

Andreas Moring

Künstliche Intelligenz und Intuition

Robuste und nachhaltige Entscheidungen
in digitalen Arbeitswelten



Springer Gabler

Künstliche Intelligenz und Intuition

Andreas Moring

Künstliche Intelligenz und Intuition

Robuste und nachhaltige Entscheidungen
in digitalen Arbeitswelten

Andreas Moring
Hamburg, Hamburg, Deutschland

ISBN 978-3-658-42017-8 ISBN 978-3-658-42018-5 (eBook)
<https://doi.org/10.1007/978-3-658-42018-5>

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.

© Der/die Herausgeber bzw. der/die Autor(en), exklusiv lizenziert an Springer Fachmedien Wiesbaden GmbH, ein Teil von Springer Nature 2023

Das Werk einschließlich aller seiner Teile ist urheberrechtlich geschützt. Jede Verwertung, die nicht ausdrücklich vom Urheberrechtsgesetz zugelassen ist, bedarf der vorherigen Zustimmung des Verlags. Das gilt insbesondere für Vervielfältigungen, Bearbeitungen, Übersetzungen, Mikroverfilmungen und die Einspeicherung und Verarbeitung in elektronischen Systemen.

Die Wiedergabe von allgemein beschreibenden Bezeichnungen, Marken, Unternehmensnamen etc. in diesem Werk bedeutet nicht, dass diese frei durch jedermann benutzt werden dürfen. Die Berechtigung zur Benutzung unterliegt, auch ohne gesonderten Hinweis hierzu, den Regeln des Markenrechts. Die Rechte des jeweiligen Zeicheninhabers sind zu beachten.

Der Verlag, die Autoren und die Herausgeber gehen davon aus, dass die Angaben und Informationen in diesem Werk zum Zeitpunkt der Veröffentlichung vollständig und korrekt sind. Weder der Verlag noch die Autoren oder die Herausgeber übernehmen, ausdrücklich oder implizit, Gewähr für den Inhalt des Werkes, etwaige Fehler oder Äußerungen. Der Verlag bleibt im Hinblick auf geografische Zuordnungen und Gebietsbezeichnungen in veröffentlichten Karten und Institutionsadressen neutral.

Planung/Lektorat: Susanne Kramer

Springer Gabler ist ein Imprint der eingetragenen Gesellschaft Springer Fachmedien Wiesbaden GmbH und ist ein Teil von Springer Nature.

Die Anschrift der Gesellschaft ist: Abraham-Lincoln-Str. 46, 65189 Wiesbaden, Germany

Inhaltsverzeichnis

1	Einleitung	1
1.1	Fragestellung und Relevanz	1
1.2	Gang der Untersuchung und Stand der Forschung	4
	Literatur	6
2	Funktion und Einsatz von Künstlicher Intelligenz	7
2.1	Künstliche Intelligenz	8
2.2	Die wichtigsten Anwendungen von KI heute und morgen	25
2.3	Einführung und Nutzung von KI in Unternehmen	27
2.3.1	Finden und definieren von Use Cases	34
2.3.2	Änderungen in der Führung durch KI	41
2.4	KI und Ethik	44
2.5	KI und Nachhaltigkeit	47
2.5.1	Nachhaltigkeit von KI-Systemen selbst	53
2.5.2	KI und ML-Methoden für die nachhaltige Verringerung von Umweltbelastungen	55
2.6	Bei welchen Entscheidungen auf KI stützen – und bei welchen nicht	65
	Literatur	67
3	Funktion und Einsatz von menschlicher Intuition	71
3.1	Historische Definitionen und Beschreibungen der Intuition	71
3.2	Was ist Intuition?	77
3.3	Biologische Grundlagen der Intuition	113
3.3.1	Bedeutung von Emotionen	125
3.3.2	Bedeutung von Hirnwellen	130
3.4	Komplexität, Intuition und Entscheiden	135
3.5	Intuition und Nachhaltigkeit	148
3.6	Bei welchen Entscheidungen wir uns auf Intuition stützen sollten – und bei welchen nicht	151
	Literatur	154

4	Wie KI und Intuition genutzt werden sollten	159
4.1	Gemeinsamkeiten von KI und Intuition	159
4.2	Intuition und Führung	161
4.3	Training von Intuition als Kompetenz	170
4.4	Intuition erkennen und trainieren	181
	Literatur	193
5	AI + AI – Archaische Intelligenz im Zeitalter von Artificial Intelligence ...	197



1.1 Fragestellung und Relevanz

Künstliche Intelligenz (KI) ist in unserem Alltag angekommen. Das gilt im Privaten wie im Beruflichen. KI wird auch nicht mehr verschwinden. Künstliche Intelligenz ist keine Applikation oder ein Produkt, es ist ein technologisches Prinzip, eine Grundstruktur, die universell in den verschiedensten Bereichen und für unterschiedliche Zwecke einzusetzen ist. Damit ist KI ihrem Wesen und ihrer Wirkung nach vergleichbar mit dem Internetprotokoll, mit Markup Languages oder mit neuen Formen der digitalen Kommunikation wie Social Media. Natürlich sind alle genannten Beispiele technologisch und strukturell nicht miteinander zu vergleichen. Doch alle hatten einen revolutionären Einfluss auf unser Leben und Arbeiten und haben ihn weiterhin. Künstliche Intelligenz in ihren vielfältigen Formen und Anwendungen wird ebensolche revolutionären und umfassenden Folgen haben. Wir sehen bereits heute in unterschiedlichen Branchen wie der Logistik, der Medizin, der Finanzwirtschaft oder der Landwirtschaft KI-Anwendungen in Aktion. Auch das ist ein Zeichen für einen grundlegenden technologischen Wandel: Wenn sich eine Technologie in vielen, ja fast allen, Umfeldern anwenden und einsetzen lässt, dann werden die Folgen und Effekte auch überall zu spüren sein.

Dabei sind wir bereits in eine neue Stufe eingetreten, ohne dass die ersten Stufen der KI-Evolution schon bei uns allen merkbar angekommen wären. Generative KI – also jene, die etwas scheinbar aus sich selbst heraus hervorbringen kann, wie beispielsweise ChatGPT oder Midjourney – führt Menschen im Sinne des Wortes sichtbar vor Augen, dass viele unserer Tätigkeiten, die wir unter „Arbeit“ oder unserem „Job“ subsumieren von KI übernommen werden können. Unter generativer KI werden also datenbasierte Technologien verstanden, die neue Ideen, Inhalte oder Lösungen erstellen können, anstatt nur vordefinierte Regeln oder Anweisungen abzuarbeiten. Eine Studie der University of Pennsylvania untersuchte Anfang 2023 (Eloundou et al. 2023), auf welche Jobs sich

generative KI wie ChatGPT am stärksten auswirkt. Danach gehören Buchhalter zu den Berufsgruppen, die am stärksten von den Möglichkeiten der generativen Künstlichen Intelligenz betroffen sind. Mindestens die Hälfte der Aufgaben in der Buchhaltung könnten mit dieser Technologie viel schneller erledigt werden. Auch Mathematiker, Programmierer, Dolmetscher, Schriftsteller und Journalisten müssten damit rechnen, dass die Künstliche Intelligenz zumindest einen Teil ihrer bisherigen Aufgaben übernehmen kann. Denn obwohl die KI-Systeme derzeit bei ihren Antworten oft noch fehlerhafte Fakten „halluzinieren“, liefern sie bei Aufgaben wie Übersetzung, Klassifizierung, kreativem Schreiben und Generierung von Computercodes bereits jetzt schon beachtliche Ergebnisse. Diese Fähigkeiten würden sich, wie das bei Künstlicher Intelligenz nun mal so ist, mit der verstärkten Nutzung und Anwendung noch deutlich verbessern und die Entwicklung beschleunigen. Die Studie geht davon aus, dass die meisten Arbeitsplätze in irgendeiner Form durch KI-Sprachmodelle verändert werden. Rund 80 % der Arbeitnehmer in den USA seien in Berufen tätig, in denen mindestens eine Aufgabe durch generative KI schneller erledigt werden könne. Hierbei ist zu beachten, dass nicht komplette Jobs durch KI wegfallen werden, sondern bestimmte Aufgaben in diesen Jobs an Maschinen beziehungsweise KI-Systeme übertragen werden können. Hierzu hat auch der Autor dieses Buches bereits 2021 mit „KI im Job – Leitfaden zur erfolgreichen Mensch-Maschine-Zusammenarbeit“ mit eigenen Untersuchungen und Erkenntnissen Stellung genommen. Es gibt aber laut der Pennsylvania-Studie auch Berufe, in denen KI nur wenige Effekte haben wird. Dazu gehören vor allem handwerkliche Tätigkeiten wie Köche, Kfz-Mechaniker und Jobs in der Öl- und Gasförderung oder auch in der Forst- und Landwirtschaft.

Eine Studie der Investmentbank Goldman Sachs hat Anfang 2023 (Hatzius et al. 2023) ebenfalls zu prognostizieren versucht, was diese Entwicklung für den Arbeitsmarkt konkret bedeuten kann. Wenn die sogenannte generative KI die erwarteten und noch weitgehend versprochenen Fähigkeiten wirklich einhalte, könne dies zu erheblichen Verwerfungen auf dem Arbeitsmarkt führen. Die Studienmacher gehen davon aus, dass etwa zwei Drittel der derzeitigen Arbeitsplätze einem gewissen Grad an KI-Automatisierung ausgesetzt sind. Die generative KI könne bis zu einem Viertel der derzeitigen Arbeit ersetzen. Rechne man diese Schätzungen auf die ganze Welt hoch, so könnte generative KI das Äquivalent von 300 Mio. Vollzeit Arbeitsplätzen der Automatisierung aussetzen.

Es zeigt sich, dass vor allem verwalterische Tätigkeiten und zusammenfassende Tätigkeiten, die weitgehend aus Routinen bestehen und festen Regeln und Abläufen folgen, von der Automatisierung mittels KI betroffen sein werden. Es sind die sogenannten „white collar Jobs“, welche die nächste Welle der digitalen Revolution am stärksten abbekommen werden. Es trifft damit den Mittelbau in Unternehmen und in der Gesellschaft als Ganzes. Schauen wir auf die gängigen Tätigkeiten in den sogenannten Bürojobs, dann besteht dort ein Großteil der Arbeit darin, Zusammenfassungen zu schreiben, Wissen zu sammeln und zu verdichten. Künstliche Intelligenz ist besonders gut, wenn es darum geht etwas zu erkennen, zuzuordnen, zu vergleichen, zu optimieren und zu prognostizieren. Besonders

die ersten drei Aufgaben oder Tätigkeiten sind der Schwerpunkt vieler verwalterischer Prozesse oder von dem, was wir als „Management Aufgaben“ beschreiben. Hier wird KI überall Einzug halten und Aufgaben übernehmen. Bei den Aufgaben der Optimierung und der Prognose wird KI ebenfalls viel an Arbeit von Menschen übernehmen können. Doch hier gibt es verschiedene Dimensionen und Unsicherheiten. So ist es immer eine Frage der Interpretation und des jeweiligen Ziels, was unter einem Optimum zu verstehen ist. Manchmal gibt es so ein eindeutiges Optimum auch gar nicht. Das ist jeweils eine Frage des Kontextes und der Komplexität. Da ist selbst KI schnell überfordert. Menschen mit ihrem Wissen, ihren Erfahrungen und ihrer Intuition können hier besser verstehen und entscheiden. Bei Prognosen ist es ähnlich. Alle Prognosen sind mit Unsicherheiten belastet, es kann immer zu unlogischen Entwicklungen und zu Überraschungen kommen. Wir Menschen sind relativ gut im Umgang mit solchen Unsicherheiten – auch wenn (oder vielleicht gerade weil?) wir Unsicherheiten nicht mögen. KI kann in Unsicherheit kaum oder auch gar nicht verlässlich und nachhaltig navigieren. Wir leben aber in Zeiten zunehmender Unsicherheiten.

- ▶ Es ist also keine Frage, ob sich Unternehmen, Organisationen und Menschen mit den Folgen der KI-Revolution auf ihren Alltag in Beruf und im gesamten Leben auseinandersetzen wollen. KI wird nicht wieder verschwinden. Deswegen lautet die zentrale Fragestellung dieses Buches: Wie sollte eine Arbeitsteilung zwischen KI-Systemen und Menschen aussehen, die ihren jeweiligen einzigartigen Kompetenzen gerecht wird und robuste und nachhaltige Entscheidungen befördert?

Die Relevanz der Fragestellung ergibt sich aus den obigen lediglich skizzierten Änderungen in der künftigen Arbeitswelt. Wir wissen: Es wird eine neue Arbeitsteilung zwischen Mensch und Maschine geben – wir wissen nur noch nicht genau, welche. Es wird neue Abläufe und Prozesse in Unternehmen und Organisationen geben – wir wissen nur noch nicht genau welche. Die Beantwortung der erkenntnisleitenden Fragestellung dieser Untersuchung soll wiederum einen Leitfaden genau dafür liefern.

Reden wir über Prozessinnovationen, dann reden wir über die mächtigsten und leistungsfähigsten Innovationen. Neue Prozesse und Abläufe zeitigen mehr Auswirkungen und Effekte als beispielsweise Produktinnovationen. Deswegen geht es hier auch um die Leistungsfähigkeit und die Wettbewerbsfähigkeit von Unternehmen und Organisationen. Innovation und Kreativität sind ebenfalls entscheidend im Wettbewerb. Wir werden im Verlaufe dieser Untersuchung sehen, dass Innovation und Kreativität menschliche Domänen sind, die auf engste mit der menschlichen Intuition verknüpft und verbunden sind. Bisher lag der Fokus vor allen Dingen auf den Innovationseffekten und Innovationspotenzialen von KI-Technologie. Darum lohnt ein vertiefter Blick auf die menschliche Komponente dieser Dimension umso mehr.

Die Relevanz der Fragestellung ist ebenfalls zu begründen, weil in Unternehmen und Organisationen nach der ersten Welle der KI-Integration zunehmend auch ethische Fragestellungen zur Mensch-KI-Interaktion aufkommen und diskutiert werden. Die Beantwortung solcher Fragen ist zudem ein wichtiger Bestandteil des Employer Branding von Unternehmen. Wer in diesem Zusammenhang keine klare Antwort und keine klaren Strategien hat, der ist kein attraktiver Arbeitgeber. Das ist höchst wichtig. Denn KI-Technologien sind sicher neu, faszinierend und revolutionär. Doch die knappe Ressource heute und in Zukunft sind kompetente und motivierte Mitarbeiterinnen und Mitarbeiter.

Ebenfalls in diesem Zusammenhang gehört die Dimension der Nachhaltigkeit. Aus Gründen der planetaren Grenzen und Belastbarkeit unserer Welt und auch aus Gründen des Verlangens nach einem Sinn, einem „purpose“ und einer Identifikation von Mitarbeiterinnen und Mitarbeitern mit ihrem Unternehmen. Nachhaltigkeit ist eine schlichte Notwendigkeit. KI kann für Nachhaltigkeit in Prozessen und Abläufen sorgen und bestehende und bekannte Modelle und Systeme analysieren und optimieren. Das wird in Verlauf des Buches noch eingehend beschrieben und analysiert. Doch vernetztes Denken in komplexen Zusammenhängen, Kontexten und Kreisläufen können nur Menschen als natürliche und körperliche Wesen leisten. Nachhaltigkeit ist also nicht allein durch Technologie zu erreichen, sondern nur mit diesen genannten menschlichen Fähigkeiten, die für KI-Systeme nicht erreichbar oder darstellbar sind. Zudem brauchen wir immer wieder neue Ideen und kreative Lösungen, die nur von und aus Menschen und ihren Erfahrungen kommen können.

1.2 Gang der Untersuchung und Stand der Forschung

Dieses Buch gibt zunächst einen Überblick über die gängigen Technologien und Prinzipien Künstlicher Intelligenz. Dieser technische Überblick, auch im Detail, ist notwendig für spätere Einordnungen und Analysen. Der Fokus geht anschließend auf die Einführung von KI-Technologien in Unternehmen und die damit verbundenen Change-Prozesse. Weiter werden die momentan wichtigsten Einsatzfelder und Anwendungsfelder von Künstlicher Intelligenz in unterschiedlichen Branchen und Industrien beschrieben. In der Folge werden insbesondere Einsatzszenarien und praktische Beispiele für den Einsatz von KI-Technologien für Ziele und Zwecke der Nachhaltigkeit dargestellt und analysiert. Dies dient dem vertieften Verständnis davon, wie und in welchen Zusammenhängen KI für Nachhaltigkeit in verschiedenen Dimensionen einen Beitrag leisten kann. Auch wird die Nachhaltigkeit von KI-Systemen selbst kritisch betrachtet – ein Aspekt, der bisher kaum untersucht worden ist. Die Forschung ist in Bezug auf KI und Nachhaltigkeit in den letzten Jahren deutlich aktiver und produktiver geworden. Insbesondere was Publikationen von interdisziplinären Ansätzen betrifft. Zu nennen sind hier Studien und Publikationen verschiedener Fraunhofer Institute und der Plattform Lernende Systeme (PLS), die sich sowohl mit der Nutzung von KI-Technologien für Nachhaltigkeit auseinandersetzen als

auch auf die Einführung von KI in Unternehmen und die dafür notwendigen Kompetenzen bei Mitarbeiterinnen und Mitarbeitern in Unternehmen eingehen.

In der Folge wird die menschliche Intuition dargestellt und analysiert. Hierbei wird immer wieder Bezug auf Ähnlichkeiten mit und Unterschiede zu Künstlicher Intelligenz genommen, um die Perspektive der Fragestellung des Buches im Blick zu behalten. Zunächst werden die Ergebnisse und Erkenntnisse der Intuitionsforschung insbesondere der vergangenen rund zwei Jahrzehnte dargestellt. Vorangestellt wird dem ein kurzer Überblick über die Historie der Intuition und ihrer Bewertung und Akzeptanz in Wissenschaft, Kultur und Gesellschaft. Die bedeutendsten Arbeiten und Erkenntnisse sind hier von Kahnemann, Gigerenzer, Sadler-Smith, Salas, Rosen und DiazGranados oder Dörfler und Szendrey geleistet worden. Im Folgenden werden die neuro-biologischen Erkenntnisse und Diskussionen zu Kognition, Bewusstsein, Wahrnehmungen, Denken und Intuition dargestellt. Dies dient dem Verständnis von Funktionsweisen der genannten Prozesse, um sie mit der Funktions- und Arbeitsweise von Künstlicher Intelligenz vergleichen zu können und Gemeinsamkeiten und Unterschiede schärfer herausarbeiten zu können. Hier haben in den vergangenen Jahren insbesondere Seth, Hoffmann und Dweck aufschlussreiche Forschungen und Ergebnisse realisiert. In diesem Zuge wird weiter auf die Rolle von Emotionen und Hirn-Oszillationen eingegangen, weil diese eine besondere Rolle für die menschliche Intuition spielen und bei der Bewertung von Intuitionen (Emotionen) und dem Training von Intuition als Kompetenz (Oszillationen) entscheidend sind. Hier wird auf Untersuchungen unter anderem von Feldman-Barrett oder Jensen und Mazahari rekurriert werden. Anschließend werden komplexe Entscheidungen und die Rolle von Heuristiken und Intuitionen hierbei betrachtet. Zum einen, weil mehr oder weniger alle schwerwiegenden Entscheidungen in komplexen Umwelten erfolgen und weil in Zeiten der zunehmenden Unsicherheiten die Komplexität ohnehin steigt. Zum anderen, weil insbesondere Fragen und Entscheidungen der Nachhaltigkeit stets vielschichtig und komplex sind. Darum soll auch auf den Zusammenhang von Nachhaltigkeit und Intuition zum Abschluss dieses Teils der Untersuchung eingegangen werden.

Entsprechend widmet sich der dritte Hauptteil der Untersuchung der Bedeutung und Rolle von Intuition in der Führung und bei Führungsentscheidungen. In der Forschung haben hier unter anderem Hänsel, Kump, Dijksterhuis oder Hogarth wichtige Untersuchungen geleistet. Hierbei wird deutlich werden, dass es sich bei Intuition um eine Kompetenz handelt, die wie andere Kompetenzen auch bewusst eingesetzt werden sollte. Dafür bedarf es aber Übung und Training. Daher werden die Möglichkeiten, die eigene Intuition zu trainieren und entwickeln, dargestellt und kritisch eingeordnet. Auch hier liegt der Schwerpunkt der Betrachtung der Fragestellung der Untersuchung entsprechend auf dem Zusammenspiel und der Aufgabenteilung mit Künstlicher Intelligenz und dem Ziel der Nachhaltigkeit und Resilienz bei Analysen und Entscheidungen.

Als Essenz der dargestellten Untersuchungen und Auswertungen wird die Fragestellung des Buches beantwortet. Die Aspekte der Beantwortung der Fragestellung werden kurz beleuchtet und eingeordnet. Ziel dabei ist es, Menschen und Unternehmen einen

Leitfaden und Entscheidungskriterien für die eigene praktische Anwendung und Umsetzung zu geben. Denn Ziel muss es sein, Künstliche Intelligenz (Artificial Intelligence) und menschliche Intuition (Archaic Intellience) ihren Domänen entsprechend zu entwickeln und einzusetzen und damit zu robusten, resilienten und nachhaltigen Strategien und Entscheidungen zu gelangen und diese zu leben.

Literatur

- Eloundou, T., Manning, S., Mishkin, P., Rock, D.: GPTs are GPTs: An Early Look at the Labor Market Impact Large Language Models, Pennsylvania 2023
- Hatzius, J., Briggs, J., Kodnani, D., Pierdomenico, G.; The Potentially Large Effects of Artificial Intelligence on Economic Growth, London 2023



Funktion und Einsatz von Künstlicher Intelligenz

2

Dieses Kapitel gibt einen Überblick über die wichtigsten Technologien und Modelle, die gemeinhin unter dem Begriff der „Künstlichen Intelligenz“ zusammengefasst werden. Es geht darum, ein grundlegendes Verständnis der Funktions- und Arbeitsweise dieser Technologien zu entwickeln und Anwendungsfälle kennenzulernen. Wichtig hierbei ist auch, dass es sich trotz des Namens nicht um eine menschenähnliche Form der Intelligenz in Maschinen und Systemen handelt, sondern in erster Linie die Optimierung unterschiedlicher Prozesse das Ziel von KI-Anwendungen ist. Auf technische Zusammenhänge und Details wird ebenfalls eingegangen, weil diese für das Verständnis notwendig sind. Auf der Basis dieses Wissens wird es später möglich sein, die Herausforderungen und Änderungen klar zu benennen und zu begründen, die auf Unternehmen durch den Einsatz von KI-Technologien unausweichlich zukommen und von denen auch die Mitarbeiter betroffen sind. Auf dieser Basis wird es ebenfalls möglich sein, eine Analyse der Mitarbeitermotivation durchzuführen, wenn es um die Frage gehen wird, welche Faktoren und Umstände bei der Implementierung von KI-Technologien (besonders) zu beachten sind und wie das richtige Vorgehen bei dieser Implementierung aussehen sollte. Bei dieser Analyse werden dann auch die speziellen Fragen erörtert, die im Zentrum dieser Untersuchung stehen. Das heißt, wie eine sinnvolle Aufgaben- und Arbeitsteilung zwischen Mensch und KI mit dem Ziel größtmöglicher Nachhaltigkeit, Robustheit und Resilienz aussehen sollte.

2.1 Künstliche Intelligenz

Künstliche Intelligenz beschäftigt sich mit Methoden, die es einem Computer ermöglichen, solche Aufgaben zu lösen, die, wenn sie vom Menschen gelöst werden, Intelligenz erfordern. Der Begriff der Künstlichen Intelligenz umfasst zwei grundlegende Aspekte:

- Zum einen wird darunter die Schaffung und Nachahmung menschlichen Verhaltens und Denkens verstanden. Das ist das anspruchsvollere und visionäre Ziel.
- Der zweite Aspekt ist die automatische und autonome Aufgabenerledigung, die klar definierte und abgegrenzte Aufgabenbereiche übernehmen kann.

Besonders der zweite Aspekt wird kurzfristig für Unternehmen relevant oder ist es schon und wird das Arbeitsleben, die Prozesse und Aufgaben in Unternehmen verändern. Beispiele für autonome Aufgabenerledigung kennen wir: autonomes Fahren, intelligente Softwareassistenten in Unternehmen oder auch für den privaten Gebrauch in Apps oder direkt auf dem Smartphone sowie automatische Sprach- und Bilderkennung. Diese Systeme funktionieren bereits sehr zuverlässig und integrieren sich zunehmend in unseren Alltag. Merkmal beider Ansätze der KI ist das selbstständige Lernen und Verarbeiten neuer und unbekannter Daten. Neue Informationen fließen in das interne Modell ein, was dann zur Anpassung des Systems an neue Umweltbedingungen und Anforderungen führt.

Das immer stärkere Zusammenwachsen von Big Data mit Künstlicher Intelligenz ist aktuell die wichtigste Entwicklung, die beeinflusst, wie Firmen in Zukunft Geschäftswerte aus ihren Daten und ihren analytischen Möglichkeiten erzielen. Künstliche Intelligenz und Machine Learning werden momentan gerne austauschbar verwendet. Beide Begriffe tauchen regelmäßig auf, wenn es um Big Data, Analytik und die breiteren Auswirkungen der technischen Veränderungen geht. Bei beiden besteht der wahre Wert für das Unternehmen in den Daten, ohne die jedwede Künstliche Intelligenz sozusagen „kein Futter“ zum Lernen und zum laufenden Optimieren, Anpassen und Steuern hätte.

Muster erkennen, Entscheidungen treffen

Künstliche Intelligenz ist also der Überbegriff für Anwendungen, bei denen Maschinen menschenähnliche Intelligenzleistungen wie Lernen, Urteilen und Problemlösen erbringen. Die Technologie des maschinellen Lernens (ML) – ein Teilgebiet der Künstlichen Intelligenz – lehrt Computer aus Daten und Erfahrung zu lernen und Aufgaben immer besser auszuführen. Ausgefeilte Algorithmen können in unstrukturierten Datensätzen, wie Bildern, Texten oder gesprochener Sprache, Muster erkennen und anhand dieser Entscheidungen im Sinne von Zuordnungen oder Voraussagen selbstständig treffen (Vgl. Doherty et al. 2016; Ertel 2018; Kaplan 2017; Agarwal 2018).

Das maschinelle Lernen geschieht entweder durch Training anhand eines Datensatzes mit bereits bekannten Outputs („überwachtes Lernen“) oder Algorithmen müssen selbst Muster in Daten erkennen („unüberwachtes Lernen“). Möglich ist auch Lernen durch Belohnung

und Bestrafung („verstärktes oder Reinforcement Learning“), bei dem der Algorithmus selbstständig erkennt, ob die Lernkomponente dem gesamten System nutzt (Belohnung) oder nicht (Bestrafung). Die Daten liegen entweder strukturiert vor, etwa in Tabellenform, oder unstrukturiert als Text, Bild oder Sprache – wie bei E-Mails oder Social Media Posts. Machine Learning kann prinzipiell alle Daten verarbeiten, was natürlich ein großer Vorteil ist.

Und wo bleiben wir Menschen dabei?

Wir Menschen neigen dazu, ein System immer dann für intelligent zu halten, wenn und solange wir nicht genau wissen, wie es funktioniert. Gleichzeitig ist genau das auch unheimlich für uns und wir fühlen uns verunsichert. Als es noch keinen Computer gab, der professionelle Schachspieler schlagen konnte, war man überzeugt, dass ein System wirklich „intelligent“ sein müsse, wenn es tatsächlich selbständig die besten Menschen im Schach besiegen könnte. Nachdem das System gebaut wurde (IBM's DeepBlue) und die besten Schachspieler der Welt schlagen konnte, drehte sich die Wahrnehmung sehr schnell, da es sich ja doch nur um einen raffinierten Algorithmus handelte, kombiniert mit sehr viel Rechenleistung. Unsere Einstellung zu KI und Einschätzung ihrer Folgen auf uns und unser Leben und Arbeiten kann sich also durchaus aufgrund von Erfahrung und Gewöhnung ändern.

Ähnlich verhält es sich mit vielen anderen Problemen, die heute scheinbar selbstverständlich mit KI-Systemen und KI-Modellen gelöst werden können, bei denen man sich vor nicht allzu langer Zeit aber sicher war, dass für ihre Lösung Intelligenz erforderlich ist. Die Wahrnehmung von Intelligenz hängt also zum einen davon ab, ob wir die Art und Weise der Lösungsfindung lückenlos verstehen. Andererseits bezieht sich Intelligenz immer auf eine bestimmte Problemstellung, und Menschen sind sehr gut darin, ihre Intelligenz zur Lösung sehr vieler unterschiedlicher Problemarten einzusetzen. Wichtig ist es vor allem ein Verständnis davon zu haben, wie Technologien und Verfahren der Künstlichen Intelligenz funktionieren und nach welchen Regeln und Prinzipien sie arbeiten. Nur wer die Regeln kennt, kann ein Spiel auch spielen und beurteilen. Verständnis und Wissen ist die unabdingbare Basis für Souveränität, Sicherheit und Entscheidungsfähigkeit. Damit lassen sich auch Veränderungen und Innovationen gestalten und Unternehmen in dynamischen Umbruchzeiten führen.

Machine Learning

Ein wichtiges Merkmal von Systemen mit künstlicher Intelligenz ist die Fähigkeit, selbstständig zu lernen. Klassische Software funktioniert so: Die Probleme und Fragen werden auf Basis von vorher festgelegten Regeln abgearbeitet. Selbstlernende Machine-Learning-Algorithmen können im Unterschied dazu die besten Regeln für die Lösung bestimmter Aufgaben selber lernen. Hierbei spielen sogenannte neuronale Netze eine zentrale Rolle, die später genauer beschrieben werden. Ein künstliches neuronales Netz besteht aus vielen einzelnen Neuronen, die meistens in mehreren miteinander verbundenen Schichten (Layern) angeordnet sind. Die Zahl der Layer bestimmt unter anderem den Grad der Komplexität,

den ein künstliches neuronales Netz abbilden kann. Viele Layer machen ein neuronales Netz „tief“ – deswegen wird in diesem Zusammenhang auch vom Deep Learning als einer Unterkategorie des Machine Learning gesprochen.

Wichtig beim sogenannten überwachten maschinellen Lernen ist die Tatsache, dass in diesem Verfahren das richtige Ergebnis für uns Menschen bekannt ist, weil wir die Eingangsdaten kennen, die in die Maschine bzw. das neuronale Netz eingegeben werden. Eingangsdaten können zum Beispiel Zahlen sein oder Objekte oder Wörter. Das Netz oder die Maschine „kennt“ das richtige Ergebnis aber nicht, ist sozusagen blank und soll es jetzt eben „lernen“. Das Lernen funktioniert dann auf folgende Weise (vgl. Rashid 2016; Raschka und Mirjalili 2018): Nachdem die Netz-Struktur aufgebaut wurde, erhält jedes Neuron ein zufälliges Anfangs-Gewicht. Dann werden die Eingangs-Daten in das Netz gegeben, und jedes Neuron gewichtet die Eingangs-Signale mit seinem Gewicht und gibt das Ergebnis weiter an die Neuronen der nächsten Schicht (Layer). Am letzten und abschließenden Output-Layer des Netzes wird schließlich das Gesamt-Ergebnis berechnet. Dieses wird in der Regel wenig mit dem bekannten tatsächlichen Ergebnis zu tun haben, da ja alle Neuronen ein zufälliges Anfangsgewicht haben. Man kann jedoch die Größe des Fehlers berechnen und den Anteil, den jedes Neuron an diesem Fehler hatte, und dann das Gewicht jedes Neurons ein kleines bisschen in die Richtung verändern, die den Fehler minimiert. Dann erfolgt der nächste Durchlauf, eine erneute Messung des Fehlers und Anpassung der Gewichte und so weiter. So „lernt“ ein neuronales Netz langsam aber sicher, von den Input-Daten auf die bekannten Output-Daten zu schließen.

Auf der einen Seite des neuronalen Netzes werden die Input-Daten eingespeist. Dabei wird jedes Input Signal an jedes einzelne Neuron des ersten Layers verteilt. Jedes Neuron gewichtet dann das ankommende Signal mit einem Input-spezifischen Gewicht, das zu Beginn zufällig vergeben wurde, addiert einen sogenannten Neuron-spezifischen Bias-Term hinzu und summiert alle in dem Maße gewichteten Input Daten zum Output dieses einen Neurons. Oft wird der Output dabei noch durch eine nicht lineare Aktivierungsfunktion geleitet, um zum Beispiel einen bestimmten Wertebereich des Outputs zu erzwingen (vgl. Rashid 2016; Raschka und Mirjalili 2018). Meist werden hierfür Sigmoid- oder Tanh-Funktionen verwendet. Der Output jedes Neurons wird dann als Input an alle Neuronen des folgenden Layers weitergegeben. Dieser Prozess setzt sich fort, bis der Output-Layer erreicht wird, der das Ergebnis aller Berechnungen liefert.

Bisher hat also noch kein Lernprozess stattgefunden. Da alle Gewichte bei der Initialisierung eines neuronalen Netzes zufällig innerhalb eines vorgegebenen Wertebereichs gewählt werden (z. B. zwischen -1 und 1), wird das Ergebnis ein komplett zufälliger Wert sein. Hier kommen die anfangs bereits erwähnten bekannten „richtigen“ Ergebnisse oder auch Beispiele ins Spiel. Ein Beispiel bedeutet in diesem Fall eine Kombination von echten Input-Output-Datenpaaren. Diese Beispiele werden im Rahmen des Trainings von künstlichen neuronalen Netzen verwendet, um alle Gewichte und Bias Terms optimal einzustellen, sodass das Netz am Ende des Trainings für alle Input-Daten und auch für bisher noch nicht gesehene neue Input-Daten das korrekte Ergebnis berechnen kann. Für einen

Satz von Input-Daten (auch Features genannt) errechnet das noch untrainierte neuronale Netz jeweils ein Ergebnis. Dieses Ergebnis wird dann mit den bekannten Ergebnissen des Beispiel-Datensatzes (auch Targets oder Label genannt) verglichen. Anschließend wird die Größe der Abweichung beziehungsweise des Fehlers berechnet.

Das eigentliche „Lernen“ der Maschine

Jetzt beginnt das eigentliche „Lernen“: Der gemessene Fehler wird rückwärts zurück in das künstliche neuronale Netz geleitet (der sog. Backward Pass oder Backward Propagation) und jedes Gewicht sowie jeder Bias Term wird ein kleines Stückchen in die Richtung angepasst, die den Fehler kleiner macht (vgl. Rashid 2016; Raschka und Mirjalili 2018). Die Größe dieser Anpassung wird zum einen über den Anteil, den ein bestimmtes Neuronen-Gewicht am Ergebnis hatte (d. h. über sein aktuelles Gewicht) berechnet, und zum anderen über die sogenannte Learning Rate, die zu den wichtigsten Einstellgrößen (Hyperparameter) von neuronalen Netzen gehört. Gängige Learning Rates sind z. B. 0,001 oder 0,01. Das bedeutet: Lediglich ein Hundertstel bis ein Tausendstel des errechneten Fehlers wird pro Durchlauf korrigiert. Ist die Anpassung pro Durchlauf zu groß, kann es dazu kommen, dass das Minimum der Fehlerkurve verfehlt wird und die Abweichungen immer größer statt kleiner werden. Dann spricht man von „Overshooting“. Manchmal wird die Learning Rate daher während des Trainings zunehmend verkleinert, um das Minimum der Fehlerfunktion besser zu bestimmen.

Nachdem alle Gewichte angepasst sind, erfolgt ein erneuter Durchlauf aller Input-Daten und die erneute Messung des Fehlers sowie die Back-Propagation dieses Fehlers zur erneuten Anpassung der Gewichte. Ein kompletter Durchlauf aller Input-Daten wird dabei jeweils als Epoche bezeichnet. Dabei können die Input-Daten je nach Größe des Datensatzes auch in gleich große Gruppen (Batches) eingeteilt werden, und das Training kann jeweils pro Batch durchgeführt werden (vgl. Kaplan 2017; Aggarwal 2018). Dies kann z. B. sinnvoll sein, um ein künstliches neuronales Netz schneller lernen zu lassen, oder um Begrenzungen der Rechenkapazität des ausführenden Computers einzuhalten. Je mehr Beispiele ein künstliches neuronales Netz für das Training bekommt und je öfter es diese gesehen hat, desto kleiner wird der Fehler bei den Ergebnissen. Eine Gefahr gibt es dabei: Wenn ein neuronales Netz während des Trainings alle bekannten Daten sehr oft gesehen hat, kann es dazu kommen, dass das künstliche neuronale Netz diese Daten eher auswendig lernt, statt ein abstraktes Konzept zu lernen. Dieses Problem wird auch als Overfitting bezeichnet. Da neuronale Netze auch hochkomplexe Funktionen abbilden können, besteht die Gefahr, dass sie irgendwann die perfekte Funktion für jeden bekannten Datenpunkt gefunden haben, diese Funktion aber für neue Daten nicht gut funktioniert (vgl. Ertel 2018).

Den „Lernerfolg“ mit Testdaten überprüfen

Um sicherzustellen, dass ein Netz von bekannten Beispieldaten abstrahieren und auch korrekte Ergebnisse für bisher nicht gelernte Input-Daten liefern kann, werden die Beispieldaten

vor dem Training unterteilt in Trainingsdaten, Testdaten und Blind-Testdaten, z. B. im Verhältnis 70/20/10. Während des Trainings werden dann nur die Trainingsdaten verwendet und die Fehlerquote wird jeweils sowohl für die Trainingsdaten als auch für die Test-Daten gemessen. Der gemessene Fehler der Test-Daten wird jedoch nicht in das Netz zurückgespeist. Dann wird das neuronale Netz durch Anpassungen aller Variablen so verbessert, dass es die maximale Performance in Bezug auf Trainings- und Test-Daten erreicht. Erst wenn das Netz vermeintlich vollständig trainiert ist, kommen die Blind-Testdaten zum Einsatz. Wenn das künstliche neuronale Netz auch im Blind-Test gut abschneidet, ist die Wahrscheinlichkeit hoch, dass es ein abstraktes Konzept gut gelernt hat.

Wenn das künstliche neuronale Netz fertig trainiert ist, werden alle Gewichte und Verzerrungen als sogenannter „Checkpoint“ gespeichert (vgl. Kreutzer und Schirrenberg 2019). Das neuronale Netz kann dann jederzeit mit diesen erneut gestartet werden. Der eigentliche Betrieb eines trainierten neuronalen Netzes ist deutlich einfacher und schneller als der Lernprozess vorher und kann deshalb beispielsweise auch auf Mobilgeräten oder normalen Rechnern nahezu in Echtzeit erfolgen. Ein fertig trainiertes künstliches neuronales Netz kann jederzeit mit neuen Daten nachtrainiert werden, da die „Checkpoints“ ja bereits bekannt sind. Es ist auch möglich, ein vortrainiertes neuronales Netz als Basis für das Training mit eigenen Daten zu verwenden. Bei diesem sogenannten Fine-Tuning von künstlichen neuronalen Netzen kann so auf bereits gelernte allgemeine Strukturen zurückgegriffen werden und das Netz muss nur noch die neuen Klassen lernen. Dies ist insbesondere bei der sehr rechenintensiven Verarbeitung von großen Datenbeständen nützlich, sowohl bei Bildern als auch bei Sprache und Texten oder anderen Arten von Daten. Vortrainierte künstliche neuronale Netze oder auch anpassbare API Services werden mittlerweile von IBM, Microsoft, Amazon, Google, Uber, Facebook und anderen Dienstleistern angeboten.

Für das eben dargestellte überwachte Lernen (Supervised Learning) wird, wie beschrieben, eine große Menge an Beispieldaten benötigt. Eine große Menge bedeutet hier beispielsweise eine Million Beispiele. Zwar können künstliche neuronale Netze teilweise auch bereits mit kleineren Datensätzen brauchbare Ergebnisse erzielen, aber je mehr Daten zur Verfügung stehen, desto besser. Das Supervised Learning selber kann noch weiter unterteilt werden in verschiedene Methoden der Datenverwendung und Datenweitergabe innerhalb von künstlichen neuronalen Netzen. Bei sogenannten Recurring Neural Networks fließt z. B. das Ergebnis der vorherigen Input-Daten in die Berechnung des aktuellen Outputs ein. So können beispielsweise Zeitreihen und Texte analysiert und verarbeitet werden. Das gleiche gilt auch bei Long-Short-Term-Memory Netzen (LSTM) und Sequence-to-Sequence Netzen, die unter anderem für die Spracherkennung und für die Übersetzung von Texten verwendet werden (vgl. Kramer 2016; Ertel 2018). Für die Bildverarbeitung werden sogenannte Convolutional Neural Networks (CNN) verwendet, welche Bilder mit einem Raster abtasten und von tieferen Ebenen (Punkten, Linien etc.) in jedem Layer weiter abstrahieren zu höheren Konzepten (ein Gesicht, ein Haus etc.).

Weitere Verfahren, wie künstliche neuronale Netze lernen können, sind das Unsupervised Learning, (unüberwachtes lernen) bei dem Systeme nur Input-Daten erhalten und selber

versuchen, diese sinnvoll zu klassifizieren. In diesem Zusammenhang wird von „starker KI“ gesprochen. Unüberwachte Algorithmen des maschinellen Lernens leiten Muster aus einem Datensatz ohne Bezug auf bekannte oder gekennzeichnete Ergebnisse ab. Im Gegensatz zu überwachtem maschinellen Lernen können unüberwachte maschinelle Lernverfahren nicht direkt auf ein Regressions- oder Klassifizierungsproblem angewendet werden, da sie keine Ahnung haben, wie die Werte für die Ausgabedaten aussehen könnten, was es Ihnen unmöglich macht, den Algorithmus so zu trainieren, wie sie es normalerweise tun würden. Unbeaufsichtigtes Lernen kann stattdessen verwendet werden, um die zugrunde liegende Struktur der Daten zu entdecken (vgl. Russel und Norvig 2016).

Unbeaufsichtigtes maschinelles Lernen gibt vor, bisher unbekannte Muster in den Daten aufzudecken, aber meistens sind diese Muster schlechte Annäherungen an das, was überwachtes maschinelles Lernen erreichen kann. Da man zudem nicht weiß, wie die Ergebnisse aussehen sollten, gibt es keine Möglichkeit zu bestimmen, wie genau sie sind, sodass überwachtes maschinelles Lernen besser auf Probleme der realen Welt anwendbar ist. Der beste Zeitpunkt für den Einsatz von unüberwachtem maschinellen Lernen ist, wenn es keine Daten über die gewünschten Ergebnisse gibt, wie z. B. die Bestimmung eines Zielmarktes für ein völlig neues Produkt, das ein Unternehmen noch nie zuvor verkauft hat.

Unüberwachtes maschinelles Lernen

Einige Anwendungen von unüberwachten Techniken des maschinellen Lernens sind:

Durch Clustering kann der Datensatz automatisch nach Ähnlichkeit in Gruppen aufgeteilt werden. Häufig überschätzt die Clusteranalyse jedoch die Ähnlichkeit zwischen Gruppen und behandelt Datenpunkte nicht als Individuen (vgl. Rashid 2016; Kaplan 2017; Wartala 2018; Yao et al. 2019). Aus diesem Grund ist die Cluster-Analyse eher eine schlechte Wahl für Anwendungen wie Kundensegmentierung und Targeting. Die Anomalieerkennung kann automatisch ungewöhnliche Datenpunkte im Datensatz entdecken (vgl. Rashid 2016; Kaplan 2017; Wartala 2018; Yao et al. 2019). Dies ist nützlich, um betrügerische Transaktionen aufzuspüren, fehlerhafte Hardwareteile zu entdecken oder einen Ausreißer zu identifizieren, der durch einen menschlichen Fehler bei der Dateneingabe verursacht wurde.

Association Mining identifiziert Gruppen von Elementen, die häufig zusammen in einem Datensatz vorkommen (vgl. Rashid 2016; Kaplan 2017; Wartala 2018; Yao et al. 2019). Einzelhändler verwenden es häufig zur Warenkorbanalyse, da es Analysten ermöglicht, häufig gleichzeitig gekaufte Waren zu entdecken und effektivere Marketing- und Merchandising-Strategien zu entwickeln.

Latente Variablenmodelle werden häufig für die Datenvorverarbeitung verwendet, z. B. zur Reduzierung der Anzahl der Merkmale in einem Datensatz

(Dimensionalitätsreduzierung) oder zur Zerlegung des Datensatzes in mehrere Komponenten.

Die Muster, die sich mit unüberwachten Methoden des maschinellen Lernens aufdecken lassen, können sich auch bei der späteren Implementierung von überwachten Methoden des maschinellen Lernens als nützlich erweisen. So kann beispielsweise eine unüberwachte Technik verwendet werden, um eine Clusteranalyse der Daten durchzuführen und dann den Cluster, zu dem jede Zeile gehört, als zusätzliches Merkmal im Modell des überwachten maschinellen Lernens zu verwenden (halbüberwachtes maschinelles Lernen). Ein weiteres Beispiel ist ein Betrugserkennungsmodell, das Anomalieerkennungsscores als zusätzliches Merkmal einsetzt.

Reinforcement Learning

Auch das Reinforcement Learning gehört zum unbewachten oder autonomen Lernen. Beim Reinforcement Learning kann ein neuronales Netz selbst die Input-Daten steuern (z. B. die Tasten eines Gaming Controllers) und dynamische Output-Daten zurückerhalten, zusammen mit einer Aufgabe bezüglich dieser Output-Daten (z. B. einen Punktestand zu maximieren) (vgl. Lapan 2020).

In Abgrenzung zu den beiden anderen Methoden (supervised und unsupervised Learning) werden beim Reinforcement Learning jedoch vorab keine Daten benötigt. Stattdessen werden diese in einer Simulationsumgebung in vielen Durchläufen in einem Trial-and-Error-Verfahren während des Trainings generiert und gelabelt.

Reinforcement Learning steht für eine ganze Reihe von Einzelmethoden, bei denen ein Software-Agent selbständig eine Strategie erlernt. Das Ziel bei dem Lernvorgang ist es, die Zahl an Belohnungen innerhalb einer Simulationsumgebung zu maximieren. Beim Training führt der Agent zu jedem Zeitschritt Aktionen innerhalb dieser Umgebung aus und erhält jeweils ein Feedback. Dabei wird dem Software-Agenten vorab nicht gezeigt, welche Aktion in welcher Situation die beste ist. Vielmehr erhält er zu bestimmten Zeitpunkten eine Belohnung. Während des Trainings lernt der Agent auf diese Weise die Folgen von Aktionen auf Situationen in der Simulationsumgebung einzuschätzen. Auf dieser Basis kann er eine langfristige Strategie entwickeln, um die Belohnung zu maximieren.

Eine sogenannte „Policy“ ist dann das gelernte Verhalten eines Software-Agents. Eine Policy gibt an, welche Action bei einer beliebigen Verhaltensvariante (Observation) aus der Lernumgebung (Environment) ausgeführt werden soll, um die Belohnung (Reward) zu maximieren (vgl. Ertel 2018; Lapan 2020). Wie kann so eine Policy abgebildet werden? Dafür kann beispielsweise eine sogenannte Q-Table verwendet werden. Darin wird eine Tabelle mit allen möglichen Beobachtungen als Zeilen und allen möglichen Actions als Spalten aufgebaut. Die Zellen werden dann während des Trainings mit den sogenannten Value-Werten gefüllt, welche den erwarteten zukünftigen Reward darstellen. Das Verwenden der Q-Table hat aber auch seine Grenzen: Sie funktioniert nur, wenn der Action- und Observation-Space