

Brühl, Volker

Working Paper

Big Data, Data Mining, Machine Learning und Predictive Analytics: Ein konzeptioneller Überblick

CFS Working Paper Series, No. 617

Provided in Cooperation with:

Center for Financial Studies (CFS), Goethe University Frankfurt

Suggested Citation: Brühl, Volker (2019) : Big Data, Data Mining, Machine Learning und Predictive Analytics: Ein konzeptioneller Überblick, CFS Working Paper Series, No. 617, Goethe University Frankfurt, Center for Financial Studies (CFS), Frankfurt a. M., <http://nbn-resolving.de/urn:nbn:de:hebis:30:3-480542>

This Version is available at:

<http://hdl.handle.net/10419/191736>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

No. 617

Volker Brühl

Big Data, Data Mining, Machine
Learning und Predictive Analytics –
ein konzeptioneller Überblick

The CFS Working Paper Series

presents ongoing research on selected topics in the fields of money, banking and finance. The papers are circulated to encourage discussion and comment. Any opinions expressed in CFS Working Papers are those of the author(s) and not of the CFS.

The Center for Financial Studies, located in Goethe University Frankfurt's House of Finance, conducts independent and internationally oriented research in important areas of Finance. It serves as a forum for dialogue between academia, policy-making institutions and the financial industry. It offers a platform for top-level fundamental research as well as applied research relevant for the financial sector in Europe. CFS is funded by the non-profit-organization Gesellschaft für Kapitalmarktforschung e.V. (GfK). Established in 1967 and closely affiliated with the University of Frankfurt, it provides a strong link between the financial community and academia. GfK members comprise major players in Germany's financial industry. The funding institutions do not give prior review to CFS publications, nor do they necessarily share the views expressed therein.

Big Data, Data Mining, Machine Learning und Predictive Analytics – ein konzeptioneller Überblick

Prof. Dr. Volker Brühl

Frankfurt am Main, 21. Januar 2019

Abstract:

Deutsch:

Mit der fortschreitenden Digitalisierung von Wirtschaft und Gesellschaft wächst die Bedeutung von Big Data Analytics, maschinellem Lernen und Künstlicher Intelligenz für die Analyse und Prognose ökonomischer Trends. Allerdings werden in wirtschaftspolitischen Diskussionen diese Begriffe häufig verwendet, ohne dass jeweils klar zwischen den einzelnen Methoden und Disziplinen differenziert würde. Daher soll nachfolgend ein konzeptioneller Überblick über die Gemeinsamkeiten, Unterschiede und Interdependenzen der vielfältigen Begrifflichkeiten im Bereich Data Science gegeben werden. Denn gerade für Entscheidungsträger aus Wirtschaft und Politik kann eine grundlegende Einordnung der Konzepte eine sachgerechte Diskussion über politische Weichenstellungen erleichtern.

Englisch:

Due to the ongoing process of digitisation, Big Data Analytics and Artificial Intelligence are becoming more and more relevant for the analysis of economic processes, trends and the future competitiveness of German industry. However, these technical terms are often applied in economic policy discussions without clearly differentiating between the various disciplines, methods and instruments that make up modern Data Science. Therefore, this article aims to give a conceptual overview covering commonalities, differences and linkages between Big Data, Data Mining, Machine Learning und Predictive Analytics. Political decision-makers and top managers will benefit from a fundamental understanding of the different concepts and technological applications when discussing strategic decisions.

JEL Classification: A10, C10, D80

Big Data, Data Mining, Machine Learning und Predictive Analytics – ein konzeptioneller Überblick

Prof. Dr. Volker Brühl

1. Einführung

Seit geraumer Zeit werden die disruptiven Auswirkungen der Digitalisierung auf die Zukunftsfähigkeit bestehender Geschäftsmodelle, aber auch auf den Wandel ganzer industrieller Sektoren sowie der Gesamtwirtschaft diskutiert. Schon heute ist erkennbar, dass Wertschöpfungsketten aufbrechen und sich neu konfigurieren. Digitale Plattformen ermöglichen neue Geschäftskonzepte, Unternehmen agieren zunehmend in mehreren Netzwerken gleichzeitig. Die Digitalisierung verändert nicht nur die industrielle Landschaft, sondern auch die Arbeitsmärkte, die urbane Infrastruktur, Mobilität, Wohnen und unser gesellschaftliches Leben. All diese Veränderungen wären letztlich nicht möglich ohne neue Technologien, die es erlauben, ein beschleunigt wachsendes Datenvolumen zu erfassen, auszuwerten und auf vielfältige Weise zu nutzen. Das Spektrum potenzieller Anwendungen umfasst die intelligente Steuerung von Verkehrsströmen, autonomes Fahren oder digitale Produktionsanlagen in der Industrie ebenso wie neue Verfahren zur medizinischen Diagnostik oder bessere Wettervorhersagen. Die Auswertung von Social Media-Daten erlaubt ein besseres Kundenverständnis und damit letztlich personalisierte Produkte und Dienstleistungen.

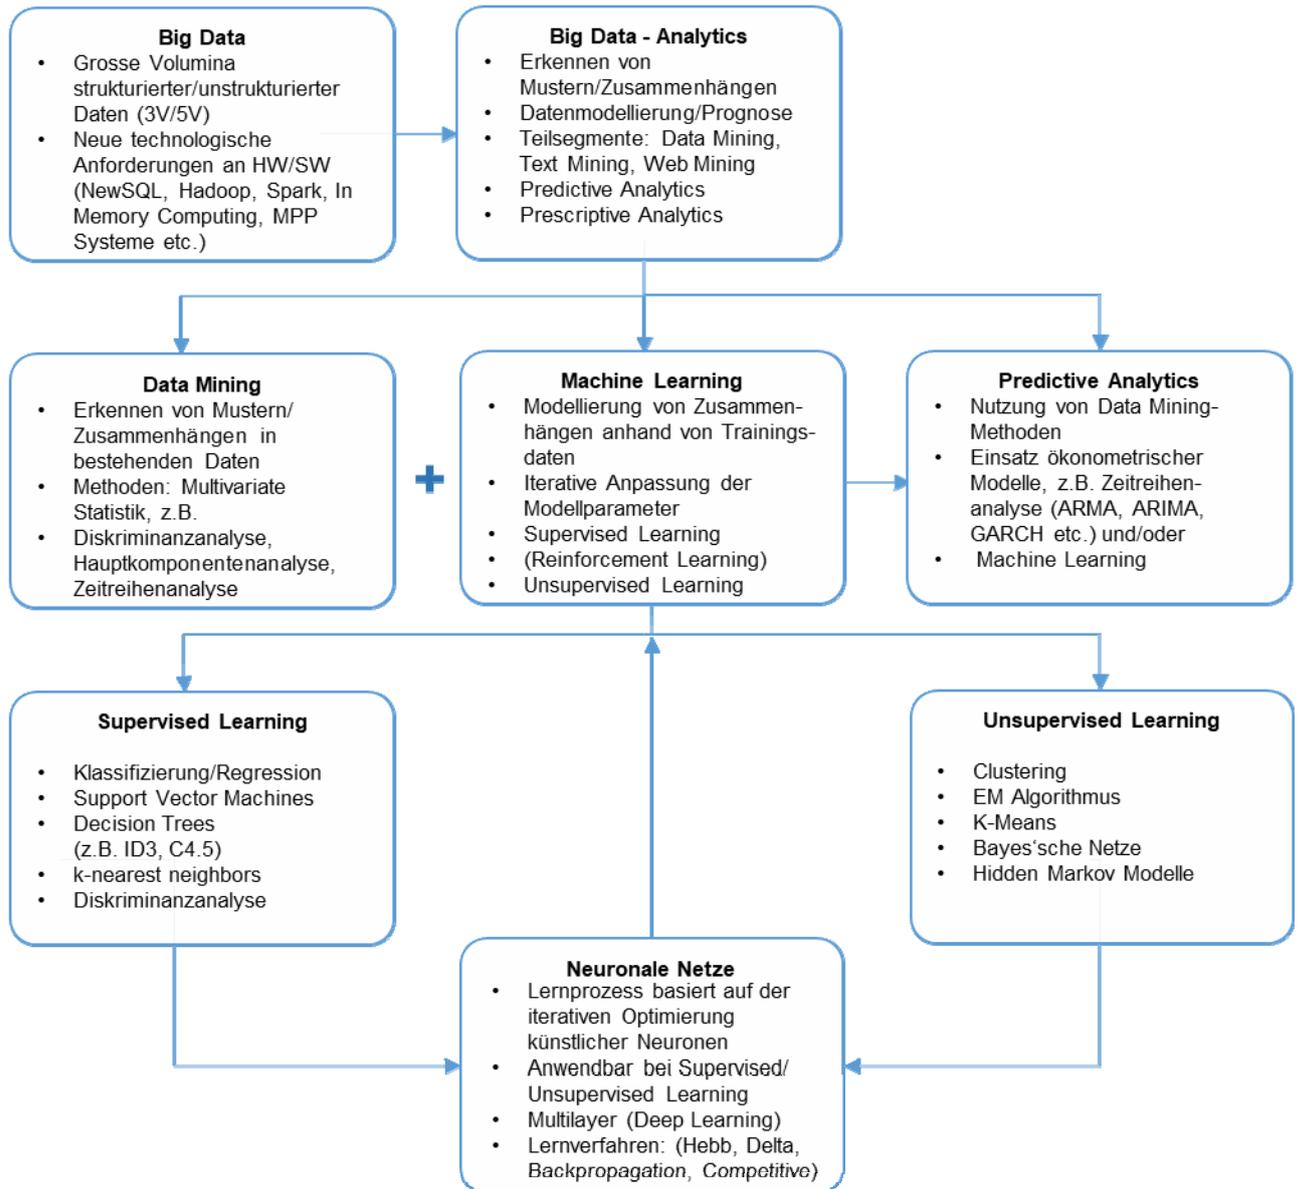
In diesem Zusammenhang werden unterschiedliche Schlagwörter wie Big Data, Predictive Analytics, maschinelles Lernen und nicht zuletzt Künstliche Intelligenz in wirtschaftspolitischen oder unternehmensstrategischen Diskussionen verwendet, ohne dass jeweils klar zwischen den einzelnen Methoden und Disziplinen differenziert würde. So bleibt oft unklar, worin sich eigentlich aus dem Data Mining bekannte Analyseverfahren von Big Data- oder Predictive Analytics unterscheiden. Was bedeutet Maschinelles Lernen genau und in welchem Verhältnis stehen diese Lernverfahren zum Themenfeld Predictive Analytics? Warum ist maschinelles Lernen nur ein Teil des Forschungsgebietes der Künstlichen Intelligenz? Wann spricht man überhaupt von KI?

Nachfolgend soll ein strukturierter Überblick über die Gemeinsamkeiten, Unterschiede und Interdependenzen der vielfältigen Begrifflichkeiten im Bereich Data Science gegeben werden. Denn gerade für Entscheidungsträger aus Wirtschaft und Politik, die in der Regel nicht mit den methodischen bzw. technologischen Details vertraut sind bzw. sein können, kann eine grundlegende Einordnung der Konzepte eine sachgerechte Diskussion über strategische oder politische Weichenstellungen erleichtern.

2. Big Data

Einen Überblick über die Zusammenhänge zwischen Big Data, Data Mining, Maschinellern Lernen und Predictive Analytics gibt Abbildung 1. Zunächst soll der Begriff Big Data als Ausgangspunkt und Grundlage der weiterführenden Methoden und Instrumente präzisiert werden. Unter Big Data versteht man das Phänomen, dass infolge der Digitalisierung von Wirtschaft und Gesellschaft nicht nur das Volumen der Daten („Volume“), sondern auch die Geschwindigkeit der Generierung, Verarbeitung und Speicherung von Daten („Velocity“) sowie die Heterogenität der Datentypen und -quellen („Variety“) in den letzten Jahren stark zugenommen hat.

Abbildung 1: Big Data, Maschinelles Lernen und Predictive Analytics



Quelle: Eigene Darstellung

Da sich die Komplexität eines Datenpools gerade durch das Zusammenwirken dieser drei Faktoren („3V“) ergibt, erscheint es wenig sinnvoll, ein Datenvolumen zu definieren, ab welchem Datenvolumen man von Big Data spricht.¹ Die Einschätzungen variieren zwischen einem Mindestdatenvolumen von 10 Terabyte bis zu 1 Petabyte (1 Petabyte = 10^{15} Bytes), das kontextabhängig in einem bestimmten Zeitraum zu erfassen und zu verarbeiten ist.² Spätestens ab einem zu verwaltenden bzw. zu verarbeitenden Datenvolumen von etwa 100 Terabyte stoßen herkömmliche Speicher- und Verarbeitungssysteme an ihre Grenzen.

¹ Vgl. Laney, D., 3D Data Management: Controlling Data Volume, Velocity and Variety, Stamford 2001. Andere Autoren erweitern den Big Data-Begriff um eine vierte Dimension (Relevanz, „Value“) oder gar fünfte Dimension (Zuverlässigkeit, „Veracity“). Einen Überblick geben z. B. Wamba, S.L., Akter, S., Edwards, A., Chopin, G., Gnanzou, D., How 'big data' can make big impact: Findings from a systematic review and a longitudinal case study, International Journal of Production Economics, 165, 2015

² Vgl. IDC, Big Business dank Big Data – Deutschland, Frankfurt 2012

Dabei können die Daten aus sehr unterschiedlichen Quellen (IP, Sensoren, Social Media, Verbindungsdaten, Transaktionsdaten, Geschäftszahlen etc.) stammen, unterschiedliche Datentypen (Texte, Zahlen, Bilder etc.) beinhalten bzw. in strukturierter oder unstrukturierter Form vorliegen. Zu den wichtigen Treibern des Datenwachstums gehören die zunehmende (mobile) Internetnutzung, die steigende Nutzungsintensität von Sozialen Netzwerken, die fortschreitende Digitalisierung von Produktion, Haushalt, Energieversorgung und Mobilität (Internet of Things, IoT) und Dienstleistungen (Internet of Services, IoS). Hinzu kommen sinkende Hardware-Kosten für Endgeräte, Server und Speichermedien. Insgesamt wächst das verfügbare Datenvolumen mit hoher Geschwindigkeit. Schätzungen gehen davon aus, dass das weltweit verfügbare Volumen elektronischer Daten von ca. 33 Zettabytes im Jahr 2018 auf etwa 175 Zettabytes im Jahr 2025 ansteigen wird (1 Zettabyte = 10^{21} Bytes).³

Um diese enormen Datenvolumina verarbeiten zu können, benötigt man nicht nur entsprechend leistungsfähige Prozessoren. Die Erfassung und Verarbeitung dieser enormen zumeist heterogenen Datenvolumina erfordert in der Regel auch neue Datenbank- und Verarbeitungstechnologien. Denn herkömmliche Datawarehouse-Konzepte, die auf relationalen Datenbanken betrieben und mit SQL gelesen und bearbeitet werden, stoßen bei Big Data schnell an ihre Grenzen. Zu den neuen für Big Data geeigneten Systemen gehören neben sog. NoSQL- („Not only SQL“) Datenbanken beispielsweise die Apache Hadoop- bzw. Apache Spark-Technologien, die es als verteilt arbeitende Software ermöglichen, intensive Rechenprozesse mit großen Datenmengen (im Petabyte-Bereich) auf Computerclustern durchzuführen. Hadoop ist ein in Java geschriebenes Open Source-Framework zur parallelen Datenverarbeitung auf sehr hoch skalierbaren Server-Clustern.⁴ Alternativ oder auch in Ergänzung zu Hadoop Technologien kommen In-Memory-Systeme zur Anwendung, bei denen Rechnerprozesse direkt im Hauptspeicher verarbeitet und somit deutlich schneller durchgeführt werden können.⁵ Alternativ oder in Kombination zu Hadoop können Massive Parallel Processing (MPP)-Systeme im Bereich Big Data eingesetzt werden. Darunter versteht man eine Computerarchitektur, bei der zahlreiche Prozessoren gleichzeitig einen Teil der Gesamtdaten bearbeiten.

3. Big Data Analytics

Unter Big Data Analytics versteht man Methoden und Verfahren, mit denen man in Big Data versteckte Strukturen, Muster oder Zusammenhänge entdecken kann, um modellbasierte Prognosen für künftige entscheidungsrelevante Entwicklungen treffen zu können („Predictive Analytics“) oder sogar Entscheidungen selbst vorschlagen bzw. im Grenzfall automatisiert treffen zu können („Prescriptive Analytics“). Abbildung 1 verdeutlicht die unterschiedlichen Teilbereiche, die man unter „Big Data Analytics“ subsumieren kann.

Häufig werden die Begriffe Data Mining, Machine Learning und Predictive Analytics nahezu synonym oder zumindest nicht trennscharf verwendet. Der Begriff des Data Mining wird schon seit vielen Jahren verwendet, während die Bezeichnung „Predictive Analytics“ sich erst seit wenigen Jahren zu verbreiten beginnt. Data Mining wird häufig als ein Prozessschritt im Rahmen des sogenannten „Knowledge Discovery Process“ verwendet, der einen mehrstufigen Prozess der Wissensgenerierung umfasst, der von der Datengewinnung und -transformation über die Datenanalyse zu verwertbarem Wissen führt.⁶ Daher kann man die Verfahren des maschinellen Lernens durchaus als ein Teilgebiet des Data Mining interpretieren und somit Data Mining als Oberbegriff für sämtliche datengestützten Analyse- und Prognoseverfahren begreifen.

³ Vgl. IDC, Data Age 2025 - The Digitization of the World, Framingham 2018

⁴ Vgl. Intel, Big Data 101: Unstructured Data Analytics, Santa Clara, 2012

⁵ Vgl. Freiknecht, J., Papp, S., Big Data in der Praxis: Lösungen mit Hadoop, Spark, HBase und Hive. Daten speichern, aufbereiten, visualisieren, München 2018

⁶ Vgl. Fayyad, U., Piatetsky-Shapiro, G., Smyth, P., From Data Mining to Knowledge Discovery in Databases, AI Magazine Volume 17 Number 3 1996

Alternativ kann man – und dies wird in diesem Beitrag vorgeschlagen - Big Data Analytics als Oberbegriff für Data Mining, Machine Learning und Predictive Analytics verstehen. Dies erleichtert insbesondere die Einordnung des recht neuen Terminus „Predictive Analytics“ und ermöglicht es zudem, die Methoden und Algorithmen stärker hinsichtlich ihrer Analyse- bzw. Prognosefunktion zu trennen. Dabei umfasst Data Mining die (wiederholte) Anwendung statistischer Analysemethoden zur Erkennung von Trends, Strukturen und Muster in den jeweiligen Datensätzen. Dabei kommen Methoden aus der Multivariaten Statistik wie Verfahren der Cluster- bzw. Diskriminanzanalyse (u.a. zur Klassifikation bzw. Kategorisierung) oder ökonomische Verfahren der Zeitreihenanalyse zum Einsatz. Der Fokus des Data Mining liegt also vor allem auf der explorativen Analyse bestehender strukturierter Daten. Werden unstrukturierte Daten wie Texte, Web-Content oder Nutzerverhalten im Internet untersucht, spricht man von Text-Mining bzw. Web-Mining.

Im Unterschied zu Data Mining sollen nachfolgend dann Methoden und Prozesse dem Bereich „Predictive Analytics“ zugeordnet werden, wenn sich diese auf die datengestützte Prognose von künftigen Ereignissen oder Trends konzentrieren. Dabei werden häufig Methoden des maschinellen Lernens als einem Teilgebiet der Künstlichen Intelligenz angewendet. Alternativ oder ergänzend kommen je nach Problemstellung und Datenkontext auch ökonomische Methoden zur Entwicklung von Prognosemodellen zum Einsatz.⁷ Daher wird an dieser Stelle vorgeschlagen, den Bereich des Predictive Analytics insofern als eine Weiterentwicklung von Data Mining zu betrachten, als das Instrumentarium des Data Mining um Methoden aus dem Maschinellen Lernen ergänzt wird (Abbildung 1).

4. Maschinelles Lernen und Künstliche Intelligenz

Maschinelles Lernen ist ein Teilgebiet des Forschungsgebietes „Künstliche Intelligenz (KI)“. Letztere wird weithin zu den Schlüsseltechnologien gezählt, die künftig die Wettbewerbsfähigkeit zahlreicher Industrien prägen werden. Dabei wird der Begriff der Künstlichen Intelligenz durchaus sehr unterschiedlich definiert. So kann man Künstliche Intelligenz als Oberbegriff für Technologien und Systeme verstehen, die Aufgaben durchführen können, die ansonsten menschliche Intelligenz erfordern.⁸ Dazu bedarf es bestimmter Fähigkeiten, die sich vereinfacht in „Wahrnehmen“, „Verstehen“, „Handeln“ und „Lernen“ einteilen lassen.⁹ Maschinelles Lernen ermöglicht das Trainieren moderner KI-Systeme, so dass sich diese an veränderte Umweltbedingungen anpassen, selbst optimieren und damit deutlich bessere Ergebnisse erzielen können als frühere KI-Systeme, die auf klar definierten und fest programmierten Regeln basierten. Das Ziel von KI besteht letztlich darin, einen rational und autonom agierenden Agenten zu entwickeln. Dieser kann z. B. über Sensoren relevante Umweltinformationen erfassen, analysieren und mit Blick auf bestimmte Performance-Parameter optimale Schlussfolgerungen ziehen. Diese wiederum werden über Aktoren in physische (Robotik) oder virtuelle Handlungen (z. B. Chatbots) umgesetzt. Maschinelle Lernalgorithmen stellen sicher, dass die Handlungsergebnisse bzw. Veränderungen der Umweltzustände erfasst und somit neue Informationen generiert werden, die in einem iterativen Prozess schrittweise die Zielerreichung des Systems optimieren. Unabhängig vom konkreten Anwendungsfall müssen auf maschinellem Lernen basierende Modelle vor ihrem Einsatz anhand von verfügbaren Ausgangsdaten trainiert und getestet werden, um eine möglichst gute Prognosegüte zu erreichen. Dabei können je nach Datenverfügbarkeit und Use Case grundsätzlich zwei Lernkategorien unterschieden werden.¹⁰

⁷ In der Zeiteihenanalyse werden dazu z. B. ARMA-, ARIMA- oder GARCH-Modelle eingesetzt, auf die an dieser Stelle nicht weiter eingegangen werden soll.

⁸ Vgl. Russel, S.J., Norvig, P., Artificial Intelligence – A Modern Approach, third edition, London 2010

⁹ Vgl. z. B. DFKI/Bitkom, Künstliche Intelligenz - Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung, Berlin, Kaiserslautern 2018

¹⁰ Zum Begriff des maschinellen Lernens vgl. Mitchell, T.C., Machine Learning, New York 1997. Das sog. reinforcement learning („bestärkendes Lernen“) ist eine weitere Kategorie maschinellen Lernens,

4.1 Supervised Learning oder Unsupervised Learning

Überwachtes Lernen („Supervised Learning“) liegt vor, wenn ein Prognosemodell entwickelt wird, das mit Hilfe von gegebenen Input- und bekannten (korrekten) Outputdaten trainiert wird. Aus dem Vergleich der modellbasierten Prognosen mit den korrekten Outputs können Prognosefehler erkannt und das Modell schrittweise optimiert werden. Grundlage sind in der Regel Regressions- oder Klassifizierungsmodelle. Mit steigenden Trainingsdaten reduzieren sich die Prognosefehler. Anwendungsfälle finden sich z. B. in den Bereichen der Sprach- oder Bilderkennung, der Identifizierung von Spam-Mails oder im Kredit scoring. Lernalgorithmen, die im Zusammenhang von überwachtem Lernen eingesetzt werden, sind beispielsweise Entscheidungsbaumverfahren, Support Vector Machines (SVM), Diskriminanzanalyse oder „k-nearest neighbors“-Algorithmen (Abbildung 1).

Unüberwachtes Lernen („Unsupervised Learning“) wird zumeist bei sehr heterogenen Daten verwendet, für die keine konkreten Outputdaten vorliegen. Anhand von Merkmalen der Inputdaten sollen verborgene Muster und Strukturen erkannt und der Datenbestand in Cluster segmentiert werden. Als Lernalgorithmen können z. B. Bayes-Netze, Hidden Markov-Modelle oder k-Means-Modelle verwendet werden (Tabelle 1).¹¹ Anwendungsfelder finden sich z. B. in der Marktforschung, um aus Transaktionsdaten oder Social Media Daten Kundensegmente zu extrahieren.

4.2 Künstliche Neuronale Netze

Künstliche neuronale Netze (KNN) werden als eine Form des maschinellen Lernens sowohl im Bereich des überwachten als auch des unüberwachten Lernens eingesetzt. Konzeptionelles Vorbild für KNN ist die Informationsübertragung im menschlichen Nervensystem. Das Gehirn besteht etwa aus 100 Milliarden Nervenzellen (Neuronen), die die Aufnahme, Speicherung, Verarbeitung und Weitergabe von Informationen ermöglichen. Jedes Neuron besteht vereinfacht gesagt aus einem Zellkörper (Soma), einer Vielzahl von Dendriten und einem Axon (Abbildung 2).¹²

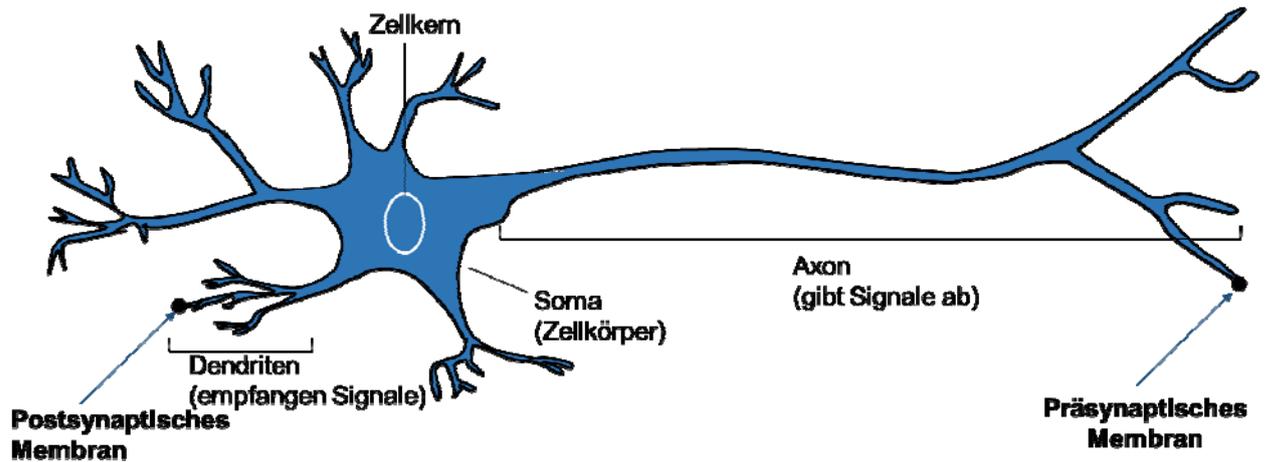
Die Dendriten sind die Verästelungen des Zellkörpers, die Informationen in Form von ankommenden elektrischen Signalen empfangen und an den Zellkörper zur Informationsverarbeitung weiterleiten. Das Axon, das über eine Vielzahl von Verzweigungen verfügt, leitet elektrische Impulse bzw. Informationen an die Synapsen weiter, sofern die Summe der über die Dendriten empfangenen Eingangssignale einen bestimmten Schwellenwert überschreitet. Die Synapsen stellen über die Ausschüttung von Botenstoffen (Neurotransmitter) den Kontakt und damit die Informationsübertragung zu anderen Neuronen her. Durch Lernvorgänge werden die Neuronen untereinander zu sehr komplexen neuronalen Netzen verknüpft. Je nach Komplexität der Aufgabe können Milliarden von Neuronen simultan beispielsweise bei der Erkennung von Mustern beteiligt sein.

die es autonomen Agenten durch gegebene Anreizsysteme ermöglichen soll, eigenständig optimale Verhaltenstrategien zu erlernen.

¹¹ Vgl. Ertel, W., Künstliche Intelligenz – eine praxisorientierte Einführung, Wiesbaden 2016

¹² Vgl. Bartheld, C.S., Bahney J., Herculano-Houzel, S., The search for true numbers of neurons and glial cells in the human brain: A review of 150 years of cell counting, The Journal of Comparative Neurology, 524 (18) 2016

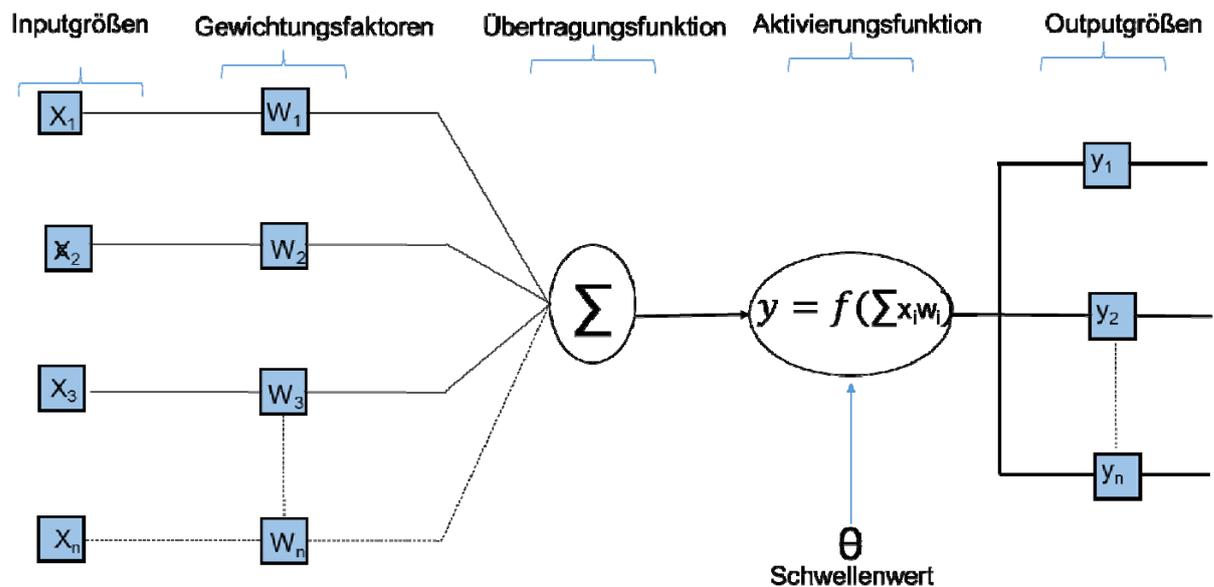
Abbildung 2: Aufbau einer Nervenzelle (Neuron) – stark vereinfacht



Quelle: Eigene Darstellung

Wie bei biologischen neuronalen Netzen besteht ein künstliches Neuronales Netz aus einer Vielzahl von künstlichen Neuronen (Units). Abbildung 3 verdeutlicht den vereinfachten Aufbau eines einzelnen künstlichen Neurons (Unit). Jedes Unit verfügt über eine bestimmte Anzahl von Eingabeparametern, die mit Gewichtungsfaktoren versehen werden. Die Summe der gewichteten Eingabewerte wird dann mit Hilfe einer Aktivierungsfunktion bewertet. Bei Überschreiten eines bestimmten Schwellenwertes werden ein oder mehrere Outputsignale generiert.

Abbildung 3: Aufbau eines künstlichen Neurons (Unit)

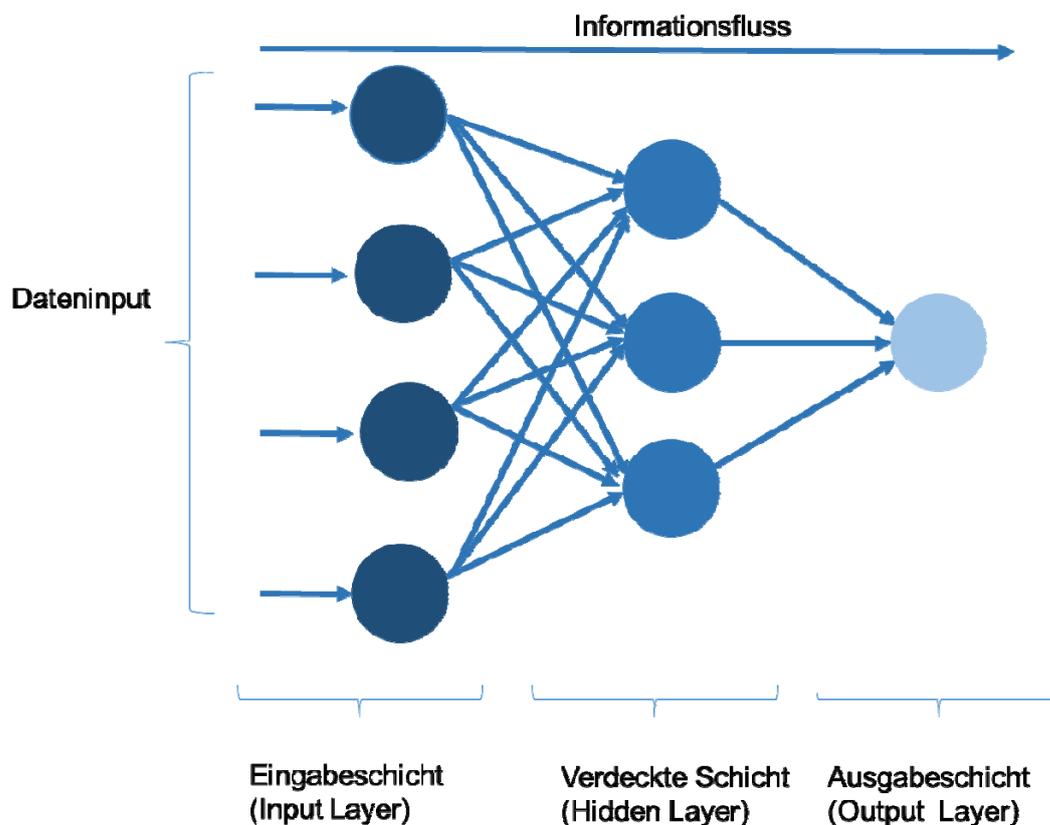


Quelle: Eigene Darstellung

Durch die Verknüpfung einer Vielzahl von Neuronen entstehen Künstliche Neuronale Netze (KNN), die aus unterschiedlichen Schichten (Layer) bestehen. Neuronen, die Informationen von außen aufnehmen, bilden insgesamt den Input Layer, während Neuronen, die

Informationen an die Umwelt abgeben, den Output Layer darstellen. Neuronen, die sich zwischen den Input- bzw. Output Units befinden (Hidden Units), bilden ein oder mehrere Hidden Layer. KNN können nach unterschiedlichen Kriterien segmentiert werden, beispielsweise nach der Anzahl der verborgenen Schichten. Herkömmliche KNN enthalten zumeist nur wenige Hidden Layer, während sog. "tiefe" KNN mehrere hundert Hidden Layer aufweisen können. Diese auch als "Deep Learning"-Modelle bezeichneten KNN erfordern aufgrund der Vielzahl der Verbindungen zwischen den Neuronen ein hohes Volumen an Trainingsdaten, um eine hinreichend gute Prognosequalität zu erreichen. Darüber hinaus kann man je nach Richtung der Informationsverarbeitung zwischen rückkoppelungsfreien „Feed Forward-Netzen“ oder Netzen mit Rückkoppelungseffekten zwischend den Ebenen ("Feedback-Netze") differenzieren. Abbildung 4 zeigt beispielhaft den Aufbau eines dreischichtigen Feed Forward-Netzes.

Abbildung 4: Beispiel für ein dreischichtiges "Feed Forward-Netz"



Quelle: Eigene Darstellung

KNN finden derzeit überwiegend bei überwachten Lernsituationen Anwendung, in denen also komplexe Zusammenhänge anhand bekannter Input- und Output-Daten erlernt werden können. Dabei werden insbesondere die Gewichte der Input-Faktoren schrittweise solange geändert, bis eine möglichst optimale Approximation zwischen Input und bekannten Output-Daten erreicht wird. Dabei kommen unterschiedliche Lernverfahren zur Anwendung. Zu den bekanntesten gehört der Backpropagation-Algorithmus, der die Gewichtungen der Neuronenverbindungen in Abhängigkeit von ihrem Einfluss auf den Fehler des Netzwerkes ändert. Dadurch wird eine schrittweise Fehlerrückführung des Netzwerkes erreicht. KNN können aber auch dann angewendet werden, wenn lediglich Input-Daten und keine korrespondierenden Output-Daten bekannt sind. Dann können aus den bestehenden Input-

Daten durch rekursive Anwendung von Lernalgorithmen schrittweise Strukturen und Muster in den Daten extrahiert werden, die vorher nicht erkennbar waren. Häufig handelt es sich dabei um eine Art Klassifizierungsaufgabe. Künstliche Neuronale Netze werden inzwischen in zahlreichen Anwendungsfeldern eingesetzt oder erprobt. Dazu gehören z. B. die Bereiche Qualitätsmanagement, Produktions- oder Absatzplanung in industriellen Unternehmen, autonomes Fahren, Stromverbrauchsprognosen, Instandhaltungsprozesse oder Ratingverfahren.

5. Fazit

Fortschritte in der Informationstechnologie vergrößern mit hoher Geschwindigkeit die Erfassung, Speicherung und Verarbeitung jeglicher Form von Daten. Diese können durch Weiterentwicklungen bestehender und Entwicklung neuer Methoden zur Datenanalyse- und prognose systematisch genutzt werden. Beide Faktoren zusammen führen zu teilweise disruptiven Veränderungen auf Unternehmens-, Sektor- und gesamtwirtschaftlicher Ebene. Insbesondere bei politischen und unternehmerischen Entscheidungsträgern werden die hier erläuterten Begrifflichkeiten oftmals wenig trennscharf verwendet. Es bestehen häufig sehr unterschiedliche Auffassungen bis hin zu nebulösen Vorstellungen darüber, was man unter diesen Technologien zu verstehen hat, wo sie sich unterscheiden und wo Überlappungen bestehen. Ein grundlegendes Verständnis ist aber erforderlich, um unabhängig von den Technologieexperten wirtschafts- und gesellschaftspolitische Implikationen dieser Zukunftstechnologien analysieren und diskutieren zu können. Dieser Diskurs steht noch am Anfang. Aber es ist jetzt schon absehbar, dass nicht nur unsere Arbeitswelt in zwanzig Jahren ganz anders aussehen wird als heute. Denn es ist in nicht allzu ferner Zukunft zu erwarten, dass die bestehende Wertschöpfung in weiten Teilen der industriellen Fertigung, der Landwirtschaft aber auch des Dienstleistungssektors durch intelligente Automatisierungstechnologien mit einem Bruchteil der derzeit noch benötigten Beschäftigten erzeugt werden kann.

Recent Issues

All CFS Working Papers are available at www.ifk-cfs.de.

No.	Authors	Title
616	Nikolaus Hautsch, Christoph Scheuch, and Stefan Voigt	<i>Limits to Arbitrage in Markets with Stochastic Settlement Latency</i>
615	Winfried Koeniger and Marc-Antoine Ramelet	<i>Home Ownership and Monetary Policy Transmission</i>
614	Christos Koulovatianos and Dimitris Mavridis	<i>Increasing Taxes After a Financial Crisis: Not a Bad Idea After All...</i>
613	John Donaldson, Christos Koulovatianos, Jian Li and Rajnish Mehra	<i>Demographics and FDI: Lessons from China's One-Child Policy</i>
612	Hans Gersbach	<i>Contingent Contracts in Banking: Insurance or Risk Magnification?</i>
611	Christian Leuz	<i>Evidence-Based Policymaking: Promise, Challenges and Opportunities for Accounting and Financial Markets Research</i>
610	Christian Leuz and João Granja	<i>The Death of a Regulator: Strict Supervision, Bank Lending and Business Activity</i>
609	Christian Leuz, Steffen Meyer, Maximilian Muhn, Eugene Soltes, and Andreas Hackethal	<i>Who Falls Prey to the Wolf of Wall Street? Investor Participation in Market Manipulation</i>
608	Brandon Gipper, Luzi Hail, and Christian Leuz	<i>On the Economics of Audit Partner Tenure and Rotation: Evidence from PCAOB Data</i>
607	Vanya Horneff, Raimond Maurer and Olivia S. Mitchell	<i>Putting the Pension Back in 401(k) Retirement Plans: Optimal versus Default Longevity Income Annuities</i>