assets zu finanzialisieren.³⁷⁷

Makroökonomisch betrachtet, könnte die Finanzierung dazu führen, dass der Anteil der Finanzdienstleister an der gesamtwirtschaftlichen Wertschöpfung steigt. Zugleich würden immer weitere Teile der Gesellschaft und andere Wirtschaftsbranchen mit der Finanzindustrie vernetzt werden, die bisher weniger mit ihr verflochten sind.

³⁷³ Siehe für die Nutzung alternativer Daten wie Social Media durch Assetmanager z.B. Ram et al., 2017, When Silicon Valley came to Wall Street. In: Financial Times, Online verfügbar: <https://www.ft.com/content/ba5dc7ca-b3ef-11e7-aa26-bb002965bce8>, abgerufen am 14.01.2018.

³⁷⁴ Siehe z.B. Schad et al., 2017, Big-data-powered, next-generation asset liability and liquidity risk management. In: IBM Banking Breakthroughs. Online verfügbar: <https://www-01.ibm.com/common/ssi/cgi-bin/ssialias?htmlfid=ASW12435USEN>, abgerufen am 14.01.2018.

³⁷⁵ Das Hedging von Lebenserwartungsrisiken.

³⁷⁶ An sich keine neue Idee, sondern eine, die in kleiner Form bereits existiert. Siehe Chaparro, 2017, Investors are paying college students' tuition — but they want a share of future income in return. In: Business Insider. Online verfügbar: <http://www.businessinsider.de/income-share-agreements-help-students-pay-for-college-loan-alternative-2017-3?r=US&IR=T>, abgerufen am 18.01.2018.

³⁷⁷ Es gibt Marktplätze für virtuelle Assets (z.B. für Gegenstände in Computerspielen), auf denen diese für Geld gehandelt werden. Die Gesamtkosten von virtuellen Assets in Spielen sind durchaus nicht trivial, siehe z.B. Moore, 2014, A closer look at the 22-hour Eve Online battle that cost gamers over £180,000. In: Wired. Online verfügbar: <http://www.wired.co.uk/article/eve-online-battle>, abgerufen am 30.01.2018.

Bewertungsfrequenzen für illiquide Assets könnten sich durch BDAI erhöhen. Dies kann zu einer verstärkten Dynamik des Marktgeschehens beitragen.

Es sind Ansätze eines verstärkten Einsatzes von BDAI in der Bewertung von illiquiden Assets zu erkennen. Erste Anbieter bieten beispielsweise Leistungen im Bereich Residential und Commercial Real Estate an, welche die Schätzung von Transaktionspreisen durch BDAI ermöglichen.³⁷⁸ Anders als die turnusmäßige Expertenschätzung könnte dieser Ansatz eine aktuellere und kontinuierliche Bewertung dieser Assets erlauben.

Auch erweiterte Schätzungen makroökonomischer Parameter sind zumindest akademisch schon länger präsent. Hierzu gehört die aktuellere Schätzung von Inflationsraten durch Auswertung von großen Preisdatenbeständen.³⁷⁹ Derartige Daten und Verfahren könnten auch vermehrt Eingang in die Bewertung und Erstellung von Produkten am Kapitalmarkt finden.

Daraus folgt, dass Assets, die bislang geringen beobachtbaren Marktwertschwankungen ausgesetzt waren, eine deutlichere und schnellere Erfassung von Marktwertänderungen erfahren könnten. Somit würden neue Volatilitäten in bestimmten Bereichen des Kapitalmarktes erzeugt, und die Dynamik des Marktgeschehens stiege.

5.4.4 Anwendungsbeispiele

Aktuell sind im Kapitalmarkt bereits verschiedene Anwendungsfälle zu beobachten; eine Auswahl wird im Folgenden detailliert aufgearbeitet. Trotz der oben beschriebenen komplexen und vielfältigen Akteurs- und Marktlandschaft können diese spezifischen Anwendungsbeispiele konkreten Feldern der BDAI-Nutzung zugeordnet werden:

Kundenschnittstelle: Algorithmischer Handel zur Orderausführung für institutionelle Anleger. Wie in der Marktbetrachtung beschrieben, erlaubt BDAI eine Steigerung der Automatisierung und Algorithmisierung und damit eine verstärkte Maschine-Maschine-Interaktion im Handel. Dieses Anwendungsbeispiel (vgl. Kapitel 5.4.4.1) zeigt, dass der algorithmische Handel ein komplexes Ökosystem von Daten und Algorithmen erzeugt. Die ökonomische und regulatorische Auseinandersetzung mit den Folgen ist bereits weit fortgeschritten.

Kernprozesse: Integrierte Analyse- und Portfolioverwaltungsplattformen. Dieses Anwendungsbeispiel (vgl. Kapitel 5.4.4.2) zeigt, wie Akteure die Skaleneffekte von Daten-, Analytics- und Prozessanbietern nutzen könnten und welche Chancen und Risiken sich dadurch möglicherweise für Märkte und Anwender ergeben. Hierbei sind beispielsweise die Vorteile aus teilweise mächtigen Werkzeugen zu nennen, aber auch die Risiken, die sich aus der breiten Anwendung weniger Modelle oder Plattformen ergeben könnten.

Neue Geschäftsmodelle: Crowdsourcing von Investment-Algorithmen. Dieses Anwendungsbeispiel (vgl. Kapitel 5.4.4.3) zeigt, wie neue Algorithmen genutzt werden können, um Wertschöpfungsketten am Kapitalmarkt aufzubrechen. Hierbei wird ein klassischer Bestandteil von Kernprozessen, die Entwicklung von Investment-Algorithmen, externalisiert. Das Beispiel bietet auch einen Ausblick auf mögliche Kooperationsstrukturen, die sich bei der Anwendung von BDAI im Kapitalmarkt andeuten.

³⁷⁸ Hierbei handelt es sich um BDAI-Erweiterungen automatisierter Bewertungsmodelle.

³⁷⁹ Vgl. das „The Billion Prices Projekt“ der MIT Sloan Management School (<http://www.thebillionpricesproject.com/>, abgerufen am 30.01.2018).

5.4.4.1 Algorithmischer Handel zur Orderausführung durch institutionelle Anleger

1. Einleitung

Institutionelle Anleger wie Versicherer, Assetmanager und Pensionsfonds bewegen aufgrund ihrer Geschäftsmodelle mitunter kurzfristig große Volumina an Wertpapieren. Beispielsweise machte der Handel mit ETFs 2016 etwa 30 Prozent des Handelsumsatzes nach Wert an US-Aktienbörsen aus,³⁸⁰ und ETF-Blocktrading³⁸¹ umfasste 2016 über 3.000 Milliarden USD (davon ca. 80 Prozent in Aktien-ETF).³⁸² Um eine größtmögliche Prozesssicherheit bei effektiver und effizienter Ausführung zu erreichen, werden insbesondere größere Handelsaufträge mittels Algorithmen³⁸³ ausgeführt. Beispielsweise wurden an der Deutschen Börse im Oktober 2017 über zehn Millionen Aktientransaktionen im elektronischen Orderbuch ausgeführt.³⁸⁴ Derartige Volumina sind manuell nicht zu bewältigen.³⁸⁵

Dieses Anwendungsbeispiel beleuchtet eine durch BDAI unterstützte Interaktion verschiedener Marktteilnehmer an einer Kapitalmarktkundenschnittstelle. Institutionelle Anleger benutzen Algorithmen zur Orderausführung für liquide Assetklassen wie etwa Aktien, Fremdwährungen und börsengehandelte Derivate.³⁸⁶ (Zur Abgrenzung: Ausführungsalgorithmen bzw. die Handlungsausführung damit werden oft nicht dem Hochfrequenzhandel zugeordnet.³⁸⁷) Als Gegenparteien treten dabei regelmäßig z.B. andere institutionelle Anleger, Market-Maker und Banken auf; der Handel findet also oft zwischen institutionellen Teilnehmern statt.

³⁸⁰ Wigglesworth, 2017, ETFs are eating the US Stock market. In: Financial Times. Online verfügbar: <https://www.ft.com/content/6dabad28-e19c-11e6-9645-c9357a75844a>, abgerufen am 27.11.2017.

³⁸¹ Ein Blocktrade ist hierbei ein Handelsgeschäft über mehr als 10.000 Aktien oder einen Betrag von 200.000 USD oder mehr.

³⁸² Lin, 2017, Trends in ETF Block Trading. In: Credit Suisse – Trading Strategy.

³⁸³ Auf der Gegenseite eines kleinen, nicht algorithmisch ausgeführten Handelsauftrags kann allerdings wieder ein Algorithmus anzutreffen sein.

³⁸⁴ Vgl. Federation of European Security Exchanges, 2017, European Trading Statistics – European Electronic Order Book Equity Trading. Oktober 2017. Die genannte Zahl berücksichtigt nicht alle eingestellten Handelsaufträge, deren Änderungen und Stornierungen, sondern nur tatsächliche Transaktionen.

³⁸⁵ Ein algorithmischer Market-Maker hat z.B. nach eigenen Angaben eine Infrastruktur aus über 30 PB Speicherplatz mit 300 TB RAM (siehe <https://www.xtxmarkets.com/about>, abgerufen am 29.01.2018, ein „quantitative-driven electronic market-maker“).

³⁸⁶ Gemeinhin sind die fortschrittlichsten Algorithmen in Märkten mit einem Central Limit Order Book anzutreffen, vgl. Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee, S. 7.

³⁸⁷ Beispielsweise wird der Hochfrequenzhandel (High Frequency Trading, HFT) häufig beim (passiven) Market Making oder bei direktionalen bzw. Arbitrage-Strategien verortet, siehe Deutsche Bundesbank, 2016, Bedeutung und Wirkung des Hochfrequenzhandels am deutschen Kapitalmarkt. In: Monatsbericht Oktober 2016, S. 37-61; siehe Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee, S. 8; siehe Bank for International Settlements, 2011, High-frequency trading in the foreign exchange market. Markets Committee, S. 3-6. Die International Organization of Securities Commissions verortet HFT auch meist in Proprietary Trading Firms (oder Desks), siehe International Organization of Securities Commissions, 2011, Regulatory Issues Raised by the Impact of Technological Changes on Market Integrity and Efficiency. Consultation Report CR02/11 of the Technical Committee of the International Organization of Securities Commissions, S. 21.

In diesem Anwendungsbeispiel wird ausschließlich der algorithmische Handel zur Orderausführung durch institutionelle Anleger betrachtet, die Adressaten derartiger Angebote etwa von Investmentbanken sind. Dieser Handel zielt insbesondere auf die Reduktion von Transaktionskosten bzw. Market-Impact³⁸⁸ ab. Im Gegensatz dazu hat anderer algorithmischer Handel das Ziel, Preismuster oder Arbitragegelegenheiten auszunutzen³⁸⁹. Privatanleger nutzen solche Algorithmen zurzeit unter gewissen Umständen indirekt, indem ihre Aufträge gebündelt, z.B. durch eine Bank und einen Assetmanager, zugeführt werden.

Algorithmische Orderausführung muss hohe Datenvolumina und -ströme in Echtzeit verarbeiten; sie wird dementsprechend auf Basis großer Datensätze entwickelt und ist somit ein klassisches Beispiel einer BDAI-Anwendung (methodisch zunächst von der Signalverarbeitung inspiriert).

Computerisierter Handel, insbesondere zur Ausführung von Ordnern, existiert schon seit den 1970er Jahren³⁹⁰ und ist heute weit verbreitet. Auf einigen Handelsplätzen werden bereits über 50 Prozent einiger Produkte komplett – also sowohl Angebot als auch Nachfrage – durch Algorithmen gehandelt³⁹¹. BDAI-Anwendungen sind hier also bereits hoch marktrelevant.

2. Anwendung

Das folgende Beispiel soll die Anwendung verdeutlichen: Ein institutioneller Anleger gibt bestimmte Parameter für einen Auftrag in die Maske eines Handelssystems ein. Der dahinterliegende Algorithmus wird nun beispielsweise verschiedene Handelsplätze ansprechen. Trifft eine solche Anfrage auf einen Handelsplatz, löst dies darauf zum Beispiel andere Algorithmen von Kapitalmarktteilnehmern aus, die ebenfalls auf diesem Markt aktiv sind (z.B. Market-Making-Algorithmen). Die Interaktion von Algorithmen ist ein wichtiger Aspekt innerhalb der Handelsplätze, und die gegenseitigen Abhängigkeiten schaffen bereits heute so etwas wie selbstständig agierende Ökosysteme.³⁹²

Konfigurationsoptionen bei Handelsaufträgen

Die institutionellen Anleger haben die Wahl zwischen einer Vielzahl von Algorithmen, Strategien, Parametern³⁹³ und Ordertypen auf den Plattformen der Anbieter, die oft deutlich über das Funktionsspektrum der Handelsplätze hinausgehen (im einfachsten Fall ist die Wahl des Anbieters der erste oder einzige zu wählende Parameter).³⁹⁴ Derartige Ausführungsalgorithmen sind weit verbreitet und werden beispielsweise von zahlreichen Investmentbanken angeboten.

³⁸⁸ Mit Market-Impact wird hier die Auswirkung von Ordnern und Transaktionen auf den Preis eines Finanztitels bezeichnet. Beispielsweise kann eine große Kauforder zu einem Preisanstieg führen.

³⁸⁹ Vgl. Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee, S. 8. Die BIS unterteilt hier den automatisierten Handel in drei Bereiche: Einsatz von Algorithmen zur Handelsausführung, zum Market Making und für Direktionale-, Relative Value- und Arbitrage-Strategien, wobei HFT insbesondere im Market Making verortet wird.

³⁹⁰ Computerbasiert seit 1977, vgl. Farmer et al., 2011, An ecological perspective on the future of computer trading, In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science, S. 7.


³⁹¹ Federal Register, Vol. 80, No 242, Stelle 78826.

³⁹² Vgl. Farmer et al., 2011, An ecological perspective on the future of computer trading, In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science.

³⁹³ Beispiele: Wie viel von der Gesamtorder jeweils sichtbar ist; Anteil der angebotenen Volumina in den Orderbüchern, die maximal genommen werden; parallele oder serielle Ansprache von Handelsplattformen. Auch bei der Auswahl selbst kann BDAI Anwendung finden – entweder direkt auf Seiten des Kunden oder indem der Anbieter derartige Funktionen bereitstellt.

³⁹⁴ Einige Handelsplätze bieten auch selbst Algorithmen oder komplexere Ordertypen (im Grunde gekapselte Algorithmen) an.

Abbildung 25 (stilisiert): Beispiel: Der Kunde wählt und bestimmt Details zur Ausführungsmechanik, die von einem Anbieter bereitgestellt wird (z.B. von einer Bank oder Handelsplattform). Die Auswahl von Ausführungsmechaniken wird integraler Bestandteil des Handelsvorhabens.



3. Technologische Funktionsweise und Datenbasis

Algorithmischer Handel ist immer eine technologische Gesamtlösung. Handelsplätze stellen die notwendige Marktinfrastruktur zur Verfügung und sorgen für die Anbindung der anderen Marktteilnehmer.

Einige Anbieter offerieren institutionellen Investoren bereits AI-basierte Algorithmen, jedoch sind echte AI-basierte Algorithmen in der Handelsausführung institutioneller Anleger noch kein dominantes Phänomen³⁹⁵. Stattdessen sind eher statistische bzw. heuristische Verfahren weit verbreitet.³⁹⁶

Spezialisierte Algorithmen antizipieren algorithmisches Verhalten

Die verwendeten Algorithmen treten in unterschiedlicher Komplexität und verschiedenen Variationen auf. Einige Marktteilnehmer versuchen mit Algorithmen, die nicht (allein) der Handelsausführung dienen, kleinste Marktschwankungen auszunutzen. Das führt wiederum dazu, dass institutionelle Anleger Algorithmen nutzen, die dieses Verhalten bereits antizipieren und – darauf abgestimmt – Gegenalgorithmen verwenden³⁹⁷. Ein anderes – einfaches – Beispiel sind Eisberg-Aufträge³⁹⁸: Hierbei versuchen Marktteilnehmer, die Größenordnung des eigenen Auftrags nicht preiszugeben, was zur Folge hat, dass bestimmte Algorithmen diese Eisberg-Aufträge aufspüren und ausnutzen. Einfachere Algorithmen, wie etwa Eisberg-Aufträge, bieten häufig auch die Handelsplätze selbst an.

Algorithmenentwicklung mit Big Data aus Orderbuch- und Handelsdaten

Die Algorithmen werden auf Basis großer historischer Datenbestände entwickelt und sind konzeptionell damit BDAI zuzuordnen. Typischerweise werden diese Algorithmen mit Hilfe von Handels- und Orderbuchdaten entwickelt, getestet und angewendet. Beispielsweise enthalten Orderbuchdaten für jeden Zeitpunkt Preise von Kauf- oder Verkaufsangeboten und die dazugehörigen Volumina sowie zusätzlich auch Preise und Volumina für Angebote und Nachfragen zum jeweils nicht günstigsten Preis.

³⁹⁵ Siehe z.B. Noonan, 2017, JPMorgan develops robot to execute trades. In: Financial Times. Online verfügbar: <https://www.ft.com/content/16b8ffb6-7161-11e7-aca6-c6bd07df1a3c>, abgerufen am 10.12.2017.

³⁹⁶ In der Entwicklung (und zunehmend in der Auswahl) solcher Algorithmen spielt jedoch maschinelles Lernen/Artificial Intelligence bereits jetzt eine große Rolle. Grundsätzlich ist für die Entwicklung von Algorithmen, in Anlehnung an Kapitel III, die benötigte Rechen- und Speicherkapazität deutlich höher als für die Anwendung, sodass hier elastische Umgebungen eine Lösung sein können (siehe auch Kapitel 4.2). Der Unterschied zwischen Produktion und Entwicklung beruht unter anderem darauf, dass in der Entwicklung die Daten in kurzer Zeit viele Male analysiert oder genutzt werden.

³⁹⁷ Vgl. Tse et al., 2012, AES Analysis. High Frequency Trading – Measurement, Detection and Response. In: Credit Suisse – Trading Strategy. Online verfügbar: <https://edge.credit-suisse.com/edge/Public/Bulletin/Servefile.aspx?FileID=23285&m=923226224>, abgerufen am 13.11.2017.

³⁹⁸ Kann sowohl als Ordertyp direkt verfügbar sein, als auch durch Algorithmen geschaffen werden.

4. Chancen

Es sind nicht die Retailkunden, welche diese Algorithmen tatsächlich und regelmäßig nutzen, sondern beispielsweise Assetmanager. Sofern diese damit die Abwicklung großer Handelsaufträge effizienter gestalten können, sinken ihre Kosten bzw. die Transaktionskosten, die den Produkten zufallen. Davon wiederum könnten die Verbraucher profitieren.

Algorithmen optimieren Ausführung bei großvolumigem Handel

Sehr große Handelsaufträge sind für den Auftraggeber tendenziell schwieriger auszuführen. Der Grund dafür ist, dass es für diese Transaktionen wenige Gegenangebote für das Gesamtvolumen gibt, sodass der Auftraggeber dafür wegen des Market-Impacts einen Preisaufschlag bzw. -abschlag in Kauf nehmen müsste. Um dies zu vermeiden, verwendet man Algorithmen, die große Aufträge in sehr viele kleine Aufträge zerlegen und diese zum aktuellen Marktpreis ausführen.

Institutionelle Anleger nutzen beispielsweise Preisbenchmarks wie volumengewichtete Preise, um größere Volumina zu handeln, ohne wiederum selbst den Markt (zu sehr) zu beeinflussen. Diese Benchmarks sind der Ankerpunkt für einige Algorithmen in der Ausführung.

Wirtschaftliche und prozessuale Effizienz und Effektivität

Die weite Verbreitung von Algorithmen in der Auftragsabwicklung bei institutionellen Anlegern hat ihren Grund in den klaren Vorteilen des algorithmischen Handels. Aus technisch-prozessualer Sicht steht die effiziente Abwicklung im Vordergrund, also hohe Prozessgeschwindigkeit, Vermeidung menschlicher Fehler, schnelles Reagieren auf Marktveränderungen, die Fähigkeit zur gleichzeitigen Ansprache mehrerer Handelsplätze und die damit einhergehende Genauigkeit der Handelsausführung. Aus wirtschaftlicher Sicht lässt sich eine Reihe von geschäftlichen Zielen effektiv erreichen: Der Market-Impact lässt sich bei spezifischen Handelsaufträgen reduzieren und die Handelsabsicht verschleiern, wodurch sich die Kosten optimieren lassen. Ob insgesamt die Liquidität durch die Gesamtheit der Algorithmen – insbesondere durch HFT – in allen bzw. welchen Situationen oder auch bezogen auf einzelne Handelsplätze erhöht wird, ist wissenschaftlich nicht vollständig geklärt.³⁹⁹

³⁹⁹ Ob insgesamt der algorithmische Handel die Liquidität erhöht, ist wissenschaftlich nicht abschließend geklärt, siehe z.B. auch Bank for International Settlements, 2016, Electronic trading in fixed income markets. Markets Committee. Der Bundesbank-Monatsbericht vom Oktober 2016 verweist beispielsweise darauf, dass in ruhigen Marktphasen HFT einen Betrag zur Liquidität leistet, während es in hoch volatilen Phasen zu temporären Rückzügen kommt, siehe Deutsche Bundesbank, 2016, Bedeutung und Wirkung des Hochfrequenzhandels am deutschen Kapitalmarkt. In: Monatsbericht Oktober 2016, S. 37 – 61. Eine weitere Studie der ESMA befasst sich ebenfalls mit HFT und der Möglichkeit der Überschätzung von Liquidität in fragmentierten Märkten, siehe European Securities and Markets Authority, 2016, Order duplication and liquidity measurement in EU equity markets. In: ESMA Economic Report No. 1, 6.6.2016. Für eine weitere Diskussion siehe auch Farmer et al., 2011, An ecological perspective on the future of computer trading, In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science.

Geringere Markteintrittsbarrieren und bessere Grundlagen für Monitoring

Aus Sicht des Gesamtmarktes besteht durch die Verfügbarkeit einer effizienten algorithmischen Abwicklung eine höhere Chance für kleinere Anbieter, aktiv zu werden, da gegebenenfalls nicht eigene Algorithmen zur Ausführung notwendig sind und somit die initialen Investitionen geringer sind. Somit wird hier durch die Verbreitung von Algorithmen eine höhere Markteffizienz durch geringere Markteintrittsbarrieren gefördert. Da die Transaktionen insgesamt elektronisch ausgeführt werden, werden sie bereits heute aufgezeichnet, was Auswertungen aus aufsichtlich-regulatorischer Sicht ermöglicht. Zusätzlich könnte auch der jeweilige Zustand des Algorithmus (z.B. statistische Kennzahlen zur Wirkungsweise des Algorithmus) beim Anbieter mitprotokolliert werden. Auf diese Weise könnte der Handelsverlauf anhand der „Absicht“ des Algorithmus rekonstruiert werden.⁴⁰⁰

5. Risiken

Es könnten zusätzliche Kosten durch starke Marktbewegungen oder Fehler auftreten. Auch wenn Verluste durch fehlerhafte Algorithmen nicht notwendigerweise zulasten des Verbrauchers umgelegt würden, entstünden gegebenenfalls doch mittelbare Kosten, etwa erhöhte Risikokosten, die Investmentprodukten aufgeschlagen werden könnten.

Mögliche Auswirkungen von Algorithmen und deren Interaktion

Durch Algorithmen verstärkte oder ausgelöste Marktbewegungen können den Marktwert von Anlagen direkt verändern.⁴⁰¹

Algorithmen können von Dritten ausgenutzt werden. Ein illustratives Beispiel dafür ist „Algo Sniffing“. Hierbei sucht z.B. ein Algorithmus gezielt nach VWAP⁴⁰²-Algorithmen, um schneller als diese Aktien zu kaufen und dann wiederum von einem möglichen Preisanstieg zu profitieren, der durch den nachkaufenden VWAP-Algorithmus verursacht werden könnte.

Fehler- und Schadenserkennung könnte erschwert werden

Des Weiteren können aufgrund der Schnelligkeit und Effizienz der Algorithmen fehlerhafte Algorithmen oder ein fehlerhaftes Aufsetzen von Algorithmen hohe Schäden verursachen, bevor die Quelle des Problems identifiziert und isoliert werden kann.⁴⁰³ Zudem kann die Komplexität der Algorithmen bzw. des Handelsgeschehens es erschweren, Fehler (und den daraus resultierenden Schaden) festzustellen.

Darüber hinaus gibt es einen hohen Anpassungsdruck in der Vermögensverwaltungsindustrie: Da viele Unternehmen Algorithmen einsetzen, sehen sich andere gezwungen, sich auch solcher Algorithmen zu bedienen. Denn einfache Ausführungsmethoden sind unter Umständen nicht mehr effektiv, wenn sie auf Algorithmen treffen.

⁴⁰⁰ Ob dies klassisch in einer Datenbank oder Versionskontrolle erfolgt oder ob gegebenenfalls sogar Blockchain-Technologien zum Einsatz kommen, soll offenbleiben. Technisch ist die Speicherung relevanter Daten per se kein Problem. Über die Nutzung von Blockchain für Audittrails von AIs diskutiert beispielsweise Corea, 2017, The convergence of AI and Blockchain: what's the deal? In: Hackernoon. Online verfügbar: <https://hackernoon.com/the-convergence-of-ai-and-blockchain-whats-the-deal-60c618e3acc>, abgerufen am 05.12.2017. Für HFT ergeben sich auch aus MiFID II deutliche Auflagen zur Speicherung von Handels- und Orderdaten.

⁴⁰¹ Hierbei vermutlich weniger durch Ausführungsalgorithmen allein, sondern eher durch Interaktion von Algorithmen mit verschiedenen Zielsetzungen.

⁴⁰² Volumengewichteter mittlerer Preis (Volume-Weighted Average Price, VWAP).

⁴⁰³ Siehe z.B. Philips, 2012, Knight Shows How to Lose \$440 Million in 30 Minutes. In: Bloomberg. Online verfügbar: <https://www.bloomberg.com/news/articles/2012-08-02/knight-shows-how-to-lose-440-million-in-30-minutes>, abgerufen am 10.12.2017.

Algorithmen können kurzfristige Markttrends verstärken. Die oben erwähnten volumengewichteten Preialgorithmen beispielsweise sind derart konstruiert, dass um den volumengewichteten Preis herum Transaktionen ausgelöst werden. Wenn nun eine größere Transaktion am Markt ausgeführt wird, hat dies zur Folge, dass weitere Transaktionen zum selben Preisniveau ausgelöst werden, was einen Preistrend verstärken kann.⁴⁰⁴

Grundsätzlich sind Algorithmen nicht nur passive Marktteilnehmer, sondern können dazu genutzt werden, Marktverhältnisse (manipulativ) zu verändern, um dann von diesen Veränderungen zu profitieren (ein Beispiel ist die Momentum Ignition, also das Erzeugen oder Verstärken von Trends durch bestimmte Order oder Orderfolgen⁴⁰⁵, um anschließend von diesen zu profitieren). Derartige Praktiken sind aber keinesfalls auf Ausführungsalgorithmen beschränkt und eher bei direktionalen Strategien zu verorten.⁴⁰⁶

Eine höhere Geschwindigkeit im Handel könnte zu einer höheren Volatilität⁴⁰⁷ und einer instabileren (also gegebenenfalls sich rasch ändernden) Liquiditätssituation⁴⁰⁸ führen. Die höhere Marktgeschwindigkeit führt dazu, dass die Marktteilnehmer immer stärker gezwungen werden, auch kleinste und kurzfristigste Marktbewegungen mit maximalem Einsatz auszunutzen. In der Folge können bereits kleine Änderungen rasch große Auswirkungen haben.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte sind auch aufsichtlich und regulatorisch relevant. Aktuell sind bereits einige Aspekte des algorithmischen Handels wie z.B. Börsenzugänge und High-Frequency-Trading teilweise reguliert.^{409,410} Für Aufsicht und Regulierung stellt sich in der Zukunft vor allem die Frage, wie man mit immer leistungsfähigeren Algorithmen umgehen sollte.

Um die Marktintegrität insgesamt zu gewährleisten, könnte eine technische Option darin bestehen, die bisher auf Plattformen oder von Anbietern erfolgreich eingesetzten⁴¹¹ bzw. auch vorgeschriebenen⁴¹²

⁴⁰⁴ Siehe Farmer et al., 2011, An ecological perspective on the future of computer trading. In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science, S. 8.

⁴⁰⁵ Vgl. European Securities and Markets Authority, 2012, Guidelines. Systems and controls in an automated trading environment for trading platforms, investment firms and competent authorities, S. 17.

⁴⁰⁶ Beispielsweise wird von Tse et al. Momentum Ignition als HFT Strategie angesprochen (zusammen mit Quote Stuffing und Layering); siehe Tse et al., 2012, AES Analysis. High Frequency Trading – The Good, The Bad, The Regulation. In: Credit Suisse – Trading Strategy. <https://edge.credit-suisse.com/edge/Public/Bulletin/Servefile.aspx?FileID=23284&m=1815212669>, abgerufen am 15.11.2017.

⁴⁰⁷ Siehe z.B. Farmer et al., 2011, An ecological perspective on the future of computer trading, In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science, S. 9.

⁴⁰⁸ Siehe Tse et al., 2012, AES Analysis. High Frequency Trading – Measurement, Detection and Response. In: Credit Suisse – Trading Strategy. Online verfügbar: <https://edge.credit-suisse.com/edge/Public/Bulletin/Servefile.aspx?FileID=23285&m=923226224>, abgerufen am 13.11.2017.

⁴⁰⁹ Die European Securities and Markets Authority hat bereits 2012 Leitlinien für Systeme und Kontrollen veröffentlicht, siehe European Securities and Markets Authority, 2012, Guidelines. Systems and controls in an automated trading environment for trading platforms, investment firms and competent authorities.

⁴¹⁰ Beispielsweise in Deutschland durch das Hochfrequenzhandelsgesetz (konkret in § 33 Abs. 1a WpHG bzw. nach 2. FiMaNoG § 69 Abs. 2 WpHG), in der EU durch MiFID II (z.B. Art. 17, 18 und 48) und in den USA in SEC Rule 15c3–5.

⁴¹¹ Vgl. Linton, 2011, What has happened to UK equity market quality in the last decade? An analysis of the daily data. In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR1, Government Office for Science, z.B. S. 27.

⁴¹² Z.B. in Deutschland bereits mit § 24 Abs. 2a BörsG bzw. auch durch MiFID II (Art. 48 (5) in Verbindung mit Art. 18 (5)). Auch z.B. an US-Amerikanischen Börsen kommen bereits seit langem einige dieser Sicherungsmaßnahmen zum Einsatz (siehe z.B. die Darstellung in International Organization of Securities Commissions, 1992, Coordination between Cash and Derivatives Markets. Report of the Technical Committee on Contract Design of Derivatives Products on Stock Indices and Measures to Minimize Market Disruption; siehe International Organization of Securities Commissions, 2011, Regulatory Issues Raised by the Impact of Technological Changes on Market Integrity and Efficiency. Consultation Report CR02/11 of the Technical Committee of the International Organization of Securities Commissions.

Sicherungsmaßnahmen (z.B. Fail-Safes, Circuit-Breaker und Speedbumps) weiter auszubauen⁴¹³. Als Beispiel seien die möglichen Unterbrechungen des Handelsgeschehens bei extremen Volatilitätsausschlägen genannt⁴¹⁴, die als Circuit-Breaker agieren, indem sie bei starken Abweichungen des Ausführungspreises von einem Preiskorridor den laufenden Handel unterbrechen und beispielsweise in einen Auktionshandel überführen. Auch vorgelagerte Prozesse wie Plausibilitätskontrollen in der Ordereingabe (z.B. von der Deutschen Börse genutzt) zählen zu diesen Maßnahmen.

Fail-Safes können sowohl anbieterspezifisch sein – beim Verlassen bestimmter Handelsparameter (wie Volumen oder Ticketanzahl) fährt der Anbieter Algorithmen zurück⁴¹⁵ – als auch systemisch implementiert werden (ein illustratives Beispiel hierfür ist Self-Help zwischen Handelsplätzen, was auf Deutschland aber nur schwer übertragbar ist⁴¹⁶).

Eine weitere derartige Schutztechnologie sind Speed-Bumps, d. h. das bewusste Verlangsamen der Handels- bzw. Quotierungsinformationen⁴¹⁷. Speed-Bumps können bestimmte algorithmische Ansätze blockieren, und einige wenige Handelsplätze setzen sie bereits ein. Manche Marktteilnehmer im algorithmischen Handel würden inzwischen Handelsplätze mit einer derartigen Struktur bevorzugen.⁴¹⁸

⁴¹³ Derartige Maßnahmen sind jedoch nicht in einem One-size-fits-all-Ansatz zu sehen, sondern müssen länder- oder regionsspezifisch und entlang von Assetklassen jeweils speziellen Anforderungen gerecht werden können (dies ist bereits in der Variation der heutigen Maßnahmen sichtbar).

Der Ausbau dieser Sicherheitsmaßnahmen könnte auch in der Nutzung von BDAI bei der Kalibrierung der Maßnahmen liegen; die European Securities and Markets Authority stellt beispielsweise auf „statistisch gestützte Methodik“ ab, vgl. European Securities and Markets Authority, 2017, Leitlinien. Kalibrierung von Notfallsicherungen und Veröffentlichungen gemäß MiFID II, S. 7. Der Ausbau könnte auch in der Nutzung von BDAI in der Ausgestaltung bzw. zur Platzierung dieser Maßnahmen liegen.

Grundsätzlich könnte auch die Frage gestellt werden, ob derartige Maßnahmen auch auf andere Bereiche des hoch vernetzten Finanzmarktes – also auf Bereiche außerhalb des direkten Handelsgeschehens – übertragen werden könnten.

⁴¹⁴ Z.B. seit Beginn im XETRA Handel der Deutschen Börse etabliert.

⁴¹⁵ Die MiFID II enthält zahlreiche Regelungen zum algorithmischen Handel bzw. mit Auswirkung darauf.

⁴¹⁶ Self-Help bedeutet im Zusammenhang mit US-amerikanischen Handelsplätzen, dass ein Handelsplatz, wenn ein anderer Handelsplatz Störungen wahrnimmt (z.B. Verzögerungen), aus dem Verbund des Order-Routings herausgenommen wird (durch einseitige Erklärung des Handelsplatzes, der diese Störung erkannt hat).

⁴¹⁷ Die Idee von Speed-Bumps als zeitweiliger Verlangsamung des Handelsgeschehens ist nicht neu; vgl. z.B. International Organization of Securities Commissions, 1992, Coordination between Cash and Derivatives Markets. Report of the Technical Committee on Contract Design of Derivatives Products on Stock Indices and Measures to Minimize Market Disruption, S. 8. Die manchmal vorgenommene Interpretation auch der grundsätzlichen Verlangsamung ist neueren Datums; siehe auch Levine, 2016, Speed Bumps Are the Hot New Thing for Exchanges. In: Bloomberg. Online verfügbar: <https://www.bloomberg.com/view/articles/2016-08-31/speed-bumps-are-the-hot-new-thing-for-exchanges>, abgerufen am 9.1.2018.

⁴¹⁸ Z.B. risk.net, 2017, Currencies flow market-maker of the year: XTX Markets. Online verfügbar: <https://www.risk.net/risk-magazine/analysis/2479841/currencies-flow-market-maker-of-the-year-xtx-markets>, abgerufen am 10.12.2017.

In eine andere Richtung weisen Überlegungen, synthetische Test- und Simulationsumgebungen zu schaffen, in denen sowohl Algorithmen als auch Policy-Maßnahmen⁴¹⁹ getestet werden könnten.⁴²⁰ Beispielsweise führt die MiFID II handelsplatzseitig Umgebungen für geregelte Märkte, Multilateral Trading Facilities (MTF) und Organised Trading Facilities (OTF) ein⁴²¹, in denen Handelsteilnehmer ihre Algorithmen testen müssen⁴²². Auch Aufsichtsbehörden könnten beispielsweise Testumgebungen sowohl für handelsplatzübergreifende als auch für Policy-Fragen nutzen.

Das folgende Beispiel soll diesen Ansatz illustrieren: In Vorbereitung auf die Dezimalisierung der NASDAQ (d.h. der Umstellung des Handels von Brüchen auf Hundertstel) wurde eine Studie erstellt, die mit Simulationen die Effekte dieser Umstellung untersuchte. Dabei zeigte sich unter anderem, dass die Änderung der Preisgranularität auch Auswirkungen auf die möglichen Handelsstrategien hat.⁴²³

Die Entdeckung und Beschreibung von Sachverhalten wie der Marktmanipulation in sehr großen Datenvolumina ist eine Herausforderung, die es vermutlich erforderlich macht, dass auch die Aufsicht BDAI einsetzt. So nutzen Aufsichtsbehörden beispielsweise die Meldungen aus der Handelsüberwachung für eigene Vorhersagen, Analysen oder die Aufdeckung von Mustern.⁴²⁴ Durch einen verstärkten Einsatz statistischer oder BDAI-Methoden könnte die Aufsicht in die Lage versetzt werden, Anomalien besser aufzudecken⁴²⁵. Um die Absicht des Marktteilnehmers näher einschätzen zu können (z.B. zufällige Begleiterscheinung oder Vorsatz), benötigt die Aufsicht aber zusätzlich zum Algorithmus weitere Informationen.

In Kapitel VI dieser Studie wird auf die aufsichtlich-regulatorischen Implikationen der genannten Themen nochmals eingegangen.

⁴¹⁹ Siehe Farmer et al., 2011, An ecological perspective on the future of computer trading, In: The Future of Computer Trading in Financial Markets – Foresight Driver Review – DR6, Government Office for Science, S. 21; siehe für ein Beispiel auch Baptista et al., 2016, Macroprudential policy in an agent-based model of the UK housing market. In: Bank of England, Staff Working Paper No. 619.

⁴²⁰ Auch um zu verhindern, dass bestimmte Maßnahmen einen Gesamtmarkt in unerwünschter Weise verändern, z.B. Handel von On-Exchange nach OTC verschieben.

⁴²¹ Art. 48 (6) MiFID II in Verbindung mit Art. 18 (5) MiFID II, bzw. in Deutschland in § 26d Abs. 2 BörsG.

⁴²² Die Tests unterliegen durchaus konkreteren Vorgaben (Art. 5 bis 7 del. VO (EU) 2017/589 (MiFID II Level II)). Beispielsweise muss eine Wertpapierfirma neben Konformitätstests (Art. 6) auch klare Methodologien für das Entwickeln und Testen von Algorithmen vorhalten (Art. 5).

⁴²³ Siehe Darley et al., 2007, A NASDAQ market simulation: Insights on a major market from the science of complex adaptive systems. New Jersey u.a.: World Scientific Publishing.

⁴²⁴ Beispielsweise zur Abschätzung der erwarteten Zahl von Meldungen, um Veränderungen in der Marktstruktur rasch zu erfassen. Die grundsätzliche Möglichkeit, in der Aufsicht Vorhersagen relevanter Ereignisse/Meldungen zu nutzen, wird bei Hunt (2017) erwähnt; siehe Hunt, 2017, From Maps to Apps: the Power of Machine Learning and Artificial Intelligence for Regulators. Speech, Beesley Lecture Series on regulatory economics, 19.10.2017.

⁴²⁵ Konzeptionell nicht unähnlich dem Einsatz statistischer Analysen in der Steuerprüfung.

5.4.4.2 Integrierte Analyse- und Portfolioverwaltungsplattformen

1. Einleitung

Der Einsatz von Analyse(-werkzeugen) im institutionellen Portfoliomanagement blickt auf eine lange Historie zurück. Ein frühes Beispiel für das Quant-Investing sind Graham und Dodd⁴²⁶. Heute ist der Einsatz solcher Werkzeuge und Plattformen⁴²⁷ stark verbreitet.

Dieses Anwendungsbeispiel zeigt, wie BDAI im Portfoliomanagement und in der Portfolioverwaltung auf institutioneller Ebene, also in einem wesentlichen Kernprozess des Assetmanagements, angewendet werden kann. Nicht betrachtet werden hier einfachere Assetallokationsmodelle aus dem Retailbereich.⁴²⁸

Die seit langem verwendeten klassischen Risikomodelle für Aktien (wie etwa Faktormodelle⁴²⁹) hatten bzw. haben bereits eine hohe Datentiefe. Diese auch heute noch genutzten Modelle bilden Aktienerträge auf grundlegenden Faktoren wie beispielsweise Value, Growth und Momentum ab. Da immer mehr und bessere Daten zur Verfügung stehen, erfassen einige heutige Modelle, Ansätze und Entwicklungen aber weitaus umfangreichere Assets und Datenpools. Damit hat sich die Nutzung von Modellen (und die der verbundenen Technologien) – ausgehend vom Aktienportfoliomanagement – stark ausgedehnt.⁴³⁰ Die zugrunde liegenden Modelle erfassen inzwischen neben liquiden Assets wie Aktien auch komplexere und teilweise weniger liquide Assets wie Mortgage-Backed Securities.

Im Aktienportfoliomanagement kamen bereits in den 1970er Jahren erste kommerziell verfügbare Faktormodelle auf⁴³¹, welche die Basis für einige frühe Plattformen bildeten. Grundsätzlich sind Analyseplattformen zwar kein neues Phänomen, die Integration verschiedener Funktionen und Tätigkeiten in Portfoliomanagement und -verwaltung in kommerziell verfügbaren Systemen ist aber stark gestiegen.

2. Anwendung

Einige Plattformen decken sämtliche Arbeitsprozesse in hoch integrierten Systemen ab (je nach Prozess auch über Portfoliogrenzen hinweg), angefangen von Attribution, Analyse, Optimierung, Handel über Risiko- und Flowmanagement⁴³² bis hin zu Compliance- und Abwicklungsfunktionen. Der Funktionsumfang hängt auch vom jeweiligen Assetmanager ab. Einige Assetmanager besitzen beispielsweise keinen eigenen Handelsbereich, sondern erstellen lediglich Handelsaufträge, die sie dann an Banken, Broker etc. weiterreichen. Einige Plattformen gestatten eine komplette End-to-End-Nutzung; bestimmte operationelle Funktionen und Tätigkeiten werden also weitgehend an die Anbieter verschoben.

⁴²⁶ Graham & Dodd, 1934, *Security Analysis*, York, PA: Whittlesey House.

⁴²⁷ Mit Plattform bezeichnen wir in diesem Anwendungsbeispiel Systeme, die Assetmanager dazu verwenden, beispielweise Portfolios zu analysieren, zu optimieren und zu administrieren. Bei diesen Systemen kann es sich auf Anbieterseite um Plattformen im engeren Sinne handeln (z.B. Hosted Services), aber auch um Systeme, die direkt beim Assetmanager installiert sind.

⁴²⁸ Auch diese Modelle sind datenbasiert, jedoch oft von geringerer Datentiefe.

⁴²⁹ Auf der Basis einer Faktorenanalyse (im weiteren Sinne), die hochdimensionale Daten (wie z.B. Erträge der Aktien eines Marktes) durch wenige Variablen (die Faktoren) zu erklären versucht, können Modelle bezüglich der Risiko- und/oder Ertragscharakteristika erstellt werden (Faktorenmodelle). Beispielsweise ist als Prototyp das Fama-French-Dreifaktorenmodell für Aktienerträge zu nennen. Siehe z.B. Fama et al., 1992, *The Cross-Section of Expected Stock Returns*. In: *Journal of Finance*. Vol. XLVII, Nr. 2, Juni 1992, S. 427–465).

⁴³⁰ Vgl. *Financial Times*, 2018, *The irreversible rise of the investing machines*. In: FT View. Online verfügbar: <https://www.ft.com/content/e1def550-f600-11e7-8715-e94187b3017e>, abgerufen am 29.01.2018.

⁴³¹ Vgl. Bender et al., 2013, *Foundations of Factor Investing*, MSCI Research Insight, S. 2.

⁴³² Das Management von Mittelzu- und -abflüssen.

Beispiel: Portfoliooptimierung

Ein typisches Beispiel für den Zusammenhang zwischen diesen verschiedenen Aspekten stellt die Portfoliooptimierung dar. Hierbei wird beispielsweise eine Portfoliozusammensetzung berechnet, die für ein gegebenes Risiko den erwarteten Ertrag maximiert (Mean-Variance-Optimierung, zurückgehend auf H. Markowitz⁴³³, wobei heutige Modelle und Verfahren hier durchaus Verfeinerungen wie z.B. Resampling⁴³⁴ liefern). Bei dieser Optimierung sind mehrere Modelle mehrerer Parteien involviert, da sowohl auf der Risiko- als auch auf der Ertragsseite Modelle zum Einsatz kommen könnten. Die Plattformen stellen hier insbesondere die Risikomodelle zur Verfügung, während Ertragsmodelle z.B. im aktiven Portfoliomanagement auf Seiten der Assetmanager verbleiben bzw. von diesen erstellt werden.

Gleichzeitig ermöglicht die höhere Integration innerhalb der Plattform bessere Feedbackloops und Workflows zwischen Analyse, Optimierung, Handel und Abwicklung sowie Risiko- und Flowmanagement. Zum Beispiel könnten aktuelle Market-Impact⁴³⁵-Daten direkt in die Optimierung fließen und so bei einer Neugewichtung des Portfolios Transaktionskosten besser berücksichtigt werden. Am Markt sind zahlreiche kommerzielle Plattformen und Tools mit verschiedenen Integrationsgraden, Analyse- und Modelltiefen verfügbar, wobei die Anbieter verschiedene Schwerpunkte haben, z.B. operationelle oder analytische Aspekte.

3. Technologische Funktionsweise und Datenbasis

Analytisch sind viele Methoden aus dem BDAI-Spektrum vertreten, während Methoden des Deep Learning im traditionellen Assetmanagement eher unterrepräsentiert zu sein scheinen.⁴³⁶ Zahlreiche Modelle haben aufgrund der langen Historie ihren Ursprung in der Zeitreihenanalyse und in der klassischen Statistik; allerdings werden Methoden wie das Clustering heute dem Unsupervised Learning zugeordnet, so dass aus dieser Sicht bestimmte Verfahren des maschinellen Lernens schon lange präsent sind.

Die Datenbasis für die Plattformen speist sich aus Marktdaten und aus zusätzlichen Daten wie Klassifikationen und Unternehmenskennzahlen.⁴³⁷ Beispielhaft seien hier Industriesektoren und der Verschuldungsgrad genannt. Zudem nutzen verschiedene Assetklassen Daten anderer Assetklassen. Ein typisches Beispiel hierfür ist die Verwendung von Aktiendaten in der Bewertung von Unternehmensanleihen: Vereinfacht repräsentiert eine Aktie eine Call-Option auf den Unternehmenswert, während der Anleiheinvestor eine Short-Put-Position besitzen würde. Die Aktienvolatilität kann und wird hierbei zur Approximation für die Volatilität des Unternehmenswerts herangezogen.

⁴³³ Markowitz, 1952, Portfolio Selection. In: The Journal of Finance, Volume 7 (1), S. 77-91.

⁴³⁴ Vereinfacht: das wiederholte Optimieren auf Basis statistischer Variationen der Eingangsparameter.

⁴³⁵ Für eine Diskussion über den Market-Impact siehe auch das vorangehende Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung durch institutionelle Anleger“.

⁴³⁶ Siehe Marriage, 2017, Fund managers deny AI threatens jobs. In: Financial Times. Online verfügbar: <https://www.ft.com/content/bd26af40-7dd9-11e7-ab01-a13271d1ee9c>, abgerufen am 29.01.2018.

⁴³⁷ Vgl. z.B. BARRA: United States Equity. Version 3 (E3), Risk Model Handbook, 1998, z.B. S. 73.

In den vergangenen Jahren gibt es den Trend, exotischere Daten – etwa Luft- oder Satellitenbilder – in Erwägung zu ziehen,⁴³⁸ also unstrukturierte Daten zu nutzen. Bei Öllagertanks von entsprechender Bauart kann beispielsweise der Füllstand durch den Schattenwurf der Tankwand auf das frei aufliegende Dach gemessen werden (dies wird bereits kommerziell genutzt bzw. angeboten). Eine weitere experimentelle Anwendung ist die Analyse von Gesicht und Mimik von Zentralbank-Gouverneuren, um Entscheidungen bzw. Handlungen der Zentralbank vorauszusagen.⁴³⁹ In beiden Fällen kommt BDAI zum Einsatz, um unstrukturierte Daten wie Satellitenbilder und Bilder von Personen auszuwerten. Dies ermöglicht es, das Datenspektrum deutlich zu erweitern.

Nicht alle diese Daten und Modelle sind bereits in existierende Plattformen integriert, aber der Plattformansatz macht es einfacher, neue Daten oder Modelle für viele Nutzer gleichzeitig bereitzustellen, da nur eine Schnittstelle geschaffen werden muss. Gleichzeitig erlaubt es BDAI, neue Daten rasch und tief zu analysieren.

4. Chancen

Da diese Plattformen von institutionellen Assetmanagern genutzt werden, könnten Verbraucher nur mittelbar – beispielsweise von einem verbesserten Portfoliomanagement – profitieren, etwa durch besseres Risikomanagement, geringere operationelle Risiken oder effektivere Nutzung von Gelegenheiten zum Abschöpfen von Mehrerträgen.

Plattformen könnten Marktbarrieren und Risiken für kleinere Anbieter senken

Mit derartigen Plattformen können kleinere Akteure mächtige Analyse- und Workflowwerkzeuge erhalten, die von ihnen selbst so nicht erstellt werden könnten. Somit könnten die Plattformen helfen, ein Level-Playing-Field über Akteure hinweg zu erzeugen, indem sie kleinere Akteure analytisch und prozessual unterstützen. Effektiv könnten die Plattformen gegebenenfalls große Abschnitte der Wertschöpfungskette verbessern, indem sie umfassendere Werkzeuge für die Arbeitsschritte zur Verfügung stellen und einfachere Rückkopplungen zwischen diesen Arbeitsschritten (zum Beispiel Analyse, Optimierung, Risikomanagement, Handel, Abwicklung) erlauben sowie operationelle Risiken verringern und so den Marktauftritt der kleineren Akteure fördern. Dies wird auch durch die Möglichkeit von End-to-End-Lösungen gefördert, da ein Akteur gegebenenfalls nur noch wenige, ausgewählte Komponenten der Wertschöpfungskette selbst vorhalten müsste.

Die Reduktion von Schnittstellen, z.B. zwischen Portfoliooptimierung, Ordererstellung, Handelsanbindung und Risikomanagement, führt zu geringeren operationellen Risiken, da die Zahl der Übertragungen zwischen Systemen reduziert und der Informationsfluss vereinheitlicht wird. Zugleich könnten die Prozesse auch insgesamt mit Protokolldaten versehen werden, so dass z.B. Analyse- oder Optimierungsergebnisse später nachvollzogen werden können.

Grundsätzlich führt ein weiterer Einsatz von Analysewerkzeugen auch zum Ausbau der systematischen Risikosteuerung am Markt.

⁴³⁸ Siehe Finley, 2015, How AI can calculate oil surplus ... from space. In: Wired. Online verfügbar: <https://www.wired.com/2015/03/orbital-insight/>, abgerufen am 29.01.2018.

⁴³⁹ Siehe Uetake, 2017, In Kuroda's face - researchers find ways to predict central bank changes, In: Reuters Business News (online). Online verfügbar: <https://www.reuters.com/article/us-japan-boj-face/in-kurodas-face-researchers-find-ways-to-predict-central-bank-changes-idUSKBN1CP0GS>, abgerufen am 11.12.2017.

5. Risiken

Auch von den Risiken sind Verbraucher mittelbar betroffen: Etwaige Fehler oder Fehlanwendungen von Systemen oder Daten könnten sich auf die Preise von Assetmanagement-Produkten auswirken.

Beim Einsatz weniger transparenter oder intransparenter Modelle besteht die Gefahr, dass Fehler verspätet erkannt bzw. Modelle falsch eingeschätzt werden – wobei solche Fehler bzw. die Auswirkungen solcher Fehler sich in höher integrierten Systemen schneller ausbreiten können. Derartige Fehler können allerdings auch bei Inhouse-Modellen lange unentdeckt bleiben.⁴⁴⁰ Bei der Nutzung von End-to-End-Plattformlösungen sind gegebenenfalls auch die Beendigung der Nutzung und die Verschiebung zu einem neuen Anbieter oder ins eigene Unternehmen schwierig; zugleich ist die operationelle Abhängigkeit vom Plattformanbieter möglicherweise hoch.

Spiegelbildlich zum oben beschriebenen Level-Playing-Field könnte ein stark unterschiedlicher Zugang zu solchen Plattformen auch Vorteile bzw. Nachteile einzelner Akteure am Markt verstärken.

Mögliche Monokulturen bei der Risikobewertung

Wenn Akteure die gleichen Risikomodelle oder Plattformen nutzen, können daraus im Extremfall Monokulturen entstehen, aus denen unter Umständen systemische Risiken erwachsen. Hier sei als Beispiel die marktweite Nutzung von Copula⁴⁴¹-Modellen für CDOs genannt, deren Schwächen in der Finanzkrise deutlich wurden⁴⁴². Andererseits kann festgestellt werden, dass kommerzielle Faktormodelle bereits seit langem Anwendung finden, ohne dass hierdurch deutlich sichtbare Marktverwerfungen auftreten (Portfoliomanager nutzen Modelle durchaus unterschiedlich und bewerben dies auch entsprechend).⁴⁴³

Ebenso bedeutet ein breiteres Datenspektrum auch einen breiteren Raum für Datenfehler oder -manipulationen. Dies könnte möglicherweise kompensiert werden, indem ein größeres Datenspektrum auch zu einer stärkeren Differenzierung zwischen den Modellen in der Portfolioverwaltung und dem Risikomanagement genutzt wird.

6. Aufsichtliche und regulatorische Themen

Aus dem vorliegenden Anwendungsbeispiel ergeben sich verschiedene aufsichtliche und regulatorische Fragen. Exemplarisch sollen hier einige Fragen aufgezeigt werden, die prinzipiell – über das Assetmanagement hinaus – auch im Zusammenhang mit anderen (integrierten) Analyse- und Verwaltungssystemen auftreten könnten.

⁴⁴⁰ Siehe z.B. Securities and Exchange Commission, 2011, SEC Charges AXA Rosenberg Entities for Concealing Error in Quantitative Investment Model. Washington, D.C., 03.02.2011. Online verfügbar: <https://www.sec.gov/news/press/2011/2011-37.htm>, abgerufen am 29.01.2018.

⁴⁴¹ Mittels einer Copula können verschiedene einzelne Wahrscheinlichkeitsverteilungen miteinander korreliert werden.

⁴⁴² Siehe z.B. Brigo et al., 2010, Credit Models and the Crisis, or: How I learned to stop worrying and love the CDOs. Online verfügbar: <http://arxiv.org/abs/0912.5427>, abgerufen am 30.01.2018

⁴⁴³ Das nächste Analogon ist eventuell die Diskussion über die antikompetitiven Auswirkungen von passiven Investments. Hierbei geht es um die Auswirkungen von passiven Investments auf den Markt bzw. die Unternehmensführung; siehe z.B. Levine, 2015, Index Funds May Work a Little Too Well. Bloomberg (online). Online verfügbar: <https://www.bloomberg.com/view/articles/2015-07-22/index-funds-may-work-a-little-too-well>, abgerufen am 29.01.2018.

Systemische Risiken in der Modell- und Datennutzung?

Ein Beispiel ist die Erfassung und Entdeckung von möglicherweise entstehenden systemischen Risiken aus der marktweiten Nutzung eines oder nur weniger Modelle oder Werkzeuge⁴⁴⁴, insbesondere auch die Notwendigkeit von Techniken zur Beurteilung dieser Risiken – etwa anhand der Frage: Welche Daten müssten erhoben werden, um die Landschaft der Plattformen bzw. die Modell- und Datennutzung innerhalb dieser Landschaft zu verstehen? Um ein Verständnis für die Auswirkungen großer Modellkulturen auf den Markt zu entwickeln, könnten auch die bereits im Anwendungsbeispiel „Algorithmischer Handel zur Oorderausführung durch institutionelle Anleger“ vorgestellten Marktsimulationen eine Rolle spielen.

Kritische Transparenz in der Analyse von Wertpapieren?

Der Einsatz von bestimmten Datenquellen, die innere Daten von Unternehmen nach außen tragen könnten, und die Nutzung bestimmter interner Daten des Assetmanagers berühren Fragen der Abgrenzung zwischen öffentlichen und privaten Informationen.⁴⁴⁵ Beispielsweise könnte ein Luftbild eines von außen nicht einseharen Parkplatzes Rückschlüsse auf die Unternehmenslage erlauben, indem man die parkenden Fahrzeuge auswertet.

Neue relevante Akteure?

Eine weitere mögliche Frage wäre, wie Analytics-Anbieter (oder intransparente Werkzeuge) mit hoher Geschäftsintegration aufsichtlich-regulatorisch betrachtet werden sollten. Eine Frage könnte zum Beispiel sein, ob der Wegfall eines Anbieters abgefangen oder kompensiert werden könnte. Insbesondere bei End-to-End-Plattformen könnten unter Umständen schwierig zu lösende Abhängigkeiten von nur wenigen Anbietern und somit operationelle Meta-Risiken entstehen, wenn viele Nutzer bzw. große Assetvolumen über wenige solche Plattformen verwaltet würden.

In Kapitel VI dieser Studie wird auf die genannten Themen noch einmal näher eingegangen.

⁴⁴⁴ Nicht unähnlich den Risiken von Monokulturen z.B. in der Landwirtschaft, also der Gefahr, dass ein Fehler oder Problem das gesamte System destabilisiert.

⁴⁴⁵ Siehe auch Thornhill, 2017, The big data scramble still relies on people, In: Financial Times. Online verfügbar: <https://www.ft.com/content/358fab32-0317-11e7-ace0-1ce02ef0def9>, abgerufen am 29.01.2018.

5.4.4.3 Crowdsourcing von Investment-Algorithmen

1. Einleitung

Das Crowdsourcing von Investment-Algorithmen – also die Verlagerung der Erstellung solcher Algorithmen an Entwickler außerhalb der Investmentfirmen über das Internet – könnte auf Basis von BDAI-Technologie die Möglichkeit bieten, zwei widerstrebende Absichten in Einklang zu bringen: die Erhöhung der Rendite bzw. der Performance bei gleichzeitiger Senkung der operativen Kosten.

Das Crowdsourcing von Investment-Algorithmen bietet eine Möglichkeit, BDAI-Entwicklungen zur Erstellung neuer Geschäftsmodelle im Assetmanagement, hierbei aktuell insbesondere im Segment der Hedgefonds⁴⁴⁶, zu nutzen, und zwar indem eine bisher klassische Kernkompetenz herausgelöst wird.

Konventionelle Entwicklung von Investment-Algorithmen

Investment-Algorithmen werden in Investmentfirmen üblicherweise von festangestellten Spezialisten⁴⁴⁷ entwickelt – auf Basis nichtöffentlicher bzw. kostenintensiver Daten wie z.B. Marktdaten. Sowohl die Algorithmen als auch die Datenbasis für deren Entwicklung sind für diese Marktteilnehmer wesentliche Teile der Geschäftsgrundlage und werden entsprechend geschützt.

Die Beschränkung auf festangestellte Spezialisten ist allerdings aus Sicht einiger Marktteilnehmer ein Nachteil, da auf diese Weise nur (relativ) wenige Algorithmen für Anlagezwecke bereitgestellt werden können. Das Crowdsourcing von Algorithmen könnte dieses Problem lösen.

Neuerung: Entwicklung von Investment-Algorithmen über Crowdsourcing

Die Idee dahinter ist, dass mit steigender Zahl verfügbarer Algorithmen die Wahrscheinlichkeit steigt, erfolgreiche Algorithmen zu finden bzw. Portfolioeffekte auf Algorithmen auszudehnen.

Zurzeit betreiben Hedgefonds das Crowdsourcing von Investment-Algorithmen vor allem in liquiden Assetklassen wie etwa Aktien und börsengehandelten Derivaten.

Hierbei sind zwei Neuerungen zu beobachten:

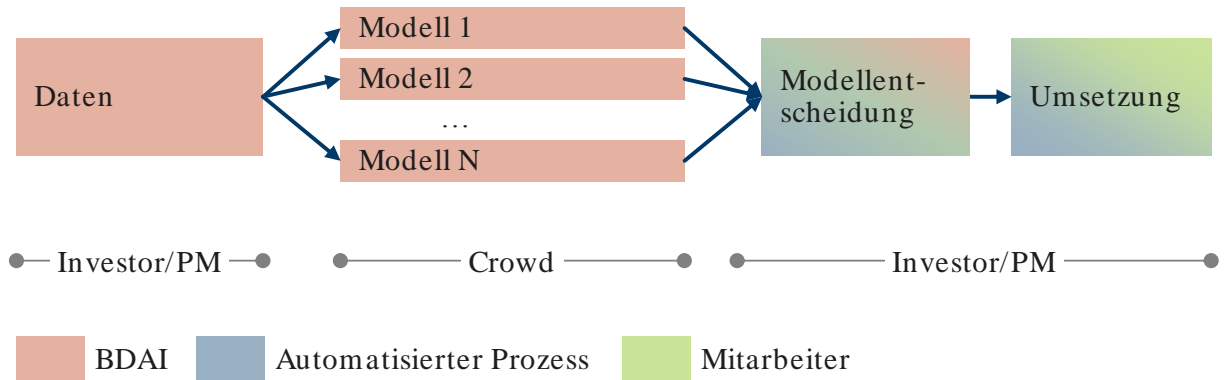
- **Analytics:** Neue Methoden und Anwendungen erlauben es, mit verschlüsselten Daten und Algorithmen zu arbeiten. So können Anwender mit Hilfe neuer Verschlüsselungstechniken auf verschlüsselten Daten Algorithmen entwickeln, und beispielsweise Hedgefonds können verschlüsselte Algorithmen testen, um deren Profitabilitäts- und Risikoprofil zu bestimmen.
- **Infrastruktur und Hardware:** Die aktuelle Dateninfrastruktur und Hardwareleistung erlauben den sicheren und schnellen Transport großer Datenmengen, sowie die Analyse, das Backtesting und die Betrachtung großer Algorithmenuniversen und darauf aufbauender Portfolien. Darüber hinaus ermöglicht die heutige Prozessorgeschwindigkeit die Verwendung verschlüsselter Daten und Algorithmen in laufenden Anwendungen und in der Entwicklung.

⁴⁴⁶ Das Crowdsourcing-Modell wird auch von Plattformen genutzt, die Investoren und Algorithmenentwickler miteinander verbinden oder Investmentssignale bereitstellen. Das bedeutet, solche Plattformen sammeln Algorithmen und stellen deren Performance dar.

⁴⁴⁷ Diese Spezialisten werden mitunter als „Quants“ bezeichnet, jedoch ist diese Bezeichnung nicht immer eindeutig.

Aktuell ist der Anteil der Hedgefonds, die Algorithmen von Crowd-Entwicklern bereitstellen lassen, sehr klein. Da allerdings Hedgefonds extrem opportunistisch⁴⁴⁸ agieren, ist es vorstellbar, dass – sofern alle technischen Hindernisse erfolgreich überwunden werden und sich entsprechende Ergebnisse einstellen – weitere Hedgefonds mit derartigen Produkten am Markt auftreten.

Abbildung 26 (stilisiert): Aufbrechen der traditionellen (Alpha⁴⁴⁹-)Prozesskette im Investmentmanagement



2. Anwendung

Investment-Algorithmen – in Abgrenzung etwa zu Algorithmen für die Abwicklung von Handelsaufträgen (siehe Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung durch institutionelle Anleger“) – treffen auf Basis unterschiedlicher quantitativer Kriterien automatisierte Anlageentscheidungen oder -empfehlungen.⁴⁵⁰ Ein Beispiel dafür sind Algorithmen, die Arbitrage betreiben, also Preisunterschiede auf verschiedenen Märkten ausnutzen.

Konkret wird das Crowdsourcing von Investment-Algorithmen beispielsweise wie folgt umgesetzt: Hedgefonds oder Plattformen stellen Entwicklern (tlw. verschlüsselte) Daten zur Verfügung. Die Entwickler konzipieren darauf aufbauend Algorithmen für Anlageentscheidungen, die dann den Hedgefonds bzw. Plattformen zur Verfügung gestellt werden. Die Hedgefonds/Plattformen evaluieren die Algorithmen maschinell⁴⁵¹ und können so diejenigen identifizieren, die am meisten Erfolg versprechen. Mit diesen Algorithmen wiederum investieren die Hedgefonds bzw. Investoren, und bei Erfolg werden die Entwickler finanziell beteiligt bzw. vergütet (beispielsweise mit einer Kryptowährung oder -tokens).

Crowdsourcing von Investment-Algorithmen wird bereits von einigen spezialisierten Start-ups bzw. neuen Teilnehmern (vorwiegend in den USA für investierbare Formen) praktiziert, etwa von Hedgefonds, Investmentunternehmen, Plattformen und spezialisierten Anbietern .

⁴⁴⁸ Neue, erfolgreiche Geschäftsmodelle werden also rasch von anderen Marktteilnehmern kopiert.

⁴⁴⁹ Mit Alpha wird der Mehrertrag eines Portfolios gegenüber dem Markt bezeichnet.

⁴⁵⁰ D.h. die Umsetzung könnte nicht automatisiert erfolgen. Zudem kann die Entscheidungsfrequenz stark schwanken (von sehr kurzen Perioden bis zu Tagen und Monaten).

⁴⁵¹ Durchaus auch hier unter Einsatz von BDAI bzw. Algorithmen, um die Erfolgswahrscheinlichkeiten der Algorithmen zu schätzen. False Positives, also die fälschliche Annahme, dass ein Algorithmus erfolgreich ist, sind ein relevantes statistisches Problem bei einer hohen Zahl von zu testenden Algorithmen, vgl. Craib et al., 2017, Numeraire: A Cryptographic Token for Coordinating Machine Intelligence and Preventing Overfitting. Online verfügbar: <https://numer.ai/whitepaper.pdf>, abgerufen am 20.02.2017.

3. Technologische Funktionsweise und Datenbasis

Ob sich dieser Ansatz durchsetzt, hängt – neben der Investmentperformance – auch von der technologischen Machbarkeit ab. Neben der Bereitstellungen der Infrastruktur können weitere möglicherweise relevante Aspekte in der Ausgestaltung beobachtet werden:

- *Verschlüsselung*: Damit eine große Zahl externer Entwickler Algorithmen entwickeln kann, müssen Hedgefonds ihnen die entsprechenden Daten zur Verfügung stellen. Da diese Daten teilweise internen Ursprungs sind oder für die Weitergabe⁴⁵² zusätzliche, teure Lizenzen benötigt würden, könnte Verschlüsselung eine Möglichkeit bieten, mit Immaterialgüterrechten der Daten umzugehen.⁴⁵³ Derartige Verschlüsselungen sind technologisch und konzeptionell anspruchsvoll, da den Entwicklern zwar die Informationen zur Verfügung gestellt werden müssen, die sie für die Entwicklung der Algorithmen brauchen, diese Informationen dürfen aber nicht identisch mit den Klarinformationen sein oder sich darauf zurückführen lassen. Zusätzlich muss es die Verschlüsselungstechnologie erlauben, große Datenmengen schnell und sicher zu ver- und entschlüsseln. Dieses Problem ist aktuell in Ansätzen gelöst. Die Verschlüsselung kann – gegebenenfalls in Kombination mit der Anonymität der Entwickler (siehe unten) – eine hohe strukturelle Intransparenz erzeugen. Zurzeit werden als Datengrundlage meist strukturierte Daten wie Aktien- und Future-Preise sowie Volumina verwendet.
- *Vertragssicherheit*: Um möglichst vielen Entwicklern die Gelegenheit zur Teilnahme zu geben, sollte man ihnen die Möglichkeit geben, anonym zu bleiben. Damit die Rechte – und damit die Grundlage für eine Gewinnbeteiligung – bei den Entwicklern verbleiben können, werden wiederum teilweise die Algorithmen selbst verschlüsselt.⁴⁵⁴ Dadurch könnte eine Trennung von Eigentum an Daten und Eigentum an Algorithmen sichergestellt werden. Zusätzlich müssen die Entwickler hinreichende Sicherheit haben, dass sie bei Erfolg tatsächlich am Gewinn beteiligt werden. Dazu werden teilweise DAO/Blockchain-Technologien⁴⁵⁵ bzw. Kryptowährungen oder -token eingesetzt. Die zu beobachtende Trennung von Daten- und Algorithmenhoheit (gegebenenfalls kombiniert mit Anonymisierung) zeigt, dass es auch für komplexe Daten- oder Immaterialgüterschutzprobleme technologische Lösungen geben könnte.

4. Chancen

Durch die Verbreiterung der Basis an Entwicklern (insbesondere Privatpersonen) für Investment-Algorithmen wird einer größeren Zahl von Personen der Zugang zu einem weiteren Aspekt des Kapitalmarktes eröffnet. Retailkunden könnten von einer möglicherweise besseren Performance und geringeren Kosten auf Seiten der Fonds und Assetmanager profitieren, falls solche Modelle erfolgreich und für Retailkunden zugänglich sein sollten.

⁴⁵² Beispielsweise wenn die Entwickler eigenständig vorgehen können.

⁴⁵³ Vgl. Craib, 2018, Encrypted Data for Efficient Markets, In: Medium.com. Online verfügbar: <https://medium.com/numerai/encrypted-data-for-efficient-markets-fffbe9743ba8>, abgerufen am 29.01.2018.

⁴⁵⁴ Ein Beispiel hierfür bietet Quantiacs, 2017. Online verfügbar: <https://quantiacs.com/Tutorials/MatlabSubmitting.aspx>, abgerufen am 29.01.2018.

⁴⁵⁵ Eine DAO (Decentralized Autonomous Organization) ist eine Kombination von Smart Contracts (d. h. Programmen, die als Verträge agieren) und Blockchain, die – grob gesprochen – zur Buchhaltung benutzt wird. Beispielsweise würden die Entwickler durch die Smart Contracts bei Erfolg ihrer Algorithmen direkt in einer Kryptowährung vergütet. Ein Beispiel für den Einsatz bietet Craib, 2017, An AI Hedge Fund Goes Live On Ethereum, In: Medium.com. Online verfügbar: <https://medium.com/numerai/an-ai-hedge-fund-goes-live-on-ethereum-a80470c6b681>, abgerufen am 29.01.2018.

Breitere Algorithmenbasis

Für die Investmentfirmen eröffnet sich die Möglichkeit, erfolgreichere Anlageentscheidungen zu treffen, da aus einer wesentlich größeren Grundgesamtheit an Algorithmen ausgewählt werden kann (einer der Anbieter spricht von über 190.000 Machine-Learning-Algorithmen⁴⁵⁶). Ein hoher Zustrom von Algorithmen könnte auch bedeuten, dass die Investmentansätze sich rasch an neue Marktphasen oder -umgebungen anpassen könnten und so die Erträge robuster würden.

Stärkere Diversifikation des Marktes

Aus Sicht des Gesamtmarktes bieten sich ebenfalls Chancen, da die größere Vielfalt an Algorithmen zu einer stärkeren Diversifikation führen könnte, wodurch der Markt effizienter und stabiler würde. Auch die Etablierung neuer Geschäftsmodelle könnte für einen diversifizierteren und somit robusteren Fondsmarkt sorgen.

5. Risiken

Intransparenzen für die Nutzer

Die Intransparenz, von der einige derartige Hedgefonds oder Plattformmodelle gekennzeichnet sind, birgt für den Verbraucher Risiken. Beispielsweise könnten hier Pump-and-Dump⁴⁵⁷-ähnliche Modelle in automatisierter Form wiederkehren (insbesondere bei Plattformmodellen, bei denen der Betreiber bzw. der Algorithmusentwickler die Verantwortung jeweils bei der Gegenseite sehen könnte). Da die beschriebenen investierbaren Modelle (Hedgefonds) zurzeit nicht für Retailinvestoren verfügbar sind, beschränken sich die Risiken auf einen sehr begrenzten Investorenkreis.

Die Herausforderung, Fehler zu identifizieren (siehe unten), könnte für die Investoren und Investmentfirmen, die das Crowdsourcing für Investment-Algorithmen nutzen, zu Verlusten führen. Die Kontrolle des Algorithmenuniversums wiederum bedeutet gegebenenfalls höhere Kosten und einen größeren Aufwand, die einen der Ausgangsvorteile des Modells nivellieren könnten.

Mögliche Hürden für (makro-)ökonomische Risikobewertung

Der Crowdsourcing-Ansatz ist grundsätzlich in Teilen agnostisch und rein ergebnisorientiert. Das heißt, die Hedgefonds, Plattformen bzw. Investoren, welche die gesamte Infrastruktur zur Verfügung stellen, prüfen unter Umständen die große Zahl bereitgestellter Algorithmen lediglich auf deren Profitabilität bzw. evaluieren Performance- und Risikocharakteristika und investieren dann auf Basis der vielversprechendsten Algorithmen. Die Investoren (oder die Portfoliomanager) verstünden dann die Funktionsweise ihrer eigenen Anlageentscheidungen auf Basis von statistischen Auswertungen⁴⁵⁸ und Simulationen/Markttests der Algorithmen.⁴⁵⁹ Risiken könnten somit nicht mehr direkt (makro-)ökonomisch bewertet werden. Aus demselben Grund könnten Portfoliomanager Fehler oder Schwachstellen dieser Algorithmen – sowohl vor der Investitionsentscheidung als auch bei Problemen im Laufe der Investition – nur schwer einzeln beheben. Sie könnten sie jedoch beispielsweise im Rahmen einer Portfoliosteuerung abfangen.

⁴⁵⁶ Vgl. Craib, 2016, Super Intelligence for the Stock Market. In: Medium.com. Online verfügbar: <https://medium.com/numerai/invisible-super-intelligence-for-the-stock-market-3c64b57b244c>, abgerufen am 29.01.2018.

⁴⁵⁷ Das irreführende Aufpumpen von Aktienpreisen bei geringem Volumen und Preisniveau, um anschließend die Aktien an Investoren zu verkaufen. Übertragen könnte dies hier z.B. bedeuten: Ein aktiv umgesetzter Algorithmus ist „erfolgreich“ durch das Kaufen von Aktien mit geringer Liquidität; dies erhöht den Preis stark, was wiederum die Algorithmus-Performance verbessert. Steigen nun mehr Investoren ein, so verkaufen die Algorithmus-Entwickler Aktien mit hohem Gewinn (bevor bei nachlassender Aktiennachfrage der Preis einbricht).

⁴⁵⁸ Dabei können auch gegebenenfalls Informationen zur Genese berücksichtigt werden.

⁴⁵⁹ Das ist per se keine neue Entwicklung im Investmentbereich.

Markteffekte könnten auch dann auftreten, wenn ähnliche Algorithmen mit ähnlichen Wirkungsweisen (und ähnlichen Schwachstellen) bei einer größeren Zahl von Marktteilnehmern auftreten. Dies würde dann passieren, wenn eine große Zahl von Marktteilnehmern auf dieselbe Crowd zugriffe. Verstärken würde sich dieser Effekt, wenn aus dieser einen Crowd absichtlich fehlerhafte Algorithmen an die Investoren gegeben würden.

6. Aufsichtliche und regulatorische Themen

Die im vorliegenden Anwendungsbeispiel dargestellten Aspekte werfen verschiedene aufsichtliche und regulatorische Fragen auf. Zunächst ist der Grundansatz, eine Vielzahl von Algorithmen zu präsentieren, bereits von Plattformen mit Signalgebern (bzw. Algorithmen) bekannt. Dieser Ansatz tritt bei den oben angesprochenen Vorgehensweisen allerdings technologisch verstärkt und ausgebaut auf. Die Anwendung bestimmter kryptographischer Verfahren könnte zusätzliche Komplikationen hervorrufen: Ein Entwickler von Signalen bzw. Algorithmen wüsste möglicherweise nicht, ob er Finanzsignale entwickelt, und wäre somit durch Regulierung schwerer zu fassen⁴⁶⁰, sofern diese darauf abstellt, dass ein Entwickler bewusst Finanzsignale erzeugt. Dies könnte beispielsweise dann der Fall sein, wenn der Signalgeber selbst reguliert werden könnte, was im Zusammenhang mit Plattformen bzw. bei kommerziellen Signalgebern der Fall sein könnte.⁴⁶¹

Übersicht behalten trotz Intransparenz?

Zudem stellt sich aus aufsichtlich-regulatorischer Sicht die Frage, wie mit einer möglichen starken Verbreitung von agnostisch handelnden Investmentfirmen umgegangen werden sollte.⁴⁶² Die Diskussion schließt sich an das Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung durch institutionelle Anleger“ an – auch hierbei besteht eine Herausforderung in der möglichen gegenseitigen Abhängigkeit von verschiedenen Algorithmen und Marktteilnehmern.

Verschlüsselung und/oder Anonymisierung erzeugen aus Sicht der Aufsicht grundsätzlich Transparenzprobleme und können effektive Aufsicht und entsprechende Regulierung erschweren. Aus Sicht des Datenschutzes sind sie jedoch zu begrüßen. Insbesondere die sich abzeichnenden Möglichkeiten (z.B. mittels homomorpher Verschlüsselung), Daten- und Algorithmenhoheit zu trennen, könnten einen breiteren Einsatz im Datenschutz bzw. bei der Erhaltung von Datensouveränität bei komplexen Datenaustauschen zwischen verschiedenen Akteuren finden (siehe auch Kapitel 3.5.2).

Rechtliche Einordnung der Vertragsverhältnisse bei Auftritt in Deutschland erforderlich

Da bisher Hedgefonds in den USA Crowdsourcing von Investment-Algorithmen nutzen, wäre bei einem Auftritt in Deutschland bzw. Europa zu beobachten, wie beispielsweise das rechtliche Verhältnis zwischen dem Assetmanager und den Algorithmentwicklern ausgestaltet wird (z.Z. wird zum Beispiel von einer Lizenz auf den Algorithmus gesprochen,⁴⁶³ bei einem anderen Modell könnte der Entwickler sogar anonym bleiben⁴⁶⁴). Hieraus abgeleitet wäre zu betrachten, ob es sich beispielsweise um eine Auslagerung handeln könnte und inwieweit diese Modelle die Anforderungen daran erfüllen könnten.

⁴⁶⁰ Unabhängig davon, ob der Entwickler anonym bleibt.

⁴⁶¹ Siehe zum Beispiel die Ausführungen der BaFin zum Thema Signal Following und Social Trading, Online verfügbar: https://www.bafin.de/DE/Aufsicht/FinTech/Signalgebung/signalgebung_node.html, abgerufen am 9.1.2018.

⁴⁶² Nicht unähnlich bestimmten Diskussionen über passive Investments.

⁴⁶³ Vgl. z.B. Quantopian-Website. Online verfügbar: <https://www.quantopian.com/allocation>, abgerufen am 19.11.2017.

⁴⁶⁴ Vgl. Metz, 2016, 7,500 Faceless Coders Paid in Bitcoin Built a Hedge Fund's Brain. In: Wired. Online verfügbar: <https://www.wired.com/2016/12/7500-faceless-coders-paid-bitcoin-built-hedge-funds-brain/>, abgerufen am 17.1.2018.

Sofern reine Blockchain-Assets in den hier besprochenen Strukturen als Spekulations- oder Investitionsobjekte dienen (also Assets wie bestimmte Kryptowährungen bzw. -tokens, die nicht dem echten Kapitalmarkt zugerechnet werden), wäre keine Anbindung der Hedgefonds an den traditionellen Kapitalmarkt erforderlich.⁴⁶⁵ Diese Fonds wären – im Gegensatz zu Fonds, die mit Hilfe von Algorithmen am echten Kapitalmarkt aktiv sind – möglicherweise von außen nicht zu erkennen. Wie ließen sich derartige Strukturen entdecken und rechtlich einordnen?

Ebenso könnte in Systemen mit verteiltem Konsensus (z.B. Blockchain) die Zuordnung von Verantwortung schwierig werden, da Entscheidungen u.U. sich nicht mehr einzelnen Akteuren zuordnen lassen.

Spiegelung des Crowdsourcings auf aufsichtlicher Seite?

Darüber hinaus bestünde zumindest die theoretische Möglichkeit, das Crowdsourcing auf Seiten der Aufsicht selbst zu nutzen. In einem solchen Szenario würden verschlüsselte⁴⁶⁶ Daten über eine Online-Plattform (anonymen) Anwendern zur Verfügung gestellt. Die Identifikation von Schwachstellen oder Anomalien wiederum würde zu einer finanziellen Kompensation der (anonymen) Data-Scientists führen. Damit würde das dargestellte Geschäftsmodell auf aufsichtlicher Seite gewissermaßen gespiegelt. Dass dies auch in der Praxis erprobt wird, zeigt das Beispiel des Department for Homeland Security in den USA, das einen öffentlichen Data-Science-Wettbewerb mit dem Ziel betrieb, die Transportation Security Administration in die Lage zu versetzen, Gefahren auf Bildmaterial besser zu erkennen.⁴⁶⁷

In Kapitel VI dieser Studie wird auf einige aufsichtlich-regulatorische Implikationen und Leitfragen vertieft eingegangen.

⁴⁶⁵ Beispielsweise würden diese Spekulationen dann nicht auf normalen Märkten oder Handelsplätzen getätigt, sondern auf Märkten, die gegebenenfalls bisher keiner Regulierung oder Aufsicht unterliegen.

⁴⁶⁶ Oder anderweitig hinreichend geschützte Daten.

⁴⁶⁷ Siehe Department of Homeland Security, 2017, Passenger Screening Algorithm Challenge. Online verfügbar: <https://www.challenge.gov/challenge/passenger-screening-algorithm-challenge/>, abgerufen am 29.01.2018.

VI. Perspektive der Aufsicht

6.1 Einordnung in den Kontext der Studie

Aufsicht und Regulierung müssen sich frühzeitig mit innovativen Entwicklungen befassen | In den bisherigen Kapiteln wurden detailliert die möglichen Auswirkungen von BDAI-Technologie auf die Finanzdienstleistungsbranche untersucht. Durch die Kombination von massenhaft verfügbaren Daten und deren Analyse lassen sich neue Erkenntnisse generieren. In der Finanzdienstleistungsbranche läuft die Wertschöpfung aus Daten vor allem über Produkt- und Prozessinnovation. In den Marktbetrachtungen und Anwendungsbeispielen wurde gezeigt, dass die Veränderungen und Erweiterungen von Produkten und Prozessen sowohl von bestehenden als auch neuen Anbietern angetrieben werden. Die Folge von Markteintritten und entstehenden Abhängigkeiten von externen BDAI-Anbietern kann die Entstehung neuer Strukturen im Markt sein. Dabei handelt es sich aber um einen schrittweisen, dynamischen Prozess, der sich im traditionellen Banken- und Versicherungsgeschäft noch im Anfangsstadium befindet und bei den Akteuren im Kapitalmarkt schon mehr Praxisrelevanz erreicht hat. Aufsichtlich-regulatorisch gilt es, diesen potenziell tiefgreifenden Wandel zu verstehen und zu begleiten. Im Rahmen dieses Berichts wurden deshalb sowohl die Chancen als auch die Risiken von BDAI-Innovationen skizziert.

Implikationen aus Produkt- und Prozessinnovation sowie aus der Entstehung neuer Anbieter und Marktstrukturen | Zur Herleitung der aufsichtlichen Implikationen von BDAI werden die wesentlichen Effekte dieses Phänomens für die drei oben skizzierten Wirkungskanäle betrachtet: Produktinnovationen, Prozessinnovationen und die daraus folgende Entstehung neuer Anbieter und Marktstrukturen. Für jeden einzelnen BDAI-Effekt wird untersucht, ob dieser eine aufsichtliche bzw. regulatorische Reaktion erfordert. Wie genau diese Reaktionen und Antworten auszugestalten sind, sollte Gegenstand einer breiten nationalen und internationalen aufsichtlich-regulatorischen Diskussion sein. Deswegen werden die möglichen aufsichtlich-regulatorischen Implikationen in diesem Kapitel in Form von strategischen Leitfragen aufgeworfen, die es gemeinsam auf nationaler wie internationaler Ebene zu beantworten gilt.

Ganzheitliche Betrachtung | Aufsichtliche bzw. regulatorische Implikationen werden für die Themenblöcke Finanzstabilität (makroprudenzielle Dimension) und Marktaufsicht, Unternehmensaufsicht (mikroprudenzielle Dimension) und den kollektiven Verbraucherschutz abgeleitet. Das Kapitel ist im Folgenden in diese drei Oberthemen gegliedert. Es werden mögliche aufsichtlich-regulatorische Implikationen für das gesamte Finanzsystem untersucht – also für Banken, Versicherungsunternehmen und den Kapitalmarkt⁴⁶⁸. BDAI-Entwicklungen sind aber auch jenseits des Finanzsystems von Bedeutung und werfen übergeordnete gesellschaftliche und politische Fragen auf, über die bereits vielfach diskutiert wird. Die Implikationen für Finanzaufsicht und -regulierung sind auch vor dem Hintergrund dieser übergeordneten Diskussionen zu sehen. Die für das Finanzsystem wichtigsten übergeordneten Themen werden im letzten Teil dieses Kapitels kurz skizziert.

⁴⁶⁸ Unter dem Begriff „Kapitalmarkt“ werden in dieser Studie u.a. Wertpapierdienstleistungsunternehmen, Investmentvermögen, Kapitalverwaltungsgesellschaften und Betreiber von Handelsplätzen (Börsen) subsumiert.

6.2 Aufsichtlich-regulatorische Implikationen

Abbildung 27: Aufsichtlich-regulatorische Implikationen im Überblick

| Ziele | Aufsichtlich-regulatorische Themen |
|---|--|
| Finanzstabilität und Marktaufsicht | 1 Entstehung neuer Geschäftsmodelle und Entitäten |
| | 2 Vernetzung von Märkten und Marktteilnehmern |
| | 3 Technische Begrenzung von Fehlentwicklungen |
| | 4 Systemrelevanz neu definieren und adressieren |
| Unternehmens- aufsicht | 1 BDAI-Governance |
| | 2 Abwehr von Finanzkriminalität und Verhaltens-Verstößen |
| | 3 Genehmigungspflichtige interne bzw. aufsichtlich abgenommene Modelle |
| | 4 Umgang mit Informationssicherheitsrisiken |
| Kollektiver Verbraucher- schutz | 1 Gefahr der Diskriminierung |
| | 2 Souveränität der Verbraucher |

6.2.1 Finanzstabilität und Marktaufsicht

Meinung

Big Data und Artificial Intelligence wird eine enorme Wirkkraft zugeschrieben – etwa die, neue Geschäftsmodelle auf dem Finanzmarkt hervorzubringen. Aufsehern stellt sich die spannende Frage, ob diese Geschäftsmodelle unter bestehendes Aufsichtsrecht fallen und eine Erlaubnis benötigen. Fallen sie nicht darunter, bringen aber materielle Risiken mit sich, könnten regulatorische Anpassungen erforderlich werden.



Dr. Thorsten Pötzsch

BaFin-Exekutivdirektor
Abwicklung

BDAI könnte auch neue systemrelevante Anbieter auf den Plan rufen. Es ist beispielsweise vorstellbar, dass Unternehmen mit datengetriebenen Geschäftsmodellen aufgrund ihrer Skalierbarkeit und Reichweite schnell an Systemrelevanz gewinnen. Systemrelevanz könnte aber auch entstehen, wenn eine Vielzahl von Marktteilnehmern identische oder sehr ähnliche Grundlagen für Prozesse oder Algorithmen nutzt, die ihnen zentrale Daten- oder Plattformanbieter zur Verfügung stellen. Das Phänomen BDAI stellt die bisherige Definition von Systemrelevanz auf den Prüfstand – und damit auch den aufsichtlich-regulatorischen Umgang damit.

In der Geldwäscheerkennung ist BDAI noch in der Erprobung. Aber es ist gut vorstellbar, dass es auf diesem Gebiet eine weitreichende Wirkung entfaltet. Derzeit erweisen sich automatisch erzeugte Hinweise auf einen Geldwäscheverdachtsfall in der nachfolgenden Prüfung oft als nicht vertiefungswürdig. BDAI-Verfahren könnten helfen, die Qualität der Treffer zu erhöhen und bisher unerkannte Muster selbstständig zu erkennen. Dazu müssen Banken und Versicherer aber erst einmal mit solchen Verfahren umgehen können. Die Lernkurve ist steil, und die BaFin geht davon aus, dass die Unternehmen alles daran setzen, sie zu bewältigen

6.2.1.1 Entstehung neuer Geschäftsmodelle und Unternehmen

Regulierungslücken frühzeitig identifizieren und adressieren | In den Marktbeobachtungen wurde verdeutlicht, dass die durch BDAI getriebenen Innovationen neue Anbieter auf den Plan rufen (vgl. Kapitel V). Die Disaggregation der Wertschöpfungskette kann dadurch weiter voranschreiten, insbesondere, wenn bestehende Unternehmen mit neuen Spezialanbietern kooperieren. Verstärkt wird dieser Effekt durch technische Lösungen wie APIs (Application Programming Interface, d.h. eine Schnittstelle zur Anwendungsprogrammierung). Das Phänomen BDAI bringt auch neuartige Geschäftsmodelle und Marktteilnehmer hervor, die regulatorisch noch nicht adäquat erfasst sind. Solche Fälle müssen identifiziert und das Spektrum der zu beaufsichtigenden Anbieter und Unternehmen sollte entsprechend erweitert werden.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Welche Geschäftsmodelle sind derzeit zu beobachten bzw. in naher Zukunft zu erwarten, die von der jetzigen Regulatorik nicht hinreichend erfasst werden?
 - Welche Analyse-Methoden, z.B. aus der Marktforschung, könnten helfen, entsprechende Geschäftsmodelle frühzeitig zu adressieren?
 - Sollten der zunehmende Wettbewerbs- und Margendruck noch stärker als bisher bei der Beurteilung der mittel- und langfristigen Solvenz bestehender Marktteilnehmer berücksichtigt werden?
-

6.2.1.2 Vernetzung von Märkten und Marktteilnehmern

BDAI kann zu einer stärkeren Vernetzung von Märkten und Marktteilnehmern führen | Grundsätzlich zeigen alle Marktbetrachtungen und verschiedene Anwendungsbeispiele zu Banken, Versicherungsunternehmen und zum Kapitalmarkt, dass Märkte und Marktteilnehmer künftig noch stärker als bislang vernetzt sein werden. Eine Vernetzung kann mittelbar entstehen, z.B. über die Nutzung von gleichen Modellen, Daten und Plattformen, aber auch unmittelbar, nämlich durch neue Vertrags- und Handelsbeziehungen, die erst durch den Einsatz von BDAI erforderlich werden. Das Aufbrechen der Wertschöpfungsketten kann zudem dazu führen, dass zunehmend neue Akteure in den Markt eintreten, die wiederum vielfältig vernetzt sind.

Transparenz und Kontrolle über neue Strukturzusammenhänge behalten | Diese stärkere Vernetzung könnte das Marktgeschehen komplexer machen, indem beispielsweise ehemals interne Prozesse eines einzigen Akteurs über mehrere Marktteilnehmer verteilt werden. An den Schnittstellen zu und zwischen diesen Marktteilnehmern können neue Risiken entstehen. Gerade weil diese Risiken dann nicht mehr innerhalb der Organisationsstruktur beaufsichtigter Unternehmen liegen, besteht die Gefahr, dass diese sie nur unvollkommen identifizieren und steuern. Aufsichtlich und regulatorisch gilt es daher, die sich ändernden Strukturen des dynamischen Marktes und die daraus resultierenden Risiken zu bewerten und zu adressieren.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Wie können die Struktur des dynamischen Marktes und die daraus resultierenden Risiken dauerhaft transparent gemacht werden?
 - Könnten beispielsweise langfristig Methoden aus der Graphenanalyse oder topologische Verfahren in der aufsichtlichen Erkennung von Marktstrukturen zum Einsatz kommen?
- Könnten derart gewonnene Erkenntnisse bei der Kalibrierung makroprudenzieller Puffer Anwendung finden, etwa indem Vernetzungsgrade direkt berücksichtigt werden, wie es bei der Bestimmung von SIFIs⁴⁶⁹ praktiziert wird?
- Wie können Risiken identifiziert werden, die nicht innerhalb der Organisationsstruktur beaufsichtigter Marktteilnehmer liegen und die sowohl die Marktteilnehmer selbst als auch die Aufsicht nur unvollkommen identifizieren und steuern können (Beispiel: Risiken, die sich durch die Abhängigkeit von externen Ratings ergeben)?

⁴⁶⁹ Das Kürzel SIFI steht für „Systemically Important Financial Institution“.

6.2.1.3 Technische Begrenzung von Fehlentwicklungen

BDAI-induzierte Vernetzung erhöht die Gefahr von Kaskadeneffekten | Auch außerhalb von Handelsplätzen besteht in stark vernetzten Systemen die Gefahr, dass sich Störungen rasch und unkontrolliert ausbreiten. Dies ist insbesondere mit Blick auf die im vorigen Punkt (vgl. 0) angesprochene Vernetzung relevant, da hierdurch Kaskadeneffekte verstärkt werden könnten.

Technische Sicherheitsmaßnahmen aus dem Handel auf andere Bereiche übertragen | Im Anwendungsbeispiel „Algorithmischer Handel zur Orderausführung für institutionelle Kunden“ wurde über technische Sicherheitsmaßnahmen diskutiert, die bereits jetzt an Handelsplätzen und im algorithmischen Handel einen großen Raum einnehmen, wie etwa Volatilitätsunterbrechungen. Konzeptionell sind Sicherheitsmaßnahmen nicht nur auf Handelsplätze begrenzt bzw. strukturell erweiterbar. Es stellt sich die Frage, ob solche technischen Maßnahmen im BDAI-Kontext auch außerhalb von Handelsplätzen erforderlich und sinnvoll anwendbar wären. Beispielsweise könnte über Abkopplungsmechanismen für Datenströme nachgedacht werden, da Datenzulieferungen durch BDAI stark an Bedeutung gewinnen.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Wären technische Maßnahmen zur Begrenzung von Kaskadeneffekten im BDAI-Kontext auch außerhalb von Handelsplätzen nötig und sinnvoll anwendbar?
 - Wie könnten existierende Schutzmaßnahmen wie zum Beispiel Volatilitätsunterbrechungen, Speed Bumps und Circuit Breaker optimiert oder gezielt fortentwickelt werden bzw. innovative Schutzmaßnahmen gefördert werden, beispielsweise durch Experimente in Testumgebungen?
-

6.2.1.4 Systemrelevanz neu definieren und adressieren

BDAI ermöglicht die Entstehung neuer systemrelevanter Anbieter | In den Marktbeobachtungen (vgl. Kapitel V) ist deutlich geworden, dass durch den Einsatz von BDAI systemrelevante Anbieter entstehen könnten. Beispielsweise könnten Anbieter mit datengetriebenen Geschäftsmodellen aufgrund ihrer Skalierbarkeit und Reichweite schnell an Systemrelevanz gewinnen. Jedoch könnte Systemrelevanz auch entstehen, wenn zentrale Daten- oder Plattformanbieter einer Vielzahl von Marktteilnehmern identische oder sehr ähnliche Grundlagen für Prozesse oder Algorithmen zur Verfügung stellen. Systemrelevanz könnte zudem auch aus der Interaktion verschiedener Marktteilnehmer als Struktur erwachsen.

Systemrelevanz neu definieren und adressieren | Klassische aufsichtliche Methoden zur Bestimmung von Systemrelevanz könnten in diesem Fall ungeeignet sein, bzw. müssten erweitert werden. Zudem muss geprüft werden, ob die bekannten Risikomitigationsmaßnahmen auch bei neuen systemrelevanten Unternehmen und Strukturen greifen. Es stellt sich daher die Frage, ob und wie der bank- und versicherungsfachlich geprägte Begriff der Systemrelevanz weiterentwickelt werden muss, um auch neuen Geschäftsmodellen und Marktstrukturen gerecht zu werden.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Muss der Begriff der Systemrelevanz angesichts sich ändernder Marktstrukturen weiterentwickelt werden, und, wenn ja, wie kann dies geschehen?
 - Könnten auch hier die im vorherigen Kapitel erwähnten Methoden zur Strukturaufklärung, zum Beispiel aus der Topologie, zum Einsatz kommen?
 - Müssen bekannte Risikomitigationsmaßnahmen für den Umgang mit potenziellen neuen systemrelevanten Unternehmen und Strukturen angepasst werden?
-

6.2.2 Unternehmensaufsicht⁴⁷⁰

Meinung

In der Versicherungsbranche ist eine starke Tendenz zur Modernisierung der Prozesse zu beobachten. Zu den Technologien mit großem Potenzial zählen Big Data und Artificial Intelligence, wie auch in diesem Bericht deutlich wird.



Dr. Frank Grund

BaFin-Exekutivdirektor der Versicherungs- und Pensionsfondsaufsicht

Vor allem im Zusammenhang mit der Dunkelerarbeitung ist häufig von künstlicher Intelligenz die Rede. In vielen Fällen scheint es sich aber eher um eine Weiterentwicklung regelbasierter Algorithmen zu handeln, die Schadenfälle mal gut und mal weniger gut kategorisieren und entsprechend regulieren bzw. entscheidungsvorbereitend arbeiten. Die Herausforderung für die Branche wird darin bestehen, wirkliche Intelligenz im Sinne einer eigenen kognitiven Leistung, also der Lösung eines bislang unbekanntem komplexen Entscheidungsproblems zu entwickeln.

Big Data ist derzeit in erster Linie ein Thema bei der risikogerechten Differenzierung von Versicherungsprämien. Neu ist das Phänomen zwar nicht, aber durch die fortschreitende Digitalisierung rückt es stärker in den Fokus der Öffentlichkeit. Man denke beispielsweise an die Vielzahl von Tarifierungsmerkmalen in der Kfz Versicherung oder in der Berufsunfähigkeitsversicherung.

Darüber hinaus macht das öffentliche Interesse auch die Grenzen von Big Data deutlich. So wird eine immer stärkere Preisdifferenzierung mitunter als gesellschaftlich unerwünscht angesehen. Auch gibt es datenschutzrechtliche und moralische Bedenken.

Doch mit der Zeit werden diese und weitere Technologien immer weitere Kernprozesse der Versicherungswirtschaft erfassen. Der Bericht nennt einige Beispiele. Von dieser Entwicklung sollten auch die Versicherungsnehmer profitieren, da die Kommunikation mit dem Versicherer erleichtert, Kernprozesse beschleunigt und mittelfristig Kosteneinsparungen realisiert werden.

Ob die Digitalisierung das Potenzial für einen fundamentalen Wandel des Geschäftsmodells birgt, wird die Erprobung neuer Technologien zeigen. Die Versicherungsaufsicht der BaFin stellt sich jedenfalls auf die zunehmende Bedeutung von BDAI ein und baut das notwendige Knowhow auf.

⁴⁷⁰ Der Begriff Unternehmensaufsicht bezieht sich hierbei grundsätzlich auf Unternehmen, die einer laufenden Aufsicht unterliegen, also sowohl Kredit-, Finanzdienstleistungs- und Zahlungsinstitute als auch Versicherungsunternehmen und beaufsichtigte Kapitalverwaltungsgesellschaften. Die Implikationen für die jeweiligen Aufsichtsregimes sind naturgemäß unterschiedlich.

Meinung

In der Welt von Big Data und Artificial Intelligence sind Finanztransaktionsdaten ein wertvoller Rohstoff. Kein Wunder also, dass sich auch Anbieter außerhalb des Finanzsektors dafür interessieren. Vertrauen ist im Finanzsektor allerdings ein mindestens ebenso wichtiger Rohstoff, gerade wenn es um den Umgang mit persönlichen Daten geht. Es wird sich zeigen, welcher Anbieter in der Lage ist, dieses Vertrauen zu wecken und zu erhalten.



Raimund Röseler

BaFin-Exekutivdirektor
der Bankenaufsicht

Die etablierten Banken verfügen über den Rohstoff Vertrauen – und über den Rohstoff Finanzdaten. Beste Voraussetzungen, sollte man denken. Und doch könnten sie den Anschluss verlieren. Bevor die klassische Bankenwelt von den Vorzügen von BDAI profitieren kann, müssen einige Institute erst einmal ihre alten IT-Systeme ersetzen. Die Zeit drängt, und die Konkurrenz ist groß. Bigtechs könnten von außen in den Finanzsektor vorrücken. Sie verfügen nicht nur über riesige Datenmengen, sie haben auch die moderne Technik, Daten produktiv zu nutzen.

Banken können in dieser durchdigitalisierten Umgebung nur bestehen, wenn sie umfassend in Technologie investieren – und in Köpfe. Den Banken muss klar sein, dass es um alles geht, nämlich darum, das traditionelle Geschäftsmodell zukunftstauglich zu machen. Es muss ein Kulturwandel stattfinden. Das Vertrauen der Kunden darf diesem Wandel allerdings nicht zum Opfer fallen.

Klar sein muss auch, dass künstliche Intelligenz immer nur ein Hilfsmittel sein kann. Die Verantwortung für alle Entscheidungen trägt immer die Geschäftsleitung. Vieles lässt sich auslagern, Verantwortung nicht! Daran wird auch BDAI nichts ändern.

6.2.2.1 BDAI-Governance

Verantwortung bleibt bei der Geschäftsleitung – BDAI in eine ordnungsgemäße

Geschäftsorganisation einbetten | BDAI wird weitere Möglichkeiten der Automatisierung marktüblicher Prozesse schaffen – vom Chatbot bis zur Liquiditätssteuerung. Ein Beispiel hierfür ist das Fortschreiten der Automatisierung im Kreditvergabeprozess bei Banken und im Schadenmanagement bei Versicherungsunternehmen (vgl. Kapitel 5.2.1 und 5.3.1). Ziel der weiteren Automatisierung ist eine Steigerung der Effizienz und der Effektivität – und damit eine Senkung der Kosten. Das kann jedoch nicht bedeuten, dass die Verantwortung für die Ergebnisse BDAI-gestützter Prozesse auf Maschinen übertragen wird. Wichtig ist deshalb, bei der Ausgestaltung (teil-)automatisierter Prozesse eine Einbettung in eine wirksame, angemessene und ordnungsgemäße Geschäftsorganisation zu gewährleisten. Die Verantwortung auch für automatisierte Prozesse verbleibt bei der Geschäftsleitung des beaufsichtigten Unternehmens. Um dies sicherzustellen, ist eine angemessene Dokumentation erforderlich.

Blackbox-Ausreden sind unzulässig – Erklärbarkeit/Nachvollziehbarkeit von Modellen ist geboten und kann den Analyseprozess verbessern

| Es liegt in der Verantwortung des beaufsichtigten Unternehmens, die Erklärbarkeit/Nachvollziehbarkeit⁴⁷¹ von BDAI-basierten Entscheidungen zu gewährleisten. Insbesondere wurde in Kapitel 3.5.2 ausgeführt, dass auch bei sehr komplexen Modellen zumindest Einblicke in die Funktionsweise des Modells und die Gründe für Entscheidungen erzielt werden können und Modelle nicht zwangsläufig als Blackbox verstanden werden müssen. Die Aufsicht wird es daher nicht akzeptieren, wenn man ihr ein Modell als unerklärbare Blackbox präsentiert. Darüber hinaus bietet eine bessere Verständlichkeit von Modellen die Chance, den Analyseprozess zu verbessern – etwa, indem die verantwortlichen Stellen im beaufsichtigten Unternehmen Overfitting und Datenbias (vgl. Kapitel 3.3.1) erkennen.

Bestehende Konzepte im Rahmen von Machine-based Governance weiterentwickeln | Es ist unter Umständen erforderlich, etablierte Governance-Konzepte wie das Vier-Augen-Prinzip weiterzuentwickeln und auf automatisierte Prozesse zu übertragen.⁴⁷² Beispielsweise könnte darüber nachgedacht werden, für bestimmte besonders risikobehaftete BDAI-Anwendungen besondere Schutzmaßnahmen einzuführen, die aus anderen technologischen Anwendungen bereits bekannt sind. In der Luftfahrt werden zur Geschwindigkeitsmessung z.B. mehrere unabhängige Systeme verwendet – das Back-up wäre dann wieder ein Algorithmus.

Bestehende Dokumentationsanforderungen durch Ergebniskontrollen ergänzen | Aufgrund der Komplexität der Anwendungen, die auch aus Art und Umfang der eingesetzten Daten resultiert, ist darüber hinaus zu überlegen, ob künftig neben den oben beschriebenen Dokumentationsanforderungen zusätzlich auch Prozessergebnisse untersucht werden sollten. Ein Beispiel hierfür wäre die Auswertung der Ergebnisse, die ein Algorithmus in einem von der Aufsicht vorgegebenen Test-Szenario produziert.

⁴⁷¹ Erklärbarkeit beschreibt die Eigenschaft, für eine konkrete Einzelentscheidung des Systems die wesentlichen Einflussfaktoren aufzuzeigen (vgl. Kapitel 3.5.2).

⁴⁷² „Wie gehen wir beispielsweise mit Vorgaben zum Vier-Augen-Prinzip um, wenn bei voll digitalisierten Prozessen nicht einmal ein menschliches Auge auf einzelne Geschäfte schaut?“, Rede von Raimund Röseler, BaFin-Exekutivdirektor Bankenaufsicht, bei der Pressekonferenz der BaFin am 3. Mai 2018, online verfügbar: https://www.bafin.de/SharedDocs/Veroeffentlichungen/DE/Reden/re_180503_jahrespressekonferenz_p.html; abgerufen am 07.05.2018.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Erfordert der vermehrte Einsatz von BDAI eine Erweiterung bestehender Aufsichtspraktiken und entsprechender gesetzlicher Anforderungen an eine ordnungsgemäße Geschäftsorganisation?
 - Sind zusätzliche technische Schutzmaßnahmen wie sie beispielsweise in der Luftfahrt genutzt werden, erforderlich und geeignet, besonders risikobehaftete BDAI-Anwendungen im Rahmen der ordnungsgemäßen Geschäftsorganisation angemessen zu steuern?
 - Für welche BDAI-Anwendung würde eine solche besondere Behandlung in Frage kommen? Sind beispielsweise ein Chatbot und ein Modell zur Liquiditätssteuerung unterschiedlich zu behandeln?
 - Ist es erforderlich, für BDAI-getriebene Anwendungen die bestehenden Anforderungen an die Überprüfung von Prozessen über die bisherigen Dokumentationspflichten hinaus zu erweitern?
 - Ergibt es zum Beispiel Sinn, bei der Prüfung komplexer Prozesse neben einer Dokumentation auch verstärkt tatsächliche Ergebnisse zu begutachten?
 - Wie kann ein Mindeststandard für die Erklärbarkeit/Nachvollziehbarkeit von verwendeten Algorithmen – gegebenenfalls gestaffelt nach ihrem jeweiligen Einsatzgebiet – etabliert werden?
 - Ist es erforderlich, mit Blick auf eine vermehrte BDAI-Nutzung zusätzliche Eignungsanforderungen an die Leitungsebene zu stellen?
-

6.2.2.2 Abwehr von Finanzkriminalität und Verhaltensverstößen

BDAI-Potentiale bei der Nutzung in Compliance-Prozessen | Dank BDAI kann die Anomalie- und Mustererkennung verbessert werden, wodurch Compliance-Prozesse wie zum Beispiel die Geldwäscheerkennung und die Betrugsprävention effizienter und effektiver werden. Dies wurde ausführlich im Anwendungsbeispiel „Compliance“ (Vgl. Kapitel 5.2.6.2) dargestellt. Daneben kann BDAI auch eine Rolle bei der Kontrolle der Verhaltensweisen der Mitarbeiter (Employee Conduct) spielen.

Ausweichreaktionen auf weniger versierte Unternehmen vermeiden | Wird die Geldwäscheerkennung durch den Einsatz von BDAI-Technologien offenkundig sehr viel effektiver, könnten Täter auf Unternehmen ausweichen, die auf diesem Gebiet nicht so weit entwickelt sind. Es gilt zu beobachten, ob solche Ausweichreaktionen tatsächlich stattfinden.

Aufsichtliche Anforderungen an Erklärbarkeit und Effektivität von Algorithmen zur Finanzkriminalitätserkennung definieren | Außerdem ist aufsichtlich und regulatorisch darüber zu diskutieren, ob für die verwendeten Verfahren konkrete Mindeststandards in Bezug auf Erklärbarkeit/Nachvollziehbarkeit und Effektivität formuliert werden sollten. Die Ergebnisse der Algorithmen müssen in einer Weise nachvollziehbar sein, dass die Aufsichtsbehörden sie überprüfen und zuständige Stellen wie Strafverfolgungsbehörden sie verwenden können. Neben dem Abgleich mit konkreten, gegebenenfalls zu entwickelnden Mindeststandards, könnte die Effektivität auch über das Benchmarking mit anderen Anbietern aufsichtlich untersucht werden.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Wie kann verhindert werden, dass unerwünschte oder kriminelle Aktivitäten auf Unternehmen verlagert werden, deren Geldwäscheerkennung mit Blick auf BDAI weniger weit entwickelt ist?
 - Welche Anforderungen an die Erklärbarkeit und Dokumentation müssen Algorithmen erfüllen, damit ihre Ergebnisse für hoheitliche Sanktions- und Eingriffsmaßnahmen im Rahmen der Gefahrenabwehr und der Strafverfolgung valide genutzt werden können?
 - Müssen für die Nutzung von BDAI-Techniken insbesondere in der Geldwäscheerkennung allgemeine Standards für die Effektivität der angewendeten Verfahren festgelegt werden?
-

6.2.2.3 Genehmigungspflichtige interne bzw. aufsichtlich abgenommene Modelle

Einsatzmöglichkeiten von BDAI in aufsichtlich abgenommenen Modellen | Bei beaufsichtigten Unternehmen könnte der Wunsch entstehen, BDAI-Methoden auch bei Modellen anzuwenden, welche die Aufsicht genehmigen muss – zum Beispiel Modelle des Internal Ratings Based Approach bei Banken. Dies dürfte dann der Fall sein, wenn der Einsatz von BDAI präzisere Ergebnisse lieferte als die bisher eingesetzte Kombination von Methoden und Daten. So könnten bekannte Verfahren, z.B. zur Optimierung der Schätzung von Einzeladressrisiken, durch den Einsatz von BDAI möglicherweise verbessert werden. Außerdem könnte eine verbesserte Portfoliosicht die Betrachtung von Einzelrisiken womöglich anders gewichten, da beispielsweise durch Vernetzungsanalysen zwischen Kreditnehmern Konzentrationsrisiken adäquater adressiert werden könnten.

Tatsächliche Effekte von BDAI-Nutzung auf die Eigenmittelhinterlegung wären voraussichtlich begrenzt | Anzumerken ist, dass zum aktuellen Zeitpunkt noch keine BDAI-Anwendungen in den

Algorithmen derartiger Modelle zu beobachten bzw. zugelassen sind. Außerdem ist zu beachten, dass die heute bereits existierenden zugelassenen Modelle sehr fortgeschritten sind, beispielsweise was den Umfang der genutzten – auch externen – Daten angeht. Im Bankensektor ist zudem zu beachten, dass durch den bei der Finalisierung der Basel-III-Reform beschlossenen Output-Floor die tatsächlichen Effekte auf die Kapitalhinterlegung zusätzlich gedeckelt wären.

Voraussetzungen für BDAI-Nutzung in aufsichtlich abgenommenen Modellen definieren | Eine Verwendung von BDAI-Modellen stünde immer unter dem Vorbehalt einer entsprechenden aufsichtlichen Genehmigung im Einzelfall. Über den Einzelfall hinaus könnte die Frage gestellt werden, ob alle BDAI-Methoden gleichermaßen für den Einsatz in aufsichtlich abzunehmenden Modellen geeignet sind oder ob es Methoden gibt, die per se auszuschließen sind. Darüber hinaus ist zu prüfen, ob bestehende gesetzliche (Mindest-) Anforderungen an die verwendeten Daten und die Modelltransparenz mit Blick auf BDAI hinreichend sind oder erweitert werden sollten. Über eine weitere Frage sollte diskutiert werden: Welchen Komplexitätszuwachs sollte man für eine bessere Vorhersagequalität in Kauf nehmen? Bei dynamischen BDAI-Modellen stellt sich zudem die Frage, bei welchen generellen Anpassungen eine Modelländerung im aufsichtlichen Sinne vorliegen kann, die eine Bank oder ein Versicherer, beispielsweise im Rahmen der Modelländerungsrichtlinie bei Versicherungsunternehmen, bei der Aufsicht anzeigen und die unter Umständen genehmigt werden müsste.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Welche veränderten Anforderungen an den Modellentwicklungs-, -überwachungs, und -abnahmeprozess würden sich durch den Einsatz von BDAI ergeben, insbesondere im Hinblick auf zunehmend dynamische Veränderungen von Daten und Algorithmen?
 - Bei welchen generellen Anpassungen liegt eine Modelländerung im aufsichtlichen Sinne vor, die von den beaufsichtigten Unternehmen anzuzeigen und die unter Umständen zu genehmigen wäre?
- Sind bestehende gesetzliche (Mindest-)Anforderungen an die Erklärbarkeit der Modelle und Daten mit Blick auf die Anwendung von BDAI zu erweitern?
- Sind alle BDAI-Methoden in gleicher Weise geeignet, und wie kann dies festgestellt werden?
- Könnte z.B. durch den vermehrten Einsatz von Daten die algorithmische Komplexität von Modellen reduziert und dennoch die Erklärbarkeit verbessert werden?

6.2.2.4 Umgang mit Informationssicherheitsrisiken

Zunahme von Informationssicherheitsrisiken durch vermehrte BDAI-Nutzung | Das Management von Informationssicherheitsrisiken steht durch die BDAI-bedingt zunehmende Komplexität vor neuen Herausforderungen. Die von BDAI unterstützte Disaggregation von Wertschöpfungsketten und das wachsende Datenvolumen vergrößern zudem die Angriffsfläche für externe Zugriffe und verringern zugleich die Möglichkeiten eines einzelnen Anbieters, die genutzten und verteilten Daten zu kontrollieren. Zusätzlich kommt es neuerdings bei bestimmten BDAI-Algorithmen auch zu Angriffen durch Datenmanipulation – z.B. in Form von Adversarial oder Poison Attacks. Daraus resultieren andere Risiken als beim klassischen Online-Banking. In der Folge nehmen sowohl operationelle als auch Reputationsrisiken zu.

BDAI- und Verschlüsselungsverfahren zur Mitigation von Informationssicherheitsrisiken | Durch die Nutzung von BDAI könnten Informationssicherheitsrisiken aber nicht nur zunehmen. BDAI ließe sich auch in der Abwehr dieser Risiken nutzen, beispielsweise bei der Analyse und Entdeckung von Gefahren. So könnte BDAI z.B. Unregelmäßigkeiten im Verhalten von Verbrauchern beim Online-Banking feststellen und so auf eine mögliche missbräuchliche Verwendung schließen. Auch bestimmte Verschlüsselungsverfahren, welche die Anwendung von BDAI-Methoden direkt auf verschlüsselten Daten erlauben, könnten genutzt werden, um die Resilienz gegenüber solchen Risiken zu stärken.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Welche konkreten Standards sind – auch im Hinblick auf algorithmenspezifische Risiken – sachgerecht und angemessen, um Informationssicherheitsrisiken zu mitigieren?
 - Sind bestehende aufsichtliche prinzipienbasierte Anforderungen oder regelbasierte Kontrollmaßnahmen an BDAI-spezifische Sachverhalte anzupassen?
 - Welche konkreten BDAI- bzw. Verschlüsselungsverfahren könnten für die Abwehr von Informationssicherheitsrisiken geeignet sein?
-

6.2.3 Kollektiver Verbraucherschutz⁴⁷³

Meinung

Verbraucher sollten Big Data und Artificial Intelligence (BDAI) mit einer gesunden Skepsis begegnen. Selbstverständlich haben etwa maßgeschneiderte Produkte, individualisierter und schneller Service Vorteile. Doch die meisten Verbraucher dürften den Preis, den sie dafür zahlen, unterschätzen. Sie zahlen mit ihren Daten und geben sehr viel von sich preis – und zwar in vielen Fällen, ohne tatsächlich abschätzen zu können, wer diese Daten wofür nutzt.



Elisabeth Roegele

BaFin-Exekutivdirektorin
der Wertpapieraufsicht /
Asset-Management

BDAI macht es beispielsweise möglich, das Verhalten und die Bedürfnisse von Verbrauchern relativ genau vorherzusagen – vor allem, wenn Finanzdaten mit anderen Daten kombiniert werden, wie sie beispielweise Bigtechs in rauen Mengen haben. Unternehmen, die BDAI-Methoden anwenden, können dank BDAI also abschätzen, was Verbraucher zu zahlen bereit und in der Lage sind, und nutzen dies auch aus. Hinzukommt das Risiko der ungerechtfertigten Diskriminierung. Umso wichtiger ist es, Verbraucher stärker für dieses Thema sensibilisieren. Die BaFin tut ihr Bestes, ihren Teil dazu beizutragen. Sie nimmt den gesetzlichen Auftrag der Verbraucheraufklärung sehr ernst.

Die Anbieter des Finanzmarktes sind gut beraten, verantwortungsvoll mit den Daten umzugehen, die Verbraucher ihnen anvertrauen – auch wenn diese die Daten formal freigeben. Sie sind als erste in der Pflicht, wenn es darum geht, die Privatsphäre und informationelle Selbstbestimmung ihrer Kunden zu gewährleisten. Die Datenschutzbehörden haben die Aufgabe, die Umsetzung entsprechender Vorgaben zu überwachen. Häufen sich Verstöße gegen den Datenschutz, kann es zu Missständen kommen, die auch die BaFin angehen.

⁴⁷³ Vgl. Kapitel 4.1.

6.2.3.1 Gefahr der Ausnutzung von Informations- und Machtasymmetrien

Unternehmen wissen durch BDAI immer mehr über ihre Kunden | Die Erkenntnisse über Kunden nehmen in Qualität (Zoom-in) und Umfang (Big Data) zu. Auch die Vorhersagemöglichkeiten (Predictive Analytics) werden besser. Dies erlaubt sowohl eine immer genauere Beurteilung von Risiken (Kreditausfall, Krankheit, usw.) als auch eine zielgerichtete Kundenansprache (Segment-of-one). Zudem ermöglicht BDAI durch die Auswertung und Verknüpfung personenbezogener Daten eine kleinteiligere Segmentierung von Kundengruppen.⁴⁷⁴ Dies kann von Unternehmen zur Differenzierung bei der Produkt- und Preisgestaltung genutzt werden. Insgesamt können durch die Nutzung von BDAI Macht- und Informationsasymmetrien zuungunsten der Kunden zunehmen. Zu Informationsasymmetrien kann es beispielsweise kommen, wenn Verbrauchern der Gegenwert der von ihnen zur Verfügung zu stellenden Daten („Bezahlen mit Daten“) nicht bekannt ist und sie daher den faktischen Preis für ein Produkt oder eine Dienstleistung nicht kennen.

Abschöpfung der Konsumentenrente⁴⁷⁵ ist verstärkt möglich | Dabei kann für Unternehmen der – aus Sicht des Verbraucherschutzes – bedenkliche Anreiz entstehen, die Konsumentenrente einseitig abzuschöpfen, also ausschließlich mit Blick auf eine höhere Zahlungsbereitschaft und -fähigkeit. Dies könnte möglicherweise gerade für solche Anbieter interessant sein, die nicht hauptsächlich Finanzdienstleistungen anbieten, die aber die dabei gewonnenen Erkenntnisse in ihrem Kerngeschäft (etwa im Onlinehandel) verwenden. Denn insbesondere eine Verknüpfung von finanzwirtschaftlichen Transaktions- und Verhaltensdaten mit den über Online-Dienstleistungen vorliegenden Daten zu Präferenzen, Bedürfnissen und Wünschen ermöglicht es solchen Anbietern, eine umfassende Sicht auf die Zahlungsbereitschaft und -fähigkeit einzelner Kunden zu generieren. Dies ist insbesondere kritisch in Situationen, in denen Verbraucher faktisch keine Wahl mehr zwischen verschiedenen Angeboten haben, zugleich aber das Produkt oder die Dienstleistung akut brauchen, z.B. einen Kredit. Verbraucher sind daher stärker dafür zu sensibilisieren, wie ihre Daten genutzt werden können und welche Bedeutung und welchen Wert sie haben.

BDAI-induzierte Selektion kann für einzelne Verbraucher den Zugang zu Finanzdienstleistungen einschränken | Die Betrachtung von BDAI in der Versicherungsbranche hat außerdem gezeigt, dass eine genauere Einschätzung der Risikoexposition der einzelnen Versicherungsnehmer unter bestimmten Voraussetzungen zu einer verschärften Selektion führen kann. Der Einsatz von BDAI wird zwar nicht bei allen Angeboten zu einer stärkeren Differenzierung von Risiken und damit der Prämien führen (vgl. Kapitel 5.3.4).⁴⁷⁶ Dennoch können etwaige durch BDAI erst ermöglichte Selektionsmechanismen einzelnen Verbrauchern den Zugang zu bestimmten Finanzdienstleistungen unverhältnismäßig erschweren. Das kann besonders prekär werden, wenn der Verbraucher durch eine geringere Produktauswahl benachteiligt wird, aber nicht nachvollziehen kann, dass seine personenbezogenen Daten der Grund sind.

Anbieter müssen Diskriminierung vermeiden | Außerdem kann sich die Gefahr von Diskriminierung erhöhen: Algorithmen könnten Merkmale nutzen, die aus rechtlichen Gründen nicht zur Differenzierung verwendet werden dürfen. Bei der Programmierung der Algorithmen und bei der Kontrolle der Ergebnisse müssen Anbieter darauf achten, dass einzelne Verbraucher nicht diskriminiert werden. Es stellt sich die Frage, welche Kontroll- und Transparenzmechanismen ihnen dabei helfen könnten.

⁴⁷⁴ Vgl. Kapitel V Marktbetrachtungen Banken und Versicherung.

⁴⁷⁵ Vgl. Erläuterungen in Fußnote 63.

⁴⁷⁶ So wird z.B. in Segmenten mit einer aus heutiger Sicht geringen Volatilität des Erwartungsschadens eine weitere Differenzierung nicht möglich bzw. nicht nötig sein.

Diskriminierung durch Approximation verbotener Merkmale | Es besteht zudem das Risiko, dass die Differenzierung der Kundensegmente auf Basis falscher Annahmen bzw. der daraus resultierenden Schlussfolgerungen der Algorithmen erfolgt, dass also Verbraucher – wenn auch unbeabsichtigt – de facto diskriminiert werden. So dürfen private Krankenversicherer in der EU beispielsweise das Geschlecht einer Person nicht als Differenzierungsfaktor verwenden. Durch die Auswertung der biografischen Informationen, die mit dem Geschlecht korrelieren können, könnte es jedoch dazu kommen, dass das Geschlecht doch als Differenzierungsfaktor verwendet wird. Algorithmen müssen also so konzipiert werden, dass rechtliche Besonderheiten ausreichend berücksichtigt werden. Grundsätzlich müssen Unternehmen deshalb sicherstellen, fehlerhafte oder unzulässige Schlussfolgerungen aus ihren Modellen durch hinreichende Kontroll- und Transparenzmechanismen zu vermeiden.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Wie sollte aufsichtlich und regulatorisch darauf reagiert werden, dass Unternehmen durch die Nutzung von BDAI die Konsumentenrente maximal abschöpfen könnten?
 - Wie könnten Verbraucher stärker für die Bedeutung und Werthaltigkeit ihrer Finanzdaten sensibilisiert werden?
 - Wie kann durch einen ganzheitlichen aufsichtlichen und regulatorischen Ansatz gewährleistet werden, dass neben den Vorteilen einer besseren Risikoeinschätzung durch BDAI der Zugang zu erschwinglichen Finanzprodukten auch für die Kundengruppen hinreichend erhalten bleibt, die der Algorithmus aussortiert?
 - Wie kann aufsichtlich sichergestellt werden, dass künftig auch die Kunden Zugang zu Finanzdienstleistungen haben, die nicht in der Lage oder bereit sind, ihre Daten über das gesetzlich erforderliche Maß hinaus freizugeben?
 - Welche Kontroll- und Transparenzmechanismen könnten Finanzdienstleistern helfen, die Diskriminierung von Verbrauchergruppen zu verhindern?
 - Wie könnten bereits existierende Methoden zur Vermeidung von Diskriminierung auf (teil-)automatisierte Prozesse übertragen werden?
 - Welche technischen Maßnahmen sollten Finanzdienstleister ergreifen, um eine Diskriminierung zu vermeiden, z.B. eine Diskriminierung auf Basis eines unerlaubten Differenzierungsfaktors (vgl. Kapitel 3.5.5 zu nichtdiskriminierender Datenanalyse)?
 - Wie kann verhindert werden, dass BDAI-Algorithmen Merkmale, die dem Finanzdienstleister nicht bekannt sind oder die er per Gesetz nicht abfragen darf, ungewollt über die Approximation eines Merkmals zu einer Diskriminierung genutzt werden?
-

6.2.3.2 Souveränität der Verbraucher

Vertrauen in den Finanzmarkt sicherstellen – Kooperation mit Datenschutzbehörden könnte zunehmen

| Auch in Zeiten verstärkter BDAI-Nutzung muss gewährleistet sein, dass Verbraucher berechtigterweise darauf vertrauen können, dass sie auf dem Finanzmarkt fair und korrekt behandelt werden. Die Gewährleistung von Privatsphäre und informationeller Selbstbestimmung sind wesentliche Voraussetzungen für nachhaltiges Vertrauen. Werden Kundendaten missbraucht, kann dadurch das Vertrauen in einzelne Unternehmen geschädigt werden. Dieser Vertrauensverlust kann auch auf ganze Marktsegmente übergreifen. Es liegt zwar in der Verantwortung von Datenschutzbehörden, die Umsetzung der Datenschutzvorgaben zu überwachen. Häufen sich jedoch Verstöße gegen den Datenschutz, können Missstände entstehen, die auch Implikationen für die Finanzaufsicht haben. Die Kooperation von Finanzaufsichts- und Datenschutzbehörden könnte also zunehmend an Bedeutung gewinnen.

Souveränität der Verbraucher als Katalysator für Vertrauen in BDAI-Innovationen | Durch BDAI-Anwendungen nimmt die Komplexität der Datennutzung zu, wodurch die Selbstbestimmung der Verbraucher gefährdet wird. Der Verbraucher muss souverän darüber entscheiden können, ob er BDAI-basierte Finanzdienstleistungen in Anspruch nehmen und eine gegebenenfalls erforderliche Datenfreigabe erteilen möchte. Eine souveräne Entscheidung kann er nur treffen, wenn er angemessen über die potenzielle Reichweite und die Konsequenzen der Nutzung seiner Daten aufgeklärt wird, wenn er die Datennutzung verlässlich kontrollieren kann und wenn er tatsächlich Wahlfreiheit hat. Diese Voraussetzungen muss der Anbieter gewährleisten. Auch Finanzdienstleister sind verpflichtet, ihren Kunden die nach der EU-DSGVO zustehenden Rechte einzuräumen, wie beispielsweise das Löschen oder Ändern personenbezogener Daten. Im Sinne einer hinreichenden Verbraucheraufklärung wird es nicht genügen, dem Verbraucher unverständliche und komplizierte Nutzungsbedingungen zur Verfügung zu stellen, welche meist ungelesen akzeptiert werden. Wer das Vertrauen der Verbraucher erhalten will, muss sie angemessen und verständlich über die Nutzung ihrer Daten informieren.

Der (empfundene und faktische) Druck, Daten freizugeben, könnte steigen | Laut Umfragen (Factsheet Data Protection Eurobarometer) haben viele Verbraucher den Eindruck, dass sie beispielsweise bei Online-Dienstleistungen keine Kontrolle mehr über ihre Daten hätten (vgl. Kapitel IV). Viele äußern zudem, dass sie oft keine andere Möglichkeit sähen, als ihre Daten bereitzustellen, wenn sie bestimmte Dienstleistungen in Anspruch nehmen wollen. Sollten für Finanzdienstleistungen durch die Nutzung von BDAI künftig noch mehr Daten angefordert werden als ohnehin schon, könnte der (empfundene und faktische) Druck auf Verbraucher steigen, ihre Daten bereitzustellen, etwa um einen Kredit zu angemessenen Konditionen zu erhalten und um eine Versicherung zu bezahlbaren Prämien abschließen zu können.

Gewährleistung von Wahlfreiheit durch Bereitstellung datensparsamer Produkte | In diesem Zusammenhang stellt sich die Frage, wie genau Aufsicht und Regulierung die angemessene Wahlfreiheit der Verbraucher auch in Zeiten von BDAI adressieren sollten. Denkbar wäre etwa, dass Aufsicht und Regulierung sicherstellen, dass Verbrauchern stets auch hinreichend datensparsame bzw. konventionelle Finanzdienstleistungen als Alternativen angeboten werden, damit kein faktischer Zwang zur Datenfreigabe erzeugt werden kann. Wie Datensparsamkeit bzw. Konventionalität in diesem Kontext zu definieren sind und um welche Finanzdienstleistungen es sich handeln sollte, wäre zu erörtern.

Technische Möglichkeiten zur Verwendung von BDAI mit anonymisierten Daten | Insgesamt lassen sich viele BDAI-Innovationen auch mit Hilfe hinreichend pseudonymisierter bzw. anonymisierter Daten kreieren, sodass über technische Datenschutzmaßnahmen (z.B. Privacy-preserving-Data-Mining) Innovationen auch ohne den Rückgriff auf persönliche Daten ermöglicht werden. Durch ein Privacy-by-design-Konzept kann also das Verbrauchervertrauen in BDAI-Innovationen zusätzlich gestärkt werden. Ferner könnten Anbieter, die BDAI nutzen, weitere innovative Ansätze erproben und implementieren, um Vertrauensschutz im Umgang mit persönlichen Daten zu ermöglichen. Beispielsweise wäre der Einsatz der Blockchain- bzw. Distributed Ledger Technologie denkbar.

Daraus abgeleitet ergeben sich folgende Leitfragen:

- Wie können technische Datenschutzmaßnahmen wie z.B. Privacy-preserving-Data-Mining am besten dazu beitragen, das Verbrauchervertrauen zu stärken und zugleich das BDAI-Potential zu nutzen?
 - Sollten Aufsicht und Regulierung sicherstellen, dass datensparsame/konventionelle Finanzdienstleistungen als Alternativen angeboten werden? Wie wäre Datensparsamkeit/Konventionalität in diesem Kontext zu definieren und um welche Finanzdienstleistungen sollte es dabei gehen?
-

6.3 Gesamtgesellschaftlicher Rahmen

Meinung

In Zeiten fortschreitender Digitalisierung, von Big Data und Artificial Intelligence ist es auch für Aufsichtsbehörden wie die BaFin eine Herausforderung, auf der Höhe der Zeit zu sein und zu bleiben. Dies gilt besonders im Hinblick auf die rasanten Entwicklungen in diesen Themenfeldern.



Beatrice Freiwald

BaFin-Exekutivdirektorin
Innere Verwaltung und
Recht

Die Aufsicht kann sich eine Schwachstelle auf diesem Gebiet nicht erlauben, und es wird immer wichtiger für sie, BDAI-Know-how aus- und aufzubauen: im Umgang mit den Unternehmen und Anbietern des Finanzmarktes ebenso wie für ihre Aufsichtsprozesse. Die BaFin muss also ihre Beschäftigten entsprechend (weiter-)qualifizieren und bei der Auswahl neuen Personals darauf achten, möglichst viel BDAI-Wissen zu gewinnen. Für Behörden ist es zwar nicht immer einfach die richtigen Talente zu gewinnen und zu halten. Was aber für die BaFin als Arbeitgeberin spricht, sind die vielfältigen anspruchsvollen Aufgaben, deren internationale Bezüge und die Möglichkeit, früh Verantwortung zu übernehmen, seine Ideen einzubringen und die Weiterentwicklung der Aufsicht mitzugestalten.

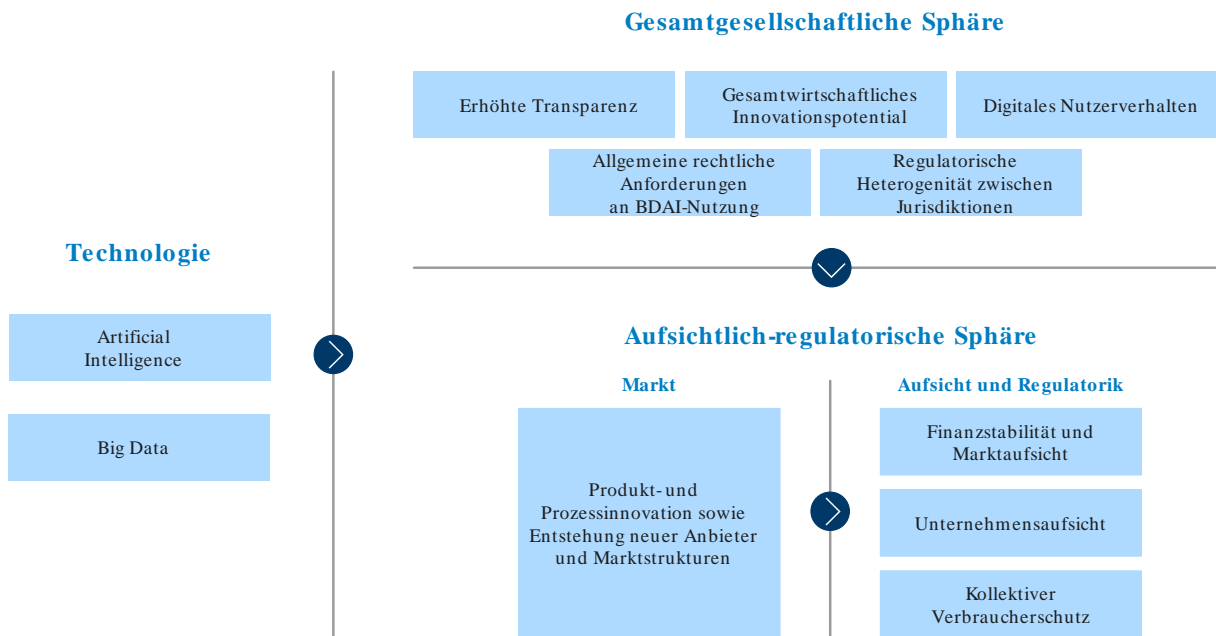
Auch die Aufsicht wird in BDAI-gestützte Verfahren investieren müssen. BDAI hat das Potenzial, die klassischen Aufsichtsprozesse qualitativ zu verbessern, sodass beispielsweise Muster schneller erkannt werden können.

Effektivitäts- und Effizienzsteigerungen sind im Zuge der allgemeinen Digitalisierung allerdings vor allem bei standardisierbaren Prozessen denkbar. Aufsicht ist und bleibt dagegen ein hoch flexibler Prozess, bei dem die Bewertung komplexer Sachverhalte im Vordergrund steht. Diese Abwägungsprozesse im Rahmen von diffizilen Ermessensentscheidungen prägen eine qualitativ hochwertige Aufsicht. Mehr Standardisierung bedeutet oft auch eine Einschränkung der Flexibilität. Ob und wie BDAI diesen Konflikt auflösen kann, muss sich erst noch zeigen.

Die Nutzung von BDAI hat wie oben bereits geschildert gesamtgesellschaftliche Bedeutung und wirft auch jenseits der Finanzaufsicht und -regulierung wichtige Fragen auf. Beispielsweise könnte es zu einer strukturellen Transformation der Wirtschaft kommen, die auch mit einem signifikanten Arbeitsplatzabbau einhergehen könnte. Dies könnte wiederum Auswirkungen auf beaufsichtigte Unternehmen haben. Die im vorherigen Kapitel hergeleiteten möglichen Implikationen für Aufsicht und Regulierung sind daher in den Kontext der gesamtgesellschaftlichen Auswirkungen des Einsatzes von BDAI einzubetten.

Im Folgenden sollen deshalb die wesentlichen gesellschaftlichen Diskussionsfelder skizziert werden, die mit der Nutzung von BDAI in der Finanzdienstleistungsbranche einhergehen.

Abbildung 28: Einbettung der aufsichtlich-regulatorischen BDAI-Effekte in den gesamtgesellschaftlichen Kontext



Erhöhte Transparenz | BDAI kann zu einer erhöhten Transparenz des Marktes und seiner Teilnehmer (Unternehmen und Verbraucher) beitragen⁴⁷⁷. So können Anbieter den Kundennutzen mit neuen, innovativen Angeboten erhöhen, weil sie durch BDAI mehr über die ökonomische Situation und die Präferenzen von Verbrauchern wissen. Andererseits können Unternehmen, wie oben geschildert, mit Hilfe von BDAI durch individualisierte und situative Preisgestaltung die Konsumentenrente stärker abschöpfen. Auf einem Markt mit hinreichendem Wettbewerb stünden allerdings (standardisierte) Vergleichsmöglichkeiten und eine hohe Auswahl an anderen Angeboten zur Verfügung, wenn sie den Verbrauchern etwa über Plattformen zugänglich gemacht würden und unabhängig wären.

Gesamtwirtschaftliches Innovationspotential | BDAI erlaubt Effizienz- und Effektivitätssteigerungen in vielen unternehmerischen und gesellschaftlichen Bereichen. Das damit einhergehende Innovationspotential bei Prozessen und Produkten könnte auch die Realwirtschaft ankurbeln und darüber hinaus sogar positive externe Effekte mit sich bringen. So kann eine höhere Verfügbarkeit und bessere Auswertung von Daten dazu beitragen, gesamtgesellschaftliche Risiken und Schäden einzudämmen. Ein Beispiel in diesem Sinne sind Telematik-Angebote von Versicherungsunternehmen. Die mit Telematik-Versicherungstarifen eventuell einhergehende Schadensprävention kann – etwa bei der Kraftfahrtversicherung – Unfälle verhindern und so zur allgemeinen Risiko- bzw. Schadensminderung beitragen.

⁴⁷⁷ Dies gilt jedoch nicht für alle Marktteilnehmer gleichermaßen, da es davon abhängig ist, ob dem Marktteilnehmer BDAI-Anwendungen zugänglich sind, die erhöhte Transparenz erzeugen. Denkbar ist, dass die Transparenz für Verbraucher durch die Zunahme von Anbietern tendenziell auch abnehmen kann, wenn ihnen keine entsprechenden BDAI-Werkzeuge zugänglich sind, die Transparenz erzeugen.

Digitales Nutzerverhalten | Die Analyse von digitalem Nutzerverhalten erfolgt oft durch den Zugriff auf persönliche Daten bzw. Daten, die Rückschlüsse auf individuelle Eigenschaften von Verbrauchern zulassen. Diese Daten sind häufig ein wesentlicher Bestandteil BDAI-basierter Innovationen und Dienstleistungen. Zugleich können die aus dem digitalen Nutzerverhalten ableitbaren Informationen das Verhalten des einzelnen Verbrauchers beeinflussen und seine Freiheit einschränken. Die zunehmende und vielfältigere Datengenerierung und -bereitstellung kann es für viele Verbraucher erschweren einzuschätzen, welche Daten ein Unternehmen vorhält, wie es sie auswertet und wer sonst noch Zugriff auf diese Daten hat. Verbraucher könnten sich gezwungen sehen, ihr Verhalten anzupassen.

Allgemeine rechtliche Anforderungen an BDAI-Nutzung | Eine zentrale Frage in der politisch-legislativen Diskussion lautet, wie und wo Algorithmen eingesetzt werden sollen und können und welche Anforderungen an ihre Entwickler und Verwender gestellt werden müssten. Auf nationaler wie auf europäischer Ebene gibt es hierzu diverse Initiativen.⁴⁷⁸ Unabhängig von den finanzmarktspezifischen Fragen müssten die allgemeinen Anforderungen an BDAI-Nutzung, die sich aus diesen Vorstößen ergeben, auch im Finanzmarkt berücksichtigt werden. Ein Beispiel für die Festlegung rechtlicher Anforderungen an BDAI könnte die Nachweisführung bei Gerichtsverfahren in Fällen sein, in denen es um Entscheidungen bzw. Handlungen geht, die auf Algorithmen basieren. Die prozessuale Beweisführung wird durch die hohe Komplexität algorithmenbasierter Verfahren vor neue Herausforderungen gestellt. Das gilt insbesondere, wenn eine schriftliche Nachweisführung erforderlich ist.

Regulatorische Unterschiede zwischen Jurisdiktionen | Während die Auswirkungen BDAI-basierter Geschäftsmodelle in den verschiedenen Staaten vergleichbar zu sein scheinen, können Regulierungs- und Aufsichtspraxis immer noch von Land zu Land unterschiedlich sein. Dadurch verschärft sich die Gefahr von Aufsichtsarbitrage. Das Phänomen BDAI macht es umso wichtiger, grenzüberschreitend eine gleichwertige Regulierung und vergleichbare Aufsichtspraktiken zu vereinbaren – getreu dem Motto „gleiches Geschäft, gleiches Risiko, gleiche Regel“. Dies gilt es für den gesamten Wirkungskreis von BDAI auch künftig zu gewährleisten – vor allem im Rahmen neuer Marktstrukturen. Zugleich müssen die Besonderheiten nationaler Märkte auch künftig angemessen berücksichtigt werden.

⁴⁷⁸ Beispielsweise fordert das Europäische Parlament die Europäische Kommission auf, einen Vorschlag für eine unionsweite Begriffsbestimmung von cyber-physischen Systemen, autonomen Systemen, intelligenten autonomen Robotern und deren Unterkategorien festzulegen und ein europäisches Registrierungssystem anzulegen; siehe Entschließung des Europäischen Parlaments vom 16. Februar 2017 mit Empfehlungen an die Kommission zu zivilrechtlichen Regelungen im Bereich Robotik (2015/2103(INL)). Der Sachverständigenrat für Verbraucherfragen, ein Beratungsgremium des Bundesministeriums der Justiz und für Verbraucherschutz, empfiehlt eine Rechtsvorschrift zu Algorithmen, um den Vorgaben des Verbraucherrechts, des Datenschutzrechts, des Anti-Diskriminierungsrechts und der digitalen Sicherheit zu entsprechen; siehe Digitale Souveränität. Gutachten des Sachverständigenrats für Verbraucherfragen (2017).

VII. Anhang

7.1 Detaillierte Beschreibung der Verfahren des maschinellen Lernens

Im Folgenden wird das maschinelle Lernen aus der inhaltlichen Perspektive beschrieben, also mit Blick auf eine Lernaufgabe. Dazu werden die wichtigsten Lernaufgaben, deren Unterschiede und Einsatzgebiete erläutert.

Begleitendes Beispiel

Um die einzelnen Algorithmen, Verfahren sowie die Lernaufgaben besser verstehen zu können, wird nachfolgend innerhalb der Exkurse ein vereinfachtes Beispiel verwendet, das unterschiedliche Lernaufgaben und damit die Anwendung unterschiedlicher Verfahren zulässt. Das Beispiel beschreibt mögliche Fragen, die in Bezug auf eine Kfz-Versicherung von Interesse sein können.


Bei der ersten Frage soll im Rahmen der Kündigungsprävention vorhergesagt werden, ob ein Versicherungsnehmer seinen Vertrag kündigen wird, ob er eine Kündigung in Betracht zieht, sich aber durch entsprechende Gegenmaßnahmen des Unternehmens davon abhalten lässt, oder ob er nicht zur Kündigung neigt. Es soll also, basierend auf historischen Kundenentscheidungen, für neue Situationen eine der drei genannten Klassen vorhergesagt werden. Für die Modellierung muss zunächst festgestellt werden, welche Faktoren einen potenziellen Einfluss auf den Versicherungsnehmer haben und ihn zur Kündigung bewegen können. Zur Vereinfachung werden in diesem Beispiel nur die Dauer der Schadenfreiheit in Jahren sowie die Kilometerleistung des Fahrzeugs pro Jahr betrachtet. Allerdings können auch auf den ersten Blick eher unscheinbare Faktoren wie zum Beispiel Wetterdaten und Twitter-Feeds die Entscheidung eines Versicherungsnehmers beeinflussen.

Für eine zweite Frage wird angenommen, dass die erwartete Höhe eines Versicherungsschadens in Euro vorhergesagt werden soll. Im Gegensatz zur ersten Frage sollen hier demnach keine festen Klassen, sondern eine numerische Variable modelliert werden. Zur Vereinfachung wird hier nur ein Merkmal zur Vorhersage berücksichtigt, nämlich das Alter des Fahrzeugs in Jahren.

7.1.1 Überwachtes Lernen (Supervised Learning)

Überwachte Lernverfahren werden oft verwendet, um Beispiele in bestimmte Kategorien oder Klassen einzuordnen (Geldwäsche erkennen, Kreditwürdigkeit einordnen und in Bildern Gegenstände und Personen erkennen). Solche Aufgaben bezeichnet man als Klassifikationsaufgaben. Abbildung 29 stellt eine solche Aufgabe für die erste Frage des begleitenden Beispiels dar, in der die Kündigungsklasse für einen Kunden einer Kfz-Versicherung vorhergesagt werden soll. Ein geeignetes Verfahren lernt also zunächst die Klassifikation basierend auf den Datenpunkten mit bekannten Labels (Kreise) und sagt dann die Label für unbekannte Daten (Quadrate) vorher.

Abbildung 29: Darstellung der Klassifikation neuer Datenpunkte (Quadrate) anhand der Label bekannter Datenpunkte (Kreise) für den skizzierten Datensatz am Beispiel der Vorhersage der Kündigungsklasse



Bekannte Klassifikationsverfahren sind zum Beispiel Entscheidungsbäume, Support Vector Machines, Feed-forward Neuronale Netze und die logistische Regression, die nachfolgend in Exkursen näher erläutert werden. Erläutert werden auch die Regressionsverfahren der linearen Regression und der Support Vector Regression.

Um die richtigen Lernverfahren auswählen zu können, müssen die entsprechenden Annahmen der Verfahren geprüft und die Typen der Merkmale untersucht werden. Kann z.B. eine lineare Regression nur kontinuierliche Merkmale berücksichtigen und vorhersagen, so kann eine Varianzanalyse auch eine Mischung aus kontinuierlichen und kategorischen Merkmalen zur Schätzung verwenden.

Exkurs: Entscheidungsbaum-Lernen


Ein bekanntes Beispiel für ein überwachtes Lernverfahren, das zur Klassifikation genutzt werden kann, ist das Entscheidungsbaum-Lernen⁴⁷⁹. Ein Entscheidungsbaum stellt eine Abfolge von Entscheidungsfragen bereit, mit denen eine Frage beantwortet werden kann. Um die Antwort zu erhalten, wird am Wurzelknoten gestartet, von dem aus der Baum dann von oben nach unten durchlaufen wird. An jedem Knoten wird, je nach Ausprägung eines bestimmten Merkmals, entschieden, welcher weitere Weg im Baum verfolgt wird. Am Ende wird dann ein Blatt erreicht, das die Antwort auf die Frage enthält.

⁴⁷⁹ Quinlan 1993, C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers Inc., San Francisco.

Das Entscheidungsbaum-Lernen besteht nun darin, einen möglichst guten Entscheidungsbaum automatisch anhand gelabelter Daten zu lernen. Dazu werden für einen Datensatz alle in Frage kommenden Entscheidungen getestet, wobei für nominale Merkmale jeweils nur einzelne Merkmale mit einem festen Wert verglichen werden (z.B. „Wochentag = Montag“) und für numerische Merkmale nur einzelne Merkmale mit festen Schwellwerten (z.B. „Börsenpreis < 250 Euro“). Anhand eines statistischen Maßes wird dann bewertet, mit welcher Entscheidung das Label am besten vorhersagbar ist. Anschließend wird dann rekursiv auf Basis der so entstandenen Teil-Datensätze jeweils ein Unter-Entscheidungsbaum für die Verfeinerung der Prognose gelernt.

Wird wieder der oben skizzierte Datensatz betrachtet, so kann die Aufgabe, anhand der Schadenfreiheit in Jahren und der Kilometerleistung pro Jahr die Kündigungsklasse vorherzusagen, mit Hilfe eines Entscheidungsbaums beantwortet werden. Wie in Abbildung 30 gezeigt, würde ein Baum mit zwei Regeln ausreichen, um einen neuen Datenpunkt eindeutig in eine der drei Kündigungsklassen einzuordnen. Die erste Regel fragt danach, ob die Kilometerleistung pro Jahr über oder unter 100.000 km liegt. Liegt sie darunter, so handelt es sich um die Klasse „Keine Kündigung“. Liegt sie darüber, entscheidet die Schadenfreiheitsgrenze von zehn Jahren, ob der Versicherungsnehmer voraussichtlich kündigt oder noch von der Kündigung abgehalten werden kann.

Abbildung 30: Möglicher Entscheidungsbaum mit zugehörigen Regeln, der für das skizzierte Beispiel genutzt werden könnte, um aus Kilometerleistung und Schadensfreiheit den Kündigungsstatus vorherzusagen.




Ausgehend vom Basialgorithmus des Entscheidungsbaum-Lernens existieren viele Weiterentwicklungen. So können Entscheidungsbäume zum Beispiel angepasst werden, um auch Regressionsaufgaben zu lösen. Aufgrund ihrer Einfachheit und Effizienz dienen Entscheidungsbäume auch häufig als Basis für Ensemble-Methoden, die mehrere einfache Modelle kombinieren, um auf diese Weise komplexere oder robustere Modelle lernen zu können. Ein Beispiel dafür sind Random Forests, die zunächst viele möglichst unkorrelierte Bäume erzeugen, indem zufällig Elemente aus der Trainingsmenge gezogen werden, anhand deren dann der Baum aufgrund von zufällig ausgewählten Merkmalkombinationen erstellt wird. Für die Vorhersage werden die Vorhersagen der einzelnen Bäume dann gemittelt. Eng verwandt mit dem Entscheidungsbaum-Lernen ist das Regellernen, bei dem statt Bäumen eine Menge einzelner Wenn-Dann-Regeln gelernt wird.

Exkurs: Support Vector Machine

Die Support Vector Machine⁴⁸⁰ (Stützvektormaschine, SVM) ist ein häufig genutztes Klassifikationsverfahren. Die Idee dieses Verfahrens ist, dass es die Trennlinie zwischen den Klassen so setzt, dass ihr Abstand zu beiden Klassen möglichst groß ist. Dadurch wird die Klassifikation robust gegen Rauschen. Da sich dieses Verfahren nur schwer für die Trennung von drei Klassen erklären und darstellen lässt, wird hier vereinfacht angenommen, dass nur zwei Kündigungsklassen vorhergesagt werden sollen. Dazu werden die Kündiger und die zurückgewonnenen Kündiger zu einer Klasse zusammengefasst, nämlich zu den Versicherungsnehmern, die versuchen zu kündigen. Sollen diese Daten, wie in Abbildung 31 gezeigt, mit einer SVM klassifiziert werden, lege das Verfahren die Trennlinie, wie gezeigt, zwischen die zwei Gruppen.

Abbildung 31: Mögliches Ergebnis einer SVM angewandt auf den skizzierten Datensatz, wenn die Datenpunkte anhand der Kündigungsklasse getrennt werden sollen



In der einfachsten Version der SVM werden die Daten mittels einer linearen Trennlinie – mathematisch auch Hyperebene genannt – klassifiziert. Wenn sich die Objekte nicht linear trennen lassen, wird der Kern-Trick angewandt, bei dem mittels einer Transformationsfunktion die Datenobjekte in einen höher-dimensionalen Raum überführt werden, in dem sie dann durch eine lineare Hyperebene getrennt werden können. Dieser Ansatz wird dadurch effizient, dass diese Transformation nicht explizit berechnet werden muss. Durch die Rücktransformation entsteht eine nicht-lineare Trennebene. Vorteile dieses Verfahrens sind eine hohe Flexibilität und eine sehr gute theoretische Fundierung.⁴⁸¹

⁴⁸⁰ Cortes et al., 1995, Support–vector networks. In: Machine Learning Journal, 20, S. 273–297.

⁴⁸¹ Vapnik 1998, Statistical Learning Theory. John Wiley & Sons, Inc.

Exkurs: Neuronale Netze

Eine aktuell sehr populäre Klasse von Algorithmen sind die (künstlichen) neuronalen Netze⁴⁸². Arbeiten an neuronalen Netzen reichen bis in die 1950er Jahre zurück⁴⁸³ und nehmen ihre Inspiration aus der Funktionsweise des menschlichen Gehirns. Die kleinste Einheit eines neuronalen Netzes, ein Neuron, wird dabei mathematisch durch eine Funktion dargestellt, die einen Vektor numerischer Eingaben mit linearen Gewichten multipliziert und dann mit einer nicht-linearen Aktivierungsfunktion transformiert. Einzelne Arten von Neuronen unterscheiden sich durch eine Vielzahl möglicher Aktivierungsfunktionen. Der Vektor von Gewichten entspricht dem vom Neuron zu lernenden Modell. Ein neuronales Netz entsteht nur daraus, dass einzelne Neuronen auf unterschiedliche Arten gekoppelt werden, die Ausgaben einzelner Neuronen also wieder als Eingaben weiterer Neuronen dienen.

Die Art, wie die Neuronen miteinander gekoppelt sind, nennt man die Architektur des Netzes. Diese kann unterschiedlich tief und komplex sein. Eines der einfachsten neuronalen Netze ist das einlagige Feed-Forward-Netz, bei dem die im Input Layer hereingegebenen Informationen über ein Hidden Layer (d.h. eine Menge von Neuronen mit derselben Eingabe, aber unterschiedlichen Gewichten) zum Output Layer prozessiert werden. Das Output Layer gibt am Ende die Klassifizierung aus. Das Training des neuronalen Netzes, d.h. das Einstellen der einzelnen Gewichte, geschieht durch eine mathematische Optimierung. Während das Training der Netze sehr rechenzeitintensiv ist, kann die Anwendung der Netze in Echtzeit erfolgen. Abbildung 32 zeigt eine mögliche Verwendung eines einlagigen Feed-forward-Netzes für die Klassifikation der Kündigung im skizzierten Datensatz.


Zum Lernen wird die Methode der Back-Propagation eingesetzt, bei der die Ausgabeentscheidungen mit den tatsächlich richtigen Antworten verglichen werden, um einen Fehler der Ausgabe zu berechnen. Diese Fehlerwerte werden dann zurück in das Netzwerk gegeben, wodurch der Algorithmus die Gewichte an jedem Knoten adjustiert. Nach einigen Durchläufen konvergiert ein solches Netzwerk generell so, dass die Vorhersagefehler gering sind.

Im Vergleich zu vielen anderen Verfahren können neuronale Netze auch komplexe Entscheidungen treffen und damit auch Grenzen setzen, die keinen bestimmten Strukturaufgaben unterliegen. Zudem sind neuronale Netze auch auf Basis sehr großer Datenmengen effizient trainierbar. Zu ihren Nachteilen zählt eine geringe Transparenz der Modelle.

⁴⁸² Bishop, 1995, Neural networks for pattern recognition. Clarendon Press.

⁴⁸³ Rosenblatt, 1958, The perceptron - a probabilistic model for information storage and organization in the brain. In: Psychological Review, 65, S. 386 – 408.

Abbildung 32: Mögliche Verwendung eines einlagigen Feed-forward neuronalen Netzes, um für den skizzierten Datensatz die Kündigung für neue Versicherungsnehmer zu klassifizieren.



Exkurs: Logistische Regression

Die logistische Regression gehört – trotz ihres Namens – zu den Klassifikationsverfahren. Im Unterschied zu anderen Verfahren wird hierbei aber nicht nur die Vorhersage der Klasse, sondern die Wahrscheinlichkeit der Klassenzugehörigkeit eines Beispiels gelernt. Von „logistischer Regression“ spricht man, weil für dieses Verfahren technisch ein Regressionsansatz genutzt wird. Dabei werden die Werte der Merkmale mit Koeffizienten multipliziert und zu einem Score aufaddiert. Aus diesem Score wird anhand einer mathematischen Funktion die Wahrscheinlichkeit für den Wert des Labels berechnet. Sind die erklärenden Merkmale selbst Klassen, z.B. unterschiedliche Berufsgruppen, erhält man pro Klasse einen Score.


Aufgrund ihrer Einfachheit und hohen Transparenz wird die logistische Regression häufig in der Finanzdienstleistungsindustrie eingesetzt, etwa in Bonitätsmodellen (Ausfallwahrscheinlichkeit) und in der Betrugserkennung. Oft nehmen Experten sogar manuelle Korrekturen vor – insbesondere für Fälle, die selten in den Daten vorkommen, oder für eine gezielte Auf- oder Abwertung im Geschäftsinteresse. Diesen unstrittigen Vorteilen steht gegenüber, dass die Modellgüte der logistischen Regression häufig gegenüber den oben dargestellten nichtlinearen Verfahren deutlich abfällt.

Exkurs: Lineare Regression

Eine wichtige Anwendung von Regressionsaufgaben liegt in der Prognose etwa von Risiken, Produktnachfragen und optimalen Preisen. Ein sehr häufig genutztes Verfahren dafür ist die lineare Regression. Dort wird ein Label y durch ein lineares Modell basierend auf einer oder mehreren Eingabemerkmale erklärt. Man unterscheidet also zwischen einem univariaten Modell mit nur einem Eingabemerkmale x und einem multivariaten Modell mit mehreren Eingabemerkmale x_1, x_2, \dots, x_n . Ein univariates Modell wird durch die Gleichung $y = m \cdot x + b$ beschrieben, wo m die Stärke des Einflusses von x auf y beschreibt und b eine Konstante darstellt. Für das oben genannte Beispiel und die zweite Frage könnte also der Versicherungsschaden in Euro in Abhängigkeit vom Alter des Fahrzeugs in Jahren modelliert werden, wie in Abbildung 33 gezeigt wird.


Vorteile der linearen Regression sind ihre Einfachheit und die Tatsache, dass sich erfahrungsgemäß gerade bei hochdimensionalen Daten auch nicht-lineare Abhängigkeiten gut durch eine geeignete lineare Funktion annäherungsweise bestimmen lassen. Nachteil ist die mangelnde Flexibilität, wenn die Daten anders verteilt sind.

Abbildung 33: Mögliches Ergebnis einer linearen Regression für den skizzierten Datensatz, die den Versicherungsschaden abhängig vom Alter des Fahrzeugs modelliert



Exkurs: Support-Vector Regression


Abbildung 34: Mögliches Ergebnis einer Support-Vector-Regression für den skizzierten Datensatz. Durch den maximal erlaubten Fehler entsteht eine obere und untere Schranke, innerhalb deren die meisten Beispiele liegen



Die Support-Vector-Regression⁴⁸⁴ erweitert die Idee der Support Vector Machine auf die Regression. Anstatt eine lineare Funktion zu finden, die zwei Klassen mit möglichst breitem Abstand trennt, wird die mathematisch sehr ähnliche Aufgabe gelöst, eine möglichst einfache Funktion zu finden, die das Label mit einem vorgegebenen maximalen erlaubten Fehler genau trifft. Der Vorteil der Support Vector Regression liegt darin, dass mit dem oben beschriebenen Kern-Trick wiederum sehr einfach eine nicht-lineare Funktion gelernt werden kann. Des Weiteren ist die dahinterliegende Theorie genau wie bei der Support Vector Machine gut erforscht. Der Nachteil ist eine hohe Laufzeit bei der Anwendung auf große Datenmengen.

⁴⁸⁴ Drucker et al., 1997, Support Vector Regression Machines, In: Advances in Neural Information Processing Systems 9, S. 155 - 161.

Abbildung 35: Mögliches Ergebnis einer Support-Vector-Regression für den skizzierten Datensatz. Durch den maximal erlaubten Fehler entsteht eine obere und untere Schranke, innerhalb deren die meisten Beispiele liegen.



7.1.2 Unüberwachtes Lernen (Unsupervised Learning)


Beim unüberwachten Lernen werden mit unterschiedlichen Verfahren intrinsische Muster aus den Daten extrahiert. Im Unterschied zum überwachten Lernen liegt hier also keine Frage vor, die sich in ein konkretes Zielmerkmal kodieren lässt. Zwei der wichtigsten Lernaufgaben im unüberwachten Lernen sind das Clustering und die Anomalieerkennung – zum Beispiel zur Datenqualitätssicherung.

7.1.2.1 Beispiel k-Means-Clustering

Eines der bekanntesten Clustering-Verfahren ist das k-Means-Clustering, bei dem eine Beispielmenge von Datenpunkten in eine vorgegebene Zahl von k Clustern unterteilt wird. Cluster werden jeweils durch ihren Mittelpunkt (den Zentroid) und eine Abstandsfunktion definiert, d.h. ein Punkt gehört zu dem Cluster, zu dessen Mittelpunkt er am nächsten ist. Zunächst werden üblicherweise k zufällige Clusterzentren gewählt und die einzelnen Datenpunkte werden dann dem Clusterzentrum zugewiesen, zu dem sie jeweils am nächsten liegen. Für die sich daraus ergebenden Cluster werden anschließend die tatsächlichen Zentren berechnet, und die Datenpunkte werden erneut dem nächsten Zentrum zugeteilt. Dieser Schritt wird so lange wiederholt, bis sich die Einteilung der Punkte in die k Cluster nicht mehr ändert.

Für das oben genannte Beispiel zeigt Abbildung 36 zwei mögliche Clustering-Ergebnisse für $k = 2$ (links) und $k = 3$ (rechts), wenn die Schadenfreiheit in Jahren (y-Achse) und die Kilometerleistung pro Jahr (x-Achse) betrachtet wird:

Abbildung 36: Mögliche Clustering-Ergebnisse durch k-Means für $k = 2$ (links) und $k = 3$ (rechts) vorgegebene Cluster.



Das k-Means-Clustering ist ein sehr leistungsfähiges Verfahren und wird häufig eingesetzt. Der Nachteil ist allerdings, dass die Ergebnisse sehr stark von der Merkmalsauswahl und den Parametern abhängen, die der Data Scientist auswählen kann. Es sind daher sehr viele verschiedene Ergebnisse möglich. Außerdem ist dieses Verfahren nicht in der Lage, überlappende Gruppen sauber zu trennen.


7.1.2.2 Beispiel Anomalieerkennung

Ein prominenter Ansatz zur Anomalieerkennung setzt darauf, zuerst die Struktur des Großteils der Daten zu erkennen – etwa durch Clustering und einfache statistische Verteilungsannahmen – und dann Punkte zu finden, die dieser Struktur nicht folgen. Sie stellen somit die Hypothese auf, was „normal“ ist und damit zusammengehört und was von der geschätzten Normalität abweicht. Ein zweiter Ansatz besteht darin, direkt Funktionen zu definieren, die den Grad der Abweichung eines Datenpunktes bewerten.

Im k-Nearest-Neighbor-Verfahren zur Anomalieerkennung wird etwa der Abstand eines Beispiels zu seinem nächsten Nachbarn (bzw. allgemein der Abstand zum k-nächsten Nachbarn) als Maß der Abweichung definiert. In Abbildung 37 ist beispielsweise der markierte Punkt anhand beider Ansätze eine Anomalie: Weder passt er zum Muster der drei Cluster, noch liegt er nahe an seinem nächsten Nachbarn.

Nachteil der Anomalieerkennung ist, dass die Ergebnisse oft nicht intuitiv sind. Zwar scheint Anomalieerkennung für einen zweidimensionalen Fall für den Menschen eine einfache Aufgabe zu sein, tatsächlich ist sie aber für höhere Dimensionen äußerst kompliziert.

Abbildung 37: Möglicher Ausreißer im skizzierten Datensatz (markiert in rot), der durch Anomalieerkennung identifiziert werden könnte



7.2 Zusammenfassung der Papiere der europäischen Aufsichtsbehörden und des Financial Stability Boards

Diese Studie schließt an eine Reihe von Veröffentlichungen zu den Themen Big Data, Advanced Analytics und Artificial Intelligence in der Finanzdienstleistungsbranche an, die in jüngerer Zeit von führenden Institutionen aus den Bereichen Regulatorik und Aufsicht vorgelegt wurden. Für die Einordnung der vorliegenden Studie sind die Berichte des Financial Stability Board, des Joint Committee of the European Supervisory Authorities, des Basel Committee on Banking Supervision und der European Banking Authority besonders hervorzuheben. Das Thema Big Data in der Finanzbranche haben zudem die europäischen Institutionen (Europäisches Parlament und EU-Kommission) aufgegriffen.⁴⁸⁵ Die Inhalte dieser Veröffentlichungen werden im Folgenden zusammenfassend dargestellt.

Tabelle 1: Aufsichtlich-regulatorische Berichte zu Big Data und Artificial Intelligence

| Institution | Titel des Berichts | Veröffentlichung |
|--|--|-------------------------|
| Joint Committee of the European Supervisory Authorities | Final Report on Big Data | März 2018 |
| Financial Stability Board | Artificial intelligence and machine learning in financial services. Market developments and financial stability implications | November 2017 |
| Basel Committee on Banking Supervision | Sound Practices: Implications of fintech developments for banks and bank supervisors (Konsultationspapier) | August 2017 |
| European Banking Authority | Discussion Paper on the EBA's approach to financial technology (FinTech) | August 2017 |
| Financial Stability Board | Financial Stability Implications from FinTech. Supervisory and Regulatory Issues that Merit Authorities' Attention | Juni 2017 |

Joint Committee: Final Report on Big Data (März 2018)

Das Joint Committee of the European Supervisory Authorities (ESAs)⁴⁸⁶ hat einen Bericht zu Big Data veröffentlicht.⁴⁸⁷ Hierin wird das Feedback der Stakeholder zu einem Diskussionspapier zur Nutzung von Big Data durch Finanzdienstleister ausgewertet, welches das Joint Committee im Dezember 2016 veröffentlicht hatte.⁴⁸⁸ In dem Bericht werden potenzielle Vorteile und Risiken des Gebrauchs von Big Data durch

⁴⁸⁵ Siehe European Parliament, 2016, Report on FinTech: the influence of technology on the future of the financial sector (2016/2243(INI)); European Commission, 2017, Consultation Document FinTech: A more competitive and innovative European financial sector; European Commission, 2017, Assessment of current and future impact of Big Data on Financial Services. Online verfügbar: https://ec.europa.eu/info/sites/info/files/file_import/1606-big-data-on-financial-services_en_0.pdf, abgerufen am 16.11.2017. European Banking Authority, 2017, Discussion Paper on the EBA's approach to financial technology (FinTech), S. 9 ff. Online verfügbar: <https://www.eba.europa.eu/-/eba-publishes-a-discussion-paper-on-its-approach-to-fintech>, abgerufen am 16.11.2017.

⁴⁸⁶ European Banking Authority (EBA), European Insurance and Occupational Pensions Authority (EIOPA), European Securities and Markets Authority (ESMA).

⁴⁸⁷ Vgl. Joint Committee of the European Supervisory Authorities, 2018, Final Report on Big Data. Online verfügbar: <https://esas-joint-committee.europa.eu/Publications/Reports/Final%20Report%20on%20Big%20Data.pdf>, abgerufen am 25.04.2018.

⁴⁸⁸ Vgl. European Securities and Markets Authority, 2016, Discussion Paper on the Use of Big Data by Financial Institutions. Online verfügbar: <https://www.esma.europa.eu/press-news/consultations/joint-committee-discussion-paper-use-big-data-financial-institutions>, abgerufen am 07.11.2017.

Finanzdienstleister bewertet, die sich im Wesentlichen mit den im Diskussionspapier getroffenen Aussagen decken. Der Bericht enthält keine Empfehlung, gesetzgeberisch aktiv zu werden. Begründung: Die bestehenden rechtlichen Anforderungen in den relevanten Bereichen (Datenschutz, Internetsicherheit, Verbraucherschutz sowie sektorspezifische Finanzgesetzgebung) bilden einen bereits recht soliden Rahmen zur Risikominimierung.

Dieser Rahmen werde durch die Anwendung weiterer wichtiger Rechtsvorschriften (z.B. IDD⁴⁸⁹, MiFID II, PSD2 bzw. DSGVO) weiter gestärkt. Die Auswirkungen dieser neuen Vorschriften soll durch die ESAs beobachtet und evaluiert werden.

Um der Entwicklung von Big Data weiter gerecht zu werden, sollen die Aufseher weiter koordiniert zusammenarbeiten, damit alle relevanten Vorschriften eingehalten werden. Die ESAs regen zudem an, dass Finanzinstitute good practices für die Nutzung von Big Data implementieren (robuste Big-Data-Prozesse und Algorithmen, Verbraucherschutz und Offenlegung der Verwendung von Big Data).

Der finale Bericht wurde zusammen mit einem Verbraucherinformationsblatt (Verwendung von Big Data durch Finanzinstitute) veröffentlicht⁴⁹⁰, das die wesentlichen Botschaften in einfacher Sprache zusammenfasst, um das Bewusstsein der Verbraucher für die Chancen und Risiken von Big Data zu schärfen.

Financial Stability Board (FSB): Artificial intelligence and machine learning in financial services. Market developments and financial stability implications (November 2017)

Das Financial Stability Board hat im November 2017 einen Bericht zu Artificial Intelligence und maschinellem Lernen im Kontext von Finanzdienstleistungen publiziert.⁴⁹¹ Der Schwerpunkt der Analyse und Bewertung liegt auf Implikationen für die Finanzstabilität.⁴⁹² Der Bericht nutzt Anwendungsbeispiele von Finanzdienstleistern, um über die neuen Technologien zu diskutieren. Zu den sich schnell ausweitenden Anwendungsfeldern gehören aus Sicht des FSB Betrugserkennung, Kapitaloptimierung und Portfoliomanagement. Zugleich hebt der Bericht hervor, dass die aktuelle Datengrundlage noch nicht ausreicht, um die Auswirkungen von AI und maschinellem Lernen abschließend zu bewerten.

Das FSB stellt fest, dass durch AI und ML Effizienzsteigerungen im Finanzsystem möglich seien. Darüber hinaus könnten auch Regulatory Technology (RegTech) und Supervisory Technology (SupTech) zu einer verbesserten regulatorischen Compliance beitragen. Netzwerk- und Skaleneffekte könnten jedoch dazu führen, dass systemrelevante Akteure außerhalb des regulierten Sektors entstehen. Neue Muster der Interdependenz zwischen Finanzmarkt und Finanzinstituten aufgrund neuer Datenkorrelationen würden zudem bislang unerwartete Herausforderungen auf. Aus aufsichtlicher und regulatorischer Perspektive betont das FSB zudem die Schwierigkeiten, die durch intransparente Modelle für die Interpretierbarkeit und die aufsichtliche Beurteilung entstünden. Es seien daher entsprechende Kompetenzen und Fähigkeiten erforderlich, um die neuen komplexen AI- und ML-Ansätze zu verstehen und zu überwachen. Zudem ist aus Sicht des FSB die Einhaltung relevanter Vorgaben im Bereich Datenschutz, Verhaltensrisiken und Cybersicherheit essenziell.

⁴⁸⁹ Versicherungsvertriebsrichtlinie (Insurance Distribution Directive).

⁴⁹⁰ Siehe European Securities and Markets Authority, 2018, Verwendung von Big Data durch Finanzinstitute. Online verfügbar: https://www.esma.europa.eu/sites/default/files/library/big_data_factsheet_de.pdf, abgerufen am 25.04.2018.

⁴⁹¹ Siehe Financial Stability Board, 2017, Artificial intelligence and machine learning in financial services. Market developments and financial stability implications. Online verfügbar: <http://www.fsb.org/2017/11/fsb-considers-financial-stability-implications-of-artificial-intelligence-and-machine-learning/>, abgerufen am 06.11.2017.

⁴⁹² In zwei Anhängen geht das FSB zudem auf „Legal issues around AI and machine learning“ und „AI ethics“ ein. Darin werden auch die Themen Datenschutz und Datensouveränität im Kontext von Artificial Intelligence und maschinellem Lernen betrachtet.

Basel Committee on Banking Supervision (BCBS): Sound Practices: Implications of fintech developments for banks and bank supervisors (August 2017)

In Anbetracht steigender Investitionen in Fintechs und des dadurch erwarteten Wandels in der Finanzbranche hat das BCBS eine Taskforce eingesetzt, um zu untersuchen, welche Bedeutung Fintechs für Aufsichtsbehörden und Banken haben. In dem Konsultationsdokument „Sound Practices“⁴⁹³ hat das BCBS seine Ergebnisse vorgestellt. Darin werden fünf Szenarien für die Entwicklung des Bankenmarktes identifiziert und daraus Empfehlungen für Aufsichts- und Regulierungsbehörden abgeleitet. Die Szenarien basieren auf der Annahme, dass es für Banken angesichts des technologischen Wandels und sich ändernder Kundenerwartungen immer schwieriger wird, ihre Geschäftsmodelle aufrechtzuerhalten. Ein wesentliches Thema wird aus Sicht des BCBS der Wettbewerb um die Kundenbeziehungen sein. Das BCBS geht davon aus, dass die aktuellen technologischen Veränderungen disruptivere Wirkungen haben werden als frühere Innovationen. Zentrale Faktoren dafür seien die schnelle Annahme von Fintech-Dienstleistungen und niedrigere Eintrittsbarrieren.

European Banking Authority (EBA): Discussion Paper on the EBA’s approach to financial technology (FinTech) (August 2017)

Auch die Europäische Bankenaufsichtsbehörde hat 2017 ein Konsultationspapier zum Thema Fintech herausgegeben.⁴⁹⁴ Darin legt die EBA die Resultate einer Bestandsaufnahme des europäischen Fintech-Sektors vor, die sie in Zusammenarbeit mit nationalen Aufsichtsbehörden durchgeführt hat. Auf Basis der Ergebnisse hat die EBA eine Reihe von Themen ermittelt, für die sie weitere Analysen und Maßnahmen für erforderlich hält. In ihrem Konsultationspapier schlägt die EBA folgende Bereiche vor: Autorisierungs- und Sandboxing-Regime; prudenzielle Risiken für Kreditinstitute, Zahlungsinstitute und E-Geld-Institute; die Auswirkungen von Fintechs auf die Geschäftsmodelle von Finanzinstituten; Verbraucherschutz und Geschäftsverhalten im Privatkundengeschäft; die Auswirkungen von Fintechs auf die Abwicklung von Finanzinstituten sowie auf die Bekämpfung der Geldwäsche und der Terrorismusfinanzierung.

Financial Stability Board: Financial Stability Implications from FinTech. Supervisory and Regulatory Issues that Merit Authorities’ Attention (Juni 2017)⁴⁹⁵

Gegenwärtig – so das vorläufige Fazit – bestehe keine Gefährdung der Finanzstabilität durch Fintech-Innovationen. Das FSB stellt jedoch zehn Aspekte heraus, denen Regulierungs- und Aufsichtsbehörden besondere Aufmerksamkeit widmen sollten. Auch hierbei betont das FSB, dass es weiterhin wichtig sei, besser zu verstehen, wie Geschäftsmodelle von Start-ups und etablierten Finanzdienstleistern durch Fintech tatsächlich beeinflusst werden.

⁴⁹³ Siehe Bank for International Settlements, 2017, Sound Practices: Implications of fintech developments for banks and bank supervisors. Basel Committee on Banking Supervision. Online verfügbar: <https://www.bis.org/bcb/publ/d415.htm>, abgerufen am 16.11.2017.

⁴⁹⁴ Siehe European Banking Authority, 2017, Discussion Paper on the EBA’s approach to financial technology (FinTech). Online verfügbar: <https://www.eba.europa.eu/-/eba-publishes-a-discussion-paper-on-its-approach-to-fintech>, abgerufen am 16.11.2017.

⁴⁹⁵ Financial Stability Board, 2017, Financial Stability Implications from FinTech. Supervisory and Regulatory Issues that Merit Authorities’ Attention. Online verfügbar: <http://www.fsb.org/wp-content/uploads/R270617.pdf>, zuletzt eingesehen am 07.11.2017.

Ein übergreifendes Thema im FSB-Bericht ist die internationale Kooperation. Hierzu nennt das FSB drei prioritäre Handlungsfelder für Regulatorik und Aufsicht: das Management von Risiken durch Drittanbieter, die Minderung von Cyberrisiken und das Monitoring von makroökonomischen Risiken. Weitere relevante Themen aus Sicht des FSB sind offene Fragen zu grenzüberschreitenden Angeboten, die eingeschränkte Nachvollziehbarkeit von Big-Data-Modellen, Agilität und Flexibilität des regulatorischen Rahmens, die Zusammenarbeit von privatem und öffentlichem Sektor sowie der Ausbau der Kommunikation und des Austauschs zwischen Regulierungs- und Aufsichtsbehörden. Das FSB weist auch auf die Notwendigkeit hin, Kapazitäten und Expertise aufzubauen, um die durch Fintechs ausgelösten Entwicklungen adäquat adressieren zu können. Zudem schlägt das FSB vor, die Implikationen digitaler Währungen näher zu untersuchen.