

SENACOR

Smart Retail Banking

Potentiale und Herausforderungen Künstlicher Intelligenz

Eine praxisorientierte Studie

Verfassende:

Gilbert Fridgen, Prof. Dr. (Universität Luxemburg SnT)

Marc-Fabian Körner (Universität Bayreuth, Projektgruppe Wirtschaftsinformatik des Fraunhofer FIT)

Vadim Răgo (Universität Luxemburg SnT)

Werner Steck, Dr. (Senacor Technologies AG)

Alexander Stohr (Projektgruppe Wirtschaftsinformatik des Fraunhofer FIT)

Christian Wolfangel (Senacor Technologies AG)



Disclaimer

Die vorliegende, praxisorientierte Studie wurde vom Interdisciplinary Center for Security, Reliability and Trust der Universität Luxemburg, der Projektgruppe Wirtschaftsinformatik des Fraunhofer-Instituts für Angewandte Informationstechnik FIT und der Senacor Technologies AG nach bestem Wissen und unter Einhaltung der entsprechenden Sorgfalt erstellt.

Das Interdisciplinary Center for Security, Reliability and Trust der Universität Luxemburg, die Projektgruppe Wirtschaftsinformatik des Fraunhofer-Instituts für Angewandte Informationstechnik FIT, die Senacor Technologies AG, bzw. ihre gesetzlichen Vertreter und/oder Erfüllungsgehilfen übernehmen keinerlei Garantie dafür, dass die Inhalte dieser Studie gesichert, vollständig, für bestimmte Zwecke brauchbar oder in sonstiger Weise frei von Fehlern sind. Die Nutzung dieser Studie geschieht ausschließlich auf eigene Verantwortung.

In keinem Fall haften das Interdisciplinary Center for Security, Reliability and Trust der Universität Luxemburg, die Projektgruppe Wirtschaftsinformatik des Fraunhofer-Instituts für Angewandte Informationstechnik FIT, die Senacor Technologies AG, ihre gesetzlichen Vertreter und/oder Erfüllungsgehilfen für jegliche Schäden, seien sie mittelbar oder unmittelbar, die aus der Nutzung der Studie resultieren.

Smart Retail Banking – Potentiale und Herausforderungen Künstlicher Intelligenz

Vorwort	4
Executive Summary	5
Zielstellung und Vorgehensweise der Studie	6
Grundlagen künstlicher Intelligenz	8
Künstliche Intelligenz als Begriff	8
Teilbereiche von Künstlicher Intelligenz	12
Grenzen von Künstlicher Intelligenz	16
Relevante Trends im Bankensektor	20
Digitalisierung der Kundenschnittstelle	20
Regulatorische Entwicklungen	23
KI-Einsatz im Retail Banking: Ergebnisse der Interviews	27
Use Cases in Banken – bisher hinter den Möglichkeiten	27
Kooperationen mit FinTechs als möglicher Ausweg	33
Handlungsprämissen für den Erfolg von KI-Projekten	34
Literaturverzeichnis	40
Über die Verfassenden	44
Impressum	46

Vorwort

Die Digitalisierung und die damit verbundene, zunehmende Durchdringung von Wirtschaft und Gesellschaft mit digitalen Technologien stellt Unternehmen vor die Herausforderung, ihre Geschäftsmodelle fortlaufend zu hinterfragen und die Potenziale neuer Technologien bestmöglich zu nutzen, um innovative Geschäftsmodelle zu ermöglichen. Eine dieser Technologien, die zuletzt durch den zunehmenden Einzug in den öffentlichen Diskurs, in strategische Regierungsagenden und auch geschäftliche Überlegungen hohe Aufmerksamkeit erregt hat, ist Künstliche Intelligenz (KI). Der Einsatz von KI kann zu Veränderungen oder sogar zu einer radikalen Neudefinition von Wertschöpfungspfaden führen und verspricht die Generierung erheblichen Geschäftswertes. Um diesen Veränderungen jedoch gerecht zu werden, müssen Unternehmen ihre Struktur, ihre Prozesse und ihre Kultur kontinuierlich hinterfragen und gegebenenfalls neu denken.

Diese Veränderungen machen auch vor dem Bankensektor keinen Halt. Gerade Retailbanken sehen sich durch die fortschreitende Digitalisierung der Kundenschnittstelle sowie der neuen Zahlungsdiensterichtlinie PSD2 zunehmend auch Wettbewerb außerhalb des Bankensektors ausgesetzt. Um langfristig relevant zu bleiben, müssen die Banken ihr Wertversprechen gegenüber den Kundinnen und Kunden neu denken. Innovative KI-Anwendungen können dabei helfen, setzen jedoch eine ganzheitliche Transformation der Banken voraus, die sich über mehrere Ebenen der Organisation erstreckt.

Durch einen intensiven Austausch mit Expertinnen und Experten aus der Bankenbranche, bankennahen IT-Dienstleistern und FinTechs haben wir den Status-quo von KI-Projekten im Retail Banking beleuchtet und leiten Handlungsprämissen ab, die unseres Erachtens für den Erfolg von KI-Projekten im Retail Banking unabdingbar sind. Wir hoffen, Ihnen mit unserer Studie Einblicke und Denkanstöße zum wertschaffenden, sinnvollen Einsatz von KI im Retail Banking zu geben.

Wir wünschen Ihnen viel Spaß bei der Lektüre und laden Sie ein, mit uns in einen Dialog zu treten. Gerne stehen wir Ihnen für Fragen, Diskussionen und Anregungen zur Verfügung.



Prof. Dr. Gilbert Fridgen
PayPal-FNR PEARL Chair in
Digital Financial Services,
SnT-Interdisciplinary Center for
Security, Reliability and Trust,
Universität Luxemburg



Dr. Werner Steck
Partner
Senacor Technologies AG



Christian Wolfangel
Partner
Senacor Technologies AG

Executive Summary

Künstliche Intelligenz (KI) zählt derzeit zu den prominentesten digitalen Technologien und verspricht in Zukunft erheblichen Geschäftswert zu generieren. Es wird erwartet, dass KI einen Großteil der heute existierenden Branchen beeinflussen wird bzw. das bereits tut. Das gilt entsprechend auch für den Bankensektor. Im Vordergrund sollte dabei jedoch nicht nur die technologische Weiterentwicklung stehen, sondern insbesondere der wertschaffende, sinnvolle Einsatz von KI-Anwendungen. Ein entsprechendes Wertversprechen ist gerade im Retail Banking an der Kundenschnittstelle unabdingbar.

Für die vorliegende Studie wurden 22 Expertinnen und Experten aus der Bankenbranche in wissenschaftlich fundierten, qualitativen Interviews befragt. Die Studie vermittelt ein umfangreiches Verständnis der Grundlagen von KI sowie des heutigen Stadiums von KI-Projekten im deutschen Retail Banking und zeigt Handlungsfelder auf, um das Potenzial von KI zukünftig sinnvoll nutzen zu können.

Die Auswertung zeigt, dass Projekte zu KI im Retail Banking bisher nur langsam initiiert werden. Gründe hierfür liegen u.a. in den über Jahre hinweg aufgebauten technischen Schulden der Banken, insbesondere in Form von inflexiblen Altsystemen, sowie Datenschutzbedenken in Bezug auf die Nutzung von personenbezogenen Daten. Infolgedessen schaffen es die Banken bisher nicht, die Vorteile von KI-Anwendungen an ihre Kundinnen und Kunden zu kommunizieren, beziehungsweise diese notwendigen Vorteile zu schaffen.

Für innovative KI-Anwendungen, die grundsätzlich an den Produkten einer Bank ansetzen, müssen die Banken ihr Wertversprechen neu denken und die Entwicklung von Technik und Business Cases integriert vorantreiben. Auf dem Weg zum „KI-basierten Bankenökosystem“ dient dabei der use-case-getriebene Ausbau der Infrastruktur als Zwischenziel. Für den Erfolg der entsprechenden KI-Projekte ist deshalb die Zusammenarbeit zwischen Business und IT sowie eine fortlaufende Auseinandersetzung mit compliancerechtlichen Fragestellungen entscheidend. Während Outsourcing nur selten Vorteile aufweist, können die Banken durch strategische Kooperationen mit FinTechs das entsprechende Know how zur Umsetzung von KI-Projekten aufbauen bzw. Zugang zu relevanter Technologie schaffen.

Zielstellung und Vorgehensweise der Studie

Künstliche Intelligenz (KI) ist bereits seit einigen Jahren Bestandteil zahlreicher, teils kontroverser Diskussionen in Wissenschaft und Praxis; auch die Bankenbranche setzt sich bereits mit einer Vielzahl an Einsatzmöglichkeiten auseinander: Geldwäscheerkennung, gezieltere Ansprache von Kundinnen und Kunden oder verbesserte Kreditvergabe sind dabei nur einige Optionen. Der wertschaffende Einsatz von KI stellt dabei jedoch auch erhebliche Anforderungen an das Datenmanagement und Know-how in Banken.

Die vorliegende Studie soll den aktuellen Stellenwert von KI im deutschen Retail Banking erfassen und dabei beantworten, mit welchen Maßnahmen Banken KI-Projekte zum Erfolg führen können. Im ersten Teil der Studie werden dazu relevante Grundlagen von KI vorgestellt. Der zweite Teil der Studie skizziert notwendige Entwicklungen und Handlungsoptionen für einen wertschöpfenden Einsatz von KI in der Branche. Ihre Erkenntnisse leiten die Autoren dabei aus im Rahmen der Studie geführten Interviews ab. Für die Auswertung der Interviews, welche die Autoren der Studie mit 22 Expertinnen und Experten (vgl. Tabelle 1) aus der Branche geführt haben, wurde ein qualitativer Ansatz gewählt: Wissenschaftlichen Standards entsprechend, basieren die Interviews dabei auf einem von den Autoren entwickelten, semistrukturierten Leitfaden. Die Expertinnen und Experten gaben dabei eine Einschätzung zur Relevanz und zu Besonderheiten von KI-Anwendungen im Bankensektor ab, berichteten von persönlichen Erfahrungen in KI-Projekten und schätzten die weitere Entwicklung in der Branche ein.

Für das klassische Retail Banking wurden Expertinnen und Experten der DACH-Region interviewt, die entweder selbst im Retail Banking arbeiten oder einen direkten Bezug zu Retailbanken haben. In ihrer überwiegend leitenden Position waren und sind sie maßgeblich an Entscheidungen zur Anwendung von KI im entsprechenden Kontext oder an der konkreten Umsetzung von Projekten beteiligt. Eine weitere Perspektive wurde durch die Befragung von FinTechs des Luxemburgischen FinTech-Hubs LHoFT gewonnen.

Art des Unternehmens	Rolle
Bonusprogram	Founder
Direktbank	Bereichsleitung
Direktbank	Bereichsleitung
Direktbank	Vorstandsmitglied IT
Finanzberatung	Vorstandsmitglied IT
FinTech	Co-Founder
FinTech	Co-Founder
FinTech	CEO
FinTech	Founder
FinTech Hub	Co-Founder
IT-Dienstleistung	Data Scientist
IT-Dienstleistung	Leitung Entwicklung
IT-Dienstleistungl	Founder
IT-Dienstleistung	CPO
IT-Dienstleistung	Country Management
IT-Dienstleistung	Partner
IT-Dienstleistung	Partner
Spezialbank	Data Scientist
Startup-Finanzierung	Data Scientist
Universalbank	Managing Director
Universalbank	Leitung Retail
Universalbank	Leitung Vertrieb

Tabelle 1: Übersicht der Interviewpartner

Grundlagen künstlicher Intelligenz

Künstliche Intelligenz als Begriff

Künstliche Intelligenz (KI) wird sowohl in der Praxis als auch in der Wissenschaft nicht als einheitlicher und klar abgegrenzter Begriff verwendet. So definieren zum Beispiel Rai et al. (2019) KI als die Fähigkeit von Maschinen, kognitive Funktionen auszuführen, welche mit dem menschlichen Verstand assoziiert werden. Dazu gehören unter anderem Wahrnehmung, logisches Denken, Interaktion mit der Umwelt, Entscheidungsfindung oder sogar Kreativität. Eine etwas technischere Definition liefern Kaplan und Haenlein (2019), die KI als Fähigkeit von Systemen definieren, externe Daten korrekt zu interpretieren, darauf basierend zu lernen und durch das Gelernte spezifische Ziele und Aufgaben flexibel zu erreichen. Stone et al. (2016) beschreiben KI generalistischer, nämlich als denjenigen Teilbereich der Informatik, der sich mit der Automatisierung von Intelligenz beschäftigt.

KI beschränkt sich nach den genannten Definitionen nicht auf eine oder mehrere Anwendungen, sondern ist vielmehr ein wirtschaftliches, gesellschaftliches und organisationales Phänomen, welches Menschen in einer Vielzahl an Lebensbereichen direkt betrifft (Berente et al. 2019). Gleichzeitig ist KI jedoch nicht als technologisches Allheilmittel zu verstehen: Neben einer Vielzahl an Einsatzmöglichkeiten entstehen weitreichende Herausforderungen für Geschäftsmodelle, Mensch-KI-Interaktionen, Datenschutz/-sicherheit und auch Arbeitgebende/-nehmende.

Trotz neuer Wertschöpfungsmöglichkeiten ist KI kein neues Konzept: Bereits in den 1950er Jahren wurde der Begriff *Artificial Intelligence* (englisch für KI) erstmalig verwendet (siehe Infobox für eine kurze Übersicht der KI-Entwicklung seither). Erst die Verfügbarkeit an großen Datenmengen und die Entwicklung von Rechenleistung führte aber zu einer tatsächlichen Anwendbarkeit von KI – auch und vor allem im wirtschaftlichen Kontext.

50er – Erstmalige Nennung des Begriffes Künstliche Intelligenz

1950: Der Turing-Test sollte beantworten, wie man die Intelligenz einer KI überprüfen kann. Eine KI war demnach dann erreicht, wenn der Mensch bei einem elektronischen Frage-Antwort-Austausch nicht zwischen Menschen und KI unterscheiden können.

1956: Erste wissenschaftliche Konferenz zu KI fand statt; Prägung des Begriffs „Künstliche Intelligenz“. Entwicklung der KI-Anwendung „LOGIC THEORIST“, die 38 mathematische Theoreme beweisen konnte.

60er-70er – Wenige Fortschritte und erster KI-Winter

1957-1965: Erste Versuche von Sprachverarbeitung scheiterte, da die Semantik von Sprache vernachlässigt wurde.

1965-1975: Der erste, so genannte KI-Winter brach an: wenige Fortschritte konnten erzielt werden, dazu bezog sich die Forschung nur auf künstliche Mikrowelten. Der erster Chatbot wurde schließlich 1966 entwickelt (ELIZA, Anwendung Psychotherapie).

80er – Theorie von Neuronalen Netzen ohne Anwendungen

Anfang 1980er: Mathematische Modelle zu Neuronalen Netzen wurden in Computern umgesetzt, hatten jedoch nicht genügend Trainingsdaten; zudem waren Computer nicht leistungsstark genug.

1986: Erstes autonomes Auto Navlab wurde gebaut.

90er – Rechenleistung schlägt menschliche Leistung

1997: Sieg von Deep Blue gegen den damaligen Schachweltmeister Garry Kasparov (mit optimiertem Brute Force Verfahren).

2010er – Durchbruch von künstlichem Lernen

2011: Sieg von IBM Watson bei einem TV-Quiz, Nutzung von natürlicher Sprache für Datenbanksuchen.

2016: Sieg von AlphaGo Lee gegen den Go-Weltmeister Lee Sedol.

2017: AlphaZero schlägt nach 9 h Training das stärkste Schachprogramm sowie nach 8 h AlphaGo Lee.

2018: Eine speziell hierfür entwickelte AI (Rid 2019) übertrifft bei der Melanom-Entdeckung mit einer Trefferrate von 95% menschliche Leistungen (86,6%).

2020: Veröffentlichung der Sprach-KI GPT-3, welche in der Lage ist, englischsprachigen Text zu beliebigem Kontext zu produzieren. Die Qualität der Texte ist so hoch, dass sie von menschlichen Texten kaum unterscheidbar sind.

Infobox: Künstliche Intelligenz ist keine neue Technologie

Auch aufgrund einer bislang fehlenden, klaren Definition von KI fällt es der Wissenschaft aktuell noch schwer, KI-(verwandte)-Konzepte eindeutig zuzuordnen bzw. zu kategorisieren. Eine erste Möglichkeit der Kategorisierung bietet dabei folgende Übersicht, die Leistungen von Maschinen zum einen menschlichen und zum anderen rationalen Referenzen zuordnet:

	Mensch als Referenzleistung	Rationalität als Referenzleistung
Denkprozesse & Schlussfolgerung	Menschliches Denken Kognitive Modellierung z.B. Haugeland (1985), Belmann (1978)	Rationales Denken Denkgesetze z.B. Charniak und McDermott (1985), Winston (1992)
Verhalten	Menschliches Handeln Turing Test Ansatz z.B. Kurzweil (1990), Rich und Knight (1991)	Rationales Handeln Rationaler Agent z.B. Poole et al. (1988), Nilsson (1998)

Quelle: Russel und Norwig (2016)

Abbildung 1: Unterscheidung verschiedener Ansätze von KI

Menschliches Denken als Referenz bedeutet beispielsweise, dass die Maschine weitestgehend nah an den Denkmustern von Menschen lernt, wahrnimmt und mit der externen Umwelt interagiert. Das Vorbild für das kognitive Modell ist dabei das menschliche Gehirn, inklusive der Fähigkeit, Emotionen zu modellieren. Dagegen verhält sich die Maschine beim rationalen Handeln nach klaren Regeln der Logik (bspw. regelbasiert oder auch einen Wert minimierend, wie zeitlichen Aufwand).

Vor allem von menschlichem Handeln sind aktuelle KI-Algorithmen deutlich entfernt. Auch der Versuch das menschliche Denken/Gehirn in seiner Gänze mit Algorithmen nachzubilden und menschliches Denken somit zu simulieren, scheint bisher eher Science-Fiction als Realität. Dennoch gibt es bereits Versuche, dies zumindest für Teilbereiche des Gehirns Realität werden zu lassen. Rationalität wiederum bedeutet in diesem Kontext, dass die Maschine unter gegebenen Umständen und Informationen ideal agiert (rationales Handeln) oder logische Schlussfolgerungen zieht (rationales Denken). Besonders letzteres ist schwierig umzusetzen: Informelles Wissen kann nicht ohne Weiteres in eine Notation gebracht werden, die durch Logik gefordert wird (Russell et al. 2016).

Die Idee einer KI, die unabhängig von der Problemstellung ähnlich eines Menschen eine Lösung erarbeitet und eine Art Bewusstsein oder tieferes Selbstverständnis entwickelt, wird *starke KI-These* genannt. Hierbei wäre die KI in der Lage eine dem Menschen gleiche Referenzleistung zu erbringen. Allerdings

beschränken sich heute bereits realistische und konkrete Anwendungsfälle von KI auf die Simulation von rationalem Verhalten (die KI ist hier eine Art „Fachidiot/in“, vgl. Schneider (2018)). Die reine Simulation von rationalem Verhalten wird als *schwache KI-These* bezeichnet. Dabei zeigt sich, wie wenig eingrenzend entsprechende Konzepte sind: Der erste Sieg des von IBM entwickelten Schachcomputers *Deep Blue* gegen den damaligen Schachweltmeister Garri Kasparov im Jahr 1997 wird zwar als KI-Meilenstein genannt, gleichzeitig handelte es sich hier schlicht um ein heuristisches Brute-Force-Suchverfahren¹, bei dem viele Züge im Voraus berechnet wurden. Auch regelbasierte Anwendungen zählen demnach zu rationalem Handeln („wenn Ereignis A, dann Handlung B“), entsprechen jedoch nicht dem aktuellen KI-Verständnis in der Praxis.

KI wird in der Praxis mittlerweile vermehrt stellvertretend als Anwendung von lernenden Methoden verstanden, die eine Erfüllung von Funktionen auf eine neue Art und Weise ermöglichen. Ein ähnliches Verständnis hat auch die Bundesanstalt für Finanzdienstleistungsaufsicht (BaFin), die sich bei ihrer Studie zu Big Data und KI vor allem auf Maschinelles Lernen (oder auch englisch Machine Learning, ML) bezieht und auch auf das ML-Teilgebiet *Neuronale Netze* in Form von Deep Learning eingeht (BaFin 2018).

Abbildung 2 veranschaulicht relevante Begriffe aus dem KI-Kontext und ordnet sie in einem Verhältnis zueinander ein: KI ist ein umfassender Begriff, der sich vor allem auf Fähigkeiten von Maschinen bezieht. Machine Learning als Unterbereich beschreibt die konkrete Fähigkeit der Maschine, Wissen und Fähigkeiten aus Daten zu erlernen. Dafür können unter anderem Neuronale Netze eingesetzt werden, die in spezieller Form als Grundlage für Deep Learning fungieren. In dem folgenden Kapitel werden diese Begriffe genauer erläutert.




Abbildung 2: Einordnung von KI-Begriffen (angelehnt an Sze et al. 2017)

¹ Bei Brute-Force-Verfahren rechnet der Computer eine Variante bis zu einer bestimmten Tiefe durch und bewertet alle theoretisch möglichen Stellungen. Deep Blue hat dabei die Anzahl der zu bewertenden Stellungen reduziert und konnte das Verfahren somit effizienter anwenden.

Teilbereiche von Künstlicher Intelligenz

Machine Learning

Die Wissenschaft sieht Machine Learning (ML) als „Schlüsseltechnologie der Künstlichen Intelligenz“. ML beschreibt allgemein die Anpassung oder Änderung von Aktionen (Vorhersagen oder tatsächliche Aktionen von Rechnern), sodass diese präziser werden (Marsland 2015). Das „Lernen“ bezieht sich in diesem Fall häufig auf das Finden von statistischen Regelmäßigkeiten oder anderen Mustern in Datensätzen. Grundsätzlich werden drei Arten von ML unterschieden:




Abbildung 3: Drei Arten von Machine Learning

Beim **Supervised Learning** ordnet ein Algorithmus Eingangsdaten vordefinierten Kategorien zu; das heißt er *klassifiziert* diese Eingangsdaten (Ayodele 2010). Der Algorithmus wird dabei basierend auf Daten trainiert, die bereits korrekt beschriftet (bzw. kategorisiert) wurden. Das bedeutet, dass der Algorithmus ausschließlich vordefinierte Kategorien verwendet (daher auch *supervised*, der Mensch entscheidet über die Kategorien und der Algorithmus ordnet die Daten den Kategorien zu) und „lernt“ diese Kategorisierung auf beliebige andere Daten anzuwenden. Die Qualität des Verfahrens ist grundlegend von den vorab definierten Kategorien abhängig. Eine beispielhafte Anwendung im Banking ist die frühzeitige Erkennung von Kundenabwanderung: Basierend auf vergangenen Daten von abgewanderten Kundinnen und Kunden sowie von Stammkundinnen und -kunden (bspw. Transaktionsdaten, Produkte, Häufigkeit der Service-Nutzung) könnte eine Klassifizierung von aktuellen Kundinnen und Kunden zu „wechselbereit“ und „loyal“ vorgenommen werden. Bereits hier zeigt sich jedoch: Ein entsprechendes „KI-Projekt“ ist nicht mit der Entwicklung eines Algorithmus abgeschlossen; denn im weiteren Verlauf muss definiert werden, welche nächsten Schritte eingeleitet werden sollen, um wechselbereite Kundinnen und Kunden erneut bzw. besser zu binden.

Im Unterschied dazu ist es das Ziel von **Unsupervised Learning**, Muster aus großen Datensätzen zu extrahieren ohne bereits beschriftete Trainingsdaten vorliegen zu haben (Ghahramani 2004). Die Methode wird häufig für das so genannte *Clustering* verwendet: hierbei werden Teile der Daten automatisch gruppiert (die Gruppen stehen im Gegensatz zum Supervised Learning nicht fest), die Granularität der Gruppierung kann durch die Anwendenden bestimmt werden (bspw. Personen mit vergleichsweise hohem, mittlerem und niedrigem Einkommen). Aus Unsupervised Learning gewonnene Erkenntnisse können wiederum im Supervised Learning genutzt werden, um Kategorien für zukünftige Datensätze zu definieren. Im Vergleich zum Supervised Learning kann Unsupervised Learning gerade bei sehr großen und wenig untersuchten Datensätzen vorteilhaft sein. Ein klassisches Beispiel für Unsupervised Learning ist die Erkennung von missbräuchlichen Kreditkartentransaktionen: Dabei vergleicht der Algorithmus bisherige Transaktionen mit der zu Untersuchenden, um zu bestimmen, wie ungewöhnlich die Transaktion im Vergleich ist.

Die dritte ML Klasse, das **Reinforcement Learning**, basiert auf dem Trial and Error Prinzip: Der Algorithmus hat dabei die Möglichkeit, in einer bestimmten Umgebung (beispielsweise Börse) zu interagieren und versucht dabei die Erfolgsaussichten der eigenen Aktionen zu maximieren. Dies wird durch die Maximierung eines numerischen Signals erreicht, welches als „Belohnung“ (beispielsweise Rendite) den Erfolg des Algorithmus determiniert (Sutton und Barto 2018). Der Algorithmus ist dabei in der Lage, Veränderungen in der Umwelt festzustellen (bspw. durch Kursveränderungen), kann mit der Umwelt interagieren (bspw. durch den Kauf und Verkauf von Wertpapieren) und hat dabei ein Ziel bezüglich der Umweltzustandes. Somit sind *Sensation, Action und Goal* die drei Hauptbestandteile von Reinforcement Learning (Sutton und Barto 2018). Das Ergebnis von *Action* kann dabei beispielsweise von klassischen Bewertungsheuristiken insofern abweichen, dass sie diese übertrifft und dabei nicht nachvollziehbar ist. Der Algorithmus AlphaGo des KI-Unternehmens DeepMind (einem Tochter-Unternehmen von Alphabet) bewegte beispielsweise nach seinem erstmaligen Sieg gegen den Weltmeister Lee Sedol im Spiel Go ebendiesen zu folgender Aussage:

„Ich dachte, AlphaGo basierte auf der Berechnung von Wahrscheinlichkeiten und dass es nur eine Maschine war. Als ich diesen Zug sah, änderte ich meine Meinung. Zweifellos, AlphaGo ist kreativ.“ – Lee Sedol, 2016, Go-Weltmeister, über den Reinforcement Learning Algorithmus AlphaGo

Charlier et al. (2020) weisen darauf hin, dass Reinforcement Learning im Gegensatz zum Einsatz in Spielen mit festen Regeln im Finanzkontext bisher nur wenig Anwendung findet und beschreibt einen Use Case zur Reduzierung von Kundenabwanderung (engl. *Churn*): Dabei gewährt der Algorithmus den Kundinnen und Kunden individuelle Kreditkartenlimits oder Kredite, um risikominimal die Kundenabwanderungsquote zu reduzieren und die Rentabilität zu steigern (dies allerdings unabhängig von Regulatorik).

Neuronale Netze

Neuronale Netze (engl. *Neural Network*) sind eine mögliche Umsetzung von Machine Learning und können für alle drei ML Klassen verwendet werden. Dabei wird versucht, die Funktionsweise eines menschlichen Gehirns nachzubilden, indem Funktionen (Neuronen) in Schichten angeordnet werden. Die Eingangsschicht nimmt die Umgebung (oder eine Eingabe) auf, und Funktionen nachfolgender Schichten werden anschließend durch gewichtete Verbindungen zu vorhergehenden Schichten aktiviert (Schmidhuber 2015). Diese sehr allgemein gehaltene Definition zeigt bereits verschiedene „Bauteile“ eines Neuronalen Netzes, die individuell angepasst werden können (vgl. Wiedmann und Buckler 2003):

- Aufbau des Neurons: Hier können unterschiedliche Aktivierungsfunktionen genutzt werden (bspw. linear, stufenförmig etc.).
- Aufbau des Netzwerkes: Ein so genanntes *Feedforward Neural Network* ist eine der einfachsten Aufbauarten und wird daher häufig zur Visualisierung genutzt. Hierbei existieren nur vorwärtsgerichtete Verbindungen im Netzwerk; ein Neuron gibt Outputs demnach nur in die nachfolgende Schicht, nicht aber in vorherige Schichten (Fine 1999). Die *Reccurent Neural Networks* wiederum verbinden den Output eines Neurons zum Input, was zu einer Art Informations-Rückkopplung führt und dem Neuron ermöglicht, vergangene Eingangsdaten für den aktuellen Output zu nutzen (Siddique und Adeli 2013). Dies kommt dem menschlichen Konzept des Lernens sehr nahe und führt zur wesentlich höheren Leistungsfähigkeit von Recurrent Neural Networks im Vergleich zu den einfachen Feedforward Neural Networks (Fine 1999). Dies sind nur zwei mögliche Arten für einen Aufbau, Abwandlungen führen zu einer Vielzahl von Netzwerken².
- Lernverfahren: Hierbei wird aus den bereits beschriebenen ML-Konzepten die für die Problemstellung am besten passende gewählt.

Deep Learning

Deep Learning ist eine spezielle Form Neuronaler Netze. Es nutzt eine Vielzahl von neuronalen Schichten und wurde zu Beginn der 90er hauptsächlich in Verbindung mit Unsupervised Learning angewandt. Heute ist es auch für Reinforcement Learning relevant (Schmidhuber 2015). Drei Faktoren haben zum Durchbruch von Deep Learning geführt (Zhao et al. 2019):

- Um ein Deep Learning Modell so zu trainieren, dass seine Anwendbarkeit in der Praxis möglich ist, sind eine **große Mengen an Daten notwendig**. Gemäß Schätzungen steigt der weltweite Bestand an verfügbaren Daten, der 2018 noch 33 Zettabyte³ betrug, auf 175 Zettabyte im Jahr 2025 (Reinsel et al. 2018).

³ Ein Zettabyte entspricht einer Milliarde Terabytes.

- › Die für Deep Learning **notwendige Rechenleistung** kann mittlerweile durch Hardware bereitgestellt werden, die parallel eine erhebliche Anzahl an Rechenschritten bewältigt.
- › In den vergangenen Jahren kam es zu **erheblichen Verbesserungen von Deep Learning Algorithmen**, so dass diese zum einen immer effizienter wurden, und zum anderen verbesserte Trainingsergebnisse vorweisen können.

Die nachfolgende Abbildung verdeutlicht schematisch den Aufbau eines möglichen Neuronalen Netzes zur Bonitätsberechnung im Bankenkontext.

Ein Beispiel: Bankkundin Daniela (Abbildung 4) hat ein Eigenkapital von 120.000 Euro, einen positiven Schufa-Score und ist 35 Jahre alt. Bei der Bank selbst hat sie ein Zweitkonto, das bisher nicht überzogen wurde, und ein Depot mit einem regelmäßigen Sparplan. Aus diesen Informationen soll Danielas individuelle Bonität für einen beantragten Baukredit berechnet werden. Über zwei Zwischenschichten eines Deep Neural Networks wird die Bonität anhand vergangener Trainingsdaten berechnet⁴.




Abbildung 4: Einfaches Beispiel eines Deep Feedforward Neural Network zur Bonitätsberechnung

³ Wichtig hierbei: Dies ist in der Praxis so nicht anwendbar, da eine Erklärbarkeit des Modells fehlt. Die Berechnungen in den Zwischenschichten und somit die genaue Gewichtung einzelner Faktoren sind retrospektiv nicht mehr nachvollziehbar.

Grenzen von Künstlicher Intelligenz


Das Ziel, die Struktur und Funktion von Intelligenz zu entschlüsseln und diese Erkenntnisse dann zu nutzen, um weitere Problemstellungen zu lösen, wurde bereits 2016 von Googles KI-Unternehmen DeepMind ausgerufen (Simonite 2016). Dabei soll ein entsprechend entwickelter Algorithmus die Lösung jeder denkbaren Aufgabenstellung lernen, und so menschliche Intelligenz nachbilden. Unter diesem Eindruck sieht eine der Mitgründenden des US-amerikanischen Weiterbildungsanbieter Coursera KI gar „als neue Elektrizität“, die jede Branche verändern wird (Andrew Ng 2017). Diese fast glorifizierende Sicht auf KI wird von der Medienlandschaft häufig aufgegriffen und vermittelt das Bild einer revolutionären Technologie, die sämtliche Branchen und Geschäftsmodelle grundlegend verändern wird. Hierbei wird teilweise der Eindruck einer potenziell starken KI vermittelt, obwohl die im KI-Bereich erzielten Erfolge nach wie vor auf ML-Konzepten basieren.

Gleichzeitig liegen im gesamten ML-Bereich noch ganz grundlegende Problemstellungen vor, die auch bei verbesserten Algorithmen nicht so leicht beseitigt werden können. Eine wissenschaftliche Untersuchung zu aktuellen Unzulänglichkeiten haben Hagendorff und Wezel (2020) vorgenommen und dabei verschiedene Herausforderungen identifiziert, die sich in drei Teilbereiche untergliedern lassen: methodische (erkenntnistheoretische) Herausforderungen, gesellschaftlicher Kontext sowie technische Defizite.


Methodisch	Gesellschaftlich	Technisch
Verlust von Informationen durch Datenaggregation	Notwendiges Kontextwissen von Entwickelnden zur Branche	Modelle nach wie vor weit entfernt von starker KI
Daten beziehen sich nur auf die Vergangenheit	Bias bei der Beschriftung von Daten	Erklärbarkeit von Ergebnissen
	Fehlende Entwickelnde	Algorithmen sind sehr unflexibel
	Akzeptanz unter Kundinnen und Kunden sowie Mitarbeitenden	Abhängigkeiten von der Datenqualität (bei Supervised)
		Angriffsmöglichkeiten auf ML-Algorithmen

Tabelle 2: Ausgewählte Herausforderungen von Künstlicher Intelligenz nach Hagendorff und Wezel (2020)

Methodische Herausforderungen ergeben sich durch zwei Teilaspekte: Zum einen nutzt ML Daten, die bereits bei der Datensammlung in irgendeiner Form aggregiert oder verändert wurden. Hierbei ist es zwar das Ziel, die Realität mit Daten nachzustellen, jedoch kann es bereits hier zu Herausforderungen kommen: Personen werden in Datenströmen abstrahiert, die die tatsächliche Person und ihre Eigenschaften (bspw. Kreditwürdigkeit, Preissensitivität) unter Umständen nur teilweise, verzerrt oder sogar falsch darstellen können und – bei entsprechender Verwendung in ML-Verfahren – auch negative Konsequenzen für das resultierende Modell bedeuten. Beispiele für mögliche Ursachen können ein Bias bei der Datensammlung, mangelnde Datenintegrität, Messfehler oder auch Verzerrungen durch beispielsweise falsche Angaben sein. Ein klassisches Beispiel für Verzerrungen bei der Erfassung von Kundenvorlieben stammt aus dem eCommerce-Bereich: Bei der Geschenke-Bestellungen für Freunde verändern die Konsumierenden ihr Kaufverhalten, da sie nicht nach ihren eigenen Interessen einkaufen. Die Plattform geht dann fälschlicherweise davon aus, dass sich die Interessen der Bestellenden geändert haben und schlägt nach der Bestellung weitere Artikel aus dem gleichen Bereich vor. Ein zweites methodisches Problem ergibt sich durch den Vergangenheitsbezug von Daten. ML ist per Definition darauf ausgelegt durch das Erkennen von statistischen Mustern in Datensätzen „zu lernen“. Ändert sich beispielsweise das Verhalten der Kundinnen und Kunden durch externe Schocks (z.B. die Corona-Krise) dramatisch, kann ein entsprechender Algorithmus das im Zweifel nicht ohne Weiteres direkt abbilden. Dies bedeutet aber auch, dass eine entsprechende Software nur Outputs generieren kann, die bereits gegeben sind, nicht aber neue, abweichende Erkenntnisse oder innovative Ideen: Stattdessen zeigt ML nur Charakteristika, Muster und Strukturen, die bereits in den Daten vorliegen.



Der Teilbereich der **gesellschaftlichen Herausforderungen** entsteht vor allem durch den neuen Einsatz von ML-Techniken im wirtschaftlichen Kontext, und ist dabei nicht zwingend ein KI-spezifisches Phänomen, kann aber dennoch eine Einschränkung bei der Nutzbarkeit von Ergebnissen bedeuten: Entwickler von KI-Lösungen sollten neben ihrer informationstechnischen Ausbildung auch Erfahrungen zu Interaktionen, Strukturen und Dynamiken in den entsprechenden wirtschaftlichen Kontexten haben, in denen die KI-Lösung eingesetzt werden soll. Gerade im Bankenkontext müssen insbesondere regulatorische Anforderungen, aber auch Anforderungen der Kundinnen und Kunden sowie die Usability für Beratende beachtet werden. Damit verbunden ergibt sich ein ähnliches Problem beim Erstellen von Datensätzen für das *Supervised Learning*: durch das notwendige Beschriften von Daten, auf deren Basis der Algorithmus anschließend trainiert wird. Persönliche und kulturelle Prägungen können bei gleichen Ausgangsdaten zu unterschiedlichen Klassifizierungen und somit zu unterschiedlichen Modellen führen. Eine geringe Diversität (Hagendorff und Wezel (2020) nennen hier das Geschlecht der Entwickelnden als Beispiel), kann das Problem unter Umständen gar verstärken. Neben diesen individuellen Aspekten finden sich auch branchenweite Herausforderungen: Die Entwicklung von KI-Software setzt eine Anpassung an Daten und Kontext voraus, auf die und in dem sie genutzt werden soll. Expertinnen und Experten sowie talentierte Neueinsteigende auf diesem Feld sind noch selten, was eine Entwicklung und Implementierung entsprechend schwieriger werden lässt. Eine weitere Herausforderung für Unternehmen ist die gesellschaftliche Akzeptanz für den Einsatz von ML: Mitarbeitende, die Angst vor einem Jobverlust haben, sowie Bedenken der Kundinnen und Kunden können den Einsatz von KI bremsen. Das Kapitel *Kundinnen und Kunden* beschäftigt sich vertieft mit den dahinterliegenden Bedenken dieser Gruppe.



Daneben weisen ML-Methoden nach wie vor **technologische Herausforderungen** auf: Während das Unternehmen DeepMind die Struktur und Funktion von Intelligenz entschlüsseln möchte, gilt nach wie vor, dass unter anderem neuronale Netze zwar an „menschliche Intelligenz“ angelehnt sind, sie aber dennoch wesentlich anders funktionieren als das menschliche Lernen und Verstehen. Die Bestrebung dies zu ändern, existiert seit der Einführung des KI-Begriffes; aktuell ist jedoch nicht absehbar, ob und wann auf diesem Feld ein Durchbruch – und somit die starke KI-These – erreicht werden kann. Außerdem sieht sich vor allem der Einsatz von beispielsweise neuronalen Netzen im Bankengeschäft der Herausforderung der Erklärbarkeit seiner Ergebnisse gegenübergestellt. Dies kann unter Umständen dazu führen, dass ML im Geldwäscheerkennungs-Prozess oder im Rahmen der Kreditvergabe, bei denen nachvollziehbare Kriterien notwendig sind, nicht eingesetzt werden kann. Gleichzeitig beschäftigt sich die Wissenschaft mittlerweile intensiv mit der Erklärbarkeit von ML-Methoden. Und auch in der Praxis ist „Explainable AI“ mittlerweile anzutreffen (vgl. Gartner Hype Cycle for Artificial Intelligence 2019). Neben der Erklärbarkeit ist die Inflexibilität von ML eine weitere Limitation: Auf Trainingsdaten trainierte Algorithmen führen zu einer „Spezialisierung“ des Modells. Während sich Menschen in sich rasch ändernden Umweltbedingungen einfacher zurechtfinden, muss ein Algorithmus unter Umständen vollständig neu trainiert werden. Zusätzlich dazu wird der Algorithmus nur für seinen speziellen Zweck einsetzbar sein, eine Anwendbarkeit in einem anderen Kontext ist nicht möglich. Wie auch bei anderen Software-Entwicklungen ist auch bei KI-Applikationen die Sicherheit ein nicht zu vernachlässigender Faktor. Generell sind mehrere Typen von Angriffen auf ML-Verfahren möglich: Bei dem so genannten Data Poisoning werden dem Algorithmus speziell manipulierte Trainingsdaten zugeführt, so dass dieser erhebliche Fehler bei Anwendung generiert (Biggio et al. 2012). Eine weitere Möglichkeit ist, bereits trainierte Modelle gezielt zu täuschen: Jia und Liang (2017) nahmen beispielsweise kleine Anpassungen in Satzstrukturen vor, die Menschen vor keine Probleme stellten, aber die Genauigkeit von automatischer Texterkennung von 75% auf 36% reduzierten. Gleiches wurde auch bereits bei Bild- und Tonerkennung durchgeführt.

Abschließend lässt sich festhalten, dass die genannten Einschränkungen bei der Entwicklung von Use Cases beachtet werden müssen. Auch wenn bei KI-Anwendungen häufig das Potenzial von Kosteneinsparungen und Prozessautomatisierung im Fokus steht, darf nicht vernachlässigt werden, dass die genannten Problemstellungen erhebliche Kosten verursachen können. Sowohl die notwendigen Investitionen in entsprechendes Wissen und in IT-Infrastruktur als auch der Umgang im operativen Bereich können die Einsparpotenziale im Zweifelsfall übersteigen. ML ist somit nicht per se die beste Wahl für Business-Prozesse und Problemstellungen im Allgemeinen, sondern bietet vielmehr eine weitere, gegebenenfalls zielgerichtete Methode zur wertschaffenden Datenverwendung.

Relevante Trends im Bankensektor

Nach einer Einführung in das Thema KI wirft die vorliegende Studie nun einen kurzen Blick auf für KI-Projekte relevante Trends und Entwicklungen im Retail Banking, um aus den geführten Interviews anschließend praxisorientierte Handlungsempfehlungen ableiten zu können.

Digitalisierung der Kundenschnittstelle

Der Geschäftsbereich des Retail Bankings hat sich in den vergangenen fünf Jahren erheblich verändert: Sowohl das Verständnis für die Finanzwelt als auch die digitalen Angebote von Banken haben gemäß einer Umfrage des Digitalverbandes Bitkom seit 2016 stark zugenommen (bitkom 2019). Während 2014 nur 53% der Kundinnen und Kunden Online-Banking genutzt haben, sind es heute bereits über 70%. Dabei verwenden mittlerweile mehr als die Hälfte der Kundinnen und Kunden ihre Smartphones. Neben der gestiegenen Nutzung von Online-Banking, legt die Mehrheit der befragten Kundinnen und Kunden bei der Wahl der Bank vor allem Wert auf die Höhe der Kontoführungsgebühren und die Möglichkeit, kostenlos Bargeld am Geldautomaten abheben zu können. Da Beratungsdienstleistungen vor Ort kein ausschlaggebender Faktor mehr für die Wahl der Bank sind, ist die Bereitschaft, das kontoführende Institut zu wechseln, gestiegen.

Dabei ist die Bereitschaft zu einer reinen Onlinebank zu wechseln zwischen 2018 und 2019 von 36% auf 46% gestiegen. Dies hat erhebliche Konsequenzen für etablierte Banken: Die Anzahl an Zweigstellen hat von 2015 bis 2018 um 18% abgenommen (Deutsche Bundesbank 2018); Direktbanken verzeichnen zeitgleich einen Zuwachs an Kundinnen und Kunden: allein zwischen 2012 und 2017 stieg deren Anzahl um 20% (Statista 2018). Zwei Faktoren begünstigen die stärkere Unabhängigkeit der Kundinnen und Kunden: Vergleichsportale stellen diesen transparent eine Übersicht zu Vergleichsangeboten zur Verfügung, zudem drängen Non- und Near-Banks⁵ in das Kundensegment und sorgen für ein vergrößertes Angebot auf dem Markt. In der Praxis lassen sich diese Herausforderungen der Bankenbranche zum Beispiel in der Integration der Comdirect in die Commerzbank (Mai 2020) beobachten: Die Digitalisierung des Geschäfts und die Erfahrungen der Direktbank Comdirect in diesem Bereich haben sicherlich eine Rolle dabei gespielt, dass die Commerzbank das Angebot ihrer Tochtergesellschaft enger an das eigene Geschäftsmodell angebunden hat.

Trotz der Entwicklungen im Privatkundengeschäft und der rasanten Digitalisierung von Bankdienstleistungen, nimmt Deutschland im internationalen Vergleich eine Sonderstellung ein, die Entscheidende auch bei der strategischen (Weiter-)Entwicklung von Produkten beachten sollten: Deutsche Kundinnen und Kunden sind grundsätzlich eher zurückhaltend beim aktiven Teilen ihrer persönlichen Daten für digitale Geschäftsmodelle.

⁵ Unter Non- und Near-Banks versteht man bankfremde Anbieter wie beispielsweise Apple mit ihrem Bezahlangebot Apple Pay, die Bank-Leistungen anbieten.



Dies zeigt unter anderem eine Studie des Max-Planck-Institutes vom Februar 2020 (Kozyreva et al. 2020): Demnach gaben 82% der Befragten an, besorgt über den Schutz ihrer persönlichen Daten zu sein. Gleichzeitig passen nur 37% der Befragten Privatsphäre-Einstellungen auf Online-Plattformen an, 20% nutzen gar keine Privacy-Tools wie beispielsweise Browser-Erweiterungen. Dieses vermeintlich widersprüchliche Verhalten im Kontrast zu den vorhandenen Datenschutzbedenken wird „Privacy Paradox“ genannt.

Dieses Bild findet sich so auch im Bankenkontext wieder: Im Januar 2020 untersuchte die Senacor Technologies AG in einer Marktumfrage die Akzeptanz von datengetriebenen Geschäftsmodellen im Bankenkontext. Demnach lehnen 90% der befragten Verbrauchenden die Auswertung von Kunden- und Kontodaten zur Nutzung für personalisierte Ansprachen ab, während 25% eine Kontrolle und Meldung von bevorstehenden Deckungslücken begrüßen würden und gar 88% nicht auf eine personalisierte Ansprache verzichten möchten. Während Bankkundinnen und -kunden also zwar auf die Freigabe ihrer Daten verzichten möchten, verwenden 36% der Befragten bereits Services, mit denen sie ihre Kontodaten für Bezahldienste (Apple Pay, Paypal etc.) freigegeben, um bequemer zu zahlen.

Gleichzeitig genießen Banken ein hohes Maß an Vertrauen ihrer Kundinnen und Kunden: 78% Verbraucher würden demnach ihrer Hausbank Kontodaten für digitale Dienste freigeben, während nur 35% entsprechende Daten an Technologiefirmen weitergeben würden und sogar nur 24% an Smartphone-Banken (N26, Revolut etc.). Dieser Vertrauensvorschuss kann genutzt werden und ist für klassische Banken sicherlich ein Wettbewerbsvorteil. Hier sollte allerdings darauf geachtet werden, die Datenverwendung transparent zu machen, und von Kundinnen und Kunden die Zustimmung zur Verwendung einzuholen; denn Voraussetzung für die Freigabe ist aus Kundensicht vor allem die Information darüber, wer die Daten bekommt, was damit gemacht wird und die Möglichkeit die Zustimmung wieder rückgängig machen zu können. Anreiz für die Datenfreigabe durch die Kundinnen und Kunden sind vor allem eine bequemere Erledigung von Finanzgeschäften (82% der Befragten) oder die Vergünstigung von bestimmten Produkten (66% der Befragten). KI stehen Kundinnen und Kunden allerdings grundsätzlich noch eher verschlossen gegenüber: Mehr als die Hälfte sieht keinen Mehrwert in Anwendungen wie die Anbindung von Sprachassistenten, intelligente Finanztipps zu Wertpapieren oder Hilfestellungen bei digitalem Banking sowie personalisierte Nutzeroberflächen.

Antworten von Kundinnen und Kunden zu potenziellen Anwendungen, die überwiegend noch nicht am Markt vorhanden sind, sind allerdings kritisch zu bewerten. Hier fehlt häufig das Wissen zu Ausgestaltungsmöglichkeiten sowie der Technologie an sich.

„Häufig wissen Leute nicht, was sie wollen, bis man es ihnen zeigt.“ – Steve Jobs

Die datenschutzrechtlichen Bedenken der Kundinnen und Kunden sowie die Ablehnung von möglichen Use Cases kann klassische Retailbanken daran hindern, innovative Lösungen zu entwickeln. Daraus einen fehlenden Innovationsdruck zu schlussfolgern, wäre allerdings falsch.

Wirkliche Innovation an der Kundenschnittstelle kommt aktuell eher von digitalen Non-Banken; denn diese haben beim Thema KI einen entscheidenden Vorteil: Die bisherige Wertschöpfung basiert bereits auf Daten der Kundinnen und Kunden. Zudem haben sie Erfahrungen damit gemacht, ihr Angebot zunächst vor allem Early Adoptern zur Verfügung zu stellen. Ein Beispiel hierfür ist das C24-Bankkonto vom Vergleichsportal Check24, das im Oktober 2020 gestartet ist. Hier werden bereits Angebote wie individualisiertes Sparen sowie Vertragsoptimierung umgesetzt und als Ergänzung zum bisherigen Geschäftsmodell genutzt. Das Ziel ist hierbei zunächst nicht, die Bankenbranche nachhaltig zu verändern oder Zahlen ähnlich zu Digitalbanken zu erreichen, sondern interessierten Kundinnen und Kunden ein weiteres Angebot zu bieten, welches diese näher an Check24 bindet.

Zusammenfassend ist festzuhalten, dass der Digitalisierungstrend die Bankenbranche weiterhin unter Druck setzt und Anpassungen zum bisherigen Geschäftsmodell erforderlich werden. Die Besonderheit am deutschen Markt ist der bewusste, eher konservative Umgang der Kundinnen und Kunden mit persönlichen Daten. Hier müssen Banken grundsätzlich schon bei der Entwicklung von KI-Projekten die Interessen der Kundinnen und Kunden wahren und für eine entsprechende Bereitschaft zur Datenbereitstellung sorgen. Das bisherige Vertrauen in die Hausbank kann hierbei ein Wettbewerbsvorteil gegenüber Non- und Near-Banks sein.

Regulatorische Entwicklungen

Der regulatorische Rahmen von Banken ist auch für den Einsatz von KI von entscheidender Relevanz. So können entsprechende regulatorische Entwicklungen entweder bewusst Innovationen im Bankenmarkt fördern oder auf der anderen Seite auch hemmen bzw. verhindern. Dieses Kapitel führt zwei wesentliche gesetzliche Rahmenbedingungen an (DSGVO und PSD2), um beispielhaft die vielfältigen Auswirkungen der Regulatorik auf KI-Projekte zu veranschaulichen.

Die BaFin als eine der zentralen Aufsichtsbehörden für Banken, Finanzdienstleistungsunternehmen, Versicherungen und den Wertpapierhandel hat 2018 in ihrer Studie zu Big Data und KI bereits einige Herausforderungen und Implikationen aus regulatorischer Perspektive beschrieben (BaFin 2018). Demnach können monopolistische Strukturen (ähnlich zu Facebook) durch vorhandene Daten entstehen, die als Basis für innovative Produkte dienen und damit wiederum mehr Daten generieren. Gleichzeitig können jedoch auch unregulierte Organisationen, die bisher außerhalb des Finanzmarktes tätig waren, systemrelevant werden (entweder durch eigene Angebote an den Finanzmarkt oder B2B-Dienstleistungen).



Fünf durch KI getriebene Entwicklungen erwartet die BaFin im Bankensektor:

- 1) Eine Trennung von Kundenschnittstelle und Produktplattform (Prozesse und Funktionen zur Herstellung von Produkten und Dienstleistungen), bei der verschiedene Teile der Wertschöpfungskette von neuen Anbietenden besetzt werden
- 2) Wettbewerbsvorteile und Umverteilungen von Erträgen durch KI-Innovationen an der Kundenschnittstelle
- 3) Nutzung von Transaktionsdaten zur Optimierung von Angeboten außerhalb des Finanzsektors
- 4) Effizienzsteigerungen von bankfachlichen Kernprozessen
- 5) Monetarisierung von Daten und anonymisierten Datenauswertungen durch Finanzinstitute

Basierend auf diesen Entwicklungen hat die BaFin regulatorische Implikationen zu Finanzstabilität und Marktaufsicht, Unternehmensaufsicht sowie kollektivem Verbraucherschutz identifiziert. Demnach sollen unter anderem Regulierungslücken frühzeitig identifiziert und geschlossen sowie Systemrelevanz neu definiert und adressiert werden. Unternehmen sollen beispielsweise weiterhin die Erklärbarkeit von Modellen, insbesondere im Compliance-Bereich (Anti-Money-Laundering oder KYC) gewährleisten. Es ist zudem aufsichtsrechtlich zu klären, welche KI-Methoden sich für aufsichtlich abgenommene Modelle eignen und ob bestimmte Methoden grundsätzlich auszuschließen sind.

DSGVO

Die Europäische Datenschutz-Grundverordnung (DSGVO) ist seit dem 25. Mai 2018 wirksam und schreibt vor, in welchem Rahmen personenbezogene Daten verarbeitet werden dürfen. Intendiertes Ziel der Verordnung ist eine verbesserte Selbstbestimmung von Kundinnen und Kunden über ihre von Institutionen und Unternehmen verwendeten Daten: Damit ist zunächst die Verarbeitung von personenbezogenen Daten grundsätzlich so lange untersagt, bis Rechtfertigungsgründe der DSGVO eine entsprechende Verarbeitung erlauben. Im Retailgeschäft von Banken ist eine umfangreiche Verarbeitung von personenbezogenen Daten unumgänglich, welche entsprechend durch einige der in Art. 6 Abs. 1 Satz 1 DSGVO genannten Voraussetzungen ermöglicht werden (Guggenberger 2019):

- > Erforderlichkeit für die Erfüllung eines Vertrages oder Durchführung von vorvertraglichen Maßnahmen
- > Erfüllung von rechtlichen Verpflichtungen
- > Einwilligung der betroffenen Person

Damit ist die Nutzung von personenbezogenen Daten für KI-Modelle durch die DSGVO entsprechend reguliert und setzt Vorkehrungen bereits zu Beginn der Entwicklung eines KI Use Cases voraus: Darunter fällt unter anderem die Anonymisierung und/oder Pseudonymisierung von genutzten Daten betroffener Kundinnen und Kunden sowie ein Privacy by Design⁶ Konzept. Die DSGVO kann dadurch zwar als hemmender Faktor für KI-Innovation gesehen werden, verbietet aber nicht grundsätzlich die Verwendung von Daten für entsprechende Projekte. Dies entspricht auch der Maßgabe der Bundesregierung, die in den strategischen Eckpunkten zu KI die DSGVO als „verlässlichen gesetzlichen Rahmen für innovative Technologien und Anwendungen auch im Bereich KI“ beschreibt (Bundesregierung 2018).

PSD2

Die Zahlungsdiensterichtlinie PSD2 (Payment Services Directive 2) ist eine Richtlinie der Europäischen Union, die eine verbesserte Sicherheit im Zahlungsverkehr, höheren Verbraucherschutz sowie die Stärkung von Innovation und Wettbewerb durch die Regulierung von Zahlungsdiensten und dienstleistungsunternehmen sicherstellen soll (Bundesbank 2020). Die erste Stufe der Richtlinie ist seit dem 13. Januar 2018 in Kraft und reguliert zunächst unter anderem Haftungsobergrenzen bei Kreditkartenmissbrauch. Die zweite Stufe gilt seit dem 14. September 2019 und umfasst zum Beispiel die Verpflichtung von kontoführenden Zahlungsdienstleistungsunternehmen (meist Banken) zur gebührenfreien Bereitstellung von Schnittstellen für Drittangebote. Dabei können Kundinnen und Kunden über Drittangebote Zahlungen auslösen, auf Kontoinformationen zugreifen oder die Anbietenden als Drittemittenten nutzen. Wie schon bei der DSGVO ist auch das Ziel von PSD2 die Stärkung der Rechte von Kundinnen und Kunden, v.a. im Sinne der eigenen Verfügung über diejenigen personenbezogenen Daten, die bei Unternehmen gespeichert werden (Mai 2018). Der zentrale Unterschied ist bei PSD2 jedoch die Möglichkeit, die Daten über Drittangebote zu nutzen, während DSGVO vor allem auf den Schutz der Daten abzielt. Die neuen Wertschöpfungsmöglichkeiten können auch von Banken selbst genutzt werden, indem sie Daten zur Verfügung stellen, aber auch selbst auf PSD2-Schnittstellen anderer Banken zugreifen und für ein Wertangebot an (ggf. neue) Kundinnen und Kunden nutzen. Gleichzeitig kommt es zu einer von Banken kritisierten Wettbewerbsverzerrung: Drittangebote müssen ausschließlich DSGVO-Vorgaben beachten, während Banken Investitionen für Schnittstellen vorzunehmen haben, welche anschließend gebührenfrei von Drittanbietern verwendet werden können (Mai 2018).

PSD2 ebnet mit der Verpflichtung zur Datenfreigabe den Weg zum Open Banking, einer Öffnung der Bankenbranche gegenüber Drittangeboten. Sie führt zu einer insgesamt höheren Datenverfügbarkeit auf dem Finanzmarkt und somit einer verbesserten Grundlage für KI-Anwendungen, aber auch zu einer höheren Konkurrenz auf dem Markt, da der Wettbewerbsvorteil von Banken, aktuell über eine weitgehende Datengrundlage zu verfügen, durch PSD2 abgeschwächt wird.

⁶ Hierbei werden bereits zu Beginn der Entwicklung datenschutzrechtliche Maßgaben bei der Datenverarbeitung durch entsprechende Anpassungen der Hardware und/oder Software sichergestellt.

Auf Transaktionsdaten basierende KI-Anwendungen können demnach auch von Drittanbietenden entwickelt werden. Wie aus den im Rahmen der Studie geführten Interviews hervorgehen wird (siehe folgende Kapitel), ist gerade die Datenschnittstelle zu entsprechenden Drittangeboten bei KI-Projekten aber auch im Rahmen einer Zusammenarbeit mit innovativen Start-Ups höchst relevant.

KI-Einsatz im Retail Banking: Ergebnisse der Interviews

Der zweite Teil der vorliegenden Studie fasst die Interviews mit Expertinnen und Experten zusammen, deren Ergebnisse vier relevante Kernbereiche im Umgang mit KI im Retail Banking skizzieren:

- 1) Eine zentrale Problemstellung bei der erfolgreichen Umsetzung von KI-Projekten ist die zielorientierte **Use Case Entwicklung**. Aktuell mangelt es den Retailbanken vor allem an Ideen für Use Cases, die an der **Kundenschnittstelle** einsetzbar sind.
- 2) An der Kundenschnittstelle hemmen Datenschutzbedenken von Kundinnen und Kunden aktuell den Einsatz von KI. Zunächst muss hier eine **Personalisierung von Angeboten** der Bank stattfinden, die es ermöglicht, KI als erkennbaren Mehrwert für die Kundinnen und Kunden darzustellen; gleichzeitig wird so deren Bereitschaft gehoben, ihre Daten für entsprechende Angebote freizugeben.
- 3) Um Insellösungen und Komplexitäten zwischen verschiedenen Systemen – z.B. in Bezug auf die notwendige Datenverfügbarkeit – zu vermeiden, ist es wichtig, Anforderungen aus Use Cases an die Systemlandschaft zu identifizieren und diese schrittweise durch eine **Anpassung bzw. Modernisierung der Infrastruktur** zu erfüllen.
- 4) KI-spezifische Anforderungen an das **Projektmanagement** können die erfolgreiche Implementierung von Use Cases hemmen. Die verwendeten Daten erfordern hierbei bereits zu Beginn aber auch im weiteren Verlauf des Projektes eine starke Einbindung der Compliance-Abteilung und das Know-how von spezialisierten Data Scientists.

Use Cases in Banken – bisher hinter den Möglichkeiten

Der erste Kernbereich, den die Interviews als aktuelles Problemfeld skizzieren, umfasst anwendbare KI Use Cases in Banken. Dabei liefern die Expertinnen und Experten sowohl eine Übersicht über aktuell bestehende Use Cases als auch über Herausforderungen bei der Use Case Entwicklung.

Generell können KI Use Cases in Anlehnung an die Veröffentlichung „Developing purposeful AI use cases“ von Hofmann et al. (2020b) nach drei Typen klassifiziert werden: Die Use Case Typen sind abhängig von der Rolle der KI, vom Umfang der KI-Nutzung sowie vom Grad der Wertschöpfung durch KI im konkreten Einsatzfeld:

- 1) **Funktionale KI:** KI wird genutzt, um eine fachliche Kernfunktion bzw. -aufgabe zu erfüllen. Ein Beispiel wäre die Erstellung von Budgetprognosen durch KI-Anwendungen.
- 2) **Interaktive KI:** KI wird an der Nutzerschnittstelle für Input und/oder Output genutzt. Anwendungen finden sich im Umfeld von Mensch-Maschinen-Interaktionen (zum Beispiel Chatbots).
- 3) **Kombinierte KI:** KI wird sowohl für Input/Output als auch für die fachliche Kernfunktion genutzt. Ein mögliches Beispiel wäre ein Chatbot, der basierend auf Transaktionsdaten der Kundinnen und Kunden Kredite vergibt.

Die folgende Abbildung bietet einen Auszug zu aktuell bestehenden KI Use Cases von Banken & FinTechs. Dabei zeigt sich, dass sich die aktuellen Use Cases vor allem zu den Typen funktionale KI und interaktive KI zuordnen lassen. Ein Einsatz von kombinierter KI ist aktuell weder in der Breite vorhanden noch in den befragten Banken mittelfristig geplant.

	Funktionale KI	Interaktive KI	Kombinierte KI
Banken	Churn-Erkennung Produktvorschläge für Kundenberater AML / Fraud-Erkennung Kreditrisiko basierend auf Transaktionsdaten	Automatisierte Rechnungserfassung FAQ-Mails Sprachassistent zur Kontostandsabfrage	Chatsbots für Kontoanalysen
FinTechs	Tagging von Kontodaten Erstellung künstlicher Datensätze Money Saving Assistant	Assistent für Conversational Banking	Digitaler Investment-Berater Interaktives Ausgabentracking Intelligentes Rechnungs- und Mahnwesen

In Interviews hervorgehoben
Auf dem Markt angeboten

Abbildung 5: Use Cases in Banken und FinTechs

Während andere Digitalisierungsthemen aktuell eher im Fokus stehen, nähern sich Banken dem Thema KI nur langsam: **Die von Banken bisher entwickelten Use Cases nutzen das Potenzial von KI noch nicht aus.** Innerhalb von Banken wird KI – wenn überhaupt - meist für die Optimierung bereits vorhandener Prozesse eingesetzt, die keinen direkten Kontakt zu Kundinnen und Kunden beinhalten und keine Ergänzungen zum Wertversprechen gegenüber diesen darstellen. **Innovative KI Use Cases, die grundsätzlich an den Produkten einer Bank ansetzen und das Wertversprechen neu denken, sind in der Branche noch nicht verbreitet.** Dies ist aus zwei Gründen bedenklich: Zum einen nehmen Kundinnen und Kunden die Optimierung bestehender Prozesse nicht zwingend wahr, zum anderen können Prozessverbesserungen zwar (kurzfristig) vorteilhaft sein, verschieben gegebenenfalls aber strukturelle Probleme des Geschäftsmodells

lediglich zeitlich hinaus. Das heißt jedoch nicht, dass Banken KI nicht zur Prozessoptimierung einsetzen sollten, im Gegenteil: nach Ansicht der befragten Expertinnen und Experten setzen sich KI-basierte Prozesse zum Beispiel im Bereich Anti-Money-Laundering (AML) oder der automatisierten Rechnungserfassung in Zukunft als Standard durch. Gelingt einer Bank diese Umstellung nicht, droht sie also eher, vom Markt zu verschwinden.

Der Einfluss von entsprechenden Projekten auf die Kundenzufriedenheit kann anhand des sogenannten Kano-Modells (siehe Abbildung 6) eingeordnet werden. Die Merkmale der den Kundinnen und Kunden bereitgestellten Dienstleistungen und Produkte werden hierbei der Kundenzufriedenheit und den Kundenerwartungen gegenübergestellt. Der beispielhafte Einsatz der Technologie „Spracherkennung“ kann alle drei Merkmale des Modells beeinflussen:

- › Basismerkmale: Dies sind Merkmale, die von Kundinnen und Kunden erwartet und erst bei Nichterfüllung wahrgenommen werden, dann jedoch zu einem überproportionalen Rückgang der Kundenzufriedenheit führen. Ihre Erfüllung steigert die Kundenzufriedenheit nicht. Würden **mit der Spracherkennung Mitarbeitende eines Callcenters ersetzt**, können Basismerkmale riskiert werden, wenn die KI die Kundinnen und Kunden möglicherweise nicht versteht. Diesen fällt der Wert eines Callcenters erst bei Wegfall auf, da sie implizit davon ausgehen, dass dieses vorhanden ist und funktioniert. Natürlich sind Innovationen im Bereich der Basismerkmale allerdings nicht per se negativ behaftet. KI-Projekte in diesem Bereich können meist als klassische Effizienzsteigerung verstanden werden.
- › Leistungsmerkmale: Sie werden von Kundinnen und Kunden wahrgenommen und steigern die Kundenzufriedenheit bei stärkerer Erfüllung von Erwartungen. Sollte die **KI-Spracherkennung als „Vermittlung“** in der Lage sein, Kundinnen und Kunden im Vergleich zu Callcenter-Mitarbeitenden schneller mit der korrekten Ansprechperson zu verbinden, steigert dies auch unmittelbar die Zufriedenheit der Kundinnen und Kunden.
- › Begeisterungsmerkmale: Diese Merkmale werden von Kundinnen und Kunden nicht explizit nachgefragt, da es sich hierbei um innovative Merkmale handelt, an die diese noch gar nicht denken. Möglich wäre der Einsatz der **Spracherkennung im Kontext einer Sprachassistentz**, die unkompliziert Informationen zum eigenen Konto zur Verfügung stellt und somit das „normale“ Angebot von Banken deutlich übersteigt. Dies kann zu einer überproportionalen Steigerung der Kundenzufriedenheit führen.

Der bisherige Einsatz von KI in Retailbanken hat aktuell in den meisten Fällen einen Bezug zu den Basismerkmalen, begeistert Kundinnen und Kunden deshalb (noch) nicht, sondern riskiert eher Kundenzufriedenheit. Innovative KI Use Cases haben derweil das Potenzial, Leistungs- oder Begeisterungsmerkmale von Angeboten zu schaffen und konkrete Ergänzungen zum Wertversprechen gegenüber den Kundinnen und Kunden zu bieten. Erst der direkte Bezug zu diesen und nicht – wie bisher – zu internen Prozessen der Bank, ermöglicht Angebote, die durch Begeisterungsmerkmale einen überproportionalen Zuwachs von Kundenzufriedenheit realisieren.




Abbildung 6: Kano-Modell zur Kundenzufriedenheit

Besonders im Kundenkontakt treffen Banken jedoch aktuell sehr bewusst die Entscheidung, keine entsprechenden Use Cases zu entwickeln; denn gerade für Retailbanken ist das Kundenverhältnis und die damit verbundene Servicequalität enorm wichtig: Eine persönliche Beratung und die Beziehung zwischen den Beratenden und den Kundinnen und Kunden wird aus Sicht der Banken durch den Einsatz von KI nicht besser, sondern könnte im Gegenteil eher zum Risiko werden, wenn Kundinnen und Kunden – durch den fehlenden zwischenmenschlichen Faktor oder Datenschutzbedenken – abgeschreckt werden. Die befragten Expertinnen und Experten bestätigen in den Interviews, dass **Banken besonders im Kundenkontext mit der Entwicklung von Use Cases zögern**. Das Kundenvertrauen ist für Banken essenziell, ein mögliches Risiko in diesem Bereich wird vermieden. Umso wichtiger wären innovative Use Cases, die über einen einfachen Chatbot hinaus gehen und die Beziehung zwischen der Bank und ihren Kundinnen und Kunden langfristig stärken.

„Kundinnen und Kunden wollen nicht das Gefühl bekommen, dass die Bank sich durch einen Chatbot das persönliche Gespräch spart, sondern dass durch den Chatbot das Service-Level der Bank steigt.“
– Prof. Gilbert Fridgen

Dabei ist die Entwicklung von innovativen KI Use Cases nicht trivial, sondern erfordert eine Reihe von Vorbereitungen und Fähigkeiten. Einen möglichen Ansatz für innovative Use Case Entwicklung liefern Hofmann et al. (2020a):




Abbildung 7: Entwicklung von KI Use Cases nach Hofmann et al. (2020)

Hierbei werden vor einem Entwicklungszyklus zunächst der Einsatzbereich der KI festgelegt und die notwendigen Ressourcen bestimmt (*Eingrenzen*). Im weiteren Verlauf können dabei bereits identifizierte Use Cases priorisiert werden. Zum Vorbereiten sollten anschließend Informationen zur Technologielandschaft, der internen Organisation sowie Umweltfaktoren gesammelt werden.

Im eigentlichen Entwicklungszyklus identifizieren Unternehmen in der Aktivität *Entdecken* mögliche Handlungsfelder. Hierbei können zum einen aus der internen, stakeholderorientierten Perspektive Probleme (Domänenperspektive) und zum anderen auf dem Markt verfügbare KI Use Cases als Chancen identifiziert werden (Technologieperspektive). Anschließend sollte in der Aktivität *Verstehen* ein grundlegendes Verständnis zu den Ursachen für Probleme und Chancen aufgebaut werden, um nicht nur Symptome eines Problems zu adressieren. Abschließend werden im Entwicklungszyklus Probleme und Chancen mit Lösungen zusammengeführt (*Entwerfen*). Innovative Lösungen kommen dabei besonders dann zustande, wenn zu einem domänenspezifischen Problem keine Lösung vorliegt

(Entwicklung einer neuen KI-Lösung notwendig) oder für bestehende Lösungen kein domänen-spezifisches Problem existiert (Potenziale für die Erweiterung des eigenen Geschäftsmodells). Durch *KI-Experimente* (bspw. das Testen des Modells) können Unternehmen ergänzend das Verständnis für KI vertiefen.

Die Durchführung von Entwicklungszyklen kann nach einer aus der Perspektive des Unternehmens ausreichenden Anzahl an Use Cases beendet werden. Während der Aktivität *Einführen* müssen Unternehmen darüber entscheiden, ob die Anwendung intern oder extern entwickelt bzw. eine bereits bestehende Lösung gekauft werden soll und welcher Reifegrad hierbei gewünscht ist.

Ausgehend vom Einsatz im Bankenkontext wäre hier im Vorfeld der Einsatzbereich ggf. auf das Controlling der Bank eingegrenzt worden, um dann während der Aktivität *Entdecken* das domänen-spezifische Problem der händischen Rechnungserfassung und KI-Modelle zur Textanalyse auf dem Markt zu identifizieren. Während der Aktivität *Verstehen* hätte sich gezeigt, dass vor allem uneinheitliche Formatierungen zu der Notwendigkeit einer händischen Erfassung geführt haben. Das Abgleichen von der Lösung mit der Problemstellung führt anschließend zu einem Entwurf einer KI, die entsprechende Rechnungen automatisch erfasst und in das ERP-System übernimmt. Basierend auf verfügbaren Lösungen auf dem Markt kann dann eine *Make or Buy* Entscheidung getroffen werden.

In der Praxis führt der Fokus von Banken auf domänenspezifische Problemstellungen und eine Vernachlässigung von Marktentwicklungen aktuell dazu, dass beispielsweise neuste Entwicklungen zu erklärbarer KI⁷ im Rahmen der Use Case Entwicklung noch nicht ausreichend beachtet werden, was die Interviewten teilweise mit fehlendem Know-how begründen. Da jedoch in bestimmten Bereichen (bspw. AML) die Erklärbarkeit von Modellen so stark im Vordergrund steht, dass selbst eine verbesserte Trefferrate gegenüber der Regulatorik erst einmal sekundär bleibt, folgt daraus, dass entsprechende Projekte zur Use Case Entwicklung möglicherweise erst gar nicht initiiert werden. Hier kann ein systematischer Ansatz zur Use Case Entwicklung helfen, mit einem geringen Ressourceneinsatz aktuelle Entwicklungen zu verfolgen und ggf. bereits frühzeitig in den Banken einzusetzen.

Schlussendlich muss sich die Bank vor der Einführung eines Use Cases Gedanken darüber machen, welcher Mehrwert durch die Nutzung des Use Cases generiert werden soll bzw. kann, und welche Einflüsse durch KI erzielte Ergebnisse im Gesamtprozess haben: Wie sollen Beratende mit den Empfehlungen der KI auf Kundinnen und Kunden zugehen? Welche Maßnahmen werden ergriffen, wenn die KI abwanderungswillige Kunden identifiziert? **Bisher sind Use Cases aber häufig nicht auf ein konkretes Ergebnis ausgerichtet – es fehlt das „so what“, zum Beispiel die Integration der Erkenntnisse in die Folgeprozesse.**

⁷ Eine Übersicht an aktuellen Entwicklungen auf dem Feld Explainable AI (erklärbare KI) bieten Samek et al. (2019). Es wird beispielsweise aufgezeigt, dass ML-Modelle für autonomes Fahren bereits hinsichtlich ihres Lernprozesses und wie Entscheidungen schlussendlich getroffen werden durchleuchtet werden können.

Kooperationen mit FinTechs als möglicher Ausweg

Da bei der Einführung neben einer *Make*- auch eine *Buy*-Entscheidung möglich ist, sollten Banken berücksichtigen, dass FinTechs teilweise ambitioniertere KI Use Cases entwickeln. Banken können Kooperationen mit entsprechenden FinTechs als Alternative zur internen Use Case Entwicklung nutzen, zum Beispiel um Kundinnen und Kunden ein verbessertes Angebot zu bieten. Unabhängig von KI hat die Anzahl an Kooperationen zwischen Banken und FinTechs in den vergangenen Jahren stark zugenommen (Atzler 2018) und die kulturellen Unterschiede zwischen klassischen Banken und FinTechs hindern die Zusammenarbeit, wie vielleicht zu erwarten, nicht, sondern tragen im Gegenteil eher zu ihrem Erfolg bei. Drasch et al. (2018) unterscheiden zwischen sechs Clustern von Kooperationen zwischen Banken und FinTechs. Banken können demnach

- 1) für eine strategische Allianz in FinTechs investieren und somit den Zugang zu dem Ecosystem der FinTechs zu erhalten,
- 2) FinTechs akquirieren, um anschließend kanalspezifische Lösungen oder Interaktionsplattformen der FinTechs zu integrieren,
- 3) Kooperationen anstreben, um die Kreditvergabe der Bank zu optimieren,
- 4) Kooperationen anstreben, um Zugang zu neuen Investitionsmöglichkeiten zu bekommen. Hierbei wickelt die Bank Transaktionen des FinTechs ab und erhält somit Zugang zu dem Ecosystem des FinTechs,
- 5) Services von FinTechs nutzen, um Kundenprozesse zu innovieren, häufig in Form von technischen Neuerungen,
- 6) mit FinTechs in Frühphasen zusammenarbeiten, um Zugriff auf Innovationen zu erhalten.

Für die Entwicklung und Integration von KI Use Cases sind vor allem Strategien der Cluster 2, 5 und 6 relevant. Demnach können Banken FinTechs akquirieren, ihre Dienstleistungen in Anspruch nehmen oder in Kooperation technische Innovationen vorantreiben. Beispiele hierfür sind u.a. die Kooperation von mehreren Banken (z.B. comdirect, Deutsche Bank, DKB, HVB und ING-DiBa) mit gini im Bereich der Fotoüberweisung, die Kooperation der DKB mit FinTecSystems im Bereich des Online-Kreditabschluss (Cluster 3 oder Cluster 5) oder die Kooperation zwischen der Deutschen Bank und der dwins GmbH im Rahmen der Finanzguru-App (Cluster 6). Akquisitionen (Cluster 2) mit KI-Bezug sind aufgrund der geringen Reife des Feldes noch rar, jedoch ein zukunftsfähiges Konzept.

Insgesamt dürfen bei einer Kooperation mit FinTechs entsprechende Hürden nicht vernachlässigt werden: Während die technische Einbindung über Schnittstellen häufig innerhalb weniger Wochen möglich ist, kann die Erfüllung von regulatorischen Vorgaben durchaus bis zu einem Jahr beanspruchen. Vor allem auch deshalb, weil die Gesamtverantwortung für einen Use Case am Ende bei den Banken liegt. Die Interviewten bemerken zudem, dass die von FinTechs entwickelten Datenmodelle häufig nicht auf die bankeigenen Daten anwendbar bzw. allgemein nicht auf entsprechende Daten

ausgelegt sind. Damit steht die Bank vor der Herausforderung, eigene Lösungen entwickeln zu müssen. Im Bereich KI bilden erfolgreiche Kooperationen zwischen FinTechs und Banken deshalb aktuell noch die Ausnahme.

Handlungsprämissen für den Erfolg von KI-Projekten

Um die Potenziale von KI nutzen und den Kunden damit die zuvor beschriebenen Begeisterungsmerkmale bieten zu können, müssen die Banken ihr Wertversprechen neu denken. Nur so kann es diesen gelingen, langfristig relevant zu bleiben. Auf Basis unserer Analyse haben wir drei grundlegende, teilweise ineinandergreifende Handlungsprämissen für den wertschaffenden Einsatz von KI im Retail Banking abgeleitet.

1. Der Mehrwert für die Kundinnen und Kunden muss klar erkennbar sein

Während die GAFA-Unternehmen (Google, Apple, Facebook, Amazon) mit ihrem Angebot Kundenbedürfnisse wecken und die Datenfreigabe durch Kundinnen und Kunden deutlich weniger restriktiv stattfindet, reagieren Banken eher auf bereits bestehende Kundenbedürfnisse. So zeichneten die Interviewten beim Thema Kundenausrichtung ein sehr differenziertes Bild vom aktuellen Verständnis der Möglichkeiten, die sich für Retailbanken durch KI ergeben: Laut Aussage der Befragten setzen viele Unternehmen KI im Kundenkontakt vor allem mit der Möglichkeit gleich, personalisierte Werbung schalten zu können. Als Vorbild dienen hier zum Beispiel Social Media Plattformen. Im Gegensatz zu eben diesen Plattformen schaffen es die Retailbanken allerdings aktuell noch nicht, ihren Kundinnen und Kunden einen direkten Mehrwert durch den Einsatz von KI aufzuzeigen, sondern begnügen sich damit, ihre weiterhin standardisierten Bankprodukte bestenfalls zielgerichteter anzubieten. Im Gegenzug sind die Kundinnen und Kunden deshalb häufig nicht bereit, ihre Daten zur Verfügung zu erstellen. **Banken haben es bisher nicht geschafft, die Vorteile von KI-Anwendungen an ihre Kundinnen und Kunden zu kommunizieren beziehungsweise diese notwendigen Vorteile zu schaffen.**

„Denkbar wären hier im einfachsten Fall beispielsweise unterschiedliche Produkte für Kundinnen und Kunden, die ihre Daten zur Verfügung stellen als für solche, die dies eben nicht tun. Dabei können neben variierenden Preisen auch andere Mehrwerte für den Kunden Anreiz genug sein.“
– Dr. Werner Steck

Banken müssen es deshalb schaffen, **weniger aus ihrer Produktperspektive zu denken**, sondern vielmehr die **Bedürfnisse der Kundinnen und Kunden in den Mittelpunkt** zu stellen: Erhalten diese auf ihre Bedürfnisse und Interessen maßgeschneiderte Anlageempfehlungen oder Möglichkeiten der Altersvorsorge, werden sie eher bereit sein, personenbezogene Daten freizugeben. Beispielsweise werden Präferenzen, die das Wertesystem der Kundinnen und Kunden (z.B. gegen

Waffenhandel und gegen das Abholzen des Regenwalds) abbilden, schon heute in Suchmasken für Anlageprodukte abgefragt und bereitwillig angegeben. Gespeichert und weiterverarbeitet werden diese Daten in der Regel allerdings nicht. Wichtig ist dabei außerdem, dass es für die erfolgreiche Implementierung von Use Cases nicht auf die Verfügbarkeit von vielen Daten einer einzelnen Person ankommt, sondern vielmehr die Anzahl an Personen, die ihre Daten zur Verfügung stellen, entscheidend ist.

Die fehlende Bereitschaft für die Freigabe der Daten führt bei Banken zu Schwierigkeiten, innovative Use Cases zu entwickeln. Für die Kundinnen und Kunden erschließt sich die Notwendigkeit der Freigabe von Daten an ein bisher nicht datengetriebenes Geschäftsmodell jedoch nicht. Aktuell scheinen die Banken hier noch in einem Teufelskreis festzustecken. **Dennoch sollte Innovation aus der Bank kommen – nicht erst von Kundinnen und Kunden gefordert werden.**



Abbildung 8: Problemstellung der Use Case Entwicklung

Während Kundenanforderungen individuell sind, gibt es bisher in der Bankenbranche nur wenige Bestrebungen entsprechend angepasste Services und Produkte zur Verfügung zu stellen. **Eine individualisierte Ansprache von Kundinnen und Kunden, unabhängig von KI, ist der erste notwendige Schritt.** Erst ein entsprechendes Verständnis in Banken kann die Entwicklung von erfolgreichen Use Cases ermöglichen.

2. Der Use-Case-getriebene Ausbau der Infrastruktur dient als Zwischenziel auf dem Weg zum KI-basierten Bankenökosystem

Eine kundenzentrierte Orientierung ist bisher auch in der Organisation von IT-Systemen in Banken nicht vorhanden. Alte, monolithische Systeme verhindern aufgrund ihrer technischen Struktur eine leicht umzusetzende Flexibilisierung, zum Beispiel eine Ausrichtung der Prozesse entlang der Customer Journey, und hemmen somit auch Umsetzungen von KI Use Cases in diesem Bereich. Gleichzeitig ist die Komplexität der IT so hoch, dass eine komplette Modernisierung oder auch schon eine Änderung der bestehenden Infrastruktur mit erheblichen Investitionen verbunden wäre. Use Cases scheitern somit bereits an der mangelnden Verfügbarkeit von qualitativ hochwertigen, maschinenlesbaren Daten. Ziel sollte hier eine Vertikalisierung der IT sein: Dabei wird das System in fachlich-abgegrenzte Teilsysteme aufgeteilt, die technisch voneinander unabhängig sind. Diese so genannten Self Contained Systems können dann modular weiterentwickelt werden und ermöglichen somit eine vereinfachte Anpassung der Gesamtarchitektur an die Anforderungen von neu verwendeten Technologien.

Diese Herausforderungen nennen auch die befragten Expertinnen und Experten: historisch gewachsene IT-Systeme (Legacy-IT) hemmen in Retailbanken die Entwicklung KI-getriebener Use Cases. Die befragten Banken hatten zwei grundlegend verschiedene Ansätze mit diesem Problem im Kontext der Use Case Entwicklung umzugehen:

- 1) Aufbau eines Data Lakes, bei dem entsprechende Daten regelmäßig aus dem Kernsystem extrahiert werden (inkl. einer schrittweisen Weiterentwicklung der Legacy IT). Nach Bereitstellung des Data Lakes werden schließlich Use Cases entwickelt.
- 2) Entwicklung von Use Cases unabhängig von Datenverfügbarkeit und Infrastruktur. Für die Use Cases notwendige, spezifische Daten können am Ende der Entwicklung nur mit vergleichsweise hohem Aufwand erhoben werden.

Besonders der Aufbau eines Data Lakes stellt aus Management-Perspektive ein Risiko dar: **Der kostenintensive Aufbau eines Data Lakes beinhaltet zunächst noch keinen Mehrwert für die Business-Seite.** Kosten und der zeitliche Aufwand für den Aufbau eines Data Lakes stehen zunächst in keinem Verhältnis zum losgelösten Mehrwert für das Geschäftsmodell. Die Interviewten bestätigten, dass der Aufbau eines Data Lakes oftmals eines der ersten Projekte ist, die von Banken bei unternehmensweiten Sparmaßnahmen beendet werden.

Aber auch der zweite Ansatz birgt einige Probleme: **Eine ausschließliche Entwicklung von Use Cases ohne entsprechende, zeitgleiche Verbesserung der Datenverfügbarkeit verschiebt nur das grundsätzliche Problem von Legacy-IT in Banken.** Der Ansatz führt dazu, dass zwar experimentelle Use Cases entwickelt werden können und entsprechendes Know-how aufgebaut werden kann.

Die Use Cases können jedoch im Live-Betrieb häufig nicht umgesetzt werden, da die Datenverfügbarkeit oder die komplette Infrastruktur nicht in ausreichender Qualität vorliegt. Außerdem wird die Komplexität der gesamten IT-Infrastruktur durch die Umsetzung von Use Case spezifischen Insellösungen nur weiter erhöht.

Ein stufenweises Vorgehen von Use-Case-Entwicklung und IT-Modernisierung erscheint deshalb als probater Mittelweg:




Abbildung 9: Entwicklung einer integrierten KI-Infrastruktur

Für den Mittelweg zwischen dem Aufbau eines Data Lakes und Fokussierung auf die Use Case Entwicklung muss es zunächst gelingen, Use Cases zu identifizieren, die geringere Anforderungen an die Datenverfügbarkeit stellen und dementsprechend mit der aktuellen Infrastruktur auch tatsächlich bereits umgesetzt werden können. Auch ausgefallener Use Cases können im Anschluss leicht getestet werden, solange die entsprechenden Projekte ein geringes Budget und Laufzeit voraussetzen. Dies ermöglicht einen kontinuierlichen Know-how-Aufbau, selbst wenn die Entwicklung eines Use Cases fehlschlagen sollte.

Basierend auf erfolgreichen Use Cases können mögliche Verbesserungen von Datenverfügbarkeit und Infrastruktur identifiziert werden, und anschließend in kleineren Projekten umgesetzt werden. Vorteil hierbei ist der Verzicht auf riskante IT-Großprojekte und die Möglichkeit, bereits mit ersten Use Cases einen Businessnutzen zu erzielen. Voraussetzung für ein entsprechend stufenweises Vorgehen ist die Analyse der bestehenden Systemlandschaft hinsichtlich ihrer notwendigen Flexibilität und die Entwicklung eines strategischen Zielbildes. Das ursprüngliche Legacy Core Banking System entwickelt sich so mittel- bis langfristig zu einem **KI-basierten Bankenökosystem**.

3. Ein funktionierendes IT-Projektmanagement ist weiterhin Grundlage für den Erfolg von KI Use Cases

Die interne Organisation der Projektteams zur Entwicklung von Use Cases kann zum Beispiel klassisch über die Wasserfallmethode oder durch agile Methoden geschehen. Der starke Fokus auf den Austausch aller beteiligten Parteien und die nicht klar einzugrenzende Rollen innerhalb des Kernteams führen allerdings innerhalb der befragten Banken zu einem insgesamt agilen Ansatz. Die Teams arbeiten meist unabhängig von strikt festgelegten Vorgaben, auch innerhalb der Projekte sind die meisten Rollen nicht klar abgegrenzt. Drei kritische Faktoren wurden in den Interviews mehrfach genannt:

- 1) Lösungsorientierte Einbindung der Complianceabteilung
- 2) Kontinuierlicher Austausch mit den Geschäftsbereichen
- 3) Einsatz von Data Scientists

Die Einbindung der Complianceabteilung ist unter anderem wegen des branchenspezifischen großen Einflusses der regulatorischen Vorgaben auf das übergreifende Geschäftsmodell und auch auf KI-Projekte, sowie eine entsprechende Risikoevaluierung, notwendig. Während Datenschutzbestimmungen auch in anderen Branchen eingehalten werden müssen, nehmen besonders die befragten Retailbanken die Verarbeitung personenbezogener Daten als hohes regulatorisches Risiko wahr: Dies befeuert generelle Zweifel an der Umsetzbarkeit von KI Use Cases. Der rechtliche Rahmen der Speicherung, des Zugriffs und weitergehenden Verwendung von Daten muss in KI-Projekten grundsätzlich von Anfang an beachtet werden. **Die Verwendung von personenbezogenen Daten macht dabei eine starke Einbindung der Complianceabteilungen unabdingbar.** Die befragten Expertinnen und Experten unterstrichen, dass klare und verständliche Richtlinien der Complianceabteilungen die (datenbezogenen) Grundlagen für KI-Projekte darstellen. Dabei sollte ein fester Prozess zur Prüfung der Nutzung von Daten eingeführt werden.

Äquivalent zu anderen Branchen ist der kontinuierliche Austausch und auch die direkte Einbindung der kundenbezogenen Geschäftsbereiche bereits bei der Ideensammlung ein Erfolgskriterium für KI-Projekte. Wie bereits im Unterkapitel zu den Use Cases angeführt, kann für eine erste Ideensammlung zunächst unter Wissensträgerinnen und -trägern gearbeitet werden, welche die Problemstellungen der kundenbezogenen Geschäftsbereiche gut kennen. Während der konkreten Entwicklung der Use Cases ist nach Aussage der Interviewten allerdings ein kontinuierlicher und direkter Austausch zwischen Entwicklungsteam und den Mitarbeitenden der Geschäftsbereiche zentral für den Erfolg eines KI-Projekts.

Innerhalb des Projektteams haben die befragten Expertinnen und Experten den Einsatz von Data Scientists als kritischen Erfolgsfaktor ausgemacht: Data Scientists erfassen für KI-Modelle Probleme der Fachseite und leiten aus ihnen konkrete Use Cases ab, verstehen Daten und bereiten diese auf, entwickeln und evaluieren Datenmodelle und können schlussendlich auch bei der Überführung in den Live-Betrieb unterstützen. **Der Einsatz von Data Scientists ist kritisch für den Erfolg von KI-Projekten.**

Zusammenfassung der Handlungsprämissen

Zusammenfassend sollten Retailbanken die folgenden vier Kernbereiche und Handlungsprämissen für eine erfolgreiche Umsetzung von KI-Projekten beachten: Schon während der **initialen Entwicklung von Use Cases** sollten sie von einer bisher produktzentrischen zu einer kundenzentrischen Perspektive übergehen. Durch die **Personalisierung von Angeboten** und das Herausstellen der entsprechenden Mehrwerte können Banken der geringen Bereitschaft der Kundinnen und Kunden zur Datenfreigabe entgegenwirken. Die Implementierung von KI setzt jedoch eine gewisse Infrastruktur in den Banken voraus. Zur Vermeidung von potentiellen Komplexitäten sollten Retailbanken daher vor Projektbeginn die bestehenden **IT-Systeme hinsichtlich ihrer notwendigen Flexibilität evaluieren**. Durch kleinere Projekte können KI Use Cases stufenweise entwickelt und die bestehende Infrastruktur so entsprechend ausgebaut werden. Abschließend ist für den effektiven Einsatz von KI im Retail-Banking auch ein agiles **Projektmanagement** unter Einbezug der entsprechenden Know-how-Tragenden verschiedener Hintergründe unerlässlich. Neben der Kombination aus Data Science-, Entwicklungs- und Produkt-Know-how sollte insbesondere auch die interne Compliance-Abteilung frühzeitig für rechtliche Fragestellungen in die Projekte eingebunden werden. Insgesamt sind die genannten Prämissen nicht isoliert voneinander zu betrachten, sondern greifen ineinander und können als möglicher Erfolgspfad für die Nutzung von KI in Retailbanken dienen.

Literaturverzeichnis

Andrew Ng (2017): Why AI Is the New Electricity. Online verfügbar unter <https://www.gsb.stanford.edu/insights/andrew-ng-why-ai-new-electricity>, zuletzt aktualisiert am 13.06.2020, zuletzt geprüft am 13.06.2020.

Atzler, Elisabeth (2018): Fast jede große Bank arbeitet mit Fintechs zusammen. Hg. v. Handelsblatt. Online verfügbar unter <https://www.handelsblatt.com/finanzen/banken-versicherungen/finanz-start-ups-fast-jede-grosse-bank-arbeitet-mit-fintechs-zusammen/22076378.html?ticket=ST-4190945-XUq3bcuCGOeLh4tnjVEo-ap1>.

Ayodele, T. O. (2010): Types of Machine Learning Algorithms. New Advances in Machine Learning. Unter Mitarbeit von Yagang Zhang (Ed.). Hg. v. InTech. University of Portsmouth. Online verfügbar unter <http://www.intechopen.com/books/new-advances-in-machine-learning/types-of-machine-learning-algorithms>.

BaFin (Hg.) (2018): Big Data trifft auf künstliche Intelligenz. Herausforderungen und Implikationen für Aufsicht und Regulierung von Finanzdienstleistungen. Online verfügbar unter https://www.bafin.de/SharedDocs/Downloads/DE/dl_bdai_studie.pdf?__blob=publicationFile&v=9, zuletzt geprüft am 07.05.2020.

Berente, Nicholas; Gu, Bin; Recker, Jan; Santhanam, Radhika (2019): Managing AI. Call for Papers. Hg. v. MISQ. Online verfügbar unter <https://misq.org/skin/frontend/default/misq/pdf/CurrentCalls/ManagingAI.pdf>, zuletzt geprüft am 05.05.2020.

Biggio, Battista; Nelson, Blaine; Laskov, Pavel: Poisoning attacks against support vector machines. In: Proceedings of the 29th International Conference on Machine Learning (ICML 2012), S. 1467–1474. Online verfügbar unter <https://arxiv.org/pdf/1206.6389>, zuletzt geprüft am 26.07.2020.

bitkom (Hg.) (2019): Digital Finance - wie die Digitalisierung die Finanzbranche verändert. Online verfügbar unter https://www.bitkom.org/sites/default/files/2019-05/bitkom-prasentation_digital_finance_21_05_2019_final.pdf.

Bundesbank (Hg.) (2020): PSD2. Online verfügbar unter <https://www.bundesbank.de/de/aufgaben/unbarer-zahlungsverkehr/psd2/psd2-775434>, zuletzt aktualisiert am 13.05.2020, zuletzt geprüft am 13.05.2020.

Bundesregierung (Hg.) (2018): Eckpunkte der Bundesregierung für eine Strategie Künstliche Intelligenz. Online verfügbar unter https://www.bmbf.de/files/180718%20Eckpunkte_KI-Strategie%20final%20Layout.pdf, zuletzt geprüft am 31.05.2020.

Charlier, Jeremy; Ormazabal, Gaston; State, Radu; Hilger, Jean (2020): MQLV: Optimal Policy of Money Management in Retail Banking with Q-Learning. In: Valerio Bitetta, Ilaria Bordino und Andrea Ferretti (Hg.): Mining Data for Financial Applications. 4th ECML PKDD Workshop, MIDAS 2019, Würzburg, Germany, September 16, 2019, Revised Selected Papers. Cham, 2020. 1st ed. 2020. Cham: Springer International Publishing (Lecture Notes in Artificial Intelligence), S. 1–15.

Deutsche Bundesbank (Hg.) (2018): Bankstellenstatistik 2018. Online verfügbar unter <https://www.bundesbank.de/resource/blob/800734/a8026937292a341ea665d5cd8325c783/mL/bank-stellenstatistik-2018-data.pdf>, zuletzt geprüft am 14.06.2020.

Drasch, Benedict J.; Schweizer, André; Urbach, Nils (2018): Integrating the ‘Troublemakers’: A taxonomy for cooperation between banks and fintechs. In: Journal of Economics and Business 100, S. 26–42. DOI: 10.1016/j.jeconbus.2018.04.002.

Fine, Terrence L. (1999): Feedforward Neural Network Methodology. New York, NY: Springer-Verlag New York Inc (Information Science and Statistics). Online verfügbar unter <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10002178>, zuletzt geprüft am 01.06.2020.

Ghahramani, Zoubin (2004): Unsupervised Learning. In: Olivier Bousquet, Ulrike Luxburg und Gunnar Rätsch (Hg.): Advanced Lectures on Machine Learning. ML Summer Schools 2003, Canberra, Australia, February 2 - 14, 2003, Tübingen, Germany, August 4 - 16, 2003, Revised Lectures. Berlin, Heidelberg: Springer (Lecture Notes in Computer Science, 3176), S. 72–112.

Guggenberger, Nikolas (2019): Datenverarbeitung durch Banken im Endkundengeschäft: Grundsätze, Forderungsabtretung und Scoring. In: Zeitschrift für Bankrecht und Bankwirtschaft 31 (4), S. 254–261. DOI: 10.15375/zbb-2019-0405.

Hagendorff, Thilo; Wezel, Katharina (2020): 15 challenges for AI: or what AI (currently) can’t do. In: AI & Society 35 (2), S. 355–365. DOI: 10.1007/s00146-019-00886-y.

Hofmann, Peter; Jöhnk, Jan; Protschky, Dominik; Stähle, Philipp; Urbach, Nils; Buck, Christoph (2020a): KI-Anwendungsfälle zielgerichtet identifizieren. In: Wirtschaftsinformatik & Management 12 (3), S. 184–193. DOI: 10.1365/s35764-020-00257-z.

Hofmann, Peter; Jöhnk, Jan; Protschky, Dominik; Urbach, Nils (2020b): Developing Purposeful AI Use Cases - A Structured Method and Its Application in Project Management. In: Gronau, Heine et al. (Hg.) 2020 – WI2020 Zentrale Tracks 2020, S. 33–49. Online verfügbar unter <https://www.semanticscholar.org/paper/Developing-Purposeful-AI-Use-Cases-A-Structured-and-Hofmann-J%C3%B6hnk/c37ddc7e6bb193ecc4cb8bdc2cb3d226b4e68a40>, zuletzt geprüft am 01.06.2020.

Jia, Robin; Liang, Percy (2017): Adversarial Examples for Evaluating Reading Comprehension Systems. In: Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, S. 2021–2031. DOI: 10.18653/v1/D17-1215.

Kaplan, Andreas; Haenlein, Michael (2019): Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. In: Business Horizons 62 (1), S. 15–25. DOI: 10.1016/j.bushor.2018.08.004.

Kozyreva, Anastasia; Herzog, Stefan; Lorenz-Spreen, Philipp; Hertwig, Ralph; Lewandowsky, Stephan (2020): Artificial Intelligence in Online Environments. Representative Survey of Public Attitudes in Germany. Hg. v. Max Planck Institute for Human Development. Online verfügbar unter https://pure.mpg.de/rest/items/item_3188061_4/component/file_3195148/content, zuletzt geprüft am 01.09.2020.

Mai, Heike (2018): PSD 2, Open Banking und der Wert personenbezogener Daten. Hg. v. Deutsch Bank Research. Online verfügbar unter http://www.zbw.eu/econis-archiv/bitstream/handle/11159/2824/PSD_2_Open_Banking_und_der_Wert_personenbezogener.PDF?sequence=1, zuletzt geprüft am 13.05.2020.

Marsland, Stephen (2015): Machine learning. An algorithmic perspective. Second edition. Boca Raton, FL: CRC Press (Chapman & Hall / CRC machine learning & pattern recognition series).

Rai, Arun; Constantinides, Panos; Sarker, Saonee (2019): Next generation digital platforms : toward human-AI hybrids. In: MIS Quarterly 44 (1), S. iii–ix. Online verfügbar unter <http://wrap.warwick.ac.uk/113653/>, zuletzt geprüft am 01.07.2020.

Reinsel, David; Gantz, John; Rydning, John (2018): The Digitization of the World. From Edge to Core. Hg. v. International Data Corporation. Online verfügbar unter <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>, zuletzt geprüft am 27.06.2020.

Rid, Artem (2019): Five Milestones in the Evolution of Practical A.I. - Towards Data Science. In: Towards Data Science, 23.11.2019. Online verfügbar unter <https://towardsdatascience.com/five-milestones-in-the-evolution-of-practical-a-i-436624d56a94>, zuletzt geprüft am 07.05.2020.

Russell, Stuart J.; Norvig, Peter; Davis, Ernest; Edwards, Douglas (2016): Artificial intelligence. A modern approach. Third edition, Global edition: Pearson (Always learning).

Samek, Wojciech; Montavon, Grégoire; Vedaldi, Andrea (2019): Explainable AI: Interpreting, Explaining and Visualizing Deep Learning. Interpreting, explaining and visualizing deep learning. 1st ed. 2019 (Lecture Notes in Artificial Intelligence).

Schmidhuber, Juergen (2015): Deep Learning in Neural Networks: An Overview. In: Neural Networks 61, S. 85–117. DOI: 10.1016/j.neunet.2014.09.003.

Schneider, Katharina (2018): KI in der Finanzbranche: Wo Banken und Versicherer stehen – und wo sie hin wollen. Hg. v. Handelsblatt. Online verfügbar unter <https://www.handelsblatt.com/finanzen/banken-versicherungen/dossier-zum-download-ki-in-der-finanzbranche-wo-banken-und-versicherer-stehen-und-wo-sie-hinwollen/23863062.html?ticket=ST-3132917-v9WW7HYqaN-glrcqXM4HI-ap3>, zuletzt geprüft am 13.06.2020.

Siddique, Nazmul; Adeli, Hojjat (2013): Computational Intelligence. Synergies of Fuzzy Logic, Neural Networks Intelligent Systems and Applications. 1. Aufl. s.l.: Wiley. Online verfügbar unter <http://gbv.ebib.com/patron/FullRecord.aspx?p=1160768>, zuletzt geprüft am 01.06.2020.

Simonite, Tom (2016): How Google Plans to Solve Artificial Intelligence. Hg. v. MIT Technology Review. Online verfügbar unter <https://www.technologyreview.com/2016/03/31/161234/how-google-plans-to-solve-artificial-intelligence/>, zuletzt geprüft am 13.06.2020.

Statista (Hg.) (2018): Anzahl der Direktbank-Kunden in Deutschland in den Jahren 2000 bis 2017 mit einer Prognose für 2020. Online verfügbar unter <https://de.statista.com/statistik/daten/studie/186890/umfrage/anzahl-der-direktbank-kunden-in-deutschland-bis-2015/>, zuletzt geprüft am 15.06.2020.

Stone, Peter; Brooks, Rodney; Brynjolfsson, Erik; Calo, Ryan; Etzioni, Oren; Hager, Greg et al. (2016): Artificial Intelligence and life in 2030. One hundred year study on Artificial Intelligence - Report of the 2015 study panel. Hg. v. Stanford University. Stanford. Online verfügbar unter https://ai100.sites.stanford.edu/sites/g/files/sbiybj9861/f/ai100report10032016fnl_singles.pdf, zuletzt geprüft am 05.05.2020.

Sutton, Richard S.; Barto, Andrew (2018): Reinforcement learning. An introduction. Second edition. Cambridge, MA, London: The MIT Press (Adaptive computation and machine learning).

Sze, Vivienne; Chen, Yu-Hsin; Yang, Tien-Ju; Emer, Joel S. (2017): Efficient Processing of Deep Neural Networks: A Tutorial and Survey. In: Proceedings of the IEEE 105 (12), S. 2295–2329. DOI: 10.1109/JPROC.2017.2761740.

Wiedmann, Klaus-Peter; Buckler, Frank (Hg.) (2003): Neuronale Netze im Marketing-Management. Praxisorientierte Einführung in modernes Data-Mining. 2., überarbeitete Auflage. Wiesbaden, s.l.: Gabler Verlag.

Zhao, Zhong-Qiu; Zheng, Peng; Xu, Shou-Tao; Wu, Xindong (2019): Object Detection With Deep Learning: A Review. In: IEEE Transactions on Neural Networks and Learning Systems 30 (11), S. 3212–3232. DOI: 10.1109/TNNLS.2018.2876865.

Über die Verfassenden



Dr. Werner Steck ist Partner bei Senacor in Frankfurt und beschäftigt sich seit Jahren mit der Frage, wie sich neue Technologien auf das Bankgeschäft auswirken und wie sie sich anwenden lassen, um für das Unternehmen, aber auch für die Kunden Nutzen zu stiften. Er ist seit 2003 bei Senacor tätig und promovierte an der Universität Augsburg in Wirtschaftsinformatik.

werner.steck@senacor.com



Christian Wolfangel ist Partner bei Senacor in Bonn und verfügt über mehr als 15 Jahre Erfahrung in der Beratung. Der diplomierte Informatiker hat sich auf die digitale Transformation von Banken und Versicherern spezialisiert. Einer seiner Fokusthemen sind datengetriebene Geschäftsmodelle. Zu seinen Schwerpunkten zählen zudem die digitale Prozess- und Produktentwicklung. Er ist seit 2005 bei Senacor tätig.

christian.wolfangel@senacor.com



Prof. Dr. Gilbert Fridgen ist Inhaber des PayPal FNR-PEARL Lehrstuhls in Digital Financial Services am Interdisciplinary Centre for Security, Reliability and Trust der Universität Luxemburg. Außerdem ist er Mitgründer des Fraunhofer BlockchainLab. Als Leiter der Financial Services and Interorganizational Digital Transformations Research Group (FINATRAX) analysiert er die transformativen Auswirkungen digitaler Technologien auf einzelne Organisationen sowie auf das Verhältnis zwischen Organisationen. Dabei geht er insbesondere auf potenziell disruptive Technologien wie Blockchain/DLT, Künstliche Intelligenz, Internet der Dinge oder Quantencomputing ein.

gilbert.fridgen@uni.lu



Marc-Fabian Körner ist wissenschaftlicher Mitarbeiter und Doktorand am Kernkompetenzzentrum Finanz- und Informationsmanagement (FIM) und der Projektgruppe Wirtschaftsinformatik des Fraunhofer FIT. In seiner Forschung beschäftigt er sich unter anderem mit der disruptiven Wirkung digitaler Technologien auf verschiedenen Märkten, bspw. Finanz- und Energiemärkten.

marc.koerner@fim-rc.de



Alexander Stohr ist wissenschaftlicher Mitarbeiter und Doktorand am FIM und der Projektgruppe Wirtschaftsinformatik des Fraunhofer FIT. In seiner Forschung beschäftigt er sich insbesondere mit der Adoption emergenter Technologien, wie z.B. Blockchain und Künstliche Intelligenz, und deren sozio-technischen Implikationen.

alexander.stohr@fim-rc.de



Vadim Răgo ist wissenschaftlicher Mitarbeiter und Doktorand am Lehrstuhl in Digital Financial Services des Interdisciplinary Centre for Security, Reliability and Trust der Universität Luxemburg SnT. In seiner Forschung beschäftigt er sich unter anderem mit den Anwendungspotentialen und Auswirkungen von digitalen Technologien im Finanzsektor.

vadim.raego@uni.lu

Impressum

Herausgeber:

Fraunhofer-Institut für Angewandte Informationstechnik FIT
Projektgruppe Wirtschaftsinformatik
Universitätsstr. 12
86159 Augsburg

Senacor Technologies AG
Düsseldorfer Straße 13
65760 Eschborn

Autoren:

Interdisciplinary Centers for Security, Reliability and Trust, Universität Luxemburg
Projektgruppe Wirtschaftsinformatik des Fraunhofer-Instituts für Angewandte Informationstechnik FIT
Senacor Technologies AG

Stand:

März 2021

Copyright:

Senacor Technologies AG
Fraunhofer-Institut für Angewandte Informationstechnik FIT

Empfohlene Zitierweise:

Fridgen, G., Körner, M.-F., Rägo, V., Steck, W., Stohr, A. und Wolfangel, C. 2021. Einsatz von KI im Retail Banking – Eine praxisorientierte Studie. Augsburg, Eschborn: Projektgruppe Wirtschaftsinformatik des Fraunhofer-Instituts für Angewandte Informationstechnik FIT und Senacor Technologies AG.

Bildnachweise:

Shutterstock, Kindersps, <https://www.shutterstock.com/de/g/Kindersps>

Shutterstock, laremenko Sergii, <https://www.shutterstock.com/de/g/laremenko+Sergii>

Shutterstock, metamorworks, <https://www.shutterstock.com/de/g/chombosan>

SENACOR

Senacor Technologies AG

Düsseldorfer Straße 13 | 65760 Eschborn | www.senacor.com

Fraunhofer-Institut für Angewandte Informationstechnik FIT

Projektgruppe Wirtschaftsinformatik | Universitätsstr. 12 | 86159 Augsburg