

Data Science im Wertpapierhandel - Anwendungsfälle und Auswirkungen auf die praktizierenden Unternehmen

Nick Köhle

Hochschule Pforzheim
Tiefenbronner Straße 65
75175 Pforzheim
koehleni@hs-pforzheim.de

Frank S. Morelli

Hochschule Pforzheim
Tiefenbronner Straße 65
75175 Pforzheim
Frank.Morelli@hs-pforzheim.de

ABSTRACT

Der vorliegende Artikel stellt den Einsatz von Data Science im Wertpapierhandel anhand von zwei Anwendungsfällen, „Robo-Advice“ und „Algorithmischer Handel“, vor. Im weiteren Verlauf werden die Auswirkungen auf die praktizierenden Unternehmen in den Bereichen IT-Infrastruktur, Personal und Organisation sowie Governance und Compliance beschrieben. Am Ende des Artikels erfolgt eine Gegenüberstellung der hieraus resultierenden Chancen und Risiken bzw. Grenzen.

SCHLÜSSELWÖRTER

Wertpapierhandel, Data Science, Robo Advice, Algorithmischer Handel

EINLEITUNG

Die Finanzbranche befindet sich im Umbruch. Durch die Digitalisierung werden Verbesserungen in den Geschäftsbereichen und Kostensenkungen versprochen. Demgegenüber wirken Regulierungsanforderungen und regionale Risiken, wie z.B. geopolitische Unsicherheiten oder die Niedrigzinsphase, erschwerend auf das Geschäftsumfeld der Unternehmen ein. Zusätzlich fordern technologiegetriebene Wettbewerber das Umfeld der etablierten Wettbewerber heraus. Dadurch sinkt die Rentabilität der klassischen Geschäftsmodelle und eine Anpassung bzw. Veränderung dieser wird immer wichtiger (Liermann und Stegmann 2019).

Durch sein erhebliches Volumen ist insbesondere der Wertpapierhandel ein attraktiver Finanzsektor mit viel Potenzial in Bezug auf Effizienzsteigerung und Kostenoptimierung. Allein der weltweite Aktienhandel betrug im Jahr 2018 rund 142 Billionen US-Dollar (USD) (Statista 2019). Dabei tätigen immer mehr Maschinen die zugehörigen Investitionen: Mit bis zu 80% üben diese einen großen Einfluss auf die Geschehnisse an den Märkten aus (Li 2019). Der Einsatz von Technologien im Bereich Data Science (DS) ist daher ein zentrales Thema.

Bei DS handelt es sich um eine Disziplin, die verschiedene Fachgebiete, wie Statistik, Informatik und Entscheidungstheorie beinhaltet, Daten als zentrales Element einsetzt und in der verschiedene Technologien Anwendungen finden. Bezüglich der genauen Definitionen und praktischen Einsatzmöglichkeiten von DS sowie den dazugehörigen Themenfeldern und Technologien gibt es unterschiedliche Auffassungen und Akzentuierungen, was wiederum zu erheblichen

Überschneidungen bei den Inhalten führt (Rabasa und Heavin 2020). Generell werden Künstliche Intelligenz (KI, engl.: Artificial Intelligence) und Maschinelles Lernen (ML, engl.: Machine Learning) eingesetzt. Diese Ansätze ermöglichen es im Kontext von Big Data Muster zu erkennen und daraus Schlussfolgerungen zu ziehen, woraus sich Maßnahmen ableiten lassen. KI wird als Überbegriff für viele verschiedene Methoden und Technologien, die menschlichem Verhalten in Bezug auf Intelligenz ähneln, verwendet. ML als zugehörige Schlüsseltechnologie basiert auf Algorithmen, die durch kontinuierliches Überprüfen und Verbessern ihrer Ergebnisse Lernprozesse simulieren. Sie zielen auf die Entdeckung von Korrelationen in Datensätzen ab und erlauben so die Identifikation von darin enthaltenen Mustern. ML ist bei großen Datenmengen und heterogenen Datenbeständen sinnvoll einsetzbar (Aziz und Dowling 2019; Arslanian und Fischer 2019; Fraunhofer-Gesellschaft e.V. 2017).

Durch die immer besser werdenden Möglichkeiten im Bereich DS und der damit verbundenen Implementierung von ML-Technologien sind die Auswirkungen sowie Potenziale bezogen auf den Wertpapierhandel als hoch zu bewerten. Dies bietet sowohl Chancen als auch Risiken für die beteiligten Akteure. Der vorliegende Artikel beschäftigt sich deshalb mit der Forschungsfrage: „Wie wirkt sich DS im Wertpapierhandel auf die verschiedenen Bereiche der praktizierenden Unternehmen aus?“.

DATA SCIENCE IM WERTPAPIERHANDEL

Der Wertpapierhandel umfasst den Handel mit Wertpapieren in den Bereichen Kunden- und Eigenhandel. Der Kundenhandel umfasst die Vermögensberatung und -verwaltung sowie die Vermittlung von Wertpapieren für Kunden. Dabei tritt das verantwortliche Unternehmen „auf Rechnung von Kunden“ anstatt im eigenen Namen auf.

Der Eigenhandel wird dagegen auf „eigene Rechnung“ betrieben. Das bedeutet, dass ein Unternehmen Transaktionen mit Gewinnerzielungsabsichten betreibt und das damit verbundene Risiko trägt. Zugehörige Aktivitäten ähneln denen eines Portfoliomanagements im Kundenhandel. Jedoch ist im Eigenhandel ein umfangreicheres Regelwerk zu beachten und aufgrund der erhöhten Risiken ein angemessenes Risikomanagement erforderlich.

Die damit verbundenen Dienstleistungen werden von einer Vielzahl an Unternehmen angeboten. Dabei gibt es erhebliche Unterschiede in den jeweiligen Angebotsportfolios. Auch wenn sich die Aufgaben innerhalb der beiden Bereiche teilweise überlappen, ist im Unternehmen eine klare Trennung vorzunehmen. Diese ist räumlich einzuhalten und wird regelmäßig von den Aufsichtsbehörden überprüft. Durch die sogenannte „Chinese Wall“ versucht man einen Interessenskonflikt zwischen den Beteiligten im Kunden- und Eigenhandel zu vermeiden (Wohlschlägl-Aschberger 2015).

Abbildung 1 zeigt die unternehmenskritischen und wettbewerbsdifferenzierenden Kernprozesse in den praktizierenden Unternehmen. Diese werden oftmals von Unternehmen im Eigenhandel durchgeführt, sind aber auch im Kundenhandel vorzufinden. Die Bereiche Compliance und Risikomanagement sind nicht direkt im Hauptprozess, also von der Datenerhebung bis zum Monitoring, eingebunden, sondern als unterstützende Funktion zu interpretieren.




Abbildung 1: Kernprozesse im Handel mit Wertpapieren (Eigene Darstellung in Anlehnung an World Economic Forum 2015)

Durch die Digitale Transformation verändert sich das Umfeld der partizipierenden Unternehmen. Betroffen sind insbesondere traditionelle Banken. Nach dem Motto „Banking is necessary, banks are not“ (Bill Gates, 1994) (Bitterli 2016) drängen neue Akteure immer weiter in die Finanzbranche. Diese bestehen einerseits aus FinTechs, die durch innovative Ansätze Teile der Wertschöpfungskette reformieren, und andererseits aus BigTechs, die durch ihre technologische Überlegenheit und Kundennähe einen Vorteil aufweisen (Liermann und Stegmann 2019). Viele FinTechs möchten durch Kooperationen mit etablierten und anderen neuen Unternehmen den Markt verändern (Dapp 2017). Bei BigTechs handelt es sich um Technologie-Giganten, wie Google, Amazon, Facebook, Apple oder Tencent, die versuchen ihre Marktdurchdringung zu erweitern. Dabei sind viele

Akteure mit einem einzigen Angebot, oft im Payment-Bereich, in die Finanzbranche eingetreten und versuchen nach und nach mehr Finanzdienstleistungen, wie Kreditvergaben, Spareinlagen und Vermögensverwaltung, anzubieten (Capgemini und Efma 2020). Im Bereich der Near-Banks spielen insbesondere Investmentgesellschaften eine bedeutende Rolle: Diese investieren u.a. mit dem Vermögen von Anlegern anhand bestimmter Bedingungen in verschiedene Anlageklassen, meistens in Form eines Investmentfonds (Wohlschlägl-Aschberger 2015).

Zur Erschließung von Wettbewerbsvorteilen oder zur Einführung neuer Geschäftsmodelle spielen Menge, Geschwindigkeit und Qualität der Daten eine entscheidende Rolle (Reinsel, Gantz und Rydning 2018; Keller 2019). Das Datenvolumen wird in den kommenden Jahren im Finanzdienstleistungsbereich erheblich steigen: Betrug im Jahr 2018 die Datenmenge dort 2,078 ZB, ist zu erwarten, dass diese proportional zum globalen Datenwachstum ansteigt. Durch die hohe Anzahl an Transaktionen und den verwendeten Modellen bzw. Algorithmen werden im Finanzdienstleistungsbereich tendenziell sogar mehr Daten erzeugt und gespeichert als in anderen Geschäftsfeldern (Adeyeri 2015; Reinsel, Gantz und Rydning 2018). Entsprechend beinhaltet der Einsatz von DS im Wertpapierhandel ein großes Chancenpotenzial. Dieses wird im Folgenden anhand zweier Use Cases dargestellt: „Robo-Advice“, das im Kundenhandel Anwendung findet, und „Algorithmischer Handel“ (AH), der mehrheitlich im Eigenhandel eingesetzt wird.

Robo Advice

Der Begriff Robo-Advice subsummiert die digitale Anlageberatung und Vermögensverwaltung. Merkmale dabei sind das vollständige oder teilweise Fehlen von menschlichen Eingriffen und das Algorithmen-basierte Angebot an Dienstleistungen (Bundesanstalt für Finanzdienstleistungsaufsicht 2020). Ein Robo-Advisor repräsentiert ein Unternehmen, das diese Art von Finanzdienstleistungen anbietet (Seidel 2017). Abb. 2 zeigt den zugehörigen, typischen Geschäftsprozess. Dieser beinhaltet die Vermögensaufnahme und -analyse vom Kundenfragebogen über das Anlage-Risikoprofil bis zum Profil-Portfolio-Abgleich, sowie die Neugewichtung des Portfolios (Tonderau, van Gysegem und Bohlke 2019).

Zwischen den Robo-Advisors gibt es erhebliche Unterschiede hinsichtlich des angebotenen Dienstleistungsspektrums, der anfallenden Gebühren und der verwendeten Algorithmen. Auch die Auswahl der börsengehandelten Fonds, die Portfoliooptimierung, die Klassifizierung von Vermögenswerten und die Neugewichtung sind

i.d.R. unterschiedlich. Je nach Anbieter werden nur bestimmte Teile aus dem Prozess angeboten oder ggf. auch zusätzliche Finanzdienstleistungen bereitgestellt (Yang et al. 2017).

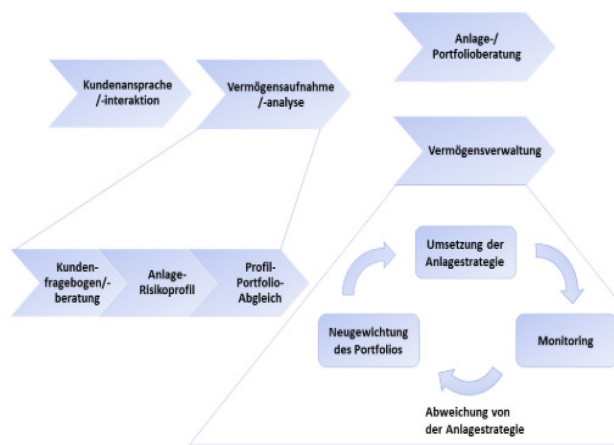


Abbildung 2: Robo-Advice-Prozess (Eigene Darstellung in Anlehnung an Yang et al. 2017; Azulay 2019; Tonderau, van Gysegem und Bohlke 2019; Boschke, Paxmann und Roßbach 2017)

Den ersten Prozessschritt bildet die **Kundenansprache und -interaktion**. Beispielsweise lassen sich anhand ähnlicher Präferenzen (wie Risikobereitschaft, Anlageziel oder demografische Situation) Korrelationen im Kundenverhalten durch Clusteranalysen identifizieren und so individualisierte Ansprachen sowie Interaktionen anbieten. Dabei sind Technologien im Bereich DS unverzichtbar. Diese ermöglichen auch den Einsatz von Predictive Analytics auf der Basis von historischen Daten (Dapp 2017).

Zusätzlich lassen sich von potenziellen Kunden Profile erstellen, um diese verschiedenen Segmenten (wie Kommunikationsverhalten oder persönliche Eigenschaften) zuzuordnen. Die Datenbasierung ermöglicht eine bessere Vorbereitung auf einen Gesprächstermin und erhöht somit die Genauigkeit der Ansprache sowie die Abschlussquote (Boschke, Paxmann und Roßbach 2017). Die Kundeninteraktion erfolgt bei Robo-Advisors mit durchgängiger digitaler Ausrichtung in Form von Text- oder Spracherkennung. (Seidel 2017) Dabei werden Chatbots und KI-basierte Systeme eingesetzt, um mithilfe einer Spracherkennungssoftware sowie einer maschinellen Verhaltensanalyse Finanzprofile zu erstellen (Boschke, Paxmann und Roßbach 2017).

Im Bereich der **Vermögensaufnahme und -analyse** wird das Anlageprofil des Kunden z.B. durch einen Kundenfragebogen oder ein Beratungsgespräch zusammengestellt und auf Basis dieser Informationen das Risikoprofil analysiert. Dies bildet das Fundament für die weitere Vermögensverwaltung oder Anlageberatung, da sich so die Kundenbedürfnisse und -wünsche adressieren

lassen. Weiter werden die bestehenden Vermögensverhältnisse untersucht und passende Anlageprodukte vorgeschlagen bzw. ausgewählt, welche die Rendite- und Risikoerwartung widerspiegeln (Boschke, Paxmann und Roßbach 2017). Dabei ist u.a. der Einsatz von Modellen des ML vorzufinden, um für den Kunden die beste Lösung zu finden (Koksal 2020).

Nach der Festlegung der Anlagestrategie und der damit verbundenen Entscheidungen, verwaltet der Robo-Advisor das Vermögen. Im Standardprozess der **Vermögensverwaltung** liegt der Fokus auf der Neugewichtung des Portfolios im Falle von Abweichungen. Die Anbieter setzen dabei ggfs. unterschiedliche Investitionsmethoden ein. Beispielsweise werden innovative Finanzmodelle aus einer Kombination von ML und der Finanztheorie oder traditionellen Anlagestrategien angewendet (Yang et al. 2017).

Bei der Datenanalyse kann ML veränderte Marktbedingungen erkennen und die Vermögensverwaltung anpassen (Koksal 2020). Manche Anbieter erweitern ihr Angebot mit zusätzlichen Vorschlägen, wie z.B. Einmalzahlungen oder Strategiewechsel. Andere Anbieter sorgen dafür, dass sich zusätzlich die Verwaltung je nach Phase dynamisch anpasst. Zum Beispiel werden in diesem Kontext vor und während der Verrentungsphase die Risiken durch Portfolioumschichtungen reduziert, um mögliche Verluste durch Marktschwankungen zu eliminieren (Boschke, Paxmann und Roßbach 2017).

Weitere Angebote sind im Bereich der Steuersenkungen bei Transaktionen vorzufinden. Dabei verwendet man ML, um spezifische Steuerfolgen zu evaluieren. Zusätzlich werden Investitionen, die zu den geringsten Steuerzahlungen führen, bestimmt (Koksal 2020).

Anders als in der Vermögensverwaltung führt man in der **Anlage- und Portfolioberatung** Analysen durch, um einen Kauf- oder Verkaufsvorschlag zu generieren. Dabei stellen Anbieter maßgeschneiderte Investmentempfehlungen zur Verfügung. Dies wird entweder zusätzlich zu den verwaltenden Tätigkeiten oder ausschließlich als alleinige Dienstleistung angeboten. Hierbei erfolgt eine Abstimmung der Kapitalmarktprognosen und Anlageoptionen mit steuerlichen Aspekten und den individuellen Zielvorstellungen des Kunden. Die Analyseergebnisse werden dann als dialogorientierte, sprachbasierte Ratschläge dem Kunden übermittelt (Boschke, Paxmann und Roßbach 2017).

Neben dem B2C-Bereich operieren Robo-Advisors auch im B2B-Bereich, indem anderen Unternehmen Knowhow oder Software-Anwendungen zur Verfügung gestellt werden. Dabei treten häufig Kooperationen zwischen den Banken, Family Offices sowie Fondsgesellschaften und den

FinTechs auf. Etablierte Unternehmen erweitern so ihre Dienstleistungen und Vertriebskanäle. FinTechs arbeiten als technischer Anbieter, eigenständiges Start-up und gleichgestellter Kooperationspartner (Müller und Pester 2019; Boschke, Paxmann und Roßbach 2017).

Der weltweite Robo-Advice-Markt verfügte im Jahr 2018 über 490 Mrd. Euro „Assets under Management“ (AuM). Verglichen mit dem weltweiten AuM ist der Anteil geringer als 1% und somit von marginaler Bedeutung. Die Wachstumsrate beträgt voraussichtlich bis 2023 36% p.a. (59% in 2019 (Statista 2020), was den Gesamtanteil und die damit verbundene Relevanz etwas erhöhen würde (Tonderau, van Gysegem und Bohlke 2019). Besonders jüngere Marktteilnehmer, bei denen die persönliche Beratung weniger essenziell ist, zeigen Interesse an diesen Anlagemöglichkeiten (Müller und Pester 2019). Durch die niedrigen Gebühren, eine gute User Experience, die Verfügbarkeit für die breite Öffentlichkeit und das Weglassen von auf Emotionen basierenden Handlungen heben sich Robo-Advisors von ihren Konkurrenten ab. Die fehlende persönliche Beratung, die geringe Angebotspalette und wenig Erfahrungswerte bezüglich der eingesetzten Verfahren lassen sich demgegenüber jedoch auch als Wettbewerbsnachteile interpretieren (Boschke, Paxmann und Roßbach 2017). Weiterhin bietet kein Robo-Advisor die vorgestellten Dienstleistungen ganzheitlich an. In der Kundenansprache und -interaktion ist der Bereich DS besonders ausgeprägt und hilft beim Onboarding von Interessenten. Der Vermögensverwaltungsbereich basiert derzeit hauptsächlich auf dem Einsatz von einfachen Algorithmen, entwickelt sich jedoch technologisch permanent weiter. Somit wird eine Möglichkeit für Anleger geschaffen, ML für den Aktienhandel nutzen zu können (Azulay 2019).

Im Bereich der aufsichtsrechtlichen und regulatorischen Anforderungen müssen je nach Entwicklung die Haftungsgrundsätze und der Verbraucherschutz durch die verantwortlichen Aufsichtsbehörden neu definiert werden (Dapp 2017). Risiken für Robo-Advisors bestehen in diesem Zusammenhang insbesondere mit dem Kundenprofiling (Poddar, Goel und Dwivedy 2019). Als Gegenmaßnahmen bauen manche Robo-Advisors ihre automatisierten Compliance-Überwachungen aus (Boschke, Paxmann und Roßbach 2017).

Algorithmischer Handel

Entsprechend der Richtlinie 2014/65/EU der Europäischen Union, auch MiFID II (Markets in Financial Instruments Directive II) genannt, wird der Algorithmische Handel als „Handel mit einem Finanzinstrument, bei dem ein Computer-

algorithmus die einzelnen Auftragsparameter automatisch bestimmt“ (Europäisches Parlament 2014) bezeichnet. Relevante Auftragsparameter sind dabei „ob der Auftrag eingeleitet werden soll, Zeitpunkt, Preis bzw. Quantität des Auftrags oder wie der Auftrag nach seiner Einreichung mit eingeschränkter oder gar keiner menschlichen Beteiligung bearbeitet werden soll“ (Europäisches Parlament 2014).

Schon in den 70er Jahren verwendete man Algorithmen für die optimale Portfoliobestimmung. In den 90er Jahren konnten darauf aufbauend die ersten vollautomatischen Handelsgeschäfte getätigt werden. Der Algorithmische Handel hat sich im Laufe der Zeit auf die Ausnutzung von Arbitragemöglichkeiten z.B. im Rahmen des Hochfrequenzhandels (HFT, engl.: high-frequency trading) fokussiert. Gegenwärtig ist der HFT aufgrund geringerer Volatilität, verbesserter Liquidität, steigender Kosten für die Handelsinfrastruktur sowie der Erhöhung von regulatorischen Kontrollen nicht mehr so attraktiv. Dadurch hat sich der Fokus im HFT in Richtung Preisermittlung und Auftragsdurchführung entwickelt, da dort der Geschwindigkeitsvorteil am besten ausgenutzt werden kann. Der Algorithmische Handel, der den „intelligenteren“ Algorithmus darstellt, wird größtenteils für die schnelle Analyse von großen Datensätzen eingesetzt (Beverungen 2019; World Economic Forum 2015).

Heutzutage versuchen Investoren mit Hilfe von Data Scientists einen Wettbewerbsvorteil bei der Vorhersage von Märkten im Sinne von Predictive Analytics zu generieren (Monaco 2019). Dabei ist die Geschwindigkeit der Interpretation von traditionellen und neuen Nachrichtenquellen gleichermaßen ausschlaggebend. Ziel ist es, die Informationsverarbeitung durch Algorithmen in Echtzeit zu ermöglichen. Hierzu stehen u.a. auch spezialisierte Datenbanken zur Verfügung. Im KI- und ML-Bereich werden Kernaktivitäten von der Hypothesenbildung bis hin zur Entscheidungsfindung automatisiert sowie Handelsstrategien kontinuierlich verbessert und korrigiert (Arslanian und Fischer 2019; World Economic Forum 2015).

In den verschiedenen Teilbereichen des Handelsprozesses setzt man die Technologien gebündelt ein. Diese Erweiterung generiert ein algorithmisches Handelssystem, das (wie in Abbildung 3 dargestellt) sich sowohl selbst anpassen als auch erkennen kann, welche Daten von Relevanz sind (Hazuria et al. 2018).

Im Bereich der **Datenerhebung** müssen zunehmend unstrukturierte Daten verarbeitet werden. Zur Gewinnung von Informationen aus natürlicher Sprache lässt sich Natural Language Processing (NLP) nutzen. Die NLP-Anwendung kann das Web

nach Nachrichten z.B. über mögliche Mergers & Acquisitions durchsuchen und damit Rechercharbeiten bezüglich Investitionsentscheidungen unterstützen. Eine weitere innovative Datenerhebung wird durch Maschinelles Sehen unterstützt. Dabei werden Geodaten z.B. von Satelliten, UAVs und Flugzeugen gesammelt (Bharadwaj 2019). Ziel dabei ist es, die bestehende Basis der Analysen zu erweitern und damit den Händler oder das System zu unterstützen, um fundiertere Entscheidungen zu treffen (Azulay 2019).




Abbildung 3: Intelligente Erweiterung der Kernprozesse im Handel mit Wertpapieren (Eigene Darstellung in Anlehnung an Hazuria et al. 2018)

Durch Big Data Analytics lassen sich **Marktanalysen** (wie Fundamentalanalysen oder technische Analysen) besser und genauer vollziehen sowie für verschiedene Zwecke einsetzen. Beispielsweise werden Anlagetrends, wie z.B. „Autonomes Fahren“ oder „Batterietechnik“, ermittelt und gezielt mit den jeweiligen Aktien verknüpft. Weitere Analysen können beispielsweise sozioökonomische Trends aus Geodaten ermitteln (Bharadwaj 2019). Zusätzlich zu den eigenen Analysen lassen sich unabhängige Analystenmeinungen miteinbeziehen.

Die Stimmung der Anleger und Verbraucher lässt sich in Form einer Sentimentanalyse berücksichtigen. Die in Echtzeit erhobenen Daten, unterstützt durch NLP, werden durch Data Mining auf Qualität geprüft und bewertet. So können aktuelle Trendphasen erkannt und Anlagestrategien zusätzlich verifiziert werden (Boschke, Paxmann und Roßbach 2017; World Economic Forum 2015). Ein Beispiel für eine entsprechende Datenerhebung und -analyse ist BlackRock und ihr „China A-Share Opportunities Private Fund 1“-Fonds. In diesem werden Satellitenbilder zur Überwachung der industriellen Aktivität genutzt, Internet- und Blog-Postings analysiert sowie die Hauptzeitung der chinesischen Regierung in Bezug auf politische Veränderungen ausgewertet, um die Entwicklung der Aktien besser vorhersagen zu können (Shen und Ruwitsch 2018).

Wie sehr soziale Medien (wie z.B. Twitter) mit der Datenerhebung und -analyse der algorithmischen Handelssysteme verbunden sind, zeigt der kurzzeitige Kurseinbruch des US-amerikanischen Marktindex Dow Jones Industrial Average (DJIA)

am 23. April 2013: In einem von Hacker gefälschten Tweet, der über die Associated Press Twitter-Seite veröffentlicht wurde, stand geschrieben, dass das Weiße Haus von zwei Explosionen getroffen und Barack Obama verletzt worden sei. Dadurch verlor der Index innerhalb von wenigen Sekunden 143 Punkte bzw. ca. 1%. Der gefälschte Tweet wurde von den zuständigen Mitarbeitern sofort korrigiert, worauf sich der Markt innerhalb weniger Minuten wieder erholte (Moore und Roberts 2013).

Der eng mit der Datenanalyse verbundene **Handelsstrategie**-Bereich wird immer mehr durch Analytik unterstützt (World Economic Forum 2015). Predictive Analytics soll die Bewegung von Aktien auf der Grundlage einer Reihe von Variablen vorhersagen und analysieren. Dabei ist entscheidend welche Aktie die höchste Rendite erzielt (Arslanian und Fischer 2019; Azulay 2019).

Im Bereich der **Handelsdurchführung** muss die Auswirkung auf den Marktpreis beim Handel mit großen Positionen Berücksichtigung finden. Eine Aufteilung in kleinere Aufträge birgt die Gefahr von nachteiliger Kursbewegungen sowie von Opportunitätskosten (Nuti et al. 2011). Um dem entgegenzuwirken, werden die herkömmlichen Analysen im Bereich der Handelsdurchführung durch ML und KI ergänzt. Sogenannte „Handelsroboter“, die auf ML basieren, automatisieren die Auftragsdurchführung und lernen in Form von Supervised Learning, wie sie auf die Marktveränderung reagieren sollen. Dabei spielt u.a. die zeitliche Abstimmung der Abschlüsse eine zentrale Rolle, da zu eng terminierte Geschäfte eine negative Marktauswirkung haben können. Um dies zu vermeiden stellen die Handelsroboter eine Reihe von Szenarien auf. Dies erfolgt typischerweise durch den Einsatz von Algorithmen (wie Bayes'sche Netzen oder Random Forest), um kurzfristige Vorhersagen zu treffen. Bei der US-amerikanischen Bank J.P. Morgan hat der Einsatz zugehöriger Technologien beispielsweise dazu geführt, dass die Anzahl von durchschnittlich 30 Operationen (wie z.B. Limit-Orders, Änderungen und Annullierungen), die zu einem zufriedenstellenden Handelsabschluss führten, durch den Einsatz von „Random Forest“ deutlich reduziert werden konnten. Teilweise wendet man KI-Agenten an, um kurzfristige Volatilität, Auftragsfluss und Marktvolumen im Handelsprozess zu berechnen. Beispielsweise kann durch „Reinforcement Learning“ ein KI-Agent lernen, wie auf Auftragsungleichgewicht und Warteschlangenposition im Orderbuch reagiert werden soll. Dabei wird jeder möglichen Aktion für ein gegebenes Marktumfeld ein Wert zugewiesen. Dieser beruht auf den Grundlagen der zu erwartenden Kosten sowie der Auftragsgröße und -wahrscheinlichkeit. Zusätzlich lässt sich durch Simulationen der Handelszeitplan optimieren und es werden Erkenntnisse gewonnen, wie sich Abschlüsse auf

den Markt auswirken (Day 2017). Im Handel mit Anleihen werden die Vorhersagen durch fehlende Marktliquidität und beschränkter Ähnlichkeit zu anderen Anleihen erschwert. Zudem ist dieser im Vergleich zum Aktienhandel komplexer, da jede Anleihe einzigartige rechtliche und finanzielle Merkmale aufweist. Hierbei kann man z.B. Clusteranalysen zur Segmentierung der einzelnen Anleihen verwenden. Anhand von quantitativen Merkmalen (wie Währung, ausstehender Betrag, Laufzeit und Fälligkeit) lässt sich eine Gruppierung sowie Analyse durchführen (Financial Stability Board 2017; Poddar und Dwivedy 2019; Day 2017). Optional kann man bei Abweichungen von den Erwartungen menschliche Händler als Experten kontaktieren, um den Algorithmus anzupassen bzw. auszutauschen (Financial Stability Board 2017; Day 2017). Um die Genauigkeit und Stabilität der von ML und KI geprägten Modelle sowie Analysen zu bestimmen, müssen Backtesting-Methoden auf rechenintensivere Verfahren zurückgreifen (Regan et al. 2017). Zudem werden die Modelle durch Stresstests im Bereich des Risikomanagements validiert.

Das **Monitoring** lässt sich zu einem kontinuierlichen Prozess der Überwachung, Suche sowie Beobachtung ausbauen, der durch stetiges „Lernen“ zu einer fortlaufenden Verbesserung führt (Reinsel, Gantz und Rydning 2018). Die erweiterte Überwachung identifiziert zusätzlich kritische Entscheidungen und die dazugehörigen Variablen, um dementsprechende Maßnahmen einzuleiten (Danas und Garsva 2016). Auch im Bereich der Risikoüberwachung ermöglichen die neuen Technologien ein besseres Management (Harmon 2019).

Zusammengefasst reflektiert das Monitoring den Handelsprozess und löst bei Bedarf die in Abbildung 3 dargestellten Anpassungen und Veränderungen aus.

Ein weiterer Bereich des AH ist das **Risikomanagement**. Dabei werden vergangene, prägende Ereignisse bezüglich der Märkte analysiert, um zukünftige Muster zu erkennen (Adeyeri 2015). Als zugehöriges Beispiel lässt sich die Bewertung der Angriffe auf Öleinrichtungen in Saudi-Arabien im September 2019, die Befürchtungen bezüglich eines regionalen Krieges ausgelöst hatten, anführen. Um Vorhersagen zu treffen wurden Analysen vom Unternehmen Predata durchgeführt. Das Ergebnis der geopolitischen Analyse, dass es keine Eskalation mit Auswirkungen auf die Märkte geben würde, hat sich als korrekt erwiesen (Chatterjee 2020).

Neben den durch die angepasste Handelsausführung reduzierten Marktpreisrisiken und dem präventiven Erkennen von Risiken, kann ML das Risikomanagement bei der Validierung der Handelsstrategie und den dazugehörigen Modellen

unterstützen (Aziz und Dowling 2019). Unsupervised Learning-Algorithmen helfen bei den Modellvalidierungen durch das Erkennen von Anomalien, die durch Stresstests ausgelöst werden. Dabei ist das Ziel, die Anzahl der Variablen, die innerhalb der Modelle zu Verlusten führen, zu begrenzen. Aber auch das Erkennen von Verzerrungen und die damit erzeugte Transparenz kann Maschinelles Lernen durch die Überprüfung von großen Datenmengen verbessern (Financial Stability Board 2017).

Im Bereich der **Compliance** lassen sich NLP und ML für die Analyse unstrukturierter Inhalte (wie Gesetze und Vorschriften) einsetzen. Aufgrund der Komplexität, aber auch der Möglichkeit dieses Themengebiet gebündelt und optimiert für eine Vielzahl von Unternehmen zur Verfügung zu stellen, wird dieser Bereich oft zentralisiert von spezialisierten RegTechs oder anderen Unternehmen angeboten (Rudin 2017). Die „Regulatory Technology“-Unternehmen zielen darauf ab, regulatorische und aufsichtliche Pflichten mit Hilfe von innovativen Technologien effektiver und effizienter zu erfüllen (Lehnert 2019).

AUSWIRKUNGEN AUF DIE

PRAKTIZIERENDEN UNTERNEHMEN

Händler setzen grundsätzlich auf zwei Vorgehensweisen, um die Qualität der Investitionsentscheidung zu verbessern. Im ersten Fall wird Maschinelles Lernen und Deep Learning in Kombination mit spezifischen Datenquellen verwendet, um erfolgreicher als die Konkurrenz zu sein. Beim zweiten Fall handelt es sich in der Praxis oft um eine Mischung aus Robo-Advice und Algorithmischem Handel. Dabei wird versucht ML zu nutzen, um bei leichter zugänglichen passiven Anlageprodukten mit niedrigen Gebühren aktive Renditeeigenschaften zu erzielen. Dies baut u.a. auf der wachsenden Beliebtheit von "Smart Beta" ETFs auf. Solche Anlageprodukte zielen darauf ab, durch Gewichtung bestimmter Anlagefaktoren, wie Unternehmensgröße oder Branchenkategorie, Überrenditen zu generieren, anstatt einfach einen Index nachzubilden. Dabei werden teilweise auch Faktoren aus weiteren Datenquellen berücksichtigt, um Neugewichtungen in Echtzeit vorzunehmen (Arslanian und Fischer 2019).

Wie die zugehörigen algorithmischen Lösungen arbeiten, zeigte der Aktienindex S&P 500 (SPX) am 29. Januar 2020: Innerhalb einer halben Stunde brach der Index um 0,6% ein, nachdem die Fluggesellschaften Lufthansa und American Airlines mitgeteilt hatten, dass Flüge nach China aufgrund von COVID-19 ausgesetzt werden. In solchen Fällen überprüfen die Algorithmen, ob die Handlungen mit den Preistrends übereinstimmen. Im weiteren Schritt beurteilen sie die Schwere des

Vorfällen anhand von Mustern im Anlegerverhalten und den wirtschaftlichen Folgen, die auf vergangenen Vorfällen basieren. Bei einem einzelnen Vorfall ohne weitere Auswirkungen können menschliche Trader oder teilweise die Maschinen selbst eingreifen und die Handlungen kompensieren. Im Fall des 29.01.2020 wurden die Verluste nach einer Stunde wieder korrigiert und der Index erreichte sein vorheriges Niveau (Chatterjee 2020).

Insgesamt werden verschiedenen Einsatzgebiete erfolgreich von einer Reihe von Unternehmen mit Technologien aus dem Bereich DS erweitert und angeboten. Für die praktizierenden Unternehmen ist daher eine differenzierte Betrachtung der dafür relevanten Rahmenbedingungen (IT-Infrastruktur, Personal und Organisation, Governance und Compliance) notwendig.

IT-Infrastruktur

Um eine effektive und effiziente Implementierung der Technologien im Bereich DS zu garantieren, müssen in den meisten Fällen tiefgreifende Veränderungen in der IT-Infrastruktur, besonders bei den traditionellen Unternehmen, umgesetzt werden. Die erfolgreiche Einführung der meisten neuen Technologien erfordert eine flexible Plattform, die einen einfachen Zugang zu dynamischen und skalierbaren Mengen an Rechenleistung und Speicherplatz ermöglicht. Cloud Servicemodelle stellen hierfür IT-Infrastrukturressourcen (Infrastructure-as-a-Service), Entwicklungsplattformen (Platform-as-a-Service) sowie abrufbare Softwarelösungen (Software-as-a-Service) zur Verfügung (Bundesamt für Sicherheit in der Informationstechnik o.J.). Der Einsatz einer öffentlichen, privaten oder hybriden Cloud-Umgebung bzw. -Organisationsform erweist sich in diesem Kontext häufig als probates Mittel (Sehgal et al. 2020). Unternehmen, darunter oftmals die neuen Akteure, deren Infrastruktur bereits auf einer Cloud basiert, können dementsprechend Vorteile daraus ziehen. Die Zugriffsgeschwindigkeit muss Anforderungen, wie der schnellen Sprach- und Bildverarbeitung, gerecht werden und darf nicht durch Silo-Datenstrukturen auf verschiedenen Systemen schwer zugänglich sein. Daher müssen im Bereich der Dateninfrastruktur Data Hubs implementiert, ggf. APIs für externe Daten bereitgestellt und Data-Lakes eingerichtet werden. Aber auch die Datenqualität spielt eine zentrale Rolle: Menschliche Eingabefehler und unvollständige oder inkonsistente Daten können schwerwiegende Folgen mit sich bringen. Deswegen ist die wichtigste Prämisse in dieser Kategorie verfügbare, geeignete Daten für die Weiterverarbeitung bereitzustellen (Arslanian und Fischer 2019; Aziz und Dowling 2019).

Personal und Organisation

Weitere Auswirkungen und Veränderungen sind im personellen und organisatorischen Bereich insbesondere dann zu spüren, wenn menschliche Fehler minimiert und die Qualität der Entscheidungen gesteigert werden soll (World Economic Forum 2015). Beispielsweise wird die Arbeit von Kundenberatern und Portfoliomanagern, aber auch von Analysten und Volkswirten, durch Algorithmen ersetzt oder ergänzt. Zusätzlich erhöhen Robo-Advisors den Margendruck und die kostenintensive traditionelle Anlagenberatung und Vermögensverwaltung wird möglicherweise zum Wettbewerbsnachteil (Müller und Pester 2019; Boschke, Paxmann und Roßbach 2017).

Für Data Scientists ist ein großes Finanzdienstleistungsunternehmen möglicherweise nicht der präferierte Arbeitgeber. Dies ist zum Teil auf Probleme des kulturellen Konservatismus zurückzuführen oder es herrscht aufgrund der zerklüfteten IT-Infrastruktur-Problemen eine mangelnde Attraktivität. Diese Einschränkungen können dazu führen, dass viele Finanzinstitute Schwierigkeiten haben Data Scientists zu gewinnen bzw. zu halten (Arslanian und Fischer 2019).

Zur Kompensation des personellen Mangels hat sich teilweise die Rolle des Citizen Data Scientists etabliert. Dieser verfügt über DS-Fähigkeiten und kann durch fortgeschrittene Analysen Unternehmen weiterhelfen, hat jedoch weniger mathematisch-statistische Kompetenzen als ein Data Scientist und verursacht i.d.R. geringere Kosten. Dabei werden fortschrittliche Tools, welche Daten analysieren und visualisieren, unterstützend eingesetzt. Dennoch kann ein Data Scientist, der die Algorithmen auswählt, Datenmodelle erstellt und trainiert sowie Lösungen bereitstellt, nicht vollständig ersetzt werden. Citizen Data Scientists können lediglich helfen die benötigte Anzahl dieser zu reduzieren (Banker 2018). Solche personellen Veränderungen sind beispielhaft im Goldman Sachs Hauptsitz in New York erkennbar. Im Jahr 2000 arbeiteten dort etwa 600 Trader im „U.S. cash equities trading desk“ und kauften bzw. verkauften Aktien für die Großkunden der Investmentbank. Heutzutage arbeiten dort lediglich noch zwei Trader und 200 Computertechniker, die die automatischen Trading-Programme unterstützen (Byrnes 2017). Um den genannten Problemen in der Personalbeschaffung, die bei vielen Unternehmen mit Sorge betrachtet werden, entgegenzuwirken und somit einem Fachkräftemangel zu entgehen, hat Goldman Sachs in Indien einen Campus mit Platz für 7000 Mitarbeiter erschlossen (Aziz und Dowling 2019). Auch die Investmentbank JPMorgan Chase versucht durch massive Investitionen in die neuen Technologien Fachkräfte für sich zu gewinnen und konkurriert dabei unter anderem mit den Unternehmen aus dem Silicon Valley. Im Fokus

stehen dabei die Investitionen von 11 Milliarden USD, die jedes Jahr unter anderem in ein Team von 50.000 Technologen investiert werden sollen (JPMorgan Chase & Co. o.J.).

Governance und Compliance

Innovationen jeglicher Art im Bereich der Finanzdienstleistungen gehen mit einem erhöhten Risiko regulatorischer Prüfungen und Maßnahmen einher. Viele Unternehmen haben gegenwärtig Bedenken bezüglich der Sicherstellung, dass die Systeme keine unerwünschten Verzerrungen hervorrufen. Teilweise sind strenge Gesetzaufgaben zu beachten, die eine Diskriminierung von Minderheiten durch finanzielle Entscheidungssysteme hart bestrafen. Weitere regulatorische Fragestellungen, die auch in vielen anderen Bereichen relevant sind, drehen sich um den Umgang mit personenbezogenen Daten und neuen Partnerschaften für den Datenaustausch. Jedoch ist dabei auch ein Eigeninteresse der Unternehmen vorhanden, da die Ruf- und Markenschädigung negative Auswirkungen hätte und möglicherweise weitere regulatorische Beschränkungen mit sich bringt. Teilweise sind die Funktionsweisen des zugrunde liegenden Modells so komplex, dass die Interpretation einer bestimmten Ausgabe nicht einmal von dem Ersteller selbst erklärt werden kann. Bei diesen Gegebenheiten äußern die Regulierungsbehörden entsprechende Bedenken. So müssen nicht-interpretierbare Systeme in den Bereichen Implementation und Überwachung noch strenger kontrolliert werden (Arslanian und Fischer 2019). Es bleibt abzuwarten, inwieweit erklärbares KI (engl.: Explainable AI/XAI) hierfür geeignete Lösungen bereitstellen wird.

In einer Umfrage von Baker McKenzie, in der 355 Führungskräfte aus weltweit tätigen Finanzinstituten befragt wurden, gaben 53% an, dass sie „nicht wirklich überzeugt“ oder „überhaupt nicht überzeugt“ sind, bezüglich der Aussage: „Meine Organisation versteht alle wesentlichen rechtlichen Risiken im Zusammenhang mit neuen Finanztechnologien“. Hinsichtlich der vorhandenen Regulierungen in Verbindung mit KI herrschen sehr differenzierte Ansichten vor. Dabei überwiegt mit insgesamt 59% die Meinung, dass weitere Regulierungen implementiert werden müssen. Darunter sind 38% teilweise und 21% überhaupt nicht der Meinung, dass genügend Regulierungen vorhanden sind (Budworth 2018).

FAZIT

Chancen

Es stellt sich die Frage, ob die Anwendung von DS im Wertpapierhandel einen positiven Nutzen für die Anwender hat. Positiv eingestellte Betrachter gehen davon aus, dass die Technologien helfen Probleme zu lösen, die weit über die Modellierung der

Auswirkungen auf den Markt hinausgehen. Besonders bei sich schnell veränderten Korrelationsstrukturen ergeben sich erhebliche Vorteile: Stresstests müssen durchgehend aktuell sein, da frühere Korrelationen nicht verlässlich sind. Nicht mehr relevante Variablen sind entsprechend auszusortieren. Gerade im Bereich des AH macht eine minimale Performancesteigerung eines geeigneten Algorithmus aufgrund der enormen Anzahl an gehandelten Aufträgen einen erheblichen Unterschied (Day 2017). Ein weiterer großer Vorteil ist die Möglichkeit schnell, genau und kostengünstig Erkenntnisse aus unstrukturierten Daten zu gewinnen. Damit können die Entscheidungen auf einem Gesamtbild basieren und müssen nicht nur anhand weniger Kriterien getroffen werden (Arslanian und Fischer 2019).

Im Bereich des Robo-Advice werden Anleger bzw. potenzielle Kunden durch die Personalisierung effektiver angesprochen und die Anlageberatung sowie Vermögensverwaltung für mehr Personen ermöglicht. Außerdem lässt sich in vielen Prozessschritten die Effizienz steigern (Poddar, Goel und Dwivedy 2019). Daraus resultieren eine höhere Qualität, ein kürzerer Onboarding-Prozess, eine bessere Kommunikation und geringere Kosten (Boschke, Paxmann und Roßbach 2017). Zusätzlich können menschliche Verwalter und Berater entlastet werden, indem KI-gesteuerte Maschinen Überwachungs- und Verwaltungsaufgaben übernehmen und so Personalressourcen freisetzen (Koksall 2020).

In der Vermögensverwaltung gibt es verschiedene Ansätze, um die Performance der Anlage oder die Auswahl der Produkte zu verbessern. Zur Auswahl stehen dabei beispielsweise „Smart-Beta“ ETFs, die durch eine KI gesteuert sind. Eines von vielen Beispielen ist der „AI Powered Equity ETF“ (AIEQ) von dem IBM Global Entrepreneur EquBot. (Equbot o.J.). Generelles Ziel solcher Anwendungen ist es, in Managementteams, Jahresabschlüssen, Nachrichten und sozialen Medien Muster zu erkennen, die Trends im Markt identifizieren. Um immer bessere Entscheidungen zu treffen und damit „intelligenter“ zu werden, analysieren solche Systeme täglich ein großes Datenvolumen. Dabei ist die Frage zu beantworten, ob sich ein Investment in die innovativen Technologien lohnt und sich die angebotenen Dienstleistungen oder ausgewählten Produkte als rentabel erweisen (Gurdus 2019).

Risiken und Grenzen

Kritische Betrachter argumentieren, dass der Einsatz von Maschinellem Lernen und der teilweise damit verbundenen „Black Box“ wenig hilfreich ist, da die Einflussfaktoren nicht wirklich bestimmt werden können. Besonders schwer sei es, eine systematische Unterscheidung zwischen temporären und permanenten Auswirkungen treffen zu können.

Manche Kritiker gehen davon aus, dass besonders im Bereich des langfristigen Investierens sich die wesentlichen Sachverhalte durch traditionelle Datenanalysemethoden feststellen lassen und der Einsatz von ML deshalb nicht nötig ist (Day 2017). In diesem Kontext sind die hohen Investitionskosten und die laufenden finanziellen Belastungen zu bewerten. Weiterhin können Risiken, wie z.B. das mangelnde Erkennen von schlechten Marktbedingungen und die Anwendung falscher Handelsstrategien, zu hohen Verlusten führen (Chan 2019).

Einer der schwerwiegendsten Fehler ereignete sich z.B. im Jahr 2012 bei der Knight Capital Group. Aufgrund eines fehlerhaften Handelsalgorithmus verlor das Unternehmen rund 440 Mio. USD in 30 Minuten (Philips 2012). Gerade durch solche Vorfälle steigt der Bedarf an menschlicher Steuerung und kontinuierlicher Überprüfung sowie einem Ausbau des Risikomanagements mit ständigen Bewertungen. Das typische „Black Box“-Verhalten bestehender KI-Lösungen erweist sich für Modellvalidierungen jedoch als kontraproduktiv (Aziz und Dowling 2019). Seit der Auflegung des „AI Powered Equity ETF“-Fonds, der größtenteils in börsennotierte US-Aktien investiert, ist beispielsweise ein wirklicher Mehrwert nicht zu erkennen. Der AIEQ schnitt mit einer 23%-Steigerung 2% besser als der DJIA, aber 10% schlechter als der SPX, ab. Besonders auffällig ist der überdurchschnittliche Einbruch Ende 2018, der das schlechtere Ergebnis erklären könnte (CNBC 2020). Es ist äußerst schwierig vorherzusagen, ob sich jemals ein essenzieller Wissensvorteil an den Märkten generieren lässt. Eventuell kann die weitere Beobachtung des Lernverfahrens und die damit verbundene Performance vom AIEQ weitere Erkenntnisse in den kommenden Jahren liefern.

Als Schlussfolgerung lässt sich ziehen, dass eine Mischung aus (kompetenten) Menschen und (fehlerfreien) Maschinen die beste Lösung darstellt (Budworth 2018). Hierfür sind sinnvolle Gestaltungsprinzipien und -kriterien für eine partnerschaftliche Kooperation zu entwickeln.

LITERATUR

- Adeyeri, Christopher (2015): Investment banks recruit for rise of big data analytics; URL: <https://www.computerweekly.com/opinion/Investment-banks-recruit-for-the-rise-of-big-data-analytics> [Stand: 26.06.2020].
- Arslanian, Henri; Fischer, Fabrice (2019): The Future of Finance.
- Aziz, Saqib; Dowling, Michael (2019): Machine Learning and AI for Risk Management; in: Lynn, Theo; Mooney, John G.; Rosati, Pierangelo; Cummins, Mark (Hrsg.): Disrupting Finance – FinTech and Strategy in the 21st Century; S. 33–50.
- Azulay, Dylan (2019): Artificial Intelligence in Finance – a Comprehensive Overview; URL: <https://emerj.com/ai-sector-overviews/artificial-intelligence-in-finance-a-comprehensive-overview/> [Stand: 02.07.2020].
- Banker, Steve (2018): The Citizen Data Scientist; in: Forbes; 2018; URL: <https://www.forbes.com/sites/stevebanker/2018/01/19/the-citizen-data-scientist/> [Stand: 05.08.2020].
- Beverungen, Armin (2019): Algorithmic Trading, Artificial Intelligence and the Politics of Cognition; in: Sudmann, Andreas (Hrsg.): The democratization of artificial intelligence – Net politics in the era of learning algorithms; S. 77–93.
- Bharadwaj, Raghav (2019): Machine Vision in Finance – Current Applications and Trends; URL: <https://emerj.com/ai-sector-overviews/machine-vision-in-finance-current-applications-and-trends/> [Stand: 25.08.2020].
- Bitterli, Micha (2016): “Banking is necessary, banks are not” - Banking blog; URL: <https://blogs.deloitte.ch/banking/2016/09/banking-is-necessary-banks-arent-bill-gates.html> [Stand: 27.08.2020].
- Boschke, Holger; Paxmann, Stephan; Roßbach, Stefan (2017): Innovative Geschäftsmodelle im Digital Wealth Management.
- Budworth, David (2018): Ghosts in the Machine Revisited – The state of artificial intelligence, risks and regulation in financial services.
- Bundesamt für Sicherheit in der Informationstechnik (o.J.): Cloud Computing Grundlagen. URL: <https://www.bsi.bund.de/DE/Themen/Unternehmen-und-Organisationen/Informationen-und-Empfehlungen/Empfehlungen-nach-Angriffszielen/Cloud-Computing/Grundlagen/grundlagen.html> [Stand: 25.08.2020].
- Bundesanstalt für Finanzdienstleistungsaufsicht (2020): Robo-Advice – Automatisierte Anlageberatung und Finanzportfolioverwaltung; URL: https://www.bafin.de/DE/Verbraucher/Finanzwissen/Fintech/RoboAdvice/robo_advice_node.html [Stand: 20.07.2020].
- Byrnes, Nanette (2017): As Goldman Embraces Automation, Even the Masters of the Universe Are Threatened; in: MIT Technology Review; URL: <https://www.technologyreview.com/2017/02/07/154141/as-goldman-embraces-automation-even-the-masters-of-the-universe-are-threatened/> [Stand: 23.07.2020].
- Capgemini und Efma (2020): World Fintech Report 2020.
- Chan, Jacinta (2019): Automation of Trading Machine for Traders – How to Develop Trading Models.
- Chatterjee, Saikat (2020): Wars and viruses: Are robots less prone to market panic?; in: Reuters Media; URL: <https://uk.reuters.com/article/us-china-health-algos-insight/wars-and-viruses-are-robots-less-prone-to-market-panic-idUKKBN1ZU1Q3> [Stand: 03.08.2020].
- CNBC (2020): AI Powered Equity ETF; URL: <https://www.cnbc.com/quotes/?symbol=AIEQ> [Stand: 26.08.2020].
- Danenas, Paulius; Garsva, Gintautas (2016): Intelligent Credit Risk Decision Support: Architecture and Implementations; in: Dunis, Christian L.; Middleton, Peter W.; Karathanasopolous, Andreas; Theofilatos, Konstantinos (Hrsg.): Artificial Intelligence in Financial Markets –

- Cutting-Edge Applications for Risk Management, Portfolio Optimization and Economics; S. 179-210.
- Dapp, Thomas F. (2017): FinTech – Traditionelle Banken als digitale Plattformen und Teil eines Finanz-Ökosystems; in: Smolinski, Remigiusz; Gerdes, Moritz; Siejka, Martin; Bodek, Mariusz C. (Hrsg.): Innovationen und Innovationsmanagement in der Finanzbranche; S. 376-383.
- Day, Sebastian (2017): Quants turn to machine learning to model market impact; URL: <https://www.risk.net/asset-management/4644191/quants-turn-to-machine-learning-to-model-market-impact> [Stand: 31.07.2020].
- Equbot (o.J.): The EquBot Artificial Intelligence Story; URL: <https://equbot.com/our-story/> [Stand: 26.08.2020].
- Financial Stability Board (2017): Artificial intelligence and machine learning in financial services.
- Fraunhofer-Gesellschaft e.V. (2017): Trends für die Künstliche Intelligenz.
- Gurdus, Lizzy (2019): This ETF run by a robot is beating the market—here's how it works; in: CNBC; URL: <https://www.cnbc.com/2019/08/02/this-etf-run-by-arobot-is-beating-the-marketheres-how-it-works.html> [Stand: 25.08.2020].
- Harmon, Richard L. (2019): Big Data and the CRO of the Future; in: Liermann, Volker; Stegmann, Claus (Hrsg.): The Impact of Digital Transformation and FinTech on the Finance Professional; S. 225-237.
- Hazuria, Samia; Vaghani, Bhumi; Kokate, Suraj; Dhawale, Mayur; Ganurkar, Priyanka (2018): The AI Revolution in Banking; URL: <https://www.aranca.com/knowledge-library/articles/investment-research/the-ai-revolution-in-banking> [Stand: 17.08.2020].
- JPMorgan Chase & Co. (o.J.): This \$11 Billion Tech Investment Could Disrupt Banking; URL: <https://www.jpmorganchase.com/corporate/news/stories/tech-investment-could-disrupt-banking.htm> [Stand: 03.08.2020].
- Keller, Kai (2019): Data and the future of financial services; URL: <https://www.weforum.org/agenda/2019/04/data-and-the-future-of-financial-services/> [Stand: 22.06.2020].
- Koksal, Ilker (2020): How AI Is Expanding The Applications Of Robo Advisory; in: Forbes; URL: <https://www.forbes.com/sites/ilkerkoksal/2020/04/18/how-ai-is-expanding-the-applications-of-robo-advisory/> [Stand: 23.08.2020].
- Lehnert, Markus (2019): Regtech auf dem Vormarsch, URL: https://www.bafin.de/SharedDocs/Veroeffentlichungen/DE/Fachartikel/2019/fa_bj_1903_Regtech.html [Stand: 09.04.2021]
- Li, Yun (2019): 80% of the stock market is now on autopilot; in: CNBC; URL: <https://www.cnbc.com/2019/06/28/80percent-of-the-stock-market-is-now-on-autopilot.html> [Stand: 14.08.2020].
- Liermann, Volker; Stegmann, Claus (2019): Introduction; in: Liermann, Volker; Stegmann, Claus (Hrsg.): The Impact of Digital Transformation and FinTech on the Finance Professional; S. 1-6.
- Monaco, Eleonora (2019): What FinTech Can Learn from High-Frequency Trading: Economic Consequences, Open Issues and Future of Corporate Disclosure; in: Lynn, Theo; Mooney, John G.; Rosati, Pierangelo; Cummins, Mark (Hrsg.): Disrupting Finance – FinTech and Strategy in the 21st Century; S. 51-70.
- Moore, Heidi; Roberts, Dan (2013): AP Twitter hack causes panic on Wall Street and sends Dow plunging; in: The Guardian; URL: <https://www.theguardian.com/business/2013/apr/23/ap-tweet-hack-wall-street-freefall> [Stand: 25.06.2020].
- Müller, Maximilian; Pester, Marion (2019): Passive Anlagestrategien und Digitalisierung in der Vermögensverwaltung; in: Seidel, Marcel (Hrsg.): Banking & Innovation 2018/2019; S. 227-246.
- Nuti, Giuseppe; Mirghaemi, Mahnoosh; Treleven, Philip; Yingsaeree, Chaikyorn (2011): Algorithmic Trading; in: Computer; 44. Aufl.; S. 61–69.
- Philips, Matthew (2012): Knight Shows How to Lose \$440 Million in 30 Minutes; in: Bloomberg; URL: <https://www.bloomberg.com/news/articles/2012-08-02/knight-shows-how-to-lose-440-million-in-30-minutes> [Stand: 02.08.2020].
- Poddar, Ayush; Dwivedy, Susovan (2019): Top Trends in Capital Markets: 2020.
- Poddar, Ayush; Goel, Saakshi; Dwivedy, Susovan (2019): Top Trends in Wealth Management: 2020.
- Rabasa, Alex; Heavin, Ciara (2020): An Introduction to Data Science and Its Applications; in: Charles, Vincent; Aparicio, Juan; Zhu, Joe (Hrsg.): Data Science and Productivity Analytics; S. 57-81.
- Regan, Samantha; Klein, Luther; Jacobs Jr., Michael; Kazmi, Sitwat (2017): Model Behavior. Nothing Artificial. Emerging Trends in the Validation of Machine Learning and Artificial Intelligence Models; Accenture.
- Reinsel, David; Gantz, John; Rydning, John (2018): The Digitization of the World from Edge to Core.
- Rudin, April J. (2017): The Regtech Revolution: Compliance and Wealth Management in 2017; URL: <https://blogs.cfainstitute.org/investor/2017/01/12/theregtech-revolution-compliance-and-wealth-management-in-2017/> [Stand: 20.07.2020].
- Sehgal, Naresh Kumar; Bhatt, Pramod Chandra P.; Acken, John M. (2020): Cloud computing with security. Concepts and practices. Second edition. Switzerland: Springer
- Seidel, Elisabeth (2017): InvestTechs und KVGs - Konkurrenz, Koexistenz oder Symbiose?; in: KPMG AG Wirtschaftsprüfungsgesellschaft (Hrsg.): Digitalisierung im Maschinenraum der Finanzdienstleister; S. 13-21.
- Shen, Samuel; Ruwitch, John (2018): Satellites and blogs: BlackRock to raise game in China stock picking; in: Reuters Media; URL: <https://www.reuters.com/article/us-china-blackrock-fund-idUSKBN1KE16U> [Stand: 30.07.2020].
- Statista (2019): Volumen des weltweiten Aktienhandels von 1980 bis 2018; URL: <https://de.statista.com/statistik/daten/studie/239389/umfrage/volumen-des-weltweiten-aktienhandels/> [Stand: 23.08.2020].

- Statista (2020): Robo-Advisors - worldwide | Statista Market Forecast; URL: <https://www.statista.com/outlook/337/100/robo-advisors/worldwide> [Stand: 22.07.2020].
- Tonderau, Grégoire; van Gysegem, Frederick; Bohlke, Axel (2019): Robo-advisory in Belgium – Can David challenge Goliath?; in: Roland Berger Focus.
- Wohlschlägl-Aschberger, Doris (2015): Bankgeschäft und Finanzmarkt - Praxiswissen kompakt; unveränderter Nachdruck 2019.
- World Economic Forum (2015): The Future of Financial Services – How disruptive innovations are reshaping the way financial services are structured, provisioned and consumed.
- Yang, Jie et al. (2017): How Robo-Advisors Manage Investment Portfolios; in: O'Reilly, Philip (Hrsg.): The Frontier of Fintech Innovation; S. 14–26.