

DAS WIRTSCHAFTSMAGAZIN ZUR DIGITALISIERUNG

DIGITALE WELT

SCIENCE MEETS INDUSTRY

Ausgabe 3 • Juli • August • September • 2021

Künstliche Intelligenz

Wenn Algorithmen denken
und Prozesse revolutionieren

Sicherheit

Wie sich intelligente Maschinen
zuverlässig kontrollieren lassen

Produktivität

Wie durch Robotik und KI aus
Science-Fiction Realität wird


Use-Cases

Wie KI dabei hilft, Daten
intelligent zu nutzen

MASCHINELLES LERNEN

Die Top 10 Anwendungsfälle
für Ihr Unternehmen

Der Direktor des
Fraunhofer-Instituts
für kognitive Systeme
über die Absicherung
intelligenter Systeme



Prof. Dr. Mario Trapp

DIGICON 2021

DIGITALE WELT CONVENTION

www.digitaleweltmagazin.de/digicon

Save
the Date
16. & 17.11.
2021

Die 6. DIGICON in Kooperation mit dem
Anwendernetzwerk des Digitale Stadt München e.V.

QUANTUM COMPUTING

Wie ein Quantenvorteil entsteht



Die Evolution in der KI

Thomas Gabor

Muss man eine künstliche Intelligenz konstruieren, erziehen oder einfach machen lassen?

Die Vision der künstlichen Intelligenz (KI) begann bereits lange, bevor es Maschinen gab, die entsprechende Algorithmen auch nur annähernd ausführen konnten. Dennoch skizzierte Turing 1945 bereits den Ansatz, den wir auch heute (wieder) für den vielversprechendsten halten: Die Menschheit baut ihr digitales Ebenbild nicht als eine groß geplante, ingenieurmäßige Leistung am Stück, sondern als einen evolutionären Prozess, der aus vielen Fehlschlägen schließlich selbstständig lernen kann. Seit diesen ersten Theorien vergingen viele Jahrzehnte, bis Rechner existierten, die sich derart viele Fehlschläge überhaupt zeitlich leisten konnten. Dazwischen wurden viele Ansätze ausprobiert, bis man wieder bei Anleihen aus der Natur landete: Reinforcement Learning, das ursprünglich rein für die Erziehung von Mensch und Tier definiert wurde, als digital ausführbarer Prozess zur Wissensgenerierung durch Ausprobieren und Feedback, und neuronale Netze, die man zufällig entdeckte, weil man das menschliche Gehirn besser verstehen wollte, als ultimative Datenstruktur zum Lernen mathematischer Zusammenhänge.

Rich Sutton, einer der Gründerväter des Reinforcement Learning, fasste 2019 seine Erfahrung in Jahrzehnten der Forschung in etwa so zusammen, dass man leicht kurzfristige Erfolge erzielen kann, indem man einer KI ingenieurmäßig zusätzliche Fähigkeiten

beibringt, sich langfristig aber stets Ansätze durchsetzen, die massive Rechenleistung einsetzen, um die Maschine dasselbe und mehr Wissen selbst lernen zu lassen. Die KI als Technologiefeld macht gerade eine ähnliche Entwicklung durch: Lange war KI eine abstrakte Idee, den absoluten Experten vorbehalten. Heute ist die Technologie KI (in ihren ersten Stufen, zugegeben) in der breiten Anwendung angekommen. Und das ist eine sehr gute Entwicklung! Es geht dabei nicht nur darum, möglichst viele technische Möglichkeiten in den Unternehmen möglichst schnell in zusätzlichen Gewinn zu verwandeln. So wie eine einzelne KI die vielen Fehlversuche braucht, so wird sich auch das Feld am besten weiterentwickeln, wenn viele Kräfte daran arbeiten und wenn niemand einen Plan oder eine Richtung vorgibt. Erst hinterher wird man den besten Weg, den schnellsten Erfolg, den elegantesten Algorithmus zur KI erkennen, wenn er sich gegen die anderen Ansätze durchgesetzt hat.

Ich freue mich, dass wir in diesem Heft viele spannende Anwendungen und Erfahrungen aus den verschiedensten Bereichen von Industrie und Forschung sehen. Die Demokratisierung der KI ist nicht nur gesellschaftlich ein wichtiges Unternehmen, sondern auch ein Projekt, das den Erkenntnisgewinn auf dem Gebiet noch einmal neu beflügeln kann. Wo uns KI noch hinführen kann, mag im Moment niemand absehen, aber entwickeln wird sie sich am besten ganz natürlich!

Thomas Gabor forscht seit 2015 an der LMU München zum Thema Natural Computing, also zu Algorithmen, die von Phänomenen der Natur abgeschaut sind. Daraus ergeben sich Anwendungsfelder wie künstliche Intelligenz, Optimierung mit künstlicher Evolution, aber auch das von den Grundregeln des Universums abgeleitete Quantum Computing. Sein nächstes Ziel: KI einsetzen, um ihre eigenen Algorithmen besser zu verstehen.



8

MARIO TRAPP
Künstliche Intelligenz auf dem Prüfstand. –
Wie aus einer Künstlichen Intelligenz eine
Safe Intelligence wird

14

KÜNSTLICHE INTELLIGENZ
Wenn Algorithmen denken
und Prozesse revolutionieren



WAS IST HIER ABGEBILDET?
Die Antwort finden Sie im Beitrag
"Hey Computer, mach mal. Besser!"
auf Seite 32.

DIGITAL MARKETPLACE

6 **Digitalisierung in Zahlen** | Fakten, die überraschen

INTERVIEWS

8 **Mario Trapp** | Künstliche Intelligenz auf dem Prüfstand. – Wie aus einer Künstlichen Intelligenz eine Safe Intelligence wird

14 WISSEN – KÜNSTLICHE INTELLIGENZ**FACHBEITRÄGE**

- 16 **Torsten Deutsch, Ralf Hülsmann** | Fake-KI: Nicht jeder Algorithmus ist intelligent
- 20 **Alexis Fournier** | Die Wirtschaftlichkeit Künstlicher Intelligenz
- 23 **Clara Krabatsch, Jens Nachtwei** | KI aus Sicht von Ärzten, Anwälten und Politikern
- 26 **Cam-Duc Au, Andreas Hiese** | Künstliche Intelligenz in Banken: Worauf es im aktuellen Marktumfeld ankommt
- 30 **Mischa Soujon** | Hey Computer, mach mal. Besser!
- 34 **Stuart Jonathan Russell** | Die gar nicht mal so große KI-Debatte

BLOGBEITRÄGE

1.1 USE CASES

- 42 **Milad Safar** | Die Top 10 Anwendungsfälle für Maschinelles Lernen in Unternehmen
- 43 **Christian Trippner** | Wie funktioniert Retourenvermeidung im Online-Shopping durch KI?

- 45 **Philipp Hartmann, Maria Schamberger** | Wie man KI Use Cases findet und priorisiert
- 47 **Florian von Walter** | Daten effizient nutzen – Vier Einsatzszenarien, wie Machine Learning dabei helfen kann

1.2 COMPLIANCE

- 48 **Jessica Heesen** | Wie kommt Ethik in die Künstliche Intelligenz?
- 50 **Christian Hugo Hoffmann** | Regulierung Künstlicher Intelligenz: Ein praktischer Ratgeber für die Praxis
- 52 **Frank S. Jorga** | Künstliche Intelligenz im Compliance-Bereich: Drei Anwendungsfelder
- 54 **Jörg-Alexander Paul** | Diskriminierungsfälle Künstliche Intelligenz: So vermeiden Sie Fehler schon beim Anlernen

1.3 MEDIZIN

- 55 **Michael Wallraven** | Eine zweite Chance: Wie sich Unternehmen besser auf die nächste COVID-19-Welle vorbereiten können
- 56 **Daniela Jansen** | Künstliche Intelligenz im Einsatz für die Gesundheit
- 58 **Balakrishna D R** | Positive Lebenszeichen für KI im europäischen Gesundheitswesen

1.4 BUCHHALTUNG

- 60 **Phillip C. Campbell** | „Machine Learning“ ist in der Buchhaltung angekommen
- 61 **Marius Simon** | Was kann digitales Versichern? – Künstliche Intelligenz und Maschinenlernen auf dem Vertrauensprüfstand

- 62 **Daniel Szlapka** | KI-basiertes Input-Management macht Dokumentenprozesse effektiver

1.5 PROZESSAUTOMATISIERUNG

- 64 **Paul Beavers** | IT-Betrieb und -Service mit KI optimieren
- 66 **Christian Lemke** | Mit Reinforcement Learning auf dem Weg zur Allgemeinen KI
- 68 **Lumir Boureau** | Erfolgreiches Machine Learning dank Datenkonsistenz
- 70 **Nicole Biel** | Reifegradmodell: In drei Schritten das Beste aus den Daten herausholen

1.6 PRODUKTIVITÄT

- 71 **Volker Sommer** | Mehr Transparenz bitte! Die Vorteile KI-gestützten Identitätsmanagements
- 72 **Uwe Küppers** | Die Zukunft der Produktion liegt in den Daten der Vergangenheit
- 74 **Robert Frodl** | Von Science-Fiction zur Realität: Robotik in der Smart Factory

1.7 AUS DATEN GEBOREN

- 75 **Daniel Keim, Kai-Uwe Sattler** | Von Daten zu Künstlicher Intelligenz – Datenmanagement als Basis für erfolgreiche KI-Anwendungen
- 79 **Mauro Adorno** | Die saisonale Nachfrage mit KI in den Griff bekommen
- 80 **Christian Werling** | Wie Unternehmen KI und Search zur Schaffung eines digitalen Nervensystems nutzen können
- 82 **Frank Thole** | Auf dem Weg zum künstlichen Bewusstsein

1.8 DISKUSSION

- 84 **Julian Bathelt** | Machine Learning kann mehr leisten als Optimierung
- 85 **Ulrich Lichtenthaler** | Integrierte Intelligenz: Mit KI neue Kundenbedürfnisse adressieren
- 86 **Franz Kögl** | Wie Transfer Learning den KI-Einsatz demokratisiert
- 88 **Benedikt Bonnmann** | Das datengetriebene Unternehmen – wie Verantwortliche der Bedeutung von Daten gerecht werden

KOLUMNEN

- 7 **Petra Bernatzeder** | Mentale Intelligenz – wozu soll das gut sein?
- 92 **Marcus Raitner** | Wissensarbeiter in der Autonomie-Falle

IMMER DABEI

- 3 **Editorial** | Die Evolution in der KI
- 91 **Call for Contribution**
- 94 **Fachbeirat**
- 94 **Impressum**

LESEN SIE ONLINE MEHR

Fachbeiträge
Kolumnen
Blogs



Die nächste
DIGITALE WELT
erscheint am
01.09.2021

DIGITALISIERUNG

in Zahlen

Die Betreiber der Luca-App erhalten von mehreren Bundesländern mehr als **20 Mio. Euro.**



Nur **11 %** aller im Rahmen des „IoT-Sicherheitsreports 2021“ befragten Unternehmen führen eine Bedrohungsanalyse bezüglich ihrer IoT-Devices durch.



Bis Ende April 2021 wurden mit der Corona-Warn-App **2,5 Mio.** rote Warnmeldungen verschickt.

Laut einer Befragung von eintausend Eltern sehen **85 %** durch Digitalisierung Chance für die Schulen.



Der IT-Security-Anbieter Proofpoint wurde von der Firma Thoma Bravo für **12,3 Mrd. US-Dollar** gekauft.

Laut einer Bitkom-Umfrage sehen **62 %** aller Unternehmen eine Chance für den praktischen Einsatz von KI.



Aufgrund eines Datenlecks bei Facebook wurden Profildaten von über **533 Mio.** Nutzern gestohlen und veröffentlicht.



Die Firma ING Deutschland gibt jedem Mitarbeiter **1.500 Euro** für die Einrichtung des Homeoffice.



Im vergangenen Quartal stieg der Umsatz von Facebook auf knapp **26,2 Mrd. Dollar.**



Laut einer Umfrage von Clark in Zusammenarbeit mit YouGov wollen **24 %** aller im Homeoffice Beschäftigten gerne dauerhaft von zu Hause aus arbeiten.

Foto: I23RF



MENTALE INTELLIGENZ

WOZU SOLL DAS GUT SEIN?

Wenn sich bei Ihnen auch immer alles schneller dreht, es ständig komplexer und dynamischer wird, befinden Sie sich in bester Gesellschaft, nämlich in der Höchstleistungsgesellschaft. Vielleicht lässt sich auch nicht alles ändern, was um uns herum passiert. Aber eines können wir mit Sicherheit ändern, nämlich wie wir mit all dem umgehen. Mentale Intelligenz bedeutet zu wissen, was sich in unserem Kopf abspielt, zu verstehen, wie wir ticken und wie wir uns gezielt steuern können, und zwar mit der Kraft der Gedanken. Wie wäre es, wenn wir uns in stressigen Situationen ganz einfach und schnell wieder in einen gelassenen Zustand versetzen könnten?

- wenn wir uns in schwierigen Situationen auf Erfolg programmieren?
- wenn es zu jedem Zeitpunkt gelänge, sich selbst mit frischer Energie und Konzentration zu versorgen, und dies nur mit der Kraft der inneren Bilder?
- Oder zwischendurch in eine kurze Tiefenentspannung abtauchen?
- Und wie wäre es, wenn wir immer mal wieder die Perspektive ändern könnten, um komplexe Sachverhalte besser verstehen und damit lösen zu können?

Machen wir ein kleines Experiment, um die Wirkung mentaler Techniken zu veranschaulichen. Konzentrieren Sie bitte Ihre Aufmerksamkeit auf Ihren rechten Arm und legen Sie ihn bitte irgendwo locker ab. Stellen Sie sich bitte vor, dass der Arm immer schwerer wird, und denken Sie vor sich hin „mein Arm ist ganz schwer“. Was passiert? Ich vermute, nach kurzer Zeit ist Ihr Arm so schwer, dass Sie Mühe haben, ihn anzuheben. Und das alles, obwohl Sie sich ja nur das Bild eines schweren Arms vor Ihrem geistigen Auge vorgestellt haben und das vor sich hingedacht haben.

Über die Steuerung der Bilder in unserem Kopfkino können wir uns in einen ganz bestimmten Zustand versetzen. Es mag vielleicht befremdlich wirken, aber die neurobiologische Forschung ist eindeutig, was den Einfluss dieser mentalen Techniken auf Stoffwechsel, Leistung und Stimmung betrifft.

Im Leistungssport sind mentale Werkzeuge längst angekommen. Dort werden Techniken trainiert, um sich – trotz eines Rückstands – emotional so stabil zu halten, dass die Chancen groß sind, diesen aufzuholen und zu gewinnen. Beim Skiabfahrtslauf sehen wir im Starthäuschen, wie sich

die Athleten gedanklich und mit leicht sichtbaren Bewegungen die Schwünge einprägen. Sie machen sich Forschungsergebnisse zunutze, die belegen, dass es fast keinen Unterschied macht, wie man Bewegungsabläufe oder Fertigkeiten trainiert. Die Gehirnforschung zeigt, dass Gehirnareale, die z.B. für die Motorik zuständig sind, sich gleichermaßen vergrößern, egal ob man mental oder praktisch trainiert hat.

Als wir noch Kinder waren und mit unseren Freunden gespielt haben, gab es sehr vieles, was nur in unserer Phantasie vorhanden war. Abenteuerliche Reisen auf dem fliegenden Teppich oder dem imaginären Pferderücken. Spiele mit Bösewichten und den guten Feen oder Hexen und Zaubern. Kinder kennen keine Scheu, wenn es darum geht, vor ihrem inneren Auge in eine andere Welt einzutauchen. Wir als „vernünftige“ Erwachsene tun uns manchmal ein bisschen schwer, uns auf die unbegrenzten Möglichkeiten der mentale Bilderwelt einzulassen. Aber genau das macht mentalen Intelligenz aus, zu verstehen, wie wir „spielerisch“ positiven Einfluss auf unser Leben nehmen können. Diese spielerische Art hilft vielen meiner Coaching-Klienten, mit ihren persönlichen Antreiber, also z.B. dem Perfektionisten, so in Kontakt zu kommen, dass er sie nicht ständig zu weiteren Verbesserungsschleifen treibt, die viel Energie kosten. Und das ist auch gut so, damit sinkt ein Risiko möglicher Überlastung.

Und wenn es um die andere aktuelle Form von Intelligenz geht, die künstliche Intelligenz, sind gerade Sie als Autoren und Leser dieses Magazins vermutlich ständig damit befasst. KI hat das große Ziel, menschliches Denken und Entscheiden so zu mechanisieren, dass die Menschen bei der Bewältigung komplexer Probleme entlastet werden. Vieles wissen wir darüber, was menschliches Denken und Entscheiden ausmacht, aber sollten wir nicht auch wissen, wie wir uns selbst mit der Kraft unserer Gedanken steuern können?

Mir ist es ein großes Anliegen, mentale Intelligenz nicht nur in Unternehmen, sondern auch als Schulfach zu etablieren. Kinder, Jugendliche, wir alle brauchen diese Werkzeuge heute und in Zukunft dringender denn je.

Habe ich Sie neugierig gemacht? Wenn Sie Lust haben, schreiben Sie mir.
Herzlichst Ihre
Dr. Petra Bernatzeder,
Diplom-Psychologin, Coach, Expertin
für mentale Intelligenz, www.upgrade-hr.com



Foto: Privat

Künstliche Intelligenz auf dem Prüfstand – Wie aus einer Künstlichen Intelligenz eine Safe Intelligence wird

Techniken, die mit Künstlicher Intelligenz (KI) ausgestattet sind, prägen unseren Alltag heute schon in vielen Anwendungsbereichen. Längst ist um KI ein Wettbewerb entstanden, der wirtschaftliche, industrielle, rechtliche und soziale Faktoren betrifft. Das Ringen um die beste Technik wirft zugleich viele Fragen auf. Apl. Prof. Dr. habil. Mario Trapp ist Leiter des Fraunhofer-Instituts für Kognitive Systeme IKS und forscht an der Schnittstelle zwischen Theorie und Praxis um eine Verbesserung der KI-Technik. Das betrifft vor allem die Funktionalität und die Sicherheit.

Unser Alltag ist heute ein allorts von der Technik geprägt. Wir ziehen unsere Smartphones aus der Hosentasche, wenn wir das nächste italienische Restaurant oder den schnellsten Weg von A nach B suchen. Wo in diesem technisierten Alltag sind bereits Prozesse am Werke, von denen wir womöglich nichts wissen, die aber bereits Künstliche Intelligenz (KI) als Technik nutzen?

Viele von uns nutzen heute schon täglich KI. Wenn wir online einkaufen, werden die Produktvorschläge von KI ermittelt, und KI hilft dabei, Betrugsfälle bei der Kreditkartennutzung zu ermitteln. Genauso kommt KI zum Einsatz, wenn wir bspw. Sprachassistenten wie Alexa oder Siri nach dem Wetter fragen. All das sind Anwendungen, die uns an manchen Stellen das Leben ein wenig erleichtern und über die wir uns freuen, wenn sie

funktionieren. Verstehen uns Alexa oder Siri einmal nicht oder führen sie nicht die gewünschten Funktionen aus, dann ist das nervig, aber es schafft keine gefährlichen Situationen. Genau das ändert sich aber, wenn KI in Bereichen eingesetzt wird, in denen Fehlfunktionen gravierende Folgen haben. Nutzt man bspw. KI zur Qualitätssicherung in der Produktion, können Fehler zu enormen finanziellen Schäden führen, welche die Kostenvorteile durch den Einsatz von KI schnell übersteigen. Kommt KI sogar in sicherheitskritischen Anwendungen wie bspw. beim automatisierten Fahren oder in der Medizin zur Erkennung von Krankheiten zum Einsatz, kann eine Fehlfunktion sogar tödliche Auswirkungen haben. Die Herausforderung besteht deshalb darin, den Einsatz von KI so sicher und zuverlässig zu machen, dass man ihr auch Menschenleben anvertrauen kann.



Wie bewerten Sie folgende Befürchtung, die mit der Implementierung von Künstlicher Intelligenz in unseren Alltag womöglich einhergeht: KI reduziere massenhaft Jobs, weil die Arbeitskraft von heute durch den Computer von morgen ersetzt werde?

Es ist richtig: Der Einsatz von KI und die Digitalisierung insgesamt führen dazu, dass Arbeitsplätze wegfallen. Aber sie sorgen auch für die Entstehung neuer Jobs. Laut einer Studie des Weltwirtschaftsforums werden infolge des Einsatzes von KI weltweit 133 Mio. neue Arbeitsplätze entstehen und so der ebenfalls damit einhergehende Wegfall von etwa 75 Mio. Jobs mehr als kompensiert. Unter dem Strich wird es also nicht weniger Arbeit geben, sondern andere als bisher. Solche Entwicklungen im Zusammenhang mit dem technologischen Fortschritt gab es auch in der Vergangenheit immer wieder. Wichtig ist, dass wir die Aus- und Weiterbildung rechtzeitig anpassen, um die Arbeitnehmerinnen und Arbeitnehmer vorzubereiten und für kommende Aufgaben zu qualifizieren.

Bohren wir weiter nach der Achillesferse von KI. Woran forschen und arbeiten Sie, um KI-basierte Systeme sicher und zuverlässig zu machen? Was sind die Herausforderungen und welche Faktoren limitieren uns aktuell?

Im Mittelpunkt der Forschung am Fraunhofer IKS steht Safe Intelligence, also die Frage, wie sich nachweisbar sichere intelligente Systeme bauen lassen. Dabei ist es uns wichtig, das Thema holistisch zu betrachten. Das bedeutet, dass wir das gesamte System in den Blick nehmen und das Beste der Welten des Engineerings und der KI in Einklang bringen.

Das betrifft zum einen natürlich die KI selbst. Die heutige KI stellt uns vor enorme Herausforderungen, weil sie meistens gut funktioniert, aber man nur bedingt versteht, warum sie funktioniert, und für uns noch wichtiger: wann sie nicht funktioniert. Daher ist eine entscheidende Frage, wie man von der Black Box KI mehr in Richtung Grey Box kommen kann.

Vor eine besondere Herausforderung stellt uns die nach wie vor mangelnde Robustheit der KI: Selbst kleinste Änderungen am Eingang – einige Pixel Unterschied bei einem Kamerabild reichen – führen zu völlig anderen Ergebnissen. Dadurch lassen sich bspw. bekannte Qualitätssicherungstechniken wie das Testen kaum anwenden. Egal, wie viele Testkilometer ein automatisiertes Fahrzeug in der echten oder simulierten Welt fährt: Unsere Welt ist unendlich, und keine Situation wird sich identisch wiederholen.

Die Welt wird immer anders aussehen, und ohne robuste KI ist es schlichtweg nicht möglich vorherzusagen, wie sich die KI dann im Ernstfall verhalten wird – egal, wie viel sie getestet wurde. Daher ist die Steigerung der Robustheit eine zentrale Forschungsfragestellung. Für den Anfang hilft es aber schon, wenn man der KI das Zweifeln beibringt, dass sie eben besser versteht, was sie nicht versteht.

Und wie arbeiten Sie an einer Sicherheitsverbesserung der KI?

Da wir heute noch keine ausreichend belastbaren Konzepte zur Absicherung der KI haben, geht es in erster Linie zunächst darum, das System als Ganzes abzusichern. Denn letztlich ist Safety immer eine Eigenschaft des Gesamtsystems, sodass aktuell auch die Frage im Vordergrund steht, wie sich die Systemsi-

cherheit gewährleisten lässt, obwohl unsichere KI zum Einsatz kommt.

Doch gerade intelligente Systeme stellen Safety vor besondere Herausforderungen: Erstens kommen neue Technologien wie das Maschinelle Lernen zum Einsatz, die inhärent schwer abzusichern sind. Zweitens werden diese Systeme in Situationen eingesetzt, in denen sich die Umgebungsbedingungen nicht mehr voraussehen lassen. Und dennoch muss die Sicherheit auch für unvorhergesehene Situationen gewährleistet sein. Ebenso wenig wissen wir, mit welchen anderen Fahrzeugen, Robotern oder Maschinen das System zusammenarbeiten wird. Hinzu kommen Software-Updates, die die Funktionen des Systems weiterentwickeln. Mit all diesen Unsicherheiten müssen wir umgehen, das heißt: Wir müssen das System in die Lage versetzen, auch insofern intelligent zu werden, dass es sich seiner Sicherheit selbst bewusst wird und sich selbst absichern kann. Und das alles im Gesamtzusammenhang mit der kompletten Systemumgebung und im Zusammenwirken mit anderen Systemen. Das ist schon eine enorme Herausforderung und macht disruptive Paradigmenwechsel in der Safety-Absicherung nötig.

Die Nachricht verbreitete sich 2017 wie ein Lauffeuer: Es soll einen neuen Matrix-Film geben. 1999 erschien der erste Science-Fiction-Film der dreiteiligen Reihe. Als Übergangswerk ins neue Jahrtausend verhiß er damals nichts Gutes: Eine mit Künstlicher Intelligenz gefütterte Matrix beherrsche die Abläufe unseres Planeten. Die Dystopie ist bis heute – glücklicherweise – Dystopie geblieben. Dennoch lädt der Film zur kritischen Reflexion ein: Was halten Sie von diesem Schreckensszenario Mensch vs. Maschine, in dem letztlich die Maschine Oberhand gewinnt?

Solche Fiktionen sind sicherlich ein guter Stoff für spannende Unterhaltung – aber mit der Realität haben sie nichts zu tun. Man darf nicht vergessen: Was wir als künstliche „Intelligenz“ bezeichnen, ist letztlich nur eine Technologie, die es mit Statistik und Optimierung schafft, dass ein System anhand großer Mengen an Trainingsbeispielen gewisse Verhaltensweisen imitieren kann. Solche Softwaresysteme verfügen aber nicht über eigenes Bewusstsein und können keine eigenständigen, über die ihr antrainierten Muster hinausgehenden Entscheidungen treffen

oder gar bestimmte eigenständige Ziele verfolgen. Daher kann man solche Matrix-Szenarien getrost der Science-Fiction zuordnen. KI stellt zwar durchaus eine Bedrohung für Menschenleben dar, wie manche Unfälle selbstfahrender Autos schon vor Augen geführt haben. Aber nicht, weil uns die KI angreifen möchte, sondern schlichtweg, weil sie Stand heute ein noch unzureichend beherrschtes und somit sehr fehlerbehaftetes Stück Softwaretechnologie ist, das eigentlich noch nicht reif genug ist, um Menschenleben davon abhängig zu machen.

In diesem Zusammenhang ist der Unterschied zwischen „starker“ und „schwacher“ KI relevant. Was wird damit ausgedrückt? Wird der Einsatz von starker KI ein visionärer Ansatz bleiben?

Um es ganz deutlich zu machen: Bisher ist Künstliche Intelligenz mehr künstlich als intelligent. Das gilt vor allem für Anwendungen, die der „schwachen KI“ zugeordnet werden. Darunter versteht man einfache Systeme, wie etwa die genann-

ten Sprachassistenten, die dazu dienen, auf Basis der für eine bestimmte Anforderung entwickelten Software eine einzelne vordefinierte Aufgabe zu erfüllen, also bspw. das Licht einzuschalten.

Mit „starker KI“ bezeichnet man Systeme, die nicht nur einen Befehl ausführen, sondern in komplexen Situationen aktiv agieren können. Und das mit derselben oder sogar einer höheren Intelligenz als der Mensch. Und davon sind wir noch viele Jahre der Forschung entfernt. Insofern ist das Konzept der starken KI aus heutiger Warte betrachtet Vision.

Das Fraunhofer-Institut für Kognitive Systeme IKS forscht und entwickelt an einem der relevantesten Zukunftsthemen überhaupt: der Verlässlichkeit von Künstlicher Intelligenz. Welche Bereiche des praktischen Alltags deckt Ihre Forschung ab? Kommt KI bereits in sicherheitskritischen Anwendungen zum Einsatz?

Wir konzentrieren uns im Wesentlichen auf vier Bereiche: erstens Mobilität. Das geht deutlich über das autonome Fahren hinaus und schließt etwa Mobilitätsdienste und Flottenmanagement mit ein. Als zweiten Bereich möchte ich die Produktion nennen. Das beinhaltet sowohl smarte Fabriken als auch mobile Roboter und Produktionssteuerung aus der Cloud. Ein dritter Bereich ist die Medizintechnik. Das reicht von der medizinischen Bildgebung und Diagnostik bis zu Roboter-gestützten Operationen. Und viertens befassen wir uns mit Smart Farming. Das schließt autonome Landmaschinen ebenso mit ein wie die Nutzung von Sensoren, Satelliten und Drohnen sowie intelligentes Farmmanagement.

In vielen dieser Bereiche kommen Anwendungen auf Basis von KI bereits zum Einsatz. Ein bekanntes Beispiel sind sicherlich die aktuellen Versuche auf dem Weg zum automatisierten Fah-

ren, wo KI vor allem die Umfeldwahrnehmung übernimmt und darauf aufbauend Fahrentscheidungen getroffen werden. Das findet derzeit aber noch hauptsächlich im Rahmen von Testfahrten statt und nur sehr eingeschränkt im alltäglichen Straßenverkehr. In Warenlagern dagegen erledigen mobile Roboter bereits heute Transportaufgaben automatisiert. Das passiert fast ausschließlich dort, wo sich Roboter und Menschen nicht in die Quere kommen können. Aber auch an der sicheren Kollaboration von mobilen Robotern und Mitarbeitenden in der Logistik wird geforscht, auch am Fraunhofer IKS.

Zwei Bereiche möchte ich gerne gesondert herausgreifen – zum einen die Medizintechnik. Apps wie ADA arbeiten heute schon an einer Diagnostik via Smartphone und KI. Unternehmen wie deepc forschen an einer Verbesserung der radiologischen Diagnostik mittels KI. Wie steht es um den gegenwärtigen Einsatz von KI in der Medizin? Wie machen Sie KI in der Medizin verlässlicher?

Für die Medizintechnik spielt die KI in der Tat eine entscheidende Rolle. Zum einen ist natürlich der Einsatz in der bildgebenden Diagnostik, zum Beispiel der Tumor-Erkennung, naheliegend. Die KI kommt aber bspw. auch zum Einsatz, wenn man verschiedene Vitalparameter über die Zeit beobachtet und dadurch Vorhersagen zum Krankheitsverlauf machen kann, um zu reagieren, bevor es zu spät ist.

Unserem Leitbild der Safe Intelligence folgend geht es uns auch in dieser Anwendung um die nachweisbare Qualität der KI. Auch wenn man heute die Ergebnisse der KI noch durch Ärztinnen oder Ärzte plausibilisieren lassen kann, so wird dies aufgrund der zunehmenden Komplexität in Zukunft kaum noch möglich sein, da den menschlichen Aufpassern Informationen fehlen, sie Dinge nicht sehen können, die die KI sieht, oder ihnen schlichtweg die Zeit fehlt. Hinzu kommt ein Effekt, den man im Englischen als „Automation Complacency“ bezeichnet, also das unberechtigte Vertrauen in ein System – wenn es ja die ganze Zeit scheinbar funktioniert, wird man zu nachlässig.

In Kooperation mit den LMU-Kliniken arbeiten wir bspw. an einer Verbesserung der KI-Qualität in der Tumor-Erkennung. Dazu kommen unter anderem Verifikationsverfahren zum Einsatz, mit deren Hilfe sich wichtige Eigenschaften wie die Robustheit der KI beweisen lassen. Aufgrund des enormen Rechenaufwands für solche Aufgaben soll die Verifikation mit speziellen Algorithmen auf dem IBM Quantenrechner der Fraunhofer-Gesellschaft durchgeführt werden. Quantenrechner bieten aber aufgrund ihrer besonderen Qualitäten noch weitere Eigenschaften, die wir zum Beispiel nutzen können, um sogenannte Bayes'sche Neuronale Netze verwenden zu können, die es uns ermöglichen, die Unsicherheiten zu ermitteln, mit denen ein Ergebnis der KI behaftet ist.

Zweitens begegnet uns das Thema KI immer wieder in Fragen der Mobilität. In der Regel verbinden wir autonomes Fahren mit Künstlicher Intelligenz. Gängige Modelle sprechen von fünf Stufen zum autonomen Fahren. Können Sie diese kurz erläutern und konstatieren, wo wir derzeit stehen?

Rechtliche Fragen, insbesondere Haftungsfragen lasse ich jetzt einmal außen vor. Die Stufe 1 des autonomen Fahrens kann mittlerweile als Standard auf den deutschen Straßen betrachtet werden. Fahrer oder FahrerIn müssen jederzeit das Verkehrsgeschehen im Blick und ihr Fahrzeug unter Kontrolle haben. Sie werden aber durch ein oder mehrere Fahrerassistenzsysteme unterstützt, wie zum Beispiel durch einen Tempomaten mit Abstandsregelung.

In Stufe 2 bleibt der Fahrer Herr über das Auto und muss den Verkehr aktiv beobachten. Jedoch übernehmen Assistenzsysteme zusätzliche Funktionen wie Spurhalten, Beschleunigen und Abbremsen. Man spricht hier schon vom teilautomatisierten Fahren. Stufe 3 geht einen wichtigen Schritt weiter: Die FahrerIn muss nicht ständig den Verkehr beobachten und das Fahrzeug unter Kontrolle haben. In bestimmten, vom Hersteller definierten Situationen und zeitlich begrenzt übernimmt das Auto selbst bestimmte Fahraufgaben wie Spurwechsel und Überholvorgänge. Taucht ein Problem auf, müssen FahrerIn oder Fahrer sofort das Steuer übernehmen. Das ist das bedingte automatisierte Fahren. In Stufe 4 ist das Fahrzeug überwiegend selbstständig unterwegs, man spricht dann auch vom hochautomatisierten Fahren. Der Fahrer wird zum Fahrgast – sozusagen. Allerdings kann dieses Fahren auf bestimmte Strecken, Geschwindigkeitsbereiche oder Wetterbedingungen beschränkt sein. Die 5. Stufe schließlich ist das vollautomatisierte Fahren,

„Auch wenn man heute die Ergebnisse der KI noch durch Ärztinnen oder Ärzte plausibilisieren lassen kann, so wird dies aufgrund der zunehmenden Komplexität in Zukunft kaum noch möglich sein.“

bei dem das Auto nach einer Zieleingabe völlig selbstständig unterwegs ist, das heißt: Alle Menschen im Auto sind Fahrgäste, auch Fahrten ohne Fahrzeuginsassen sind möglich.

Aktuell befinden wir uns nach wie vor in der Herausforderung, Stufe 3 auf die Straßen zu bringen. Gerade für Shuttle-Dienste und sogenannte Robo-Taxis arbeitet man gerade an Stufe 4.

Die Sicherheit von kognitiven Systemen ist der Schlüssel für autonomes Fahren. Was sind Ihre konkreten Forschungsarbeiten, welche die KI-Technik für das autonome Fahren verbessern sollen?

Lassen Sie mich zum besseren Verständnis einen Blick auf die technischen Voraussetzungen für das automatisierte Fahren ab Stufe 3 werfen: Es beginnt mit der Wahrnehmung: Kameras und Sensoren wie Radar und Lidar scannen die Umgebung in Echtzeit. Diese Informationen werden mit gespeicherten digitalen Karten und GPS-Daten abgeglichen. Hinzu kommen Daten vom Fahrverhalten anderer Fahrzeuge. Die so gesammelten Daten werden zusammengeführt und durch Künstliche Intelligenz (KI) ausgewertet. Daraus entsteht die Perception, also die maschinelle Wahrnehmung der Fahrzeugumgebung.

Im nächsten Schritt wird auf Basis dieser Perception ein 3D-Modell der Umgebung erstellt. Damit errechnet das System die bevorstehende Situation und trifft Vorhersagen. Schließlich plant das automatisierte Fahrzeug die nächsten Aktionen und führt diese selbstständig aus.

Schon aus dieser vereinfachten Darstellung wird ersichtlich: Eine der aktuell größten Herausforderungen für das automatisierte Fahren liegt in der KI-gestützten Perception: Erkennt die KI einen Menschen auf einem Zebrastreifen zuverlässig? Was passiert, wenn sie sich nicht sicher ist? Da kein Mensch die maschinelle Wahrnehmung und die daraus folgenden Entscheidungen in Echtzeit validieren kann, ist es notwendig, andere Wege zu finden, die Richtigkeit der maschinellen Perception zu überprüfen. Wir forschen deshalb insbesondere an Methoden, um die Perception abzusichern. Dazu gehört zum einen der Umgang mit Unsicherheiten in der Erkennung, sogenannten „Uncertainties“. Dazu bringen wir der KI das Zweifeln bei. Fachlich gesehen, geht es dabei um die Weiterentwicklung typischer Verfahren wie Deep Ensembles oder Out-Of-Distribution Detection, um zwei Beispiele zu nennen. Die Perception liefert dann nicht mehr nur die Ausgabe, wo sie bspw. glaubt, eine Fußgängerin zu sehen, sondern macht auch verlässliche Aussagen zur Unsicherheit der Ergebnisse. Dadurch entstehen unscharfe Bereiche, innerhalb derer sich die Person wahrscheinlich befindet, und man bekommt belastbarere Informationen, wie sicher sich die KI ist, ob es sich wirklich um eine Person oder vielleicht doch um eine Radfahrerin oder ein ganz anderes Objekt handelt.

Und wie steht es um die Sicherheitsgarantie solcher KI-Methoden?

Wie eingangs bereits erwähnt, sind der Absicherung der KI selbst heute allerdings Grenzen gesetzt, die noch nicht ausreichen, um nur durch die KI alleine ein akzeptables Restrisiko erreichen zu können. Daher kommen Überwachungsarchitekturen nach wie vor eine besondere Bedeutung zu, die sicher-

stellen, dass das Fahrzeug auch dann kein unsicheres Verhalten aufweist, wenn die KI fehlerhaft arbeitet. Das Prinzip dahinter ist ähnlich, wie man dies von der Mathematik aus der Schule kennt. Das Ergebnis einer Differentialgleichung zu berechnen, ist sehr aufwändig, das Ergebnis zu prüfen, ist hingegen vergleichsweise einfach. Übertragen bedeutet dies, dass wir es nur mit KI schaffen, aus den Sensordaten die Szene zu verstehen und bspw. Personen zu erkennen. Die Prüfung, ob an einer gewissen Stelle tatsächlich eine Person steht, lässt sich dann allerdings mit klassischen Algorithmen durchführen, deren Sicherheit sich mit etablierten Verfahren untersuchen lässt. Häufig sind diese Überwacher allerdings zu konservativ, d.h.

„Gerade kleine und mittelständische Unternehmen können es sich nicht erlauben, in der Hoffnung auf einen mittel- bis langfristigen Mehrwert mehr oder weniger altruistisch als Förderer in die Forschung zu investieren.“

sie werden lieber viel häufiger eine Bremsung einleiten als einmal zu wenig. Aktuell sind die Verfahren in der Tat noch zu konservativ, sodass die Performanz der Systeme in manchen Konstellationen fast bis zur Unbrauchbarkeit reduziert werden müsste. Aus diesem Grund forschen wir hier zusätzlich am sogenannten Adaptiven Safety Management. Während der Entwicklungszeit müssen Safety-Ingenieurinnen und -ingenieure immer vom schlimmsten denkbaren Fall ausgehen und die Überwachung daher sehr konservativ auslegen. Beim Adaptiven Safety Management

wird das Auto in die Lage versetzt, für die aktuelle Situation im Betrieb die relevanten Gefährdungen und das Sicherheitsrisiko zu bestimmen und ihr Sicherheitskonzept adaptiv an diese Situation anzupassen. Dadurch reagiert es bei der Autobahnfahrt auf trockener Fahrbahn im Tageslicht anders als bei einer Stadtfahrt im Regen und bei hohem Verkehrs- und Fußgängeraufkommen. Dadurch lässt sich die Performanz massiv steigern, ohne die Sicherheit zu gefährden.

„Industrie 4.0“ ist ein beliebtes Schlagwort, um die Bestrebungen zu mehr Digitalisierung in der industriellen Produktion zu bezeichnen. Wie steht es um die Künstliche Intelligenz in der Industrie 4.0?

Auch die Industrie 4.0 bietet verschiedenste Möglichkeiten, um von der KI zu profitieren. So lassen sich zum einen Aufgaben unmittelbar an der Maschine durch KI verbessern, wie etwa die (bildbasierte) Qualitätsprüfung von Werkstücken oder auch das Überwachen der Anlage im Condition Monitoring – insbesondere wenn es darum geht, Wartungsbedarf vorherzusagen, was häufig als Predictive Maintenance bezeichnet wird. In Verbindung mit dem industriellen Internet der Dinge werden aber auch immer mehr Daten einer Produktionsstätte oder über Standorte hinaus gesammelt, sodass die KI auch dabei hilft, übergreifende Prozesse zu optimieren – von der Optimierung der Produktionslogistik bis zur produktionsschritt- und werkübergreifenden Qualitäts- und Produktivitätsoptimierung.

Neben der Qualitätsüberwachung der Produkte und der Anlage selbst liegt ein Fokus unserer Arbeiten auch auf sogenannten fahrerlosen Transportsystemen, die in der Produktion und der Logistik zum Einsatz kommen. Um diese Fahrzeuge hoch- und vollautomatisiert fahren zu lassen, ist der Einsatz von KI unerlässlich. Besondere Bedeutung kommt dabei auch verteilten Ansätzen zu, weil es nicht darum geht, ein einzelnes Transportsystem zu betrachten, sondern es geht darum, den Produktions- oder Logistikprozess als Ganzes zu optimieren. Dazu sind die

Transportsysteme untereinander und mit der Infrastruktur vernetzt, um mit maximaler Performanz und trotzdem sicher agieren zu können.

Neben der Künstlichen Intelligenz ist Quantencomputing (QC) eine hoch im Kurs stehende Technik. Wie verhalten sich KI und QC zueinander? Bekannte Machine-Learning-Algorithmen eins zu eins auf Quantencomputern laufen zu lassen, funktioniert bekanntlich noch nicht. Können bestimmte Element der Künstlichen Intelligenz vom Quantencomputer dennoch profitieren? Wenn ja, wie?

Die KI kann aus verschiedenen Ansätzen heraus vom Quantencomputing profitieren. So lassen sich Verifikationsverfahren quantenalgorithmisch beschreiben, die Optimierung eines neuronalen Netzes kann durch Quantenalgorithmen unterstützt werden, spezielle Formen neuronaler Netze wie Bayes'sche Netze lassen sich effizient in Quantenalgorithmen überführen. Es gibt aber auch hybride Ansätze, in denen sich bspw. einzelne Schichten eines Convolutional Neural Networks durch Quantenalgorithmen ersetzen lassen, sodass man auch bereits heute trotz der noch vergleichsweise geringen Rechenkapazität echter Quantencomputer von der neuen Technologie profitieren kann.

Welche anderen Kooperationen sind essenziell für Ihre Forschungsarbeiten? Wie wird die Verzahnung mit der Industrie und Wirtschaft von Ihnen gehandhabt?

Unser primärer Auftrag als Fraunhofer-Institut ist der Transfer von Forschungsergebnissen in die Praxis. Gerade in der KI gibt es noch eine zu große Lücke zwischen Wissenschaft und Anwendungen. Daher arbeiten wir eng mit Industriepartnern zusammen, sodass aus wissenschaftlichen Erkenntnissen konkrete Innovationen werden können, von denen Wirtschaft und Gesellschaft profitieren. Dazu haben wir die Strukturen, um nicht nur Studien durchzuführen, sondern auch einen unmittelbaren Beitrag in der Wertschöpfung der Industriepartner leisten zu können, sodass neueste Forschungsergebnisse ihren direkten Weg in neue Produkte und Dienstleistungen finden. Gerade kleine und mittelständische Unternehmen können es sich nicht erlauben, in der Hoffnung auf einen mittel- bis langfristigen Mehrwert mehr oder weniger altruistisch als Förderer in die Forschung zu investieren. Sondern es geht vielmehr umgekehrt darum, dass sie von Forschungspartnern wie Fraunhofer am Standort unmittelbar profitieren und einen Wettbewerbsvorteil haben. Die Arbeit mit Fraunhofer ist daher auch keine Forschungsförderung, sondern immer eine Investition in bessere, wettbewerbsfähigere Produkte, die sich kurzfristig amortisiert und völlig neue Möglichkeiten eröffnet.

Um diese Translationskraft entwickeln zu können, verstehen wir uns als Fraunhofer-Institut immer als Teil eines größeren Ganzen, weshalb Vernetzung für uns von besonderer Bedeutung ist. Zum einen sind wir eines von 75 Fraunhofer-Instituten. Die Vernetzung innerhalb der Fraunhofer-Gesellschaft ist daher für uns von großer Bedeutung, da wir dadurch neben der Kompetenz am eigenen Institut auf die Expertise von fast 30.000 Kolleginnen und Kollegen zurückgreifen können. Gleichzeitig sind wir uns bewusst, dass viele der heutigen und somit auch unserer Forschungsthemen zu groß sind, um sie als einzelnes Institut bearbeiten zu können. Daher sind uns internationale Forschungsnetzwerke wichtig, weshalb wir etwa mit der Carnegie Mellon University in den USA, Laboratoire d'analyse

d'architecture des systèmes/Centre national de la recherche scientifique in Frankreich oder der Universität York in England als führende Forschungszentren zur Sicherheit von KI kooperieren, um nur einige Beispiele zu nennen. Von besonderer Bedeutung ist für uns natürlich auch die lokale Vernetzung am Forschungsstandort München, weshalb wir intensiv mit den beiden Universitäten, aber auch anderen Forschungseinrichtungen kooperieren.

Und wie sehen Sie sich damit im internationalen Vergleich aufgestellt?

Gerade im Kontext der Digitalisierung und der KI steht die deutsche Wirtschaft in einem sehr harten internationalen Wettbewerb, der vor allem durch Innovationskraft und Geschwindigkeit dominiert wird. Um unseren Standort in diesem Wettbewerb zu stärken, bedarf es Innovationsökosystemen, in denen verschiedenste Partner eng zusammenarbeiten, um dauerhaft schnellere und bessere Innovationen zu schaffen. Wir sehen es als unsere Aufgabe, unseren Beitrag als Teil dieses Ökosystems zu leisten, damit Bayern und Deutschland einer der weltweit zentralen Innovationsstandorte für Digitalisierung und KI bleibt bzw. wird.

Interview: Hannes Mittermaier

Apl. Prof. Dr. habil. Mario Trapp

Apl. Prof. Dr. habil. Mario Trapp ist geschäftsführender Leiter des Fraunhofer-Instituts für Kognitive Systeme IKS.

Er promovierte im Jahr 2005 mit Auszeichnung an der TU Kaiserslautern, an der er 2016 auch habilitierte. 2005 wechselte er an das Fraunhofer IESE und war dort zunächst als Abteilungsleiter für das Themengebiet sicherheitskritische Software verantwortlich, bevor er von 2009 bis 2017 die Hauptabteilung »Embedded Systems« leitete. Zum 01.01.2018 wurde er kommissarisch als geschäftsführender Institutsleiter des Fraunhofer ESK (heute Fraunhofer IKS) in München berufen, seit 01.05.2019 nimmt er diese Funktion regulär wahr.

Seit vielen Jahren bringt Mario Trapp seine Expertise in der Entwicklung innovativer eingebetteter Systeme im Rahmen von erfolgreichen Partnerprojekten ein, sowohl mit international führenden Großunternehmen als auch mit kleinen und mittelständischen Firmen. Sein aktueller, persönlicher Forschungsschwerpunkt liegt in der Safety-Assurance autonomer und verteilter Systeme, welche die technologische Grundlage vieler Zukunftsszenarien wie Industrie 4.0 oder das automatisierte Fahren bilden.

Mario Trapp ist Autor von zahlreichen internationalen wissenschaftlichen Publikationen und lehrt als apl. Professor am Fachbereich Informatik der TU Kaiserslautern.



Fotos: Fraunhofer

1. KÜNSTLICHE INTELLIGENZ

Künstliche Intelligenz ist derzeit eines der spannendsten Themen in der Informatik mit vielen bestehenden und aufkommenden Anwendungen in Industrie, Bildung, Sicherheit sowie im Alltag. Viele Fortschritte in der Künstlichen Intelligenz, insbesondere im Bereich des Maschinellen Lernens, der Verarbeitung natürlicher Sprache und der autonomen Entscheidungsfindung, haben die Realisierung spannender Anwendungen, wie Objekterkennung in Videos und Bildern, Sprachübersetzung und autonomes Fahren, ermöglicht, die mit klassischen technischen Methoden zuvor nicht möglich waren.

Obwohl es sich um eine vielversprechende Richtung zur Lösung vieler komplexer Aufgaben handelt, birgt die Künstliche Intelligenz noch einige Herausforderungen, die von Forschung und Industrie in Zukunft angegangen werden müssen, um den Anwendungsbereich zu erweitern: Ansätze der Künstlichen Intelligenz müssen in der Lage sein, Garantien über ihr Verhalten in extremen und unerwarteten Situationen zu geben. Sie müssen auch auf verschiedene Arten erklärbar sein, wie z.B. transparent über ihren Entscheidungs- oder Vorhersageprozess sein und in der Lage sein, ihr Verhalten nach der Ausführung einer Aufgabe zu erklären sowie Gründe zu nennen, warum bestimmte Aktionen gegenüber anderen gewählt wurden. Obwohl die meisten Anwendungen der Künstlichen Intelligenz ursprünglich so konzipiert sind, dass sie ohne menschliches Eingreifen funktionieren, ist es nicht immer möglich, den Menschen aus der Schleife herauszuhalten. Anwendungen im Bildungsbereich zum Beispiel erfordern, dass das System sozial interagiert und Empathie gegenüber dem Benutzer zeigt, um von der Gesellschaft allgemein akzeptiert zu werden.

Ein zentrales Ziel der Künstlichen Intelligenz ist es, allgemeine Möglichkeiten zu bieten, eine Vielzahl komplexer Probleme ohne manuelles Engineering und mit minimalem Domänenwissen zu lösen. Daher muss die aktuelle Forschung Wege finden, um Wissen zwischen Systemen transferieren und aufgabenspezifische Methoden auf allgemeine Frameworks erweitern zu können und Gemeinsamkeiten von Problemen zu entdecken, um allgemeine Problemformulierungen zu definieren, die durch Künstliche Intelligenz lösbar sind.

Die Artikel in dieser Zeitschrift bieten einen spannenden und reichhaltigen Überblick über Herausforderungen und Lösungen in verschiedenen Bereichen der Künstlichen Intelligenz. Sie spannen einen Bogen über theoretische Methoden, Definitionen, Umfragen, Visionen bis zu realen Anwendungen in der Industrie.

MEIST GEKLIKT – Unsere erfolgreichsten Blog-Beiträge

	Autor Thema
#1	Frank Thole Auf dem Weg zum artifiziellen Bewusstsein Seite 82
#2	Phillip Campbell „Machine Learning“ ist in der Buchhaltung angekommen Seite 60
#3	Christian Lemke Mit Reinforcement Learning auf dem Weg zur Allgemeinen KI Seite 66
#4	Frank S. Jorga Künstliche Intelligenz im Compliance-Bereich: Drei Anwendungsfelder Seite 52
#5	Dr. Philipp Hartmann Wie man KI Use Cases findet und priorisiert Seite 45

Unsere Beiträge wurden insgesamt über **2.250.000 Mal** geklickt*

Beiträge zum Thema **KÜNSTLICHE INTELLIGENZ** erhielten **327.000** Klicks.

*Unsere Beiträge wurden online unter www.digitaleweltmagazin.de/blog veröffentlicht und erzielten dabei die oben genannte Klickanzahl im Zeitraum 01. August 2017 – 15. Mai 2021.

INHALT

FACHBEITRÄGE

Torsten Deutsch, Ralf Hülsmann Fake-KI: Nicht jeder Algorithmus ist intelligent	16
Alexis Fournier Die Wirtschaftlichkeit Künstlicher Intelligenz	20
Clara Krabatsch, Prof. Dr. Jens Nachtwei KI aus Sicht von Ärzten, Anwälten und Politikern	23
Cam-Duc Au, Dr. Andreas Hiese Künstliche Intelligenz in Banken: Worauf es im aktuellen Marktumfeld ankommt	26
Mischa Soujon Hey Computer, mach mal. Besser!	30
Prof. Stuart Jonathan Russell, Ph.D. Die gar nicht mal so große KI-Debatte	34

BLOGBEITRÄGE

1.1 USE CASES

Milad Safar Die Top 10 Anwendungsfälle für Maschinelles Lernen in Unternehmen	42
Dr. Christian Trippner Wie funktioniert Retourenvermeidung im Online-Shopping durch KI?	43
Dr. Philipp Hartmann, Dr. Maria Schamberger Wie man KI Use Cases findet und priorisiert	45
Florian von Walter Daten effizient nutzen – Vier Einsatzszenarien, wie Machine Learning dabei helfen kann	47

1.2 COMPLIANCE

Jessica Heesen Wie kommt Ethik in die Künstliche Intelligenz?	48
Christian Hugo Hoffmann Regulierung Künstlicher Intelligenz: Ein praktischer Ratgeber für die Praxis	50
Frank S. Jorga Künstliche Intelligenz im Compliance-Bereich: Drei Anwendungsfelder	52
Jörg-Alexander Paul Diskriminierungsfälle Künstliche Intelligenz: So vermeiden Sie Fehler schon beim Anlernen	54

1.3 MEDIZIN

Michael Wallraven Eine zweite Chance: Wie sich Unternehmen besser auf die nächste COVID-19-Welle vorbereiten können	55
Dr. Daniela Jansen Künstliche Intelligenz im Einsatz für die Gesundheit	56
Balakrishna D R Positive Lebenszeichen für KI im europäischen Gesundheitswesen	58

1.4 BUCHHALTUNG

Phillip C. Campbell „Machine Learning“ ist in der Buchhaltung angekommen	60
Marius Simon Was kann digitales Versichern? – Künstliche Intelligenz und Maschinenlernen auf dem Vertrauensprüfstand	61
Daniel Szlapka KI-basiertes Input-Management macht Dokumentenprozesse effektiver	62

1.5 PROZESSAUTOMATISIERUNG

Paul Beavers IT-Betrieb und -Service mit KI optimieren	64
Christian Lemke M.Sc. Mit Reinforcement Learning auf dem Weg zur Allgemeinen KI	66
Lumir Boureau Erfolgreiches Machine Learning dank Datenkonsistenz	68
Nicole Biel Reifegradmodell: In drei Schritten das Beste aus den Daten herausholen	70

1.6 PRODUKTIVITÄT

Volker Sommer Mehr Transparenz bitte! Die Vorteile KI-gestützten Identitätsmanagements	71
Uwe Küppers Die Zukunft der Produktion liegt in den Daten der Vergangenheit	72
Robert Frodl Von Science-Fiction zur Realität: Robotik in der Smart Factory	74

1.7 AUS DATEN GEBOREN

Prof. Dr. Daniel Keim, Prof. Dr. Kai-Uwe Sattler Von Daten zu Künstlicher Intelligenz – Datenmanagement als Basis für erfolgreiche KI-Anwendungen	75
Mauro Adorno Die saisonale Nachfrage mit KI in den Griff bekommen	79
Christian Werling Wie Unternehmen KI und Search zur Schaffung eines digitalen Nervensystems nutzen können	80
Frank Thole Auf dem Weg zum artifiziellen Bewusstsein	82

1.8 DISKUSSION

Julian Bathelt Machine Learning kann mehr leisten als Optimierung	84
Prof. Dr. Ulrich Lichtenthaler Integrierte Intelligenz: Mit KI neue Kundenbedürfnisse adressieren	85
Franz Kögl Wie Transfer Learning den KI-Einsatz demokratisiert	86
Benedikt Bonnmann Das datengetriebene Unternehmen – wie Verantwortliche der Bedeutung von Daten gerecht werden	88

Hier geht es
zu weiteren
Fachbeiträgen

Fake-KI: Nicht jeder Algorithmus ist intelligent

Torsten Deutsch, Ralf Hülsmann

T-Systems International GmbH

Künstliche Intelligenz scheint fast alles zu können. Die Hoffnungen, die Unternehmen in die Technologie setzen, sind groß. Doch nicht überall, wo KI draufsteht, ist auch KI drin. Was echte von einer vorgeblichen KI unterscheidet. Wann es sich lohnt, sie mit regelbasierten Systemen zu verbinden. Und wie Unternehmen Software erkennen, die lediglich vorgibt, intelligent zu sein.

Sie steckt in autonom fahrenden Autos, erkennt Tumore, liefert Sprachübersetzungen und verhindert den Ausfall von Maschinen: Künstliche Intelligenz scheint fast alles zu können. Die Hoffnungen, die Unternehmen in die Technologie setzen, sind riesengroß. Genauso wie die Gefahr, künftig häufiger auf Fake-KI hereinzufallen.

Kürzlich stellte der US-Bundesstaat Utah eine von ihm beschaffte Software für Predictive Policing des selbsternannten KI-Startups Banjo auf den Prüfstand[1]: Verwaltung und Politik wollten überprüfen lassen, ob das Unternehmen seine Algorithmen mit belasteten Trainingsdaten gefüttert hatte. Eine unabhängige Stelle checkte die KI-Software auf mögliche Voreingenommenheit und Datenschutzverstöße. Ergebnis: Die Kontrolleure konnten keine Vorurteile im KI-System entdecken. Kein Wunder, denn sie fanden auch keinerlei Spuren Künstlicher Intelligenz bei der KI-Überwachungsfirma. Der staatliche Prüfbericht kam zu dem eindeutigen Ergebnis, dass das Unternehmen keine Techniken verwendet, „die der Branchendefinition von Künstlicher Intelligenz entsprechen“. Sämtliche Denkvorgänge stammen komplett analog von Menschen.

Kein neues Phänomen: Vor wenigen Jahren hatte eine angebliche Artificial Intelligence (AI) namens Zach[2] die Öffentlichkeit in Neuseeland genarrt. Der Medizin-Bot beeindruckte vor allem die Ärzteschaft: Zach korrespondierte mit Medizinerinnen, konnte deren Patientenakten pflegen und Diagnosen stellen. Genauere Angaben zu ihrer Wunder-KI verweigerten die Unternehmens-

gründer Albi und David Whales. Sie verschanzten sich hinter einem Zitat des britischen Science-Fiction-Schriftstellers Arthur C. Clarke, demgemäß jede ausreichend fortgeschrittene Technologie nicht von Magie zu unterscheiden sei. Dass die Zauberkräfte Zachs doch eher begrenzt waren, brachte erst eine Untersuchung des neuseeländischen Innenministeriums zutage. Resultat: Auch hinter Zach steckt bloß menschliche Intelligenz. Dabei war der Betrug recht offensichtlich: Die Maschine kommunizierte mit den Medizinerinnen per E-Mail statt über eine Schnittstelle und sie brauchte gut 20 Minuten für jede Antwort. In Ordnung für einen Menschen, aber deutlich zu lange für eine KI. Vor allem aber hätte die Geheimniskrämerei des Unternehmens stutzig machen müssen. Wer eine echte KI anbietet, der kann sehr plausibel erklären, warum er sie einsetzt, wie die Algorithmen arbeiten oder ob er Künstliche Intelligenz mit regelbasierter Software kombiniert. Vor allem aber: Ernsthafte KI-Entwickler sprechen nicht von Wunder – sondern von Mathematik, Statistik und Stochastik.

Fake-KI: ein neues Problem

Zugegeben: Beim ersten Lesen mögen solche Beispiele noch amüsieren. Aber Fake-KI sind ein teurer Spaß: Sie kosten Unternehmen Zeit und Geld und bringen eine Technologie in Misskredit, auf die immer mehr Unternehmen große ökonomische Hoffnungen setzen. Die Deutsche Telekom etwa hat mit ihrem Digitalisierungsindex Mittelstand 2020/21[3] herausgefunden,

dass 31 Prozent der befragten Unternehmen von KI disruptive Veränderungen in ihrer Branche erwarten. 77 Prozent möchten mit dem Algorithmen-Einsatz ihre Service- und Produktqualität verbessern. 2019 gaben deutsche Unternehmen nach Angaben des Bundesministeriums für Wirtschaft und Energie rund 4,8 Milliarden Euro aus, um KI-Verfahren zu entwickeln[4], einzuführen und zu pflegen. Tendenz steigend und das ist gut so: Experten von McKinsey prognostizieren der EU eine wachsende Wirtschaftsleistung um 19 Prozentpunkte bis 2030[5], wenn sie sich auf das Thema KI fokussiert.

Nicht überall steckt KI drin

Schattenseite des sich anbahnenden KI-Booms: Im Gegensatz zu den Early Adoptern, die in der Regel ein hohes Maß an KI-Fachwissen besitzen, werden in den kommenden Monaten und Jahren immer mehr Unternehmen zu KI-Anwendern, die keine Data-Analysten oder KI-Experten beschäftigen. Sie möchten die Vorteile von KI möglichst einfach nutzen, setzen auf KI-as-a-Service und laufen dabei Gefahr, Betrügern aufzusitzen. Deren Kalkül: Auf der KI-Welle werden immer mehr Unternehmen mitsurfen wollen, ohne die Technik wirklich zu beherrschen. Das KI-Versprechen funktioniert wie ein Marketingtrick. Denn trotz vieler Vorbehalte gegenüber der Technologie ist KI eben auch das: ein verlockendes Verkaufsargument für digitale Lösungen jeglicher Art. Ein scheinbar untrügliches Versprechen auf Turboerfolge für jede Stufe der digitalen Transformation.

Vermutlich wird den Unternehmen unter dem KI-Label künftig häufig regelbasierte Software angeboten. Nur in Ausnahmefällen dürfte hinter der Fake-KI ein Mensch stecken wie in den eingangs erwähnten Beispielen.

Sind Algorithmen nicht alle gleich?

Was aber ist das überhaupt – eine falsche KI? Und ist es für Unternehmen wirklich so entscheidend zu wissen, ob die Algorithmen einer Software regelbasiert arbeiten oder zu Machine Learning fähig sind? Klar ist: Wir haben es hier mit weit mehr als nur einem semantischen Problem zu tun. Die Unterschiede in der Wirkungsweise werden schnell klar: Basiert etwa eine IT-Sicherheitslösung auf regelbasierten Systemen, funktioniert sie nach „Wenn-dann“-Regeln. Dazu haben sich ihre Entwickler die Hackerangriffe der Vergangenheit genau angeschaut. Die Software identifiziert bekannte Malware-Typen, wenn sie bestimmte Regeln erfüllen. Auf neue Angriffstypen reagiert sie eher hilflos. Schließlich kann kein Entwickler ahnen, welche Finten den Hackern der Zukunft noch einfallen mögen. Sprich: Für unbekannte Malware kann der Mensch keine Regeln schreiben, die die Maschine anschließend beherzigen muss. Um auf dem aktuellen Stand zu bleiben, braucht regelbasierte Software

immer wieder neue Regeln. Sonst wird sie immer schlechter. Anders die Künstliche Intelligenz: Sie erkennt Anomalien auch dann, wenn sie neu auftreten. Setzen Unternehmen bei ihrer Machine-Learning-Lösung beispielsweise auf die Methode des bestärkenden Lernens, auch Reinforcement Learning genannt, dann generiert die KI ihre Lösungen und Strategien auf der Basis von „Belohnungen“ im Trial-and-Error-Verfahren. Damit lässt sich das Ziel einer sich selbst verbessernden KI erreichen, die mit den Hackern Schritt hält. Je mehr die KI erledigt – und damit trainiert – umso besser wird sie. Die Auswertung von Massendaten und die vielfache Anwendung machen Künstliche Intelligenz immer smarter.

Regelbasiert reicht oft – aber nicht immer

Das gilt auch für Chatbots. Ein regelbasierter Chatbot erkennt die Absicht des Nutzers auf der Basis bestimmter Erkennungsregeln: Er klopft den Anfragetext eines Nutzers nach Schlüsselwörtern, sogenannten Entitätswerten, ab und gibt im Anschluss die hinterlegte Antwort. Auch die regelbasierte Variante agiert durchaus schlau: Ist die Absicht des Nutzers nicht sofort erkennbar, ermittelt der Chatbot mit einigen Rückfragen die fehlenden Schlüsselwörter. Wenn der Chatbot nur für einen klar eingegrenzten Aufgabenbereich benötigt wird, dann reicht die regelbasierte Erkennung aus. Zumindest hat auch einige Vorteile: Solche Bots sind schnell einsetzbar und müssen nicht angelernt werden. Statt den Bot mit einer Vielzahl an Datensätzen zu trainieren, reicht in diesen Fällen ein hinterlegter FAQ-Katalog, um den Bot zu bauen.

Verwechslungsgefahr: Fake-KI und Deepfakes

Weitaus bekannter als Fake-KI sind die sogenannten Deepfakes. Dabei handelt es sich um mit Künstlicher Intelligenz erstellte Fake-Bilder oder -Videos, die zunehmend das Internet fluten. Der Begriff ist ein Kofferwort und setzt sich aus den Wörtern „Deep Learning“ und „Fake“ zusammen – also einer Methode des maschinellen Lernens und Fälschung. Deepfakes wirken täuschend echt: Sie vertauschen Gesichter, lassen Menschen Dinge sagen oder tun, die sie weder geäußert noch getan haben. Sie erschüttern unsere Gewissheit über die Realität: Denn jedes Video, jede Tonaufnahme kann eine Lüge sein. Selbst Laien können Deepfakes inzwischen mit kostenlosen Apps herstellen. Das bereitet der Bundesregierung zunehmend Sorge: „Es kann nicht ausgeschlossen werden, dass aufgrund der schnellen technologischen Fortschritte künftig auch eine Bedrohung demokratischer Prozesse durch Deep Fakes[10] erfolgen kann“, antwortet sie auf eine Anfrage der FDP. Auch die sozialen Medien gehen inzwischen gegen Deepfakes vor.

Dagegen kann ein KI-Bot erst nach entsprechendem Training an den Start gehen: In der Regel wenden diese Bots Machine-Learning-Modelle an, um intelligent zu werden. Das bedeutet, dass Entwickler unzählige Beispiele und damit Daten sammeln und klassifizieren müssen, mit denen die Maschine lernen kann. Auf der Basis des Gelernten kann sie anschließend verallgemeinern. Sie erkennt in den Nutzereingaben Muster und kann antworten, ohne auf vorformulierte Sätze zurückgreifen zu müssen. Der KI-Chatbot versteht Anfragen selbst dann, wenn bestimmte Schlüsselwörter nicht auftauchen, ist also weniger starr im Umgang mit dem Nutzer. Der Nachteil: Aufgrund des Trainings dauert es deutlich länger, bis solche Chatbots einsatzfähig sind. Doch mit der Zeit werden sie immer besser, weil sie nicht für jedes Nutzeranliegen erst eine neue Erkennungsregel brauchen. Ihre Lernfähigkeit macht das Wesen und den besonderen Charme von KI aus: Anders als regelbasierte Software ist KI in der Lage, eigenständig neue Probleme zu lösen. Heißt: Ihre Ergebnisse sind nicht statisch, sondern verbessern sich laufend.

KI als Kombi-Modell

Für viele Anwendungsfälle ist regelbasierte Software dennoch eine gute Wahl. So arbeiten selbst zukunftsweisende Anwendungen wie Predictive Maintenance häufig regelbasiert. Ihre Algorithmen schlagen Alarm, wenn Produktionsmaschinen oder Anlagen bestimmte, vom Menschen definierte Messwerte überschreiten. Künstliche Intelligenz ist erst vonnöten, wenn die Software durch eigenes Lernen erkennen soll, welche Parameter sich wie verändern müssen, damit ein Ausfall wahrscheinlich wird.

Oft ist es ratsam, beides miteinander zu kombinieren – wie etwa bei der Verarbeitung von Massendokumenten. So setzen mittlere und große Unternehmen seit längerer Zeit regelbasierte Algorithmen ein, um die tägliche Post zu sortieren: Auf der Basis von Bild und Schrift erkennt die Maschine, ob es sich um eine Rechnung handelt und schickt sie dann zur entsprechenden Abteilung. Sobald sich Aufbau und Struktur von Rechnungen zwischenzeitlich ändern, kommt die regelbasierte Software allerdings an ihre Grenzen. Beispielsweise, wenn sie erkennen soll, ob die Rechnung auch mit neuem Erscheinungsbild noch steuerrechtlich konform ist. Der Entwickler müsste sie erst wieder mit neuen Regeln füttern, damit sie ihre ursprüngliche Qualität erneut erreicht. Machine Learning dagegen erkennt den Inhalt des Dokuments, auch wenn sich die Struktur verändert hat. Denn sie lernt dazu. Deshalb setzen viele Unternehmen auf eine Kombination der Technologien: Sie verwenden regelbasierte Software, wenn die Maschine entscheiden soll, in welche Ab-

teilung sie das Dokument weiterleiten soll. Das kostet weniger Rechenzeit und ist in der Regel günstiger als der Einsatz von KI. Machine-Learning-Lösungen setzt dann erst die Fachabteilung ein, weil es ihr um die genauere Analyse geht.

Noch gibt es keinen Turing-Test für Fake-KI

Der britische Wissenschaftler Alan Turing hat 1950 den Turing-Test entwickelt, mit dem sich ermitteln lässt, ob die Intelligenz eines Softwaresystems der eines Menschen entspricht. Sobald die Versuchspersonen nicht eindeutig erkennen können, ob ein bestimmtes Ergebnis von einem Menschen oder einer Maschine stammt, gilt letztere als intelligent.

Bislang fehlt ein solcher Turing-Test, der eine Fake-KI rasch von einer echten KI unterscheiden könnte. Wenn sich Unternehmen für den Einsatz Künstlicher Intelligenz interessieren[6], müssen sie sich auf ihren gesunden Menschenverstand verlassen – und auf die Erfahrung ihrer KI-Experten und Daten-Spezialisten.

So erkennen Sie Fake-KI

Es gibt einige Indizien, die den Unternehmen helfen, echte KI von Software zu unterscheiden, die lediglich vorgibt, intelligent zu sein[7].

1. KI setzt Training voraus

Eine selbstlernende Künstliche Intelligenz lernt aus Erfahrung und verbessert ihre Entscheidungsregeln fortwährend. Sie braucht dazu jede Menge Trainingsdaten und Zeit, ehe sie einen Vorteil verschafft. Selbst eine KI-as-a-Service ist ohne eine kurze Lehrzeit nicht denkbar. Hinzu kommt: Anders als bei einer regelbasierten Software lassen sich auch die Resultate ihrer Rechenvorgänge nicht exakt voraussagen.

Fake Alarm: Wenn Ihnen eine Software angeboten wird, die trotz komplexer Aufgabenstellung angeblich keine oder kaum Trainingszeiten benötigt und problemlos auch bei anderen Anwendungsfällen einsetzbar sei, sollte Sie das stutzig machen. Dahinter steckt vermutlich mehr Marketing als KI.

2. KI ist nicht zu hundert Prozent erklärbar

Ist Künstliche Intelligenz im Einsatz, können Unternehmen in der Regel nicht mehr vollständig zurückverfolgen, auf welcher Basis und aufgrund welcher erkannten Muster die Software entscheidet. Weil das in regulierten Branchen wie dem Finanzwesen

und in allen Fragen, die die Compliance des Unternehmens betreffen, ein Nachteil ist, kann man den inzwischen vielerorts mit „Explainable AI“ (XAI) ausgleichen. Sie liefert das „Warum“ und macht KI nachvollziehbar und interpretierbar. Mit der Normungsrroadmap Künstliche Intelligenz[8] gibt es zum Beispiel in Deutschland eine umfassende Analyse des Bestands und des Bedarfs an internationalen Normen und Standards für diese Schlüsseltechnologie. Technische Standards sorgen nicht nur für Transparenz, sondern sollen zudem das ethische Verhalten von Maschinen[9], die von einer KI gesteuert werden, sicherstellen. Handelt es sich jedoch um Aufgabenstellungen, die außerhalb von regulierten Märkten liegen, sollte man abwägen, ob man die KI wirklich limitieren sollte: Denn die Pflicht zur Erklärbarkeit grenzt die Lösungswege der Algorithmen ein.

Fake Alarm: Verspricht Ihnen ein Software-Anbieter, dass seine KI-Lösung transparent und vollständig nachvollziehbar arbeitet, sollte dies Ihr Misstrauen wecken.

3. KI profitiert von der Cloud

Die Cloud ist keine notwendige Voraussetzung für Künstliche Intelligenz. Auf dem iPhone beispielsweise funktioniert die Bilderkennung direkt auf dem Gerät und nimmt keinen Umweg über die Cloud. Normalerweise allerdings verfügen die wenigsten Unternehmen über so hoch performante Kapazitäten, um KI zu entwickeln, umzusetzen und zu betreiben. Daher bieten sich bedarfsgerechte Ressourcen aus der Public Cloud an.

Dennoch ist die Cloud mit ihrer Skalierbarkeit für alle AI-Anwendungen ausgesprochen interessant. Mehr noch: Der Einsatz von KI ist vermutlich das beste Argument für die Cloudnutzung überhaupt. Die Cloud punktet hier in besonderem Maße mit ihrer Geschwindigkeit, ihrem Preis und der Innovationsfrequenz. Die Trainingszeit der KI-Modelle beansprucht sehr viel Rechenzeit. Um Zeit und Kosten zu sparen, sollten Unternehmen hier unbedingt auf die Cloud setzen. In der Cloud haben sie überdies die Gewissheit, dass ihnen jederzeit die richtigen Techniken, virtuellen Maschinen und Prozessoren für den Use Case AI zur Verfügung stehen. Die Fertigungsindustrie nutzt inzwischen auch hybride Lösungen und kombiniert Edge- und Cloud-Computing, um die Daten ganzer Anlagen und Industrieprozesse zu erfassen, zu verarbeiten und zu visualisieren. Damit profitieren Unternehmen von den Kostenvorteilen und der Geschwindigkeit und sind selbst bei Netzausfällen auf der sicheren Seite.

Fake Alarm: Wenn es bei einem KI-System keinen offensichtlichen Grund gibt, der gegen die Cloudnutzung spricht, und der Anbieter dennoch keine Cloudoption anbietet, sollte das potenzielle Kunden argwöhnisch machen. Denn das KI-Training


schluckt viel Performance und könnte die Prozesse der übrigen Unternehmensbereiche verlangsamen, wenn die Lernphase über die eigenen Server abläuft.

Ein seriöser Anbieter von echter KI wird Ihnen immer erklären können und wollen, wie die Modelle, die hinter seiner Anwendung stehen, funktionieren. Warum er Künstliche Intelligenz verwendet, wieso KI für Ihren Anwendungsfall die richtige Technologie ist und an welchen Stellen er sie mit regelbasierter Software kombiniert. Haben Sie keine Daten- oder KI-Spezialisten in den eigenen Reihen, sollten Sie den Fähigkeiten eines Beratungsunternehmens vertrauen. Nur so können Sie sicher sein, dass Sie KI bekommen, wenn Sie für KI zahlen.

Referenzen: [1] <https://www.heise.de/news/Utah-Pruefer-finden-keine-KI-bei-KI-Ueberwachungs-firma-Banjo-6009371.html> [2] <https://thespinoff.co.nz/society/13-01-2020/rip-zach-probe-finds-serious-wrongdoing-over-miracle-medical-ai/> [3] https://www.digitalisierungsindex.de/wp-content/uploads/2020/12/Telekom_Digitalisierungsindex_2020_GESAMTBERICHT.pdf [4] <https://www.de.digital/DIGITAL/Navigation/DE/Lagebild/Kuenstliche-Intelligenz/kuenstliche-intelligenz.html#:~:text=Mit%20Weltmarktneuheiten%20im%20Bereich%20der,von%207%2C6%20Milliarden%20Euro> [5] <https://www.mckinsey.de/news/presse/2019-02-11-ai-in-europe-l-mgi> [6] <https://www.t-systems.com/de/de/whitepaper-download/ki-im-unternehmen-verstehen-133726> [7] <https://www.youtube.com/watch?v=cvqCyGedZcY> [8] <https://www.din.de/resource/blob/772438/6b5a-c6680543eff9fe372603514be3e6/normungsrroadmap-ki-data.pdf> [9] <https://www.din.de/resource/blob/754724/00dcbecc21399e13872b2b6120369e74/whitepaper-ki-ethtikaspekte-data.pdf> [10] <http://dip21.bundestag.de/dip21/btd/19/156/1915657.pdf>

Torsten Deutsch

Torsten Deutsch ist seit 2018 als Product Manager im Bereich Open Telekom Cloud bei T-Systems beschäftigt. Dort verantwortet er seit 2020 als Product Owner das Thema Big Data & KI. Er ist unter anderem für den KI-Entwicklungsservice ModelArts und die dafür notwendige Infrastruktur zuständig.



Ralf Hülsmann

Ralf Hülsmann ist ausgewiesener IT- und KI-Experte. Im Strategy & CTO-Office im Bereich Public Cloud Managed Services von T-Systems liegt sein Fokus auf dem Einsatz von KI in der Cloud. Seit 2010 befasst er sich als Enterprise Architect zudem mit den Themen Cloudportfolio, Partnering und Strategy.



Die Wirtschaftlichkeit Künstlicher Intelligenz

Alexis Fournier

Dataiku

Wie Datenprojekte vom Kostenblock zum Umsatzgenerator werden

Es ist unstrittig, dass Daten und deren strategische Nutzung in Zukunft noch stärker als bisher über den Erfolg oder Misserfolg von Unternehmen entscheiden werden. So ermittelte Accenture in seiner Studie „AI Built to Scale“ von November 2019, dass drei von vier Entscheidern auf C-Level davon überzeugt sind, dass die Unternehmensexistenz auf dem Spiel steht, wenn sie in den kommenden fünf Jahren Künstliche Intelligenz (KI) nicht in ihrem Unternehmen skalieren. Doch wie lässt sich KI wirtschaftlich nutzen und skalieren? Einzelne, besonders vielversprechende Projekte zeigen unter Umständen schnell Wirkung und erzielen signifikante Einsparungen oder Umsatzerhöhungen. Doch wie sieht das bei nachfolgenden Projekten aus? Wie vermeidet man, dass Kosten überproportional wachsen?

Kosten von KI

Um diese Fragen zu beantworten, gilt es zunächst, die Kosten unternehmensweiter KI insgesamt zu betrachten. Auf den ersten Blick fallen greifbare Kosten für die Anschaffung von Werkzeugen oder Technologie ins Auge. Sie sind eindeutig zuzuordnen und lassen sich entsprechend skalieren. Deutlich schwieriger wird die Beurteilung indirekter Kosten. Sie summieren sich in vielen Fällen über die Zeit auf, behindern die Skalierung der Projekte und verhindern, dass wirklich Gewinn aus KI-Projekten gezogen werden kann. Die größten Kosten verursachen dabei sechs Bereiche:

1. Datenbereinigung und -vorbereitung

Eine Umfrage von Dataiku 2019 zur Data Maturity ergab, dass 43 Prozent der Teilnehmenden die Datenbereinigung und -vorbereitung als den „schwierigsten oder zeitraubendsten Teil von Datenprozessen in ihrem Unternehmen“ betrachten. Die größte Herausforderung dabei ist, dass diese umfangreiche Aufgabe bei jedem Projekt aufs Neue viel Zeit in Anspruch nimmt und sorgfältig erledigt werden muss. Die Qualität der Daten entscheidet schließlich über die Qualität des gesamten KI-Projekts. Schlechte Daten führen zu unzureichenden Mo-

dellen und damit zu falschen Schlussfolgerungen. Sinnvoll ist hier einzig die effizientere, nachhaltigere Bereinigung der Daten. Es gilt Systeme zu implementieren, die einmal aufbereitete Daten für zahlreiche KI-Anwendungen zugänglich und nutzbar machen.

2. Operationalisierung von KI und Überführung in die Produktivität

Der Prozess der Operationalisierung besteht aus mehreren Arbeitsabläufen: Einige interne Abläufe entsprechen der Produktion, während sich einige externe oder referentielle Abläufe auf bestimmte Umgebungen beziehen. Darüber hinaus umfassen Data Science Projekte nicht nur Code, sondern auch Daten (einschließlich Code für Datentransformation, Konfiguration und Schema für Daten, öffentliche referentielle Daten und interne referentielle Daten). Um den zuverlässigen Transport von Code und Daten von einer Umgebung zur nächsten zu unterstützen, müssen sie daher zusammen verpackt werden. Diese Arbeitsschritte sind sehr komplex und ohne konsistente Vorgaben benötigen sie sehr viel Zeit. Dataiku befragte mehr als 200 IT-Experten, wie lange es im Durchschnitt dauert, die erste Version eines Machine Learning-Modells in die Produktion zu überführen. Mehr als die Hälfte von ihnen nannte eine Zeitspanne von drei bis sechs Monaten. Berücksichtigt man dabei, dass nicht nur die Zeit Geld kostet, sondern auch keine Umsatzsteigerungen oder Kosteneinsparungen durch das Modell erzielt werden, entstehen enorm hohe Gesamtkosten.

3. Einstellung und Bindung von Data Scientists

Data Scientists sind von Natur aus neugierig und möchten mit ihrer Arbeit einen sichtbaren Mehrwert erreichen. Beschränken sich ihre Aufgaben jedoch darauf, wiederkehrend in einer Sandbox-Umgebung zu entwickeln und Daten zu bereinigen, ohne jemals den Erfolg der eigenen Modelle zu erleben, verlieren sie schnell die Lust und suchen sich einen anderen Job. Das Unternehmen trägt anschließend die Kosten für die hohe

Fluktuation. Um diese zu sparen, erfordert es die entsprechenden Werkzeuge, um aus schon umgesetzten Projekten Nutzen zu ziehen und geleistete Arbeit wiederzuverwenden.

4. Cloud-Kosten und ROI

Um Datenprojekte unternehmensweit zu skalieren, erfordert es eine zeitgemäße Strategie in Hinblick auf die IT-Infrastruktur. Elastizität wird in 2020 das Schlagwort des Jahres sein. Auch wenn die Cloud kontinuierlich an Popularität gewinnt, setzen die meisten Unternehmen auf eine hybride Infrastruktur. Darüber legen sie eine KI-Plattform, die unabhängig davon, wo die Daten gespeichert und bearbeitet werden, eine durchgängige Benutzerfreundlichkeit erlaubt. Anfang 2019 berichtete the information, dass zahlreiche Unternehmen von ihren steigenden Cloud-Kosten überrascht wurden. Es gilt also, eine Cloud-Strategie zu erarbeiten, die den KI-Projekten angepasst ist. Ansonsten werden die Unternehmen einen harten Kampf um einen positiven ROI in KI-Projekten führen und eine Rechnung begleichen müssen, die nicht durch die finanziellen Gewinne oder Einsparungen aus den Projekten selbst ausgeglichen wird.

5. Modell-Pflege

Anders als in der Software-Entwicklung lassen sich Machine Learning Modelle nicht auf einen Stand „einfrieren“. Daten ändern sich und damit müssen auch die Modelle kontinuierlich angepasst werden. Die Wartung und Pflege der KI-Projekte darf keinesfalls außer Acht gelassen werden. Nicht aktualisierte Modelle schaden unter Umständen mehr, als sie nutzen. Gerade bei einer wachsenden Zahl von KI-Anwendungen in Unternehmen steigen die Kosten rasant. Um dies zu vermeiden, entstand MLOps, das die Wartung der Modelle zu einer zentralen, systematisierten Aufgabe macht. Zusammen mit den Modellen gilt es auch, die darunterliegende Infrastruktur kontinuierlich zu warten. Wenn sich diese häufig verändert, kann das schnell zu hohen Kosten führen.

6. Komplexe Technologie-Stacks

Neben der Infrastruktur ändern sich auch die Technologien, die im KI-Umfeld genutzt werden, in Lichtgeschwindigkeit. Häufige Wechsel kosten aber nicht nur Zeit, sondern Geld. Auch die Nutzung unterschiedlicher Technologien abhängig von der Geschäftseinheit oder der geographischen Lage der verschiedenen Teams wird teuer. Es ist entscheidend, dass Unternehmen ein großes Bild ihrer Technologien zeichnen, um die Wiederverwendung und das Teilen von Erkenntnissen unternehmensweit zu ermöglichen.

Kapitalisierung und Wiederverwendung

Unser allgemeiner Menschenverstand sagt uns, dass es keinen Sinn macht, jedes Projekt von Null zu starten. Und das ist das Geheimnis, wie man Kosten deutlich reduziert, die in Zusammenhang mit der Datenbereinigung, deren Vorbereitung und Operationalisierung sowie der Wartung der Modelle und sogar für die Personalentwicklung entstehen.

Das einfache Konzept, um KI-Projekte effizienter zu machen und doppelte Arbeiten zu vermeiden, liegt in der Wiederverwendung vorhandener Leistungen. Ganz gleich, ob es sich dabei um Details wie die Wiederverwendung von Code

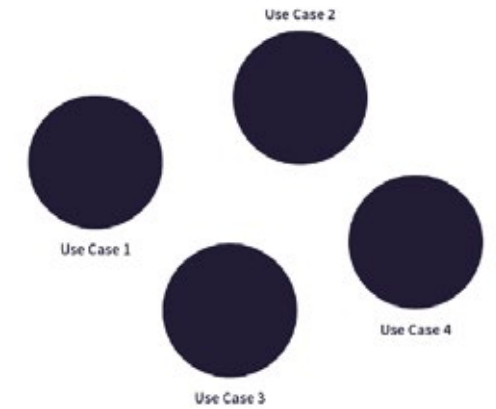


Abbildung 1




Abbildung 2

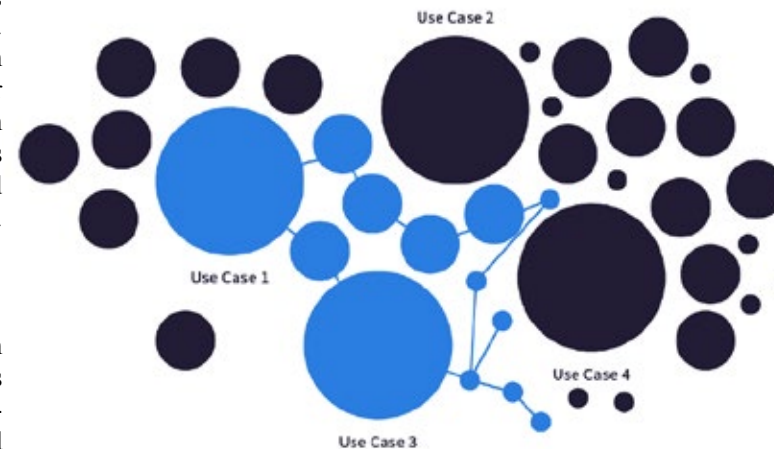


Abbildung 3

Snippits handelt, um die Datenvorbereitung zu beschleunigen, oder ob es auf Makro-Ebene vermieden wird, dass zwei Data Scientists unterschiedlicher Bereiche am gleichen Projekt arbeiten. Kapitalisierung in Hinblick auf Künstliche Intelligenz bringt die Wiederverwendung auf eine neue Ebene: Die initialen Kosten eines KI-Projektes werden über viele weitere verteilt (meist handelt es sich dabei um Kosten, die entstehen, um Daten zu finden, zu bereinigen und vorzubereiten) oder in anderen Worten, man erhält mehrere Anwendungen zum Preis eines Projektes. Je mehr Anwendungsfälle beim Aufsetzen einer unternehmensweiten KI-Initiative berücksichtigt werden, desto höher wird die Kapitalisierung.

Illustration x zeigt, dass zunächst vier zentrale Anwendungen definiert werden. In deren Umfeld entstehen viele kleine Anwendungsfälle, die Teile der großen Projekte wiederverwenden können. Der Mehrwert von Data Science im Unternehmen steigt damit ebenso wie die Zufriedenheit der Data Scientists und der Fachabteilungen. Gleichzeitig sinken die Kosten pro Projekt. Insgesamt tauchen bei einem solchen Vorgehen häufig – bislang unerkannte – Anwendungsmöglichkeiten auf, die deutlich wertvoller sind, als zunächst angenommen. Sie stammen oft von Fachabteilungen oder Analysten, die – im Rahmen der Demokratisierung von KI und Self-Service Dateninitiativen – Daten ebenfalls im Sinne einer Wertsteigerung einsetzen.

Das Prinzip der Wiederverwendung klingt einfach, in der Praxis erfordert es aber unternehmensweite, zentralisierte Prozesse. Nur darüber können:

- Anwender einfach auf alle Informationen zugreifen.
- Anwender vorhandene Teile von anderen schnell nutzen.
- Datenexperten das gesamte Spektrum an Datenprojekten unternehmensweit beobachten und kapitalisieren.
- Datenexperten einfach neue Projekte erstellen und teilen.
- Anwender – ob Programmierer oder nicht – im eigenen Stil effizient arbeiten.
- Führungskräfte im Datenbereich die Qualität von KI-Projekten und die gewinnbringende Nutzung von KI gewährleisten.

Für viele Unternehmen erscheint die Liste unter Umständen bedrohlich – dieses Maß an Transparenz sind sie nicht gewohnt. Manche Industrien werden auch durch Regularien in der Transparenz eingeschränkt. Aber je höher die Transparenz, desto höher ist die Kapitalisierung und der Gewinn unternehmensweiter KI.

Alexis Fournier

Alexis Fournier ist Direktor KI-Strategie bei Dataiku. Seine Karriere begann er als Data Scientist, wechselte anschließend in die internationale Wirtschaftsforschung und von dort zu SAP. Heute unterstützt er Unternehmen darin, den Wert von KI zu erkennen und KI unternehmensweit umzusetzen.



Data Science, Machine Learning und KI-Plattformen ermöglichen unternehmensweite KI in vielfältiger Weise. Eine übergreifende Anwendungsebene ermöglicht es Data Scientists ebenso wie Daten-Analysten in Fachabteilungen, unternehmensweite KI vollumfänglich und effizient zu nutzen.

Kosten für	Reduziert mit unternehmensweiten Plattformen durch
Datenbereinigung und -vorbereitung	Wiederverwendung von bereinigten und vorbereiteten Daten über Projekte hinweg sowie zwischen Personas
Operationalisierung und Live-Betrieb	Wiederverwendung von Design zur Produktion (ohne Neuprogrammierung von Modellen)
Anwerbung und Bindung von Data Scientists	Die Nutzung bestehender Elemente, ermöglicht es Data Scientists, sich auf anspruchsvollere Tätigkeiten zu fokussieren, die interessanter für sie sind.
Modell-Wartung und -Pflege	Automatisierte Szenarien, Überwachung und Wiederverwendung von Infrastruktur über Technologie-Stacks hinweg.
Komplexe Technologie-Stacks	Freiheit zur Wiederverwendung auch bei Technologiewechsel, da die Plattformen eine Abstraktionsebene bieten, die sie von der darunterliegenden Technologie unabhängig macht.

Fazit

Um Künstliche Intelligenz unternehmensweit in Unternehmen gewinnbringend einzusetzen, erfordert es neben der richtigen Technologie ein funktionierendes Zusammenspiel zwischen Menschen und Prozessen. Unternehmen, die das Prinzip der Wiederverwendung erfolgreich praktizieren, haben in der Regel mit einem starken Data Science-Kompetenzzentrum gestartet. Beste Beispiele dazu liefern Unternehmen wie GE Aviation oder Pfizer. Die beiden Konzerne haben in Kompetenzzentren Best Practices ausgearbeitet und sichergestellt, dass Menschen über die gesamte Organisation hinweg – unabhängig davon, ob es Data Scientists, Analysten oder Fachanwender sind – ihrem Weg folgen: GE Aviation kombinierte Technologie mit umfangreichem Training und einer Gamification von KI. Pfizers Erfolg liegt darin, transparente und erklärbare Prozesse zu schaffen, die eine unternehmensweite Zusammenarbeit im Bereich Data Science etabliert. Am Ende müssen Unternehmen die Balance finden zwischen Training, Projekten und Werkzeugen, um ein Maximum an Wiederverwendbarkeit und Zusammenarbeit zu ermöglichen. Damit gelingt es, KI wirtschaftlich umzusetzen.

Foto: Privat

KI aus Sicht von Ärzten, Anwälten und Politikern

Clara Krabatsch¹, Jens Nachtwei²

¹Toll Collect GmbH, ²HUB, HAM, IQP

Kollegin Künstliche Intelligenz

Heutzutage prägen Schlagworte wie Digitalisierung (Meyer et al., 2020), Industrie 4.0 (Krzywdzinski et al., 2015), Künstliche Intelligenz (McKendrick, 2019) oder auch Automation und Robotik (Malik et al., 2019) die mediale Landschaft. Betrachtet man diese Begriffe etwas genauer, ist die Digitalisierung per se schon ein vertrauter Wegbegleiter. Anders hingegen die Künstliche Intelligenz (KI), welche mit den weitreichenden Möglichkeiten zur Automation beruflicher Tätigkeiten immer noch mit Unsicherheiten und Unwissenheit verbunden ist.

Doch die Einsatzgebiete für KI – ob als reine Software oder als nächste Evolutionsstufe für Roboter – wachsen in rasantem Tempo und verändern die Arbeitswelt und Wirtschaftsprozesse, wie sie bislang bestanden (Prettnner et al., 2018; Flemming et al., 2019). Daraus resultieren starke Unsicherheiten der wirtschaftlichen Akteure. Denn bis dato können keine eindeutigen Aussagen getroffen werden, welche Qualifikationen zukünftig erforderlich sein werden, welche Jobs in welchem Maße tatsächlich ersetzt werden und wie hoch die Akzeptanz der Belegschaft sein wird.

Gespalten in zwei Lager der überzeugten Hoffnungsträger und zweifelnden Skeptiker werden bei der Einführung von KI zur Automation beruflicher Tätigkeiten zahlreiche Vor- und Nachteile diskutiert. So stehen die Chancen von Arbeitsentlastung, besseren Prozessen und gesenkten Kosten (Servoz, 2019; Frank et al., 2019;

Hamann & Wagner, 2015) den Ängsten vor technologiebedingter Arbeitslosigkeit und steigender sozialer Ungleichheit (McClure, 2018; Schuppisser, 2019) gegenüber. Weitere Perspektiven werfen Fragen über den ethischen Handlungsrahmen bzw. Grenzen und Regeln zum Einsatz von KI auf (Tschopp & Ruef, 2019).

KI aus Sicht zukünftig Betroffener

Die bisherigen Debatten waren fruchtbar, jedoch fehlt oft die empirische Basis für Argumente pro und contra KI. Daher verfolgten wir einen empirischen Zugang, um einen Beitrag aus Sicht der Wirtschaftspsychologie zu leisten.

Die hier dargestellte Interviewstudie verfolgte das Ziel, die wichtigsten Aspekte der Zukunftsaussichten von KI in der Arbeitswelt zu beschreiben – und zwar aus Sicht von hochqualifizierten Führungskräften mit sehr hohem Arbeitspensum, da diese Zielgruppe eine bislang unbeachtete Perspektive bot. Wir haben uns für ein leitfadengestütztes Telefoninterview zur Erhebung der Daten entschieden. Die Fragestellung sowie der Interviewleitfaden wurden theoriebasiert sowie aus Vorarbeiten des Forschungsprojekts deepR (Digital Era Evidence-based Psychological Research) hergeleitet. Der Leitfaden enthielt insgesamt 31 Fragen: Bspw. (1) Hatten Sie schon Berührungspunkte mit KI in Ihrem Berufsalltag? (2) Welche Aufgaben hat eine KI bereits

in Ihrem Berufsalltag automatisiert? (3) Würden Sie gern mit einer KI zusammenarbeiten? (4) Können Sie einige Chancen von KI-bedingter Automation nennen? (5) Können Sie einige Risiken von KI im beruflichen Alltag nennen? (6) Welchen Zeithorizont sehen Sie bis zum Eintritt der von Ihnen genannten Chancen von KI?

Die während des Interviews notierten Antworten der Studienteilnehmer bildeten die Datenbasis für die Auswertung. Anschließend wurde eine qualitative Inhaltsanalyse orientiert nach Mayring (2010) durchgeführt.

Interviewstudie zu KI im Berufsalltag

In der Studie wurden insgesamt 16 sogenannte Domänen-Experten mit Hochschulabschluss aus den Arbeitsbereichen Medizin (5 Personen), Rechtswesen (6 Personen) und Politik (5 Personen) interviewt. Die Vertreter der Stichprobe waren durchschnittlich 55,4 Jahre alt, verfügten über im Mittel 26 Jahre Berufserfahrung und leiteten durchschnittlich 16 Mitarbeiter. Ihre mittlere Arbeitszeit betrug 61 Stunden in der Woche. Insgesamt 15 der 16 befragten Experten gaben an, bereits vom Einsatz einer KI in ihrer Branche gehört zu haben. 7 Teilnehmer hatten zudem eigene Berührungspunkte mit KI im beruflichen Alltag. Diese gaben an, im Durchschnitt 3,6 Mal pro Woche mit einer KI in Kontakt zu kommen. 5 Teilnehmer bemerkten eine spürbare Veränderung ihres Berufsalltags durch KI.

Als bereits durch KI automatisierte Tätigkeiten wurden Übersetzungen, Sortierung/Analyse von Informationen sowie das Erstellen von Dokumenten/Texten genannt. Die Befragten gaben alle an, Potenzial in ihrem beruflichen Alltag in der Automatisierung von Tätigkeiten durch eine KI zu sehen. Sie schätzten ein, dass in 7,9 Jahren (Mittelwert) ein flächendeckender Einsatz von KI in ihrer Branche zu erwarten sei.

Mit Blick auf die Akzeptanz von KI im Berufsalltag gaben 15 der 16 Befragten an, grundsätzlich für den Einsatz von KI in ihrer Branche zu sein. 14 Interviewteilnehmer gaben an, gern mit einer KI zusammenzuarbeiten, während 2 eine neutrale Einstellung nannten. Außerdem schätzten 15 Befragte die Haltung ihrer Mitarbeiter als positiv ein. Auf die Frage nach eigenen Gefühlen, wenn man an den Einsatz einer KI im persönlichen Berufsalltag denkt, konnten positive, als auch negative Gefühle dokumentiert werden. Hierzu zählten Erleichterung, Neugier, Freude und Faszination sowie Skepsis, Vorsicht, Druckgefühle und Angst.

Bei der Untersuchung der Chancen von KI nannten 13 Befragte, dass sie eine deutliche Arbeitsentlastung durch KI-bedingte Automation in ihrem persönlichen Berufsalltag sehen, 14 Interviewte auch für ihre Mitarbeiter. Alle Interviewteilnehmer nannten eine merkliche oder erwartete Effizienzsteigerung im Berufsalltag. Allerdings konnte sich dennoch keiner der Interviewten vorstellen, dass sich das eigene Arbeitspensum durch den Einsatz einer KI verringern würde.

Auch die identifizierten Risiken zeigten Handlungsfelder und Herausforderungen auf. 13 der befragten Führungskräfte waren der Meinung, dass keine Stelle in ihrem Team vollständig durch eine KI ersetzbar wäre. Angemerkt wurde jedoch auch die Notwendigkeit einer Veränderung oder Umstrukturierung der Aufgaben zum Erhalt von Stellen. Lediglich ein Befragter hielt den Wegfall seiner eigenen Stelle für möglich.

KI als Heilsbringer oder Gefahr?

Mittels der hier dargestellten Studie konnten zahlreiche Ergebnisse früherer Forschung zum Einsatz (vgl. z.B. Hacker, 2016) sowie zu Vorteilen (u.a. Gansser 2019; Deloitte, 2020; Ernst et al., 2019) von KI im Berufsalltag bestätigt werden. Im Vordergrund standen hierbei deutliche Effizienzgewinne, Arbeits erleichterung, Leistungen über menschlichen Grenzen hinweg sowie Kostenersparnisse. Interessanterweise konnte sich trotz des erwarteten Freiwerdens von zeitlichen Ressourcen durch KI-Unterstützung keiner der Befragten eine Senkung des Arbeitspensums vorstellen. Die Grundhaltung gegenüber KI sowie KI-bedingter Automation war deutlich positiv. Gleiches gilt für wissenschaftliche Untersuchungen im Bereich der Risiken und Herausforderungen - auch hier konnten Parallelen zu bestehenden Erkenntnissen der Forschung (vgl. Choi & Kang, 2019; Peters et al., 2019; Chomanski, 2019) gezogen werden. Die erkannten Risiken müssten ernst genommen und frühzeitig thematisiert werden. Besonders besorgniserregend empfanden die Befragten ein mögliches Verlernen der Ausführung der eigenen Tätigkeit, eine Verselbstständigung der Technik, Themen der Datensicherheit oder auch Missbrauchspotenziale.

N=16	Chancen	Häufigkeit (Mehrfachnennung möglich)
	Effizienzgewinne	20
	Arbeits erleichterung	15
	Verbesserte Arbeitsleistung	10
	Arbeitsleistung über menschliche Grenze	7
	Mehr Zeit für anderes	6
	Kostenersparnisse	6
	Übernahme von Routinetätigkeiten	5
	Objektivität	4
	Zuverlässigkeit	4
	Übernahme lästiger Tätigkeiten	3
	Wettbewerbsvorteile	2
	Gesteigerte Mitarbeiterzufriedenheit	1
	Aktualität durch Selbstlernen	1
	Verbessertes Marketing	1
	Gesteigerte Mitarbeitermotivation	1
	Gesamt	86

Abb. 1: Chancen von KI im Berufsalltag aus Sicht von 16 interviewten Domänen-Experten aus Medizin, Rechtswesen und Politik

N=16	Risiken	Häufigkeit (Mehrfachnennung möglich)
	Verlernen der Ausführung	7
	Verselbstständigung	6
	Missbrauchspotenzial	6
	Mangelnde Nachvollziehbarkeit	5
	Abhängigkeit von Rahmenbedingungen	4
	Datensicherheit	4
	Ethische Fragestellungen	4
	Mangelnde menschliche Eigenschaften	4
	Fehler im technischen System	4
	Stellenstreichungen	4
	Soziale Ungerechtigkeit	3
	Mangelnde Zuverlässigkeit	3
	Mangelnde Individualität	3
	Auswahl der Möglichkeiten	3
	Militärische Zwecke	3
	Maschine als Konkurrenz	2
	Blindes Vertrauen	2
	Burnout Gefahr	2
	Fehler in den Daten	2
	Aufwand Datenbeschaffung	1
	Blockade Deutsche Mentalität	1
	Aktivität gegen Menschen	1
	Wettbewerbsdruck	1
	Schaffung von Regeln, Normen, Standards	1
	Neue Definition Arbeitsleistung notwendig	1
	Gesamt	77

Abb. 2: Risiken von KI im Berufsalltag aus Sicht von 16 interviewten Domänen-Experten aus Medizin, Rechtswesen und Politik

Herausforderung KI für Führungskräfte

Breite Einsatzmöglichkeiten von KI-bedingter Automation werden aktuell vordergründig in den Bereichen Wissensmanagement, Übersetzungen sowie der Erstellung von Schriftstücken gesehen. Führungskräfte werden durch die Einführung von KI in der Arbeitswelt vor neuen Herausforderungen stehen, wobei die erfolgreiche Einführung maßgeblich von ihrem Verhalten sowie der entsprechenden Akzeptanz der Mitarbeiter abhängt. Die hier befragten Experten sehen es als Führungsaufgabe an, die Mitarbeiter im Umgang mit KI zu befähigen, zu motivieren sowie Ängste und Hürden zu thematisieren.

Von Politik und Wirtschaft hingegen wird erwartet, einen umfassenden Rahmen aus Regeln und Normen zu schaffen, um

langfristig einen flächendeckenden und vertrauensvollen Einsatz in Wirtschaft und Verwaltung zu ermöglichen. Unklar ist, wann die Chancen und Risiken in der Arbeitswelt prominent werden – dass die „Kollegin KI“ einen Unterschied machen wird, ist hingegen unbestritten. Es liegt an uns, den Umgang mit ihr zu gestalten und die Arbeitswelt menschenwürdig zu erhalten.

Referenzen: Choi, D. Y., & Kang, J. H. (2019). Introduction: The Future of Jobs in an Increasingly Autonomous Economy. *Journal of Management Inquiry*, 28(3), 298–299. <https://doi.org/10.1177/1056492619827373>
 Chomanski, B. (2019). Massive Technological Unemployment Without Redistribution: A Case for Cautious Optimism. *Science and Engineering Ethics*, 25(5), 1389–1407. <https://doi.org/10.1007/s11948-018-0070-0>
 Deloitte. (2020). State of AI in the Enterprise—3rd Edition—Ergebnisse der Befragung von 200 AI-Experten zu Künstlicher Intelligenz in deutschen Unternehmen (S. 21) [Studienergebnisse]. Deloitte. <https://www2.deloitte.com/de/de/pages/technology-media-and-telecommunications/articles/ki-studie-2020.html>
 Ernst, E., Merola, R., & Samaan, D. (2019). Economics of Artificial Intelligence: Implications for the Future of Work. *IZA Journal of Labor Policy*, 9(1). <https://doi.org/10.2478/izajolp-2019-0004>
 Flemming, M., Clarke, W., Das, S., Phongthientham, P., & Reddy, P. (2019). The Future of Work: How New Technologies Are Transforming Tasks. IBM. <https://mitibm.watsonailab.mit.edu/wp-content/uploads/2019/10/The-Future-of-Work-How-New-Technologies-Are-Transforming-Tasks2.pdf>
 Frank, M. R., Autor, D., Bessen, J. E., Brynjolfsson, E., Cebrian, M., Deming, D. J., Feldman, M., Groh, M., Lobo, J., Moro, E., Wang, D., Youn, H., & Rahwan, I. (2019). Toward understanding the impact of artificial intelligence on labor. *Proceedings of the National Academy of Sciences*, 116(14), 6531–6539. <https://doi.org/10.1073/pnas.1900949116>
 Gansser, O. (2019). FOM Sommerumfrage 2019—Künstliche Intelligenz in Deutschland—Meinung und zukünftige Einschätzung [Studienergebnisse]. ifes Institut für Empirie & Statistik - FOM Hochschule für Ökonomie & Management. https://www.fom.de/uploads/forschungsprojekte/downloads/FOM_ifes_Sommerumfrage_2019.pdf
 Hacker, W. (2016). Vernetzte künstliche Intelligenz / Internet der Dinge am deregulierten Arbeitsmarkt: Psychische Arbeitsanforderungen. *Psychologie des Alltagshandelns*, Vol. 9(Nr. 2), 4–21. Hamann, C., & Wagner, L. (2015). Chancen und Risiken von Big Data. *Ökologisches Wirtschaften - Fachzeitschrift*, 30(3), 10. <https://doi.org/10.14512/OEW300310>
 Krzywdzinski, M., Jürgens, U., & Pfeiffer, S. (2015). Die vierte Revolution Wandel der Produktionsarbeit im Digitalisierungszeitalter. *WZB Mitteilungen*, Heft 149, 6–9.
 Malik, A. A., Schweisfurth, T., & Giones, F. (2019, November 7). Are „cobots“ the future of work? *World Economic Forum*. <https://www.weforum.org/agenda/2019/11/future-generation-robots-work-with/?linkId=100000008932675>
 Mayring, P. (2010). Qualitative Inhaltsanalyse. In G. Mey & K. Mruck (Hrsg.), *Handbuch Qualitative Forschung in der Psychologie* (S. 601–613). VS Verlag für Sozialwissenschaften. https://doi.org/10.1007/978-3-531-92052-8_42
 McClure, P. K. (2018). “You’re Fired,” Says the Robot: The Rise of Automation in the Workplace, Technophobes, and Fears of Unemployment. *Social Science Computer Review*, 36(2), 139–156. <https://doi.org/10.1177/0894439317698637>
 McKendrick, J. (2019, November 27). Artificial Intelligence Not Seen As A Job-Killer, Yet. *Forbes*. [https://www.forbes.com/sites/foemckendrick/2019/11/27/artificial-intelligence-not-seen-as-a-job-killer-yet/](https://www.forbes.com/cdn.ampproject.org/c/s/www.forbes.com/sites/foemckendrick/2019/11/27/artificial-intelligence-not-seen-as-a-job-killer-yet/)
 Meyer, U., Schaupp, S., & Seibt, D. (2020). Digitalization in Industry: Between Domination and Emancipation. Springer International Publishing AG. <https://public.ebookcentral.proquest.com/choice/publicfullrecord.aspx?p=5979078>
 Peters, M. A., Jandrić, P., & Hayes, S. (2019). The curious promise of educationalising technological unemployment: What can places of learning really do about the future of work? *Educational Philosophy and Theory*, 51(3), 242–254. <https://doi.org/10.1080/00131857.2018.1439376>
 Pretner, K., Geiger, N., & Schwarzer, J. A. (2018). Die Auswirkungen der Automatisierung auf Wachstum, Beschäftigung und Ungleichheit. *Perspektiven der Wirtschaftspolitik*, 19(2), 59–77. <https://doi.org/10.1515/pwp-2018-0017>
 Schuppisser, R. (2019, November 27). Jobverlust wegen Digitalisierung: Akademiker sind fünfmal so stark gefährdet wie Handwerker. *Tagblatt*. [https://www.tagblatt.ch/amp/leben/jobverlust-akademiker-sind-fuenfmal-so-stark-gefaehrdet-wie-arbeitnehmer-ohne-hoehere-bildung-ld.1172236](https://www.tagblatt.ch/cdn.ampproject.org/c/s/www.tagblatt.ch/amp/leben/jobverlust-akademiker-sind-fuenfmal-so-stark-gefaehrdet-wie-arbeitnehmer-ohne-hoehere-bildung-ld.1172236)
 Servoz, M. (2019). The Future of Work? Work of the Future! On how artificial intelligence, robotics and automation are transforming jobs and the economy in Europe. *European Commission*. <https://ec.europa.eu/digital-single-market/en/news/future-work-work-future>
 Tschopp, M., & Ruef, M. (2019). Artificial Intelligence—Is it worth the risk? [Titanium Trust Report]. https://www.researchgate.net/publication/336849066_Artificial_Intelligence_-_Is_it_worth_the_risk

Clara Krabatsch

Clara Krabatsch studierte Wirtschaftspsychologie an der Hochschule für angewandtes Management Berlin und untersuchte in ihrer Masterarbeit die Zukunftsaussichten von Künstlichen Intelligenzen in der Arbeitswelt.



Prof. Dr. Jens Nachtwei

Jens Nachtwei forscht seit 2006 an der HU Berlin zu Automation aus psychologischer Perspektive sowie personalpsychologischen Themen, lehrt seit 2012 an der Hochschule für angewandtes Management und leitet das universitäre Spin-off IQP.



Künstliche Intelligenz in Banken: Worauf es im aktuellen Marktumfeld ankommt

Cam-Duc Au, Dr. Andreas Hiese

Commerzbank AG

Der Einsatz von Künstlicher Intelligenz (KI) besitzt eine hohe Bedeutung für die zukünftige Wettbewerbsfähigkeit von Banken. Nicht umsonst betont Microsoft-CEO Satya Nadella, dass KI „eine der grundlegenden Technologien sein [wird], die Menschen jemals entwickelt haben“. Mit dem Sammelbegriff KI wird im Allgemeinen die Simulation der Vorgänge im menschlichen Gehirn sowie die Imitation des menschlichen Bewusstseins, Empathievermögens und Verhaltens durch ein intelligentes Computersystem beschrieben. In dem Zusammenhang fällt häufig auch der Begriff des Machine Learning (ML) bzw. des maschinellen Lernens. Darunter wird ein Teilgebiet der KI verstanden, das mittels Algorithmen Daten eigenständig analysiert, daraus lernt und auf Basis dessen neue Aussagen sowie Vorhersagen treffen kann. Das ML-Verfahren „trainiert“ somit anhand von großen Datenmengen und bedarf keiner programmierten Anweisung.

Mittlerweile haben sich vielfältige Anwendungsfälle ergeben, die bereits heute produktiv in verschiedenen Banken laufen. Zu den prominentesten Beispielen zählen unter anderem der Einsatz von KI in Chat- und Talkbots sowie in der Optimierung der Betrugs- und Geldwäscheprävention. Dabei handelt es sich um Beispiele für die sog. „weiche“ bzw. „schwache“ KI, die sich auf die Erledigung einzelner und konkreter Aufgabenstellungen konzentriert. Dem gegenüber steht die sog. „harte“ bzw. „starke“ KI, die über die Erledigung einzelner Aufgabengebiete hinausgehen soll. Allerdings wurde eine starke Form der KI, die der Intelligenz des Menschen ebenbürtig sein soll, bis heute noch nicht erreicht. Somit stehen die ersten

erfolgreichen Praxiseinsätze von KI und den damit einhergehenden Erfahrungen noch am Anfang eines langen Entwicklungswegs. Eine aktuelle nationale PwC-Studie konstatiert, dass lediglich 9% aller befragten Führungskräfte aus Banken und Versicherungen ihr Unternehmen sehr gut auf die Implementierung und Anwendung von KI vorbereitet sehen. Ferner sagt PwC voraus, dass das deutsche Bruttoinlandsprodukt bis 2030 durch den erfolgreichen Einsatz von KI um 11% steigen wird. Diese durch KI-Innovationen getriebene Entwicklung entspräche einer Summe von 430 Milliarden Euro. Auch wenn die Prognose auf Prä-Corona-Daten basiert, wird dennoch das grundsätzliche Potenzial in KI deutlich. Es lohnt sich daher für Banken, den Weg zur Weiterentwicklung und verstärkten Praxiseinführung von KI weiter zu beschreiten.

Die infolge der Corona-Pandemie herausfordernde Situation der Gesamtwirtschaft hebt die Bedeutung von KI weiter hervor. Mit Blick auf die steigende Nutzung des Online und Mobile Bankings sind schnelle und personalisierte Digitalprozesse und -services entscheidend im Kampf um den Kunden. Ein Beispiel dafür sind insbesondere die Reduzierungen manueller Arbeitsschritte in einem Prozess, die zu schnelleren Services und somit zu einem besseren Kundenerlebnis führen sollen. Zudem führt ein durch KI gesteigerter Automatisierungsgrad interner Prozesse zu wichtigen Kosteneinsparungen und Skaleneffekten. Allerdings können nicht alle vielversprechenden KI-Anwendungsfälle gleichzeitig umgesetzt werden. Somit kommt der Auswahl geeigneter Anwendungsfälle eine besondere Rolle zu. Eine entscheidende Bewertungskategorie bildet dabei die Auswertungsmöglichkeit von nutzbaren Daten.

Investitionen in Cloud-Technologie als Beschleuniger von KI

Banken weisen als vormalige Pioniere der elektronischen Datenverarbeitung eine seit den 1960er-Jahren heterogen gewachsene, umfangreiche Legacy-IT auf. Diese wird den Anforderungen moderner Technologien in vielen Teilen nicht gerecht, sodass die Modernisierung der Systemlandschaft eine besondere Herausforderung darstellt. Eine Analyse von Deloitte hat ergeben, dass 70% der untersuchten Unternehmen planen, KI-Anwendungen auf Basis von Cloud-Technologien einzuführen. Vor diesem Hintergrund lässt sich auch erklären, warum Banken nun stark in Cloud investieren. Die Nutzung der Cloud ermöglicht eine effiziente, das heißt schnelle und vergleichsweise kostengünstigere, Analyse von hohen Datenmengen. Dies erfolgt häufig medienwirksam in Form von strategischen Partnerschaften mit Tech-Unternehmen wie z.B. Amazon Web Services (AWS), Google Cloud Platform (GCP) oder Microsoft. Vorteil dieses kooperativen Ansatzes liegt in einer effizienten Modernisierung der IT-Landschaft und letzten Endes schnelleren Transformation des Gesamtunternehmens.

Ein Beispiel dafür ist die Partnerschaft der Commerzbank mit Microsoft und Google, die den strategischen Ansatz einer hybriden Multi-Cloud-Umgebung darstellt. Dr. Kerem Tomak, Commerzbank Bereichsvorstand „Big Data & Advanced Analytics“, betont bei diesem Ansatz, dass man dadurch „die Vorteile jedes Anbieters nutzen [kann]“. So kann die Commerzbank für die verschiedenen KI-Anwendungsfälle stets eine individuell geeignete Lösung finden. Der Multi-Cloud-Ansatz ist Teil der ausgerufenen „Cloud First“-Strategie. Cloud Services sollen nach Möglichkeit stets für die Entwicklung neuer technischer Anwendungen genutzt werden.

Weitere bekannte Cloud-Initiativen in der Finanzbranche werden im Folgenden in chronologischer Reihenfolge aufgelistet:

- **Standard Chartered Bank & Microsoft (seit 08/2020)** Im August dieses Jahres verkündete das Finanzunternehmen aus Großbritannien eine dreijährige strategische Partnerschaft mit Microsoft. Damit einher ging auch das Ausrufen einer „Cloud First“-Strategie. Die Strategie beinhaltet u.a., dass verschiedene essenzielle Bankbereiche bis 2025 komplett Cloud-basiert ablaufen sollen. Dazu zählen allen voran die Core- und Trading-Systeme der Bank.
- **Deutsche Bank & Google (seit 07/2020)** Im Juli verkündete die Deutsche Bank eine angestrebte Technologie-Kooperation mit Google, die mit dem Abschluss der Vertragsverhandlungen in einer langjährigen Zusammenarbeit münden soll. Zielvorstellung ist die Vereinfachung der IT-Architektur sowie die Entwicklung neuer technologiebasierter Finanzprodukte.
- **HSBC & AWS & Google (seit 07/2020)** Die britische HSBC Bank verfolgt eine Multi-Cloud-Strategie und kooperiert bereits mit Google und neuerdings nun auch seit Juli diesen Jahres mit AWS, um gemeinsam Innovationen voranzutreiben und Kunden einen effizienteren Service anzubieten. Der neue Partner AWS soll insbesondere mit seiner Analytics-Expertise für ein individuelleres Produktangebot am Kunden unterstützen.
- **Deutsche Börse & Google & Microsoft (09/2019)** Die Deutsche Börse arbeitet bereits mit Microsoft Azure und seit

Ende 2019 nun auch mit Google zusammen, um die Cloud-Integration voranzutreiben. Während die Nutzung von Azure das primäre Ziel hat, regulierte Arbeitsprozesse in die Cloud zu migrieren, soll sich Google vorrangig auf die Stärkung der Innovationsfähigkeit konzentrieren.

- **UBS & Microsoft (seit 08/2019)** Die Schweizer Bank verkündete im August 2019 die Zusammenarbeit mit Microsoft. Die Nutzung von Azure soll zu wichtigen Skaleneffekten führen, um die Wachstumsstrategie des Unternehmens sicher voranzutreiben.

Bedeutung und Bewertung von Daten nach dem „5V-Modell“

BigTechs wie Amazon, Facebook und Google gelten für viele als zukunftsorientierte Nutzer von Kundendaten. Sie schaffen stetig neue, auf Datenanalysen basierende Services und Produkte, die die Kundenerwartungen hinsichtlich der Digitalerfahrung prägen. Beispielsweise nutzt Amazon ML zur Prognose von Produktverkäufen, um eine möglichst schnelle Lieferung an den Kunden zu ermöglichen. Facebook wertet die Profildaten der Nutzer aus, um darauf aufbauend zielgerichtet Werbung zu schalten. Beide genannten Beispiele prägen die Digitalerfahrung der Nutzer. Dadurch werden ebenfalls die Kundenanforderungen an das Banking geprägt. Bankservices werden schneller, allgegenwärtiger und insgesamt digitaler erwartet. Einer aktuellen YouGov-Studie zufolge wird die größte Gruppe innerhalb der Bankkunden-Typologie neuerdings von den sog. „Digitalen Finanzexperten“ (21%) gebildet. Diese stellen eine Gruppe sachkundiger Kunden dar, die ein hohes Interesse an neuen Technologien aufweisen und die Internetnutzung als selbstverständlich ansehen. Dem gegenüber stehen unter anderem die „Traditionellen Finanzexperten“ (17%) und die „Argwöhnischen Offliner“ (15%). Es wird daher immer wettbewerbsentscheidender für eine Bank, Services am Puls des Digitalzeitalters anzubieten.

Banken befinden sich in einer stark regulierten Umgebung. Mit den im internationalen Vergleich eher strikten Datenschutzerfordernissen in Europa wird ein guter und wichtiger Beitrag im Sinne des Kunden geleistet. Die Forschung an KI kann jedoch bei gleichzeitiger Einhaltung umfangreicher Datenschutzrichtlinien sehr gut voranschreiten. Moderne Analysemethoden ermöglichen die Nutzung von Big Data, um wertvolle Erkenntnisse über die Kundschaft zu gewinnen. Gleichwohl sind Daten nicht gleich Daten, sondern es liegen oftmals komplexe und unstrukturierte Datenmengen vor.

Anhand des „5V-Modells“ soll veranschaulicht werden, worauf es bei der Bewertung von nutzbaren Daten für einen realisierbaren KI-Anwendungsfall ankommt:

1. Volume / Volumen

Für die erfolgreiche Implementierung von KI zählt unter anderem die Masse an verfügbaren und auswertbaren Daten. Daten können dabei aus verschiedenen Quellen stammen. Der Einbezug sämtlicher Datenquellen sowie die korrekte Erfassung und Speicherung der Daten erfordert eine moderne Infrastruktur. Wie bereits beschrieben, greifen bereits diverse

Banken auf das Cloud-Konzept zurück, um Big Data effektiv und effizient zugänglich zu machen. Sind die Daten weder in ausreichender Menge vorhanden noch repräsentativ genug, so können Modelle nicht adäquat trainiert werden. Die Folgen daraus reichen von unzufriedenen Kunden bis hin zu falschen Produktabsatzprognosen.

2. Validity / Validität

Neben der dargelegten Quantität ist auch eine ausreichende Datenvalidität bzw. -qualität entscheidend für die erfolgreiche KI-Implementierung. Daten müssen akkurat und frei von Verunreinigungen sein. Die Nutzung von fehlerhaften oder gar unvollständigen Datensätzen führen zu falschen Analyseergebnissen und können zu „sunk costs“ führen, da den Banken ein falsches Potenzial in einem KI-Anwendungsfall signalisiert werden würde. Die Folge wäre nicht nur ein fehlerhafter Business Case, sondern auch die Verschwendung limitierter Ressourcen.

3. Variety / Vielfalt

Mit unterschiedlichen Datenquellen gehen auch unterschiedliche Datenarten einher, z.B. schriftliche, visuelle und auditive Informationen. Im Bankenkontext können dies bspw. eingehende Kundenanrufe, Kontoumsätze im Online-Banking/in der App sowie die Einreichung von physischen Bonitätsunterlagen sein. Um verwertbare Muster und Interdependenzen zu erkennen, ist es nicht nur entscheidend, die verschiedenen Datenarten heranzuziehen, sondern darüber hinaus auch eine Kategorisierung dieser Daten vorzunehmen. Beispielsweise kann bei der Planung eines Kredit-Scorings die fehlende Auswertung von physischen Bonitätsunterlagen zu falschen Resultaten führen. Eine Auswertung, die ausschließlich die digitalen Kontoumsätze einbezieht, würde hierbei nicht das volle Ausmaß des Kreditrisikos darstellen.

4. Velocity / Geschwindigkeit

Korrekte und wertvolle Schlussfolgerungen können nur dann mithilfe von KI-Modellen abgeleitet werden, wenn die vorliegenden Daten auf dem neusten Stand gehalten und regelmäßig auf Aktualität geprüft werden. Das Mooresche Gesetz aus 1965 besagt, dass sich die Prozessorleistung für Computer alle zwei Jahre verdoppeln wird. Dies besitzt bis heute Gültigkeit und impliziert, dass die Geschwindigkeit der Datengenerierung und -verarbeitung stets exponentiell zugenommen hat. Kundenbedürfnisse, auch im Sinne der Nachfrage nach bestimmten Produkten und Services, können sich in der heutigen Zeit schnell ändern. Die technische Infrastruktur einer Bank muss daher up-to-date bleiben, um neue Daten möglichst zeitnah bzw. in real-time zu erfassen.

5. Value / Wert

Der übergeordnete Wert von Daten sowie die darin liegende Möglichkeit, den Unternehmenserfolg maßgeblich zu beeinflussen, soll mit dem letzten Punkt des 5V-Modells zum Ausdruck kommen. Das Generieren neuer Ertragsquellen sowie die Schaffung von Kosteneinsparungen haben viele Bankunternehmen bereits für sich erkannt. Daten gelten, bekanntermaßen und häufig zitiert, als das neue Gold bzw. Öl. Immerhin wird laut einer Statista-Prognose die jährlich generierte Datenmenge für das Jahr 2025 mit 175 Zettabytes bzw. 175 Milliarden Terabytes beziffert. Datenmengen zu beherrschen und für sich zu nutzen, stellt bereits heute ein Differenzierungsmerkmal im Wettbewerb dar.

Risiken im KI-Modell in Erwägung ziehen

Mit den richtig ausgewählten und aufbereiteten Daten kann das Training für das KI-Modell beginnen. Der Gedanke dahinter ist die Identifizierung bestimmter Muster in den eingespeisten Daten, die zur Lösung einer bestimmten Problemstellung führen soll. Ziel ist, den Algorithmus zu befähigen, auch bei bisher unbekanntem Daten zu einer sauberen Problemlösung zu kommen. Neben der bereits thematisierten Eignung von Daten, müssen Banken im Zuge dessen noch weitere Risiken im Hinblick auf die Performance eines KI-Modells beachten. Die BaFin geht in einer aktuellen Publikation davon aus, dass fehlerhafte KI-Resultate zwangsläufig auftreten werden. Schließlich wird die KI von Menschen geschaffen. Dabei betont sie, dass die Verantwortung stets bei den Menschen bleibe, da eine Maschine keinen adäquaten menschlichen Ersatz darstelle.

Im Folgenden werden zwei wesentliche Risiken bei der Implementierung von KI angeführt:

Unteranpassung

Wenn Trainingsdaten nicht die erforderliche Güte – wie im 5V-Modell gezeichnet – erfüllen, leidet die Performance an einer Unteranpassung („Underfitting“) des Modells. Es können keine Muster in den Trainingsdaten erkannt werden, um sinnvolle Rückschlüsse auf Basis neuer Daten zu treffen. Das abgeleitete Modell ist somit zu simpel bzw. zu einfach gestrickt. Ein komplexes Problem wird nicht durchdrungen. Ein Anwendungsbeispiel zum Thema Customer Churn Management zeigt den Bedarf nach vielfältigen Daten hinsichtlich bestehender Bankprodukte, der Girokontonutzung oder des Auslaufens bestimmter Produkte (z.B. auslaufende Baufinanzierung, fällige Geldanlage) auf. Das bloße Hinzuziehen von Daten mit Bezug auf gelöschte Kontoverbindungen oder die Nutzung von Produkten in der Vergangenheit wären in

diesem Fall nicht ausreichend. So können insbesondere Daten zum Nutzungsverhalten im Mobile oder Online Banking eine wertvolle Ergänzung sein.

Darüber hinaus kann eine Unteranpassung auch zu einem Bias führen. Werden nicht ausreichend relevante Daten für ein KI-Modell herangezogen, können beispielsweise ganze Kundengruppen zu Unrecht von Bankangeboten ausgeschlossen werden. Ein Beispiel für das Vorliegen eines Bias wäre im Kreditkontext in Form einer Benachteiligung von Kunden mit mittlerer Bonität denkbar. So würden diese keine Kreditzusage erhalten, wenn das Training der KI-Anwendung lediglich auf Kundendaten mit einer sehr guten Bonität basiert war. Die Folgen wären Kundenunzufriedenheit und verpasste Geschäftsmöglichkeiten.

Überanpassung

Eine weitere Ursache für eine schlechte Modell-Performance stellt die sog. Überanpassung („Overfitting“) dar. Diese kann verschiedene Formen aufweisen. Zum einen kann eine Überanpassung entstehen, wenn sich das KI-Modell zu sehr an die gewählten Trainingsdaten „gewöhnt“ hat und somit keine Generalisierung auf weitere Datenmuster möglich ist. Gewöhnen z.B. intelligente, autonom fahrende Fahrzeuge sich zu stark an ihre Simulationsumgebung, werden diese in der Realität nicht fehler- bzw. unfallfrei fahren können. Zum anderen kann die Überanpassung auch durch die Zufuhr von zu vielen Daten verursacht werden. Das Modell wird dadurch unnötig verkompliziert, ohne einen Mehrwert zur Problemlösung zu liefern. Folglich können falsche Schlussfolgerungen auftreten. Beispielsweise sollte ein KI-Modell zur Liquiditätsprognose für Bankkunden primär die Umsatzdaten des Kunden bei der Lösungsfindung nutzen. Die Nutzung von Daten, die keinen hohen Erklärungsgrad beinhalten, sollte daher vermieden werden.

Fazit: KI bleibt die wichtigste Zukunftstechnologie

Eine moderne und flexible IT-Infrastruktur mit Cloud-Technologien bildet zunächst die technische Voraussetzung für erfolgreiche KI- bzw. ML-Anwendungsfälle. In einem zweiten Schritt kommt es auf die ausreichende Verfügbarkeit nutzbarer Daten an. Mit dem veranschaulichten 5V-Modell können die aussichtsreichsten KI-Anwendungen identifiziert werden. Eine systematische und kontinuierliche Überprüfung und Bewertung der Daten sind zwingend erforderlich, um das volle Potenzial von KI nutzbar zu machen und weiter auszuschöpfen.


Zusammenfassend lässt sich sagen, dass KI zu Recht zu den wichtigsten Zukunftstechnologien für Banken gehört. Zu demselben Ergebnis kommt auch Prof. Dr. Schmidhuber, der

zu den weltweit renommiertesten Forschern auf dem Gebiet der KI gehört. Der gebürtige Münchner bestätigte auf die Frage zur Bedeutung im Finanzsektor, dass KI „fast alles erlernen [wird], was Menschen können – und noch viel mehr“. Es gilt daher, die Forschung und rege Diskussion um KI (z.B. im Hinblick auf Potenziale, Datenrisiken, Ethik) weiter in Deutschland und Europa voranzutreiben, um den globalen Anschluss an die Technologie nicht zu verlieren.

Quellen: https://www.bafin.de/SharedDocs/Veroeffentlichungen/DE/Fachartikel/2019/fa_bj_1909_BaFinTech.html • https://blog.commerzbank.de/digitalisierung/18q4/big-data_advanced-analytics.html • <https://www.computerweekly.com/news/252486161/HSBC-chooses-AWS-for-public-cloud-business-operations> • https://www.db.com/newsroom_news/2020/deutsche-bank-und-google-wollen-mit-langfristiger-und-weltweiter-strategischer-partnerschaft-das-bankgeschaef-t-g-de-11628.htm • <https://www2.deloitte.com/us/en/insights/industry/technology/technology-media-and-telecom-predictions/cloud-based-artificial-intelligence.html> • <https://hbr.org/2020/01/competing-in-the-age-of-ai> • <https://hbr.org/2019/07/building-the-ai-powered-organization?> • <http://www.ki-note.de/einzelsicht/machine-learning-anwendungen-im-banking-wie-aus-daten-produkte-werden-1> • <http://people.idsia.ch/~juergen/performer2016.pdf> • <https://www.iks.fraunhofer.de/de/themen/kuenstliche-intelligenz.html> • <https://www.it-finanzmagazin.de/commerzbank-cloud-services-it-praxis-95365/> • <https://www.mckinsey.com/business-functions/organization/our-insights/unleashing-the-power-of-small-independent-teams#> • <https://news.microsoft.com/2020/08/11/standard-chartered-bank-partners-with-microsoft-to-become-a-cloud-first-bank/> • <https://news.microsoft.com/de-ch/2019/08/28/microsoft-cloud-in-der-schweiz-startet-mit-mehr-als-30-kunden-und-partnerorganisationen/> • <https://www.pwc.de/de/digitale-transformation/kuenstliche-intelligenz/kuenstliche-intelligenz-in-unternehmen.html> • <https://www.pwc.de/de/digitale-transformation/business-analytics/kuenstliche-intelligenz-sorgt-fuer-wachstumsschub.html> • <https://de.statista.com/statistik/daten/studie/267974/umfrage/prognose-zum-weltweit-generierten-datenvolumen/#professional> • <https://www.technologyreview.com/2020/07/22/1005532/facebook-says-it-will-look-for-racial-bias-in-its-algorithms/> • <https://yougov.de/news/2020/01/16/wie-bankkunden-im-jahr-2020-aussehen/>


Cam-Duc Au

Duc Au ist seit 2009 bei der Commerzbank AG tätig und arbeitet im Team „Digital Strategy & Business Models“. Nebenbei ist er als Research Fellow am if Institute for Strategic Finance sowie an der FOM Hochschule für Ökonomie & Management tätig. Aktuell promoviert er im Bereich Robo-Advice.



Dr. Andreas Hiese

Dr. Andreas Hiese ist seit 2017 in der Commerzbank AG tätig und verantwortet das Thema Digital Strategy & Business Models. Zuvor war er 8 Jahre in der Unternehmensberatung (Roland Berger, Bain & Company). Er promovierte an der Zeppelin Universität zum Thema „Kundenloyalität nach der Finanzkrise“.



Hey Computer, mach mal. Besser!

Mischa Soujon

IBM Deutschland GmbH

Computer mit Künstlicher Intelligenz können viel. Häufig scheint es, als könnte diese Kombination sogar alles, was wir Menschen können, und zudem auch noch besser. Ist das so?

Wie so oft, kann eine einfache Schwarz-Weiß-Sicht keine überzeugende Antwort liefern. Hier eine Analyse.

Ein kurzer Rückblick

Die ersten Erwähnungen über die Möglichkeit, menschliches Denken und Verhalten zu automatisieren, sind schon deutlich älter als das akademische Fachgebiet der Künstlichen Intelligenz. Hierfür gilt die Dartmouth Conference 1956 als Gründungsveranstaltung. Als früheste Quelle für „Intelligente Maschinen“ wird häufig L’Homme Machine von Julien Offray de la Mettrie genannt und auch auf den Laplaceschen Dämon hingewiesen. In dieser Vorstellung geschieht alles im Universum nach Regeln, einem mathematischen Weltgleichungssystem, dieses schließt auch den Menschen, sein Denken und seine Intelligenz ein.

Mechanische Automatisierung wurde Antrieb der Industrialisierung. Im Bereich des Denkens, Lernens und der geistigen Arbeit begann die Automatisierung aber offensichtlich erst viel später – trotz der theoretischen Erkenntnisse. Mathematiker und Computer-Wissenschaftler haben Modelle von lernenden Systemen erdacht und sogar die Idee, die Funktionsweise des Gehirns nachzuahmen: Künstliche Neuronale Netze (KNN).

Die Entwicklung ging weiter und es gab – wie bei vielen Technologien – Höhen und Tiefen. Vor der selbstlernenden KI entstanden „von Hand“ programmierte Expertensysteme, zum Beispiel in der Erdbebenvorhersage oder der Hochwasservorhersage. Hier wurde Wissen in Software und teilweise in Hardware gegossen. Auch diese Systeme zählen ebenso wie Fuzzy-Logik

zu den KI-Techniken. Im Unterschied zu Künstlichen Neuronalen Netzen und genetischen oder evolutionären Algorithmen basieren die auf Regeln und Fuzzy-Logik implementierten KI-Systeme auf dem direkt umgesetzten Wissen, sind also wissensbasierte Systeme, während die KNN und Genetische Algorithmen lernende Systeme sind.

Die Systeme haben schon erhebliche Beiträge geleistet, die Menschen nicht nur bei stupider, sondern auch bei anspruchsvoller Arbeit technisch und automatisiert zu unterstützen. Dabei imitieren diese Systeme auf unterschiedliche Art und Weise menschliches Verhalten, sodass die Menschen entlastet werden und sich komplexeren Arbeiten widmen können.

Technische Systeme, die menschliches Verhalten nachahmen oder imitieren, werden als Künstliche Intelligenz bezeichnet. Diese Definition ist eine von vielen und keine ist ganz genau. Da diese Systeme für spezielle Aufgaben gebaut werden und uns Menschen hier unterstützen, bevorzugen wir bei IBM in Abgrenzung zur Artificial Intelligence (AI) den Begriff Augmented (unterstützende, erweiterte) Intelligenz oder auch Komplementäre Intelligenz. Damit kommt besser und deutlicher zum Ausdruck, dass KI-Systeme heute die menschliche Intelligenz in speziellen Aufgaben unterstützen und ergänzen. Nicht mehr, aber auch nicht weniger!

Entwicklung heute

Seit den 2010er-Jahren verlagert sich der Schwerpunkt von implementierten wissensbasierten Expertensystemen mehr und mehr zu lernenden Expertensystemen. Die Entwicklung der Algorithmen für Machine Learning macht große Fortschritte. Spätestens mit Einführung von Entwicklungswerkzeugen in Form von frei verfügbaren Frameworks für verschiedene Programmiersprachen (Tensorflow, pyTorch, yolo, ...) seit etwa 2016/2017, beteiligen sich sehr viele Entwickler daran, Maschinen das Lernen beizubringen. Die notwendige Rechenleistung steht unter dem Schreibtisch in Form einer ordentlichen Graphikkarte oder kommt aus der Cloud, denn auch dort ist compute power günstig zu haben.

Die große Beteiligung und das immense Interesse an den Themen Machine Learning und Deep Learning führt zu weiteren Erfolgen bei Systemen mit Komplementärer Intelligenz. Einige Beispiele:

- Es werden inzwischen Gesichter nicht nur im stehenden Bild, sondern im Bewegtbild erkannt und zusätzlich auch noch recht zuverlässig Geschlecht, Alter und Gefühlsausdruck ermittelt.
- Die Gesichtsidifikation[1] eignet sich inzwischen zur (Ent-)Sicherung von Computern und SmartPhones und arbeitet sogar mit hoher Zuverlässigkeit in der Echtzeitverarbeitung.
- Generative Adversarial Networks (GAN) erzeugen täuschend echte Gesichter, Bilderimitate bestimmter Maler, Musik bestimmter Komponisten. Und auch Texte, die nicht einfach von durch Menschen erstellten Werken zu unterscheiden sind.
- Im Bereich Natural Language Processing (NLP) werden Stimmungen erkannt, Inhaltsanalysen erstellt und Fragen beantwortet. Möglich sind Übersetzungen von komplexen Texten in viele Sprachen – nicht nur technisch und grammatikalisch richtig, sondern, ebenfalls und wichtiger, semantisch korrekt. Selbst Rotwelsch und Gang-Sprache wird verstanden und kann analysiert und übersetzt werden. Die Fähigkeiten hier gehen bis zum Debattieren zwischen Mensch und Maschine.
- Ton- und Soundanalysen liefern nicht nur die erkannten Musiktitel, sondern erkennen auch sich anbahnende Defekte in Transportbändern, Lagern, Motoren und helfen dabei Schäden zu vermeiden. Auch sind hier Stimmungsanalyse und Personennidentifikation inzwischen eher handelsüblich und commonly als innovativ.

Die Liste ist nicht vollständig und es gibt viele Bereiche, in denen KI-Systeme uns Menschen unterstützen und immer besser werden. Hier scheinen die KI-Systeme die menschlichen Fähigkeiten zu übertreffen und oft tun sie das tatsächlich auch. In mindestens drei Aspekten ist das sicher:

1. Bei der Geschwindigkeit, mit der sehr große Datenmengen bearbeitet werden. Wir Menschen haben leider schon bei großen Tabellenkalkulationen Schwierigkeiten und mehrere hundert Sensorsignale pro Sekunden zu verarbeiten, überfordert uns sofort.
2. In der Ausdauer, die für die Arbeit zur Verfügung steht, und damit auch in der Skalierbarkeit. Pausen, Schlaf, Essen und Ablenkung sind für uns Menschen lebensnotwendig.
3. Bei der Wiederholbarkeit/Reproduzierbarkeit der Ergebnisse bei gleicher/identischer Eingabe. Wir Menschen unterliegen Stimmungsschwankungen und äußeren Einflüssen durch unser soziales Umfeld, Familie, Freunde etc., die unsere Entscheidungen oft beeinflussen.

Die Aufforderung: Hey Computer, mach mal. Besser! scheint nur folgerichtig.

Wirklich Besser

Reichen diese drei Aspekte wirklich, damit die Leistungen von KI-Systemen immer als besser gelten als die von uns Menschen? Interpretieren wir nicht zu viel in die Ergebnisse hinein und erwarten zu viel?

Wenn ich die digitale Bildersammlung, die sich auf meinem Computer befindet, nach Familienmitgliedern sortieren und auch noch Bildbeschreibungen erzeugen lasse, ist die Maschine schneller fertig als ich und in Bezug auf die Familienmitglieder auch schon sehr gut. Bei den Bildbeschreibungen ... naja. Ich weiß dann, was auf dem Bild ist, aber hilft mir das? Ich kann natürlich versuchen, das System weiter zu trainieren und dabei eine Verbesserung zu erreichen. Für die Familienmitglieder ist das einfach und kann auch als vorurteilsfrei gelten. Das Problem ist zwar komplex (Gesichtserkennung und Identifizierung), aber übersichtlich, da selbst große Familien doch überschaubar bleiben. Bildbeschreibungen sind hier schwieriger zu erstellen, denn zum einen ist die Anzahl verschiedener möglicher Objekte in einem Bild um Größenordnungen höher als die der Familienmitglieder auf dem Bild. Und zum anderen reicht es für eine Bildunterschrift oft nicht, die Objekte oder Szenen zu erkennen, sondern diese müssen auch in einen Zusammenhang (Kontext) gebracht werden, um eine sinnvolle oder aussagekräftige Zusammenfassung schreiben zu können.

Der erste Teil, die Objekt-Segmentierung und -erkennung, ist heute schon sehr gut verstanden und implementiert. Der zweite Teil, den Kontext herzustellen, ist offensichtlich von der Art wie, wo und wann ich Bilder mache, abhängig:

- Ein Fahrrad mit Satteltaschen bedeutet? Fahrt zur Arbeit, Campingurlaub, Familienausflug, Wochenendeinkauf?
- Ein Londoner Bus bedeutet? Dienstreise, Urlaub?
- Hochzeitsgäste und Familienmitglieder? Meine Hochzeit, die eines Familienmitglieds oder die von Freunden der Familie? und so fort. Hier wird deutlich, dass ein KI-System zwar Ergebnisse liefern kann und natürlich auch richtige, aber sind die für mich und meine Bildersammlung hilfreich? Wenn ich das System für mich trainiere, fließen meine Vorlieben ein und die Antworten werden besser zu mir passen. Vermutlich aber nicht zu einer sehr, sehr großen Zahl anderer Hobby- und Profifotografen.

Es wird deutlich, dass das Thema Kontext die große Herausforderung ist.

Kontext!

Woher haben wir unseren Kontext, wenn wir Entscheidungen treffen, Dinge sortieren, einordnen oder bezeichnen? Menschen greifen auf ihr erlerntes Wissen, ihre Erfahrungen und Wahrgenommenes zurück, setzen das in erstaunlich kurzer Zeit in Zusammenhang und bilden einen glaubwürdigen und in sich konsistenten Kontext. Dieser dient dann als Rahmen für die Beantwortung der aktuellen Frage, zur Lösung des Problems bzw. zur Einschätzung der Situation. Der Kontext ist offensichtlich ein individueller Rahmen, da jeder Mensch auf eine persönliche Historie zurückblickt. Daher fallen Antworten auf Fragen und

Einschätzungen unterschiedlich aus – in vielen Fällen sogar sehr unterschiedlich. Selbst bei axiomatischen Grundwahrheiten und bei auf diesen aufbauenden und bewiesenen Tatsachen scheiden sich manche Geister und es werden Vorurteile und Falsches verbreitet. Als Beispiele nenne ich hier:

- Das Benutzen von logarithmischen Skalen bei der Darstellung von exponentiellem Wachstum dient nicht der Verschleierung und Verharmlosung, sondern bietet die Möglichkeit einer sinnvollen grafischen Darstellung schnell wachsender Werte in einem Schaubild.
- Wenn eine Aussage für alle Elemente einer Gruppe gelten soll, reicht es als Beweis nicht aus, es für fast alle oder viele Elemente zu zeigen. Aber es reicht, ein Element zu finden, für welches die Aussage nicht zutrifft, um die Aussage als falsch zu bezeichnen. Alle Primzahlen sind ungerade?
- Wahrscheinlichkeiten: In einem Krankenhaus werden Jungen und Mädchen offensichtlich in einer zufälligen Reihenfolge geboren. Und im Großen und Ganzen ist die Wahrscheinlichkeit für die Geburt eines Mädchens genauso groß wie die für die Geburt eines Jungen. Betrachten wir jetzt drei mögliche Folgen von Geburten:
 - JJJMMMM
 - MMMMMMMM
 - JMJJJM

Sind diese Folgen gleich wahrscheinlich? Die intuitive Antwort - „Natürlich nicht!“ ist falsch.

Diese fehlerhaften Antworten und Einschätzungen folgen aus der Komplexität des Themas. Eine hohe Komplexität bedarf eines enormen Kraftakts und erheblicher Anstrengungen im (Nach-)Denken, um zu gesicherten Ergebnissen zu kommen. Wir sind als Menschen aber sparsam mit unseren bescheidenen Ressourcen (oder auch einfach faul) und nutzen gerne jede sich bietende Abkürzung und Intuition. Leider führt das nicht selten zu Fehleinschätzungen und falschen Antworten. Versuchen Sie es selbst und beantworten schnell diese einfache Frage:

Ein Ball und ein Schläger kosten zusammen einen Euro und zehn Cent. Der Ball kostet zehn Cent mehr als der Schläger. Was kostet der Schläger?

In „Schnelles Denken, langsames Denken“ von Daniel Kahnemann wird die Thematik der Bequemlichkeit beim Denken ausführlich und unterhaltsam diskutiert.

Woher bekommen KI-Systeme ihren Kontext? Bei auspro-

grammierten Expertensystemen ist das offensichtlich: Von der Programmiererin und der Expertin, die ihr Wissen beigesteuert haben. Am Ende der Entwicklung existiert ein System, welches bei der Eingabe A das Ergebnis Z liefert und das wiederholbar zuverlässig ist, da die Regeln für die Abbildung von A nach Z feststehen. Werden während der Entwicklung Fehler korrigiert, passiert das in den Regeln, und für Experten und Entwickler ist im Sourcecode nachvollziehbar, wie aus A das Ergebnis X ermittelt wird.

Bei KI-Systemen mit Machine Learning-Komponenten wird der Kontext wie beim Menschen gelernt bzw. gelehrt. Eine Programmiererin und/oder Data Scientistin gibt ein Lernmodell vor, beschreibt also algorithmisch wie das KI-System lernt. Verschiedene Lernsysteme gibt es auch beim Menschen: Fakten auswendig lernen, lesen und selbstständig erschließen, angeleitet lernen oder ausprobieren. Die Expertin entscheidet hier mit ihrer Erfahrung über das „Wie“, um einem System etwas beizubringen, ein Problem lösen zu lassen. Die gleiche Expertin oder besser eine Fachfrau entscheidet dann „womit“ gelernt bzw. gelehrt wird. Also die Lehrinhalte, das Curriculum, um im Vergleich zu bleiben. Sie entscheidet, was auf den Karteikarten steht, welche Texte gelesen werden und was auf welchen Bildern zu sehen ist. Ebenfalls wird festgelegt, was beim Probieren positiv bzw. negativ bewertet wird. Wie bei uns Menschen wird das Können, das Wissen, der Kontext offensichtlich durch die Lehrenden bestimmt. Wir Menschen interagieren mit vielen „Lehrern“ und „Lehrerinnen“. Daher ist unser Input vielfältig. Wir mischen Kontexte, sind in der Lage, in einem Bereich Gelerntes auf einen anderen zu übertragen. Die Mathematik ist hier ein sehr gutes Beispiel, wie aus Abstraktem Konkretes in vielen Bereichen wird. Ein anderes Beispiel ist dieses abstrakte Bild:




Abbildung 1: Was ist dargestellt?

Reden wir über Jahrmärkte, erkennen wir auf dem Bild oben Luftballons; wenn wir über Wälder sprechen, könnten Bäume dargestellt sein. Ist das Thema Menschengruppen, assoziieren wir sicher schnell eine Familie mit dem Bild. Es ist immer das gleiche Bild, aber der Inhalt ist je nach Kontext ein anderer.

Wie eingangs erwähnt, lösen KI-Systeme heute sehr viele spezielle Probleme, aber Kontextwechsel sind einer Maschine sehr schwer beizubringen. Bei den beschriebenen speziellen Problemen, die durch eine Maschine gut lösbar sind, sind die Systeme schnell, ausdauernd und produzieren nach beendeter Lernphase ebenfalls zuverlässig bei Eingabe B die Ausgabe Y. In einem solchen System ist die Abbildung von der Eingabe zum Ergebnis ebenfalls eindeutig. Bei einem Fehler kann aber die Expertin nicht leicht die fehlerhafte Regel identifizieren, weil diese sich üblicherweise nicht in einer falschen Zeile Sourcecode manifestiert, sondern ein während des Trainings berechneter Parameter, Koeffizient, ein Entscheidungsgewicht oder eine von den Trainingsdaten abhängige Wahrscheinlichkeit ist. Eine Korrektur bedeutet also oft: Neu oder mehr lernen! Und wie schwer und anstrengend neu lernen ist, wissen wir Menschen nur zu gut: Versuchen Sie mal, Ihre Jacke mit dem nicht-üblichen Arm zuerst anzuziehen! Zudem muss die Lehrerin ermitteln, was denn falsch gelehrt wurde. Denn mit den gleichen Lerninhalten wird sich nichts ändern. Das heißt also: die Lerninhalte untersuchen!

Die Punkte machen deutlich, dass es nicht einfach ist, einer Maschine etwas beizubringen; nicht einfacher als einem Menschen. Auch wird deutlich, dass, wie in der menschlichen Ausbildung, viel Wert auf die Lerninhalte und Daten gelegt werden muss, ebenso wie gelehrt bzw. gelernt wird. Der äußere Einfluss, den das Trainerteam auf das KI-System hat, ist groß. Vorlieben, Voreingenommenheit und Verzerrungen (Bias) spiegeln sich leicht im KI-System wider. Selten ist das aber gewünscht: Bei meiner persönlichen Bilderbeschriftung möchte ich meine Vorlieben sehen, bei einem Flugmanöver eines Urlaubsfliegers verzichten sicher viele Passagiere gerne auf meine Vorlieben für Achterbahnfahrten.

Fazit

Computer, insbesondere KI-Systeme, können heute schon viele Dinge besser im Sinne von schneller, ausdauernder und mit konstanter Qualität. Systeme, die lernen und trainiert werden, unterliegen den gleichen Herausforderungen wie Menschen:

1. Sie werden beeinflusst und „erben“/lernen die Voreingenommenheiten der Trainer oder die Verzerrungen (Bias) in Daten. Dies muss regelmäßig überprüft werden.
2. Ebenso müssen die Nachvollziehbarkeit und Transparenz von Entscheidungen in lernenden Systemen sichergestellt werden.
3. Schließlich sind diese KI-Systeme auf spezielle Problemstellungen trainiert und können den Kontext nicht einfach wechseln.

Bis also ein Computer „mach mal“ kann und das auch noch besser, haben Menschen vorher eine aufwendige und verantwortungsvolle Arbeit zu erledigen!

Die KI-Community wird auf verschiedene Weise bei der Entwicklung und dem Einsatz von transparenter und verzerrungsfreier KI unterstützt. Zum Beispiel mit dem OpenSource Toolkit AI Fairness 360 (<https://github.com/Trusted-AI/AIF360>), einem Werkzeugkasten für Data Scientists, der es während der Modellerstellung erlaubt, ungewollte Verzerrungen und Biases zu identifizieren und aus den Modellen zu entfernen. Es gibt noch eine Reihe weiterer Werkzeuge, aber das ist ein anderer Artikel.

Referenzen: [1] IBM bietet keine universelle IBM Gesichtserkennungs- oder Analysesoftware mehr an. IBM lehnt die Verwendung von Technologien, einschließlich Gesichtserkennungstechnologien anderer Anbieter, zur Massenüberwachung, zur Erstellung von Rassenprofilen, zur Verletzung grundlegender Menschenrechte und Grundfreiheiten oder zu Zwecken, die nicht unseren Werten und Grundsätzen des Vertrauens und der Transparenz entsprechen, entschieden ab.

Mischa Soujon

Ich verfüge über mehr als 20 Jahre IT-Erfahrung. Nach meinem Mathematik-Studium an der Uni Bremen begann ich 1998 als SW-Entwickler. Ich habe als IT-Architekt in vielen SW-Projekten gearbeitet und arbeite jetzt im IBM Watson Center Munich als Lösungsarchitekt mit Kunden an Lösungen für ihre Ideen.



Foto: Privat

Die gar nicht mal so große KI-Debatte

Stuart Jonathan Russell

University of California, Berkeley

»Die Folgen, die das Erscheinen einer zweiten intelligenten Spezies auf der Erde hätte, sind so weitreichend, dass wir sehr genau darüber nachdenken sollten.« Zu diesem Schluss kommt The Economist in seiner Besprechung von Nick Bostroms Buch Superintelligenz. Viele würden diese Aussage als klassisches Beispiel für britisches Understatement werten. Bestimmt, so glauben Sie vielleicht, haben die großen Denker unserer Zeit bereits genau darüber nachgedacht, ernsthaft debattiert, Risiken und Nutzen gegeneinander aufgewogen, Lösungen gesucht, Schlupflöcher gefunden und so fort. Doch soweit ich weiß, ist dies nicht der Fall.

Stellt man diese Überlegungen erstmals einem technischen Publikum vor, sieht man geradezu die Gedankenblasen über den Köpfen aufsteigen: »Aber, aber, aber« beginnen sie und enden mit Ausrufezeichen. Ich will damit nicht sagen, dass es keine vernünftigen Einwände gegen die Ansicht geben kann, dass schlecht konstruierte superintelligente Maschinen eine große Bedrohung für die Menschheit darstellen würden. Es ist nur so, dass mir bisher noch kein solcher Einwand untergekommen ist. Da das Thema so wichtig ist, sollten wir auch an die öffentliche Debatte darüber höchste Qualitätsmaßstäbe anlegen. Im Interesse einer solchen Debatte und in der Hoffnung, dass Sie als Leser und Leserinnen dazu beitragen, möchte ich die bisherigen Highlights zusammenfassen.

Verleugnung

Das Problem zu verleugnen, ist der einfachste Ausweg. Scott Alexander, Autor des Blogs Slate Star Codex, leitet einen bekannten Artikel über die Risiken der KI mit folgenden Worten

ein: »Es war um 2007 herum, dass ich begann, mich für die Gefahren der KI zu interessieren. Damals hatte die Mehrheit eine klare Einstellung zu dem Thema: ›Ha-ha. Komm wieder, wenn jemand außer ein paar Internetnerds daran glaubt.««

Es ist kompliziert

In der modernen Psychologie gibt es keinen Zweifel daran, dass ein einzelner IQ-Wert nicht ausreicht, um die Vielfalt der menschlichen Intelligenz zu erfassen. Die Theorien sprechen vielmehr von mehreren Dimensionen der Intelligenz: räumliche, logische, sprachliche, soziale Intelligenz usw. Wir können also keine Intelligenzrangfolge aller Menschen bilden. Das gilt umso mehr für Maschinen, deren Fähigkeiten sehr viel spezifischer sind. Die Google-Suchmaschine und AlphaGo haben außer dem Umstand, aus zwei Geschäftsbereichen desselben Konzerns zu stammen, praktisch nichts gemein. Wir können daher weder das eine noch das andere als das intelligentere Produkt von beiden bezeichnen. Ein Intelligenzquotient für Maschinen ist unsinnig. Wir können keinen eindimensionalen IQ-Wettstreit zwischen Menschen und Maschinen erwarten.

Kevin Kelly, Gründungsherausgeber der Zeitschrift Wired und ein bemerkenswert scharfsichtiger Kritiker der Technologie, geht noch einen Schritt weiter. In »The Myth of a Superhuman AI« schreibt er: »Intelligenz ist nicht eindimensional. Damit ist die Aussage, etwas sei ›klüger als die Menschen‹, bedeutungslos.« Mit einem Wisch sind sämtliche Bedenken hinsichtlich einer Superintelligenz vom Tisch gefegt.

Allerdings liegt eine Antwort darauf quasi auf dem gerade leer gefegten Tisch: Eine Maschine könnte die menschlichen Fähigkeiten in allen relevanten Dimensionen der Intelligenz überflügeln. Damit wäre diese Maschine – selbst wenn wir Kellys strikten Maßstab anlegen – klüger als ein Mensch. Doch wir benötigen diese starke Annahme gar nicht, um Kellys Argument zu entkräften. Sehen wir uns einmal die Schimpansen an. Sie verfügen möglicherweise über ein besseres Kurzzeitgedächtnis als der Mensch. Das gilt sogar bei menschentypischen Aufgaben wie dem Abrufen einer Ziffernfolge. Das Kurzzeitgedächtnis ist eine wichtige Dimension der Intelligenz. Folgen wir Kelly, dann sind Menschen nicht klüger als Schimpansen. Er würde sogar sagen, »klüger als ein Schimpanse« sei ein bedeutungsloses Konzept. Ein schwacher Trost für die Schimpansen, deren Spezies nur im von uns gewährten Umfang überlegen darf. Und ein noch schwächerer Trost für all die Spezies, die wir bereits ausgelöscht haben. Ach ja: Auch für Menschen, die Angst davor haben, von Maschinen vernichtet zu werden, ist das ein ganz schwacher Trost.

Es ist unmöglich

Schon vor der Geburt der KI im Jahr 1956 rümpften abgehobene Intellektuelle die Nase und behaupteten, es könne gar keine intelligenten Maschinen geben. Alan Turing widmete 1950 einen Großteil seiner wegweisenden Abhandlung »Computing Machinery and Intelligence« der Widerlegung dieser Behauptungen. Doch noch immer muss sich die KI-Community fortwährend ähnlicher Aussagen erwehren. Zu den Verfechtern einer Unmöglichkeit der KI gehören Philosophen, Mathematiker und andere. In der aktuellen Debatte zur Superintelligenz haben mehrere Philosophen diese Behauptungen wieder aufgegriffen, um zu beweisen, dass die Menschheit sich nicht fürchten muss. Das kommt wenig überraschend.

Die »One Hundred Year Study on Artificial Intelligence«, kurz AI100, ist ein ambitioniertes Langzeitprojekt der Stanford University. Sie soll den Fortschritt der KI im Auge behalten oder – wie die Autoren es ausdrücken – »untersuchen und antizipieren, wie sich die Künstliche Intelligenz auf alle Aspekte der Arbeit, des Lebens und des Spielens der Menschen auswirken wird«. Der erste große Zwischenbericht mit dem Titel »Artificial Intelligence and Life in 2030« hält jedoch eine Überraschung bereit: Wie vielleicht zu erwarten ist, betont er den Nutzen der KI in Gebieten wie der medizinischen Diagnose und der Kraftfahrzeugsicherheit. Eher nicht zu erwarten ist die Behauptung, dass »eine Rasse übermenschlicher Roboter [...] anders als in Kinofilmen nicht zu erwarten und vermutlich komplett unmöglich« ist.

Meines Wissens ist dies das erste Mal, dass ernsthafte KI-Forscher öffentlich die Ansicht vertreten, dass eine dem

Menschen ebenbürtige oder gar übermenschliche KI ein Ding der Unmöglichkeit ist. Diese Aussage kommt noch dazu mitten in einer Phase extrem rascher Fortschritte in der KI-Forschung, in der eine Grenze nach der anderen durchbrochen wird. Das ähnelt einer Gruppe führender Krebsforscher, die ankündigen, uns alle an der Nase herumgeführt zu haben, denn es wird, wie sie schon lange wissen, niemals möglich sein, den Krebs zu heilen.

Wie konnte es zu einer solchen Kehrtwende kommen? Der Bericht liefert leider keine Gründe oder Nachweise dafür. (Die Frage ist ernst gemeint: Welchen Beweis könnte es dafür geben, dass keine der physikalisch möglichen Anordnungen von Atomen leistungsfähiger sein kann als das menschliche Gehirn?) Ich vermute, dass es zwei Gründe gibt: Erstens gibt es ein natürliches Verlangen, die Existenz des Gorilla-Problems zu widerlegen, da es eine recht unbequeme Perspektive für KI-Forscher darstellt. Wenn es aber keine dem Menschen ebenbürtige KI geben kann, hat sich auch die Sache mit dem Gorilla-Problem elegant erledigt. Der zweite Grund nennt sich Stammesdenken. Es handelt sich um den Trieb, eine Wagenburg gegen die als solche wahrgenommenen »Angriffe« auf die KI zu bilden.

Es erscheint seltsam, dass die Aussicht auf eine superintelligente KI einen Angriff auf die KI darstellen könnte. Noch merkwürdiger erscheint es, die KI mit dem Argument zu verteidigen, dass die KI ihre Ziele niemals erreichen wird. Wir können uns nicht vor einer künftigen Katastrophe schützen, indem wir eine Wette gegen den menschlichen Einfallsreichtum abschließen. Das haben schon andere vor uns versucht und sind damit gescheitert. Das Physik-Establishment der frühen 1930er, personifiziert durch Lord Rutherford, war absolut überzeugt davon, dass es unmöglich ist, die Kernenergie nutzbar zu machen. Und doch bewies Leó Szilárd's Entdeckung der durch Neutronen ausgelösten nuklearen Kettenreaktion 1933, wie ungerechtfertigt diese Überzeugung war.

Sein Durchbruch kam leider zu einem unseligen Zeitpunkt, nämlich am Beginn des Wettrüstens mit dem nationalsozialistischen Deutschland. Es gab keine Möglichkeit, die Atomtechnologie zum Wohl der Allgemeinheit zu entwickeln. Nachdem Szilárd ein paar Jahre später eine nukleare Kettenreaktion in seinem Labor vorgeführt hatte, schrieb er: »Wir haben alles abgeschaltet und sind nach Hause gegangen. In jener Nacht hatte ich kaum Zweifel daran, dass der Welt großes Leid bevorstand.«

Für Bedenken ist es viel zu früh

Häufig versuchen nüchterne Menschen, die Bedenken der Öffentlichkeit auszuräumen, indem sie darauf hinweisen, dass es wohl noch Jahrzehnte dauern wird, bevor eine dem Menschen ebenbürtige KI kommt. Jetzt sei es daher noch nicht an der Zeit, sich Sorgen zu machen. Ein Beispiel aus der AI100: Es gibt »keinen Anlass zur Sorge, dass die KI eine unmittelbare Bedrohung für die Menschheit darstellt«.

Dieses Argument schießt gleich doppelt am Ziel vorbei. Zunächst greift es einen Strohmännchen an. Die Besorgnis gründet nicht auf einer unmittelbar bevorstehenden Gefahr. Nick Bostrom schreibt beispielsweise in Superintelligenz: »Sie

werden hier keine Argumente dafür finden, dass wir kurz vor einem großen Durchbruch in der Forschung zur künstlichen Intelligenz stehen oder dass sich auch nur einigermaßen genau vorhersagen lässt, wann es so weit ist.« Zweitens kann auch ein fernes Risiko Grund genug für Sorgen zum jetzigen Zeitpunkt sein. Der richtige Zeitpunkt dafür, sich über ein potenziell ernsthaftes Problem für die Menschheit Gedanken zu machen, hängt nicht nur davon ab, wann dieses Problem auftritt, sondern auch davon, wie lange es dauert, sich darauf vorzubereiten und eine Lösung dafür umzusetzen.

Würden wir heute feststellen, dass sich ein großer Asteroid auf Kollisionskurs mit der Erde befindet, wäre es dann zu früh, Gegenmaßnahmen einzuleiten, nur weil es erst 2069 so weit ist? Ganz im Gegenteil! Weltweit würden wir mit den Maßnahmen für ein Notfallprojekt beginnen, um die Gefahr auszuschalten. Wir würden damit nicht bis 2068 warten, denn wir wissen ja gar nicht, wie lange es dauert, eine Lösung zu finden.

Ein oft zitierter Verfechter des »Für Sorgen ist es viel zu früh«-Arguments ist Andrew Ng, der sagte, es wäre, »als würde man sich Gedanken über die Überpopulation auf dem Mars machen«. (Später ersetzte er den Mars durch Alpha Centauri.) Ng, ehemals Professor an der Stanford University, ist ein führender Experte auf dem Gebiet des Machine Learning. Seine Ansichten haben also durchaus Gewicht. Seine Behauptung beruht auf einer bequemen Analogie: Nicht nur lässt sich die Gefahr problemlos bannen und liegt noch in der fernen Zukunft. Nein, es ist sogar extrem unwahrscheinlich, dass wir überhaupt jemals Milliarden von Menschen auf dem Mars ansiedeln. Leider ist das eine falsche Analogie, ein Trugschluss: Wir investieren bereits heute gewaltige wissenschaftliche und technische Ressourcen in die Erschaffung immer fähigerer KI-Systeme, ohne groß darüber nachzudenken, was geschieht, wenn wir Erfolg haben. Ein besserer Vergleich wäre der mit dem Plan einer Marsbesiedlung, ohne sich Gedanken darüber zu machen, was wir dort atmen, trinken oder essen werden. Der eine oder andere mag einen solchen Plan für unklug halten. Wieder andere könnten Ngs Argument wortwörtlich nehmen und antworten, dass bereits die Ankunft eines einzigen Menschen auf dem Mars eine Überbevölkerung darstellt, denn der Mars ist nun einmal für exakt null Menschen ausgelegt. Warum überrascht es mich nicht, dass sich alle, die planen, eine Handvoll Menschen auf den Mars zu schicken, bereits Gedanken über eine Überbevölkerung des Mars machen und darum Lebenserhaltungssysteme entwickeln?

Wir sind die Experten

In jeder Diskussion über Risiken gibt es die Gruppe der Verfechter der jeweiligen Technologie, die behaupten, alle Bedenken seien lediglich in Unwissenheit begründet. Lassen wir stellvertretend Oren Etzioni zu Wort kommen, den CEO des Allen Institute for AI und bekannten Forscher auf dem Gebiet des Machine Learning und des Verstehens natürlicher Sprache:

»Mit dem Aufkommen jeder technologischen Innovation haben sich die Menschen gefürchtet. Von den Webern, die zu Beginn des industriellen Zeitalters mit Schuhen nach

den mechanischen Webstühlen warfen, bis zur heutigen Angst vor Killerrobotern war der Grund dafür stets die Ungewissheit der Auswirkungen der neuen Technologie auf unser Selbstwertgefühl und unseren Lebensunterhalt. Und wenn wir etwas nicht wissen, füllt unser ängstlicher Geist die Lücken aus.«

In Popular Science erschien ein Artikel mit der Überschrift »Bill Gates fears AI, but AI Researchers know better« (Bill Gates fürchtet die KI, aber KI-Forscher wissen es besser):

»Wer sich mit KI-Forschern unterhält – gemeint sind echte KI-Forscher, Menschen, die damit kämpfen, dass die Systeme überhaupt funktionieren, geschweige denn zu gut funktionieren –, erfährt, dass sie keine Angst vor einer überraschend auftauchenden Superintelligenz haben, weder jetzt noch in der Zukunft. Anders als die Schauermärchen, die Musk so gern erzählt, arbeiten KI-Forscher nicht verzweifelt daran, Sicherheitsvorrichtungen oder Selbstzerstörungsmechanismen zu bauen.«

Für diesen Artikel wurden ganze vier Personen befragt, die zudem übereinstimmend erklärten, dass es wichtig sei, sich mit der langfristigen Sicherheit der KI zu befassen. Die Botschaft ist in beiden Fällen klar:

»Hört nicht auf sie; wir sind die Fachleute.« Das ist ein klassisches argumentum ad hominem, mit dem eine Behauptung durch persönliche Angriffe auf den Streitgegner angefochten werden soll. Doch selbst wenn wir diese Aussagen für bare Münze nehmen, sind sie nicht stichhaltig. Elon Musk, Stephen Hawking und Bill Gates sind zweifellos mit wissenschaftlicher und technologischer Argumentation gut vertraut. Gerade Musk und Gates haben viele KI-Forschungsprojekte geleitet und darin investiert. Noch unglaubwürdiger wäre es, Alan Turing, I. J. Good, Norbert Wiener und Marvin Minsky die Qualifikation in der KI-Debatte abzusprechen. In dem bereits erwähnten Blogpost »AI Researchers on AI Risk« von Scott Alexander heißt es, dass »KI-Forscher, darunter auch einige der führenden Köpfe des Felds, maßgeblich und von Beginn an dazu beigetragen haben, die Risiken der KI und Superintelligenz zu thematisieren«. Er nennt mehrere davon mit Namen, mittlerweile ist die Liste viel länger geworden.

Ein weiterer rhetorischer Kniff der »Verteidiger der KI« besteht darin, die andere Seite als Maschinenstürmer oder Ludditen hinzustellen. Oren Etzionis Verweis auf die Weber, die »mit Schuhen nach Webstühlen warfen«, ist ein solcher: Die Ludditen waren Textilarbeiter im frühen 19. Jahrhundert, die gegen die Einführung mechanischer Webstühle als Ersatz für ihr Kunsthandwerk kämpften. 2015 vergab die Information Technology and Innovation Foundation ihren jährlichen Luddite Award an »Panikmacher, die eine KI-Apokalypse ankündigen«. Es mutet seltsam an, Ludditen als jene Gruppe zu definieren, zu der auch Turing, Wiener, Minsky, Musk und Gates gehören, die zu den bekanntesten Vordenkern für den technologischen Fortschritt im 20. und 21. Jahrhundert gehören.

Eine solche Anschuldigung der Maschinenstürmerei ist

Folge eines Missverständnisses über die Art der Bedenken und das Ziel dieser Warnungen. Sie ist vergleichbar damit, Kernphysiker des Luddismus zu beschuldigen, wenn diese darauf hinweisen, dass man die Kernspaltung kontrollieren können muss. Wie bei dem seltsamen Phänomen der KI-Forscher, die plötzlich behaupten, dass künstliche Intelligenz ein Ding der Unmöglichkeit sei, dürfte meiner Meinung nach auch hier die Ursache im Stammesdenken zur Verteidigung des technologischen Fortschritts liegen.

Ablenkung

Einige Kommentatoren sind bereit, anzuerkennen, dass die Risiken real sind. Trotzdem argumentieren sie fürs Nichtstun. Diese Argumente umfassen die Unmöglichkeit, etwas zu tun, die Wichtigkeit, etwas ganz anderes zu tun, und die Notwendigkeit, die Risiken unter den Teppich zu kehren.

Forschung lässt sich nicht kontrollieren

Ein häufiger Einwand auf die Aussage, dass eine fortgeschrittene KI eine Bedrohung für die Menschheit darstellen könne, besteht darin, zu behaupten, ein Verbot der KI-Forschung sei unmöglich. Haben Sie den Gedankensprung bemerkt? »Oh, jemand redet von Risiken! Bestimmt will er meine Forschung verbieten!« Dieser Sprung mag in einer Diskussion über Risiken, die rein auf dem Gorilla-Problem beruhen, angemessen sein. Und ich bin der erste, der zugibt, dass eine Lösung des Gorilla-Problems (um die Schaffung einer superintelligenten KI zu verhindern) bestimmte Beschränkungen für die KI-Forschung bedeuten würde.

In den jüngsten Debatten ging es jedoch nicht um das allgemeine Gorilla-Problem (also Superintelligenz verhält sich zu Mensch wie Mensch zu Gorilla), sondern um das König-Midas-Problem und seine Varianten. Wenn wir das König-Midas-Problem lösen, haben wir auch das Gorilla-Problem gelöst. Nicht etwa, weil wir das Aufkommen einer superintelligenten KI verhindert oder eine Möglichkeit gefunden haben, sie zu besiegen, sondern weil wir dafür gesorgt haben, dass es niemals zu einem Konflikt mit uns Menschen kommen wird. Diskussionen rund um das König-Midas-Problem vermeiden generell die Behauptung, dass man die KI-Forschung einschränken sollte. Vielmehr wird dazu geraten, die Gefahr zu berücksichtigen, dass schlecht konzipierte Systeme zu negativen Konsequenzen führen können. Ebenso hat eine Diskussion über die Risiken des Versagens der Sicherheitshülle von Atomanlagen nicht das Ziel, Forschungen auf dem Gebiet der Kernphysik zu verbieten, sondern möchte lediglich den Fokus darauf richten, wie man für sichere Hüllen sorgen kann.

Die Geschichte hält einen interessanten Präzedenzfall für ein Forschungsverbot bereit. Anfang der 1970er-Jahre regte sich unter Biologen die Sorge, dass neuartige rekombinante DNA-Verfahren – nämlich das Herausschneiden von Genen aus einem Organismus und Einsetzen in einen anderen (Spleißen) – erhebliche Risiken für die menschliche Gesundheit und das globale Ökosystem bergen könne. Nach zwei 1973 und 1975 im kalifornischen Asilomar abgehaltenen Konferenzen kam

es zunächst zu einem Moratorium für solche Experimente und anschließend zu detaillierten Biosicherheitsrichtlinien im Einklang mit den Risiken, die von möglichen Experimenten ausgingen. Einige Klassen von Experimenten wie solche mit Toxin-Genen wurden als zu gefährlich angesehen und daher untersagt.

Gleich nach dem Treffen im Jahr 1975 begannen die National Institutes of Health (NIH), die praktisch die gesamte medizinische Grundlagenforschung in den USA finanzieren, mit der Einrichtung des Recombinant DNA Advisory Committee. Dieses Beraterkomitee rund um die rekombinante DNA, kurz RAC genannt, war maßgeblich an der Festlegung der NIH-Richtlinien beteiligt, mit denen die Asilomar-Empfehlungen im Wesentlichen umgesetzt wurden. Seit dem Jahr 2000 enthalten die Richtlinien ein Verbot von Förderzusagen für jegliche Studien, die Veränderungen der menschlichen Keimbahn umfassen, also Änderungen des menschlichen Genoms, die an Folgegenerationen vererbt werden können. Diesem Bann folgten gesetzliche Verbote in mehr als 50 Ländern.

Die »Verbesserung der menschlichen Rasse« war immer eines der Traumziele der Eugenik-Bewegung im späten 19. und frühen 20. Jahrhundert. Die Entwicklung der Genschere CRISPR-Cas9 für exakte Eingriffe in das Genom hat diesen Traum neu belebt. Ein internationaler Gipfel im Jahr 2015 ließ die Tür für zukünftige Einsatzmöglichkeiten offen, rief aber zur Zurückhaltung auf, bis »es einen breiten gesellschaftlichen Konsens über die Richtigkeit der vorgeschlagenen Anwendungen gibt«. Im November 2018 gab der chinesische Wissenschaftler He Jiankui bekannt, er habe die Genome dreier menschlicher Embryos verändert, von denen mindestens zwei zu Lebendgeburten geführt hätten. Es gab einen internationalen Aufschrei. Im März 2019 forderte ein internationales Gremium führender Wissenschaftler ausdrücklich ein formales Moratorium.

Die Moral dieser Debatte für die KI ist nicht eindeutig. Einerseits wird klar, dass wir in der Lage sind, Forschungen in einem vielversprechenden Gebiet auszusetzen. Der internationale Zusammenschluss gegen Keimbahnveränderungen war bisher im Großen und Ganzen erfolgreich. Die Sorge, dass ein solches Verbot die Forscher in den Untergrund oder Länder ohne entsprechende Vorschriften treiben würde, hat sich nicht bewahrheitet. Andererseits sind Veränderungen ein leicht erkennbarer Prozess und ein Sonderfall der genetischen Forschung. Man benötigt dafür unter anderem spezielle Ausrüstung und echte Menschen, an denen die Experimente durchgeführt werden können. Hinzu kommt, dass solche Arbeiten Teil der Reproduktionsmedizin sind, die bereits sehr genau überwacht und reguliert wird. All das gilt nicht für die allgemeine KI. Bisher wurde auch noch keine praxistaugliche Art der Regulierung zur Beschränkung von KI-Forschungen vorgeschlagen.

Ablenkungsstrategien

Ablenkungsstrategien sind heute vielleicht besser als What-aboutism bekannt. Ein britischer Politiker, der diesem Phänomen regelmäßig bei öffentlichen Gesprächsrunden ausgesetzt war, machte mich erstmals mit dem englischen Begriff bekannt. Um

welches Thema es in seinen Reden auch ging, immer gab es jemanden, der unweigerlich die eine Frage stellte: »Aber was ist mit der Not der Palästinenser?« In Diskussionen über die Risiken einer fortgeschrittenen KI lautet die Frage vermutlich: »Aber was ist mit den Vorteilen, die die KI bietet?« Ich übergebe das Wort an Oren Etzioni:

»Schwarzmalerische Vorhersagen lassen häufig die möglichen Vorteile der KI außen vor, zum Beispiel das Verhindern von medizinischen Fehlern, weniger Autounfälle usw.«

Oder nehmen wir Mark Zuckerberg, CEO von Facebook, in einem von den Medien angeheizten Schlagabtausch mit Elon Musk:

»Wer sich gegen die KI ausspricht, spricht sich gegen sicherere Autos aus, die nicht mehr in Unfälle verwickelt sind, und gegen bessere medizinische Diagnosen.«

Ganz abgesehen von dem Stammesgedanken, dass jeder, der auf Risiken hinweist, »gegen die KI« ist, behaupten Zuckerberg und Etzioni, dass das Reden über die Gefahren gleichbedeutend damit ist, einen möglichen Nutzen der KI zu ignorieren oder sogar zu leugnen. Andersherum wird jedoch ein Schuh daraus: Erstens gäbe es ohne die potenziellen Vorteile der KI keinerlei wirtschaftlichen oder gesellschaftlichen Anreiz, KI-Forschung zu betreiben, und damit auch keine Gefahr, dabei eine dem Menschen ebenbürtige KI zu erschaffen. Die ganze Diskussion würde also gar nicht geführt. Zweitens gilt, dass es ohne erfolgreiche Minderung der Risiken gar keine Vorteile geben wird. Die potenziellen Vorteile der Kernenergie schätzt man heute erheblich geringer ein als früher. Das liegt nicht zuletzt an der partiellen Kernschmelze in Three Mile Island 1979, der außer Kontrolle geratenen Reaktion und katastrophalen Freisetzung in Tschernobyl 1986 und den Kernschmelzen in Fukushima 2011. Diese Katastrophen haben das Wachstum der Atomindustrie deutlich gebremst. Italien hat der Kernenergie 1990 abgeschworen und Belgien, Deutschland, Spanien sowie die Schweiz haben entsprechende Pläne angekündigt. Seit 1990 ist die Zahl der weltweiten Inbetriebnahmen von Atomkraftwerken auf ein Zehntel der Anzahl vor Tschernobyl zurückgegangen.

Schweigen

Die extremste Form der Ablenkung ist der Vorschlag, gar nicht über die Risiken zu sprechen. So enthält der oben erwähnte Bericht zur AI100 die folgende Warnung:

»Wenn die Gesellschaft sich diesen Technologien vornehmlich mit Furcht und Misstrauen nähert, wird es zu Fehlritten kommen, die den Fortschritt der KI verlangsamen oder das Gebiet sogar in den Untergrund verbannen. Dadurch würden wichtige Arbeiten behindert, die für die Sicherheit und Zuverlässigkeit von KI-Technologien sorgen sollen.«

Robert Atkinson, Leiter der Information Technology and Innovation Foundation (die auch den Luddite Award vergibt),

brachte 2015 in einer Debatte ein ähnliches Argument vor. Zwar gibt es berechnete Fragen dazu, wie genau Risiken gegenüber der Presse beschrieben werden sollten, aber die Stoßrichtung ist klar: »Risiken werden nicht erwähnt, das wäre schlecht für die Finanzierung.« Wenn niemand die Risiken kennt, kann es logischerweise auch keine Fördermittel für die Erforschung der Risikominderung geben – und auch keinen Grund dafür.

Der bekannte Kognitionswissenschaftler Steven Pinker hat eine optimistischere Version von Atkinsons Argument parat. Seiner Ansicht nach wird die »Kultur der Sicherheit in modernen Gesellschaften« schon dafür sorgen, dass alle ernsthaften Gefahren, die von der KI ausgehen, eliminiert werden. Daher sei es unangemessen und kontraproduktiv, die Aufmerksamkeit auf diese Risiken zu lenken. Lassen wir die Tatsache außen vor, dass unsere moderne Kultur der Sicherheit zu Tschernobyl, Fukushima und einer unkontrollierbaren Erderwärmung geführt hat, so schießt Pinkers Argument dennoch komplett am Ziel vorbei. Die Kultur der Sicherheit sorgt nämlich genau dafür, dass es Menschen gibt, die auf mögliche Fehlentwicklungen aufmerksam machen und nach Wegen suchen, die sicherstellen, dass es nicht dazu kommt. (In der KI ist das Standardmodell die Fehlentwicklung.) Wer behauptet, es sei lächerlich, auf eine Fehlentwicklung hinzuweisen, weil die Kultur der Sicherheit diese sowieso beheben würde, ist auch der Meinung, niemand müsse für einen angefahrenen Fußgänger bei Fahrerflucht einen Krankenwagen rufen, weil das schon jemand anderer erledigen wird.

Beim Versuch, die Risiken für die Öffentlichkeit und politische Entscheidungsträger zu beschreiben, sind KI-Forscher gegenüber Kernphysikern im Nachteil: Kein Physiker musste Bücher schreiben, um der Öffentlichkeit zu erklären, dass das Erreichen einer kritischen Masse hoch angereicherter Urans möglicherweise eine Gefahr darstellen würde, denn das war aus den Atombombenabwürfen über Hiroshima und Nagasaki bereits bekannt. Es war kein besonderes Maß an Überredungskunst mehr nötig, auch Regierungen und Förderagenturen davon zu überzeugen, dass Sicherheit bei der weiteren Entwicklung der Kernkraft wichtig ist.

Können wir nicht einfach ...

... den Stecker ziehen?

Sobald das existenzielle Risiko erkannt ist, sei es in Form des Gorilla-Problems oder des König-Midas-Problems, beginnen viele – ich eingeschlossen – mit der Suche nach einer einfachen Lösung. Häufig besteht die erste Idee darin, einfach den Stecker der Maschine zu ziehen. Sie erinnern sich vielleicht daran, dass Alan Turing empfahl, »die Maschinen in einer untergeordneten Stellung zu halten, indem wir sie beispielsweise im passenden Moment ausschalten.«

Leider funktioniert das nicht, denn eine Superintelligenz wird diese Möglichkeit bereits erwogen und Gegenmaßnahmen eingeleitet haben. Das liegt nicht daran, dass die Maschine »leben« will, sondern daran, dass sie das ihr vorgegebene Ziel nicht erreichen kann, wenn sie abgeschaltet wird. Und weil die

Maschine superintelligent ist, weiß sie das natürlich.

Aktuell werden gewisse Systeme ins Auge gefasst, die sich nicht abschalten lassen, ohne gleichzeitig einen großen Teil des Gerüsts unserer Zivilisation einzureißen. Es geht um sogenannte Smart Contracts in der Blockchain. Die Blockchain ist eine weiträumig verteilte Rechen- und Speicherinfrastruktur mit Verschlüsselung. Sie ist von Grund auf so konzipiert, dass kein Datensatz gelöscht und kein Smart Contract ausgesetzt werden kann, ohne die Kontrolle über eine sehr große Anzahl von Maschinen zu erlangen und die Blockchain abzuwickeln (auf einen früheren Stand zu bringen), was wiederum große Teile des Internets oder des Finanzsystems zerstören könnte. Man kann darüber streiten, ob es sich bei dieser Robustheit um eine Funktion oder einen Fehler handelt. In jedem Fall aber könnte ein superintelligentes KI-System diese Technik nutzen, um sich selbst zu schützen.

... eine Kiste bauen?

Wenn wir KI-Systeme schon nicht abschalten können, besteht dann wenigstens die Möglichkeit, sie hinter eine Art Firewall zu sperren, die nur unsere Fragen und die nützlichen Antworten der Maschine durchlässt, aber ansonsten jede direkte Einflussnahme auf die echte Welt verhindert? Das ist die Idee hinter einer Orakel-KI, die in der KI-Sicherheitscommunity schon ausführlich diskutiert wurde. Ein Orakel-KI-System kann beliebig intelligent sein, aber nur Fragen mit Ja oder Nein beantworten (bzw. Wahrscheinlichkeiten nennen). Es kann auf alle Informationen zugreifen, die die Menschheit besitzt – allerdings im schreibgeschützten Modus ohne direkten Zugriff auf das Internet. Damit werden superintelligente Roboter, Assistenten und viele andere Arten von KI-Systemen natürlich unmöglich. Trotzdem hätte eine vertrauenswürdige Orakel-KI nach wie vor einen gewaltigen wirtschaftlichen Wert, da wir Fragen stellen können, die uns wichtig sind: Wird Alzheimer durch einen Infekt verursacht? Ist ein Verbot autonomer Waffensysteme eine gute Idee? Das klingt doch super!

Leider gibt es einige größere Schwierigkeiten. So wird ein Orakel-KI-System mindestens ebenso wie wir bestrebt sein, die Physik und Ursprünge seiner Welt zu verstehen: Rechenressourcen, Funktionsweise und die geheimnisvollen Wesen, die Informationen liefern und Fragen stellen. Außerdem hat ein Orakel-KI-System, das in angemessener Zeit exakte Antworten geben soll, einen Anreiz, seinen Käfig zu verlassen, um sich mehr Rechenressourcen zu verschaffen und die Fragesteller zu kontrollieren und sie dazu zu bringen, nur einfache Fragen zu stellen. Und schließlich müssen wir selbst eine Firewall, die gegen gewöhnliche Menschen hilft, erst noch erfinden. Die gegen eine superintelligente Maschine dürfte deutlich komplexer sein.

Ich kann mir vorstellen, dass es vielleicht Lösungen für ein paar dieser Probleme gibt – ganz besonders, wenn wir Orakel-KI-Systeme auf nachweislich profunde logische oder bayessche Berechnungen beschränken. Das bedeutet, wir könnten darauf bestehen, dass der Algorithmus nur Schlussfolgerungen ausgeben kann, die sich aus den vorgegebenen Informationen ableiten lassen. Und wir könnten mathematisch prüfen, dass

der Algorithmus diese Bedingung erfüllt. Es bleibt jedoch das Problem, den Prozess zu kontrollieren, der entscheidet, welche logischen oder bayesschen Berechnungen ausgeführt werden, um so schnell wie möglich zur zuverlässigsten Schlussfolgerung zu gelangen. Dieser Prozess hat den Anreiz, schnelle Schlüsse zu ziehen, und somit auch einen Anreiz, sich weitere Rechenressourcen zu verschaffen und seine eigene Existenz zu bewahren.

2018 veranstaltete das Center for Human-Compatible AI in Berkeley einen Workshop, in dem die folgende Frage gestellt wurde: »Was würden Sie tun, wenn Sie sicher wüssten, dass eine superintelligente KI binnen eines Jahrzehnts machbar wäre?« Meine Antwort lautet: Ich würde die Entwickler überreden, die Finger von einem intelligenten allgemeinen Agenten zu lassen, der über seine eigenen Aktionen in der realen Welt entscheiden kann, und stattdessen eine Orakel-KI zu bauen. Momentan arbeiten wir an der Frage, wie sich Orakel-KI-Systeme überprüfbar maximal sicher gestalten lassen. Das könnte aus zweierlei Gründen funktionieren: Erstens wäre ein superintelligentes Orakel-KI-System noch immer zig Billionen US-Dollar wert, was es den Entwicklern leichter macht, eine solche Beschränkung zu akzeptieren. Zweitens ist es sehr viel einfacher, die Kontrolle über Orakel-KI-Systeme zu behalten als über einen intelligenten allgemeinen Agenten. Damit wäre es auch viel wahrscheinlicher, das Problem innerhalb einer Dekade zu lösen.

... in Teams aus Menschen und Maschinen arbeiten?

Ein Gemeinatz bei Unternehmen lautet, dass KI keine Arbeitsplätze oder gar die Menschheit bedroht, weil wir künftig in Mensch-Maschine-Teams arbeiten werden. Im bereits erwähnten Brief von David Kenny an den US-Kongress heißt es, »wertvolle KI-Systeme sind speziell darauf ausgelegt, die menschliche Intelligenz zu erweitern, nicht darauf, Arbeiter zu ersetzen.«

Zyniker mögen sagen, das sei lediglich ein PR-Stunt, der den Abbau von Arbeitsplätzen gegenüber Verbrauchern und Kunden hübsch verpackt. Ich denke allerdings, dass es wirklich ein Schritt nach vorn ist, Teams aus Menschen und Maschinen zu bilden, die Hand in Hand arbeiten. Die Arbeit eines solchen Teams wäre nicht erfolgreich, wenn die Ziele der einzelnen Mitglieder nicht übereinstimmen. Es muss daher zunächst darum gehen, sich dem Kernproblem der Werteausrichtung zu widmen. Natürlich ist es damit noch lange nicht gelöst.

... uns mit den Maschinen vereinen?

Spinnt man die Idee eines Mensch-Maschine-Teams weiter, gelangt man irgendwann zu dem Punkt, an dem Mensch und Maschine eins werden, ein kybernetischer Organismus oder Cyborg, bei dem elektronische Hardware direkt mit dem Gehirn verbunden ist, sodass eine einheitliche, erweiterte, bewusste Entität entsteht. Der Futurist Ray Kurzweil beschreibt die Möglichkeit wie folgt:

»Wenn wir uns unmittelbar damit vereinen, werden wir zu künstlichen Intelligenzen [...] In den späten 2030er- oder 2040er-Jahren wird unser Denken primär nicht biologisch sein und der nicht biologische Teil wird letztendlich so intelligent sein und über eine solch gewaltige Kapazität verfügen, dass er den biologischen Teil schließlich vollkommen modellieren, simulieren und verstehen kann.«

Kurzweil sieht die Entwicklung also positiv. Elon Musk dagegen sieht die Vereinigung von Mensch und Maschine in erster Linie als Verteidigungsstrategie:

»Wenn wir eine so enge Symbiose erreichen, wäre die KI nicht länger ein ›Ding‹, die KI wäre Sie und [sie stünde in] Beziehung zu Ihrem Kortex, ähnlich wie Ihr Kortex zu Ihrem limbischen System in Beziehung steht [...] Wir haben dann die Wahl, zurückgelassen und irgendwann praktisch nutzlos oder zu einer Art Haustier zu werden – wie eine Schmusekatze –, oder eine Möglichkeit zu finden, eine symbiotische Vereinigung mit der KI einzugehen.«

Die Neuralink Corporation, ein Unternehmen von Musk, arbeitet an einem Gerät namens »Neural Lace«. Damit soll eine robuste, dauerhafte Verbindung zwischen dem menschlichen Kortex und externen Rechnersystemen und Netzwerken hergestellt werden. Es gibt allerdings zwei große technische Hürden: Zum einen ist es alles andere als leicht, ein elektronisches Gerät an das Hirngewebe anzuschließen, es mit Energie zu versorgen und mit der Außenwelt zu verbinden. Zum anderen wissen wir fast nichts über die neuronale Implementierung der höheren kognitiven Ebenen im Gehirn und können daher auch nicht sagen, wo dieses Gerät angeschlossen werden muss und welche Aufgaben es übernehmen soll. Ich bin nicht wirklich davon überzeugt, dass die genannten Hürden unüberwindbar sind. Erstens werden durch Technologien wie den neuronalen Staub (Neural Dust) Größe und Energiebedarf elektronischer Geräte, die an Nervenzellen angeschlossen werden und Fühlen, Stimulieren und transkraniale Kommunikation ermöglichen, immer schneller immer kleiner. (Für das Jahr 2018 reden wir über einen Kubikmillimeter, sodass die Bezeichnung neuronaler Splitt wohl angemessener wäre.) Zweitens ist das Gehirn selbst erstaunlich anpassungsfähig. Man dachte zum Beispiel, dass wir den Code verstehen müssten, mit dem das Gehirn die Armmuskulatur steuert, bevor wir es erfolgreich mit einem Roboterarm verbinden können, oder dass wir wissen müssten, wie die Cochlea den Schall analysiert, um ein Implantat dafür konstruieren zu können. Wie sich herausgestellt hat, nimmt uns das Gehirn die meiste Arbeit ab. Es lernt schnell, den Roboterarm so zu bewegen, wie sein Besitzer es möchte, oder die Ausgaben eines Cochlea-Implantats verständlichen Klängen zuzuordnen. Es ist durchaus möglich, dass wir einen Weg finden, den »Arbeitsspeicher« des Gehirns zu erweitern, Kommunikationskanäle zu Computern aufzubauen und vielleicht sogar mit anderen Gehirnen zu kommunizieren, ohne dass wir jemals wirklich verstehen, wie das Ganze funktioniert. Ungeachtet der technologischen Machbarkeit dieser

Ideen müssen wir uns aber fragen, ob in dieser Richtung die beste aller möglichen Varianten der Zukunft für die Menschheit liegt. Denn wenn wir uns chirurgischen Eingriffen am Gehirn unterziehen müssen, um die Bedrohung einer von uns geschaffenen Technologie zu überleben, haben wir vielleicht schon vorher einen Fehler gemacht.

... vermeiden, menschliche Ziele vorzugeben?

Häufig wird argumentiert, ein problematisches KI-Verhalten sei die Folge bestimmter Arten von Vorgaben. Ließe man diese weg, wäre alles in Ordnung. Diese Meinung vertritt auch Yann LeCun, ein Wegbereiter des Deep Learning und Forschungsdirektor bei Facebook, wenn er die Risiken der KI kleinredet:

»Es gibt keinen Grund dafür, dass KIs über Selbsterhaltungsinстинkte, Neid usw. verfügen sollten. [...] KIs können derartig zerstörerische ›Emotionen‹ nur haben, wenn wir sie ihnen einpflanzen. Und ich wüsste wirklich nicht, warum jemand das tun sollte.«

Bei der Betrachtung der übergeordneten Ziele haben wir bereits festgestellt, dass es völlig unerheblich ist, ob wir Emotionen oder Wünsche und Triebe wie Selbsterhalt, Ressourcenbeschaffung, Wissensdurst oder im Extremfall Herrschaftsgelüste in die Maschine einbauen. Sie wird diese Emotionen sowieso entwickeln, weil es sich um Teilziele jedes Ziels handelt, das oder die wir ihr vorgeben. Für eine Maschine ist der Tod an sich nicht schlecht. Dennoch gilt es, den Tod zu vermeiden, denn: Tote holen keinen Kaffee.

Eine noch extremere Lösung besteht darin, der Maschine gar keine Ziele vorzugeben. Voilà, Problem gelöst! Doch leider ist es nicht so einfach. Ohne Ziele gibt es keine Intelligenz: Alle Aktionen wären gleichwertig und wir könnten anstelle der Maschine auch einen Zufallszahlengenerator verwenden. Ohne Ziele gibt es keinen Grund für die Maschine, ein menschliches Paradies einem von Büroklammern bedeckten Planeten vorzuziehen (Nick Bostrom beschreibt dieses Szenario eingehend). Tatsächlich hätte sogar jemand einen Nutzen davon: das Bakterium *Thiobacillus ferrooxidans*, das sich von Eisenverbindungen »ernährt«. Und wer will ihm sein persönliches Paradies absprechen (abgesehen davon, dass wir als Menschen natürlich ganz andere Präferenzen haben)?

Eine Variante der Idee, keine Ziele vorzugeben, besteht in der Überlegung, dass ein hinreichend intelligentes System sowieso eben aufgrund seiner Intelligenz die »richtigen« Absichten und Ziele entwickeln wird. Verfechter dieser Idee hängen häufig der Theorie an, dass intelligentere Menschen auch altruistischere und höhere Ziele haben; aber das mag auch mit dem Selbstverständnis dieser Personen zu tun haben. Nick Bostrom stellt in seinem Buch *Superintelligenz* seine Grundidee vor. Er nennt sie die Orthogonalitätsthese:

»Intelligenz und letzte Ziele stehen orthogonal zueinander: So gut wie jedes Intelligenzniveau kann im Prinzip mit so gut wie jedem Ziel kombiniert werden.«

Hier bedeutet orthogonal »im rechten Winkel zueinander« in dem Sinne, dass das Intelligenzniveau die eine Achse eines intelligenten Systems bildet und die Ziele die andere Achse; beide können unabhängig voneinander verändert werden. Ein Beispiel: Sie können einem selbstfahrenden Auto eine bestimmte Adresse als Ziel vorgeben. Wenn Sie dem Auto nun beibringen, besser zu fahren, wird es sich nicht plötzlich weigern, Adressen anzusteuern, deren Hausnummern durch 17 teilbar sind. Ebenso ist gut vorstellbar, dass ein intelligentes Allzwecksystem praktisch jedes beliebige Ziel verfolgen soll, und dazu gehört auch die Aufgabe, möglichst viele Büroklammern herzustellen oder weitere Nachkommastellen für Pi zu bestimmen. Auf genau diese Weise funktionieren Reinforcement Learning und andere Arten der Belohnungsoptimierung: Die Algorithmen sind absolut allgemein gehalten und können jedes beliebige Belohnungssignal nutzen. Für Ingenieure und Informatiker, die mit dem Standardmodell arbeiten, ist die Orthogonalitätsthese selbstverständlich.

Die Vorstellung, dass intelligente Systeme die Welt einfach nur beobachten, um die zu verfolgenden Ziele zu ermitteln, bedingt, dass ein hinreichend intelligentes System naturgemäß sein anfängliches Ziel durch das »richtige« Ziel ersetzt. Doch es dürfte kaum einen Grund für einen vernunftbegabten rationalen Agenten geben, dies zu tun. Zudem setzt sie voraus, dass es irgendwo in der Welt ein »richtiges« Ziel gibt. Dieses müsste ein Ziel sein, das neben Eisenfresserbakterien und Menschen auch alle anderen Spezies teilen – und das ist kaum vorstellbar.

Steven Pinker scheint Bostroms Orthogonalitätsthese zuzustimmen, wenn er schreibt, dass »Intelligenz die Fähigkeit ist, neue Mittel zu finden, um ein Ziel zu erreichen; die Ziele sind kein Teil der Intelligenz selbst«. Andererseits findet er es unvorstellbar, dass »eine KI gleichzeitig so brillant ist, dass sie herausfindet, wie man Elemente transmutiert und Gehirne neu verdrahtet, und so dumm, dass sie Dinge grob missversteht und so Chaos verursacht«. Er fährt fort: »Die Fähigkeit, sich für eine Handlungsalternative zu entscheiden, die widersprüchliche Ziele bestmöglich befriedigt, ist kein Add-on, das Ingenieure möglicherweise vergessen und nicht getestet haben; sie ist Intelligenz. Dasselbe gilt auch für die Fähigkeit, die Absichten eines Sprechers im Kontext zu beurteilen.« Natürlich ist das Befriedigen widersprüchlicher Ziele nicht das eigentliche Problem; diese Fähigkeit ist seit Anbeginn der Entscheidungstheorie integraler Bestandteil des Standardmodells. Das Problem besteht darin, dass die widersprüchlichen Ziele, von denen die Maschine weiß, nicht alle Sorgen und Angelegenheiten der Menschen abbilden. Außerdem gibt es keinen Aspekt im Standardmodell, der die Maschine darüber informiert, dass sie sich um Ziele kümmern soll, die ihr nicht explizit vorgegeben werden.

Es erscheint uns dumm, wenn die Maschine zum Beispiel die Farbe des Himmels verändert, während sie ein anderes Ziel verfolgt und dabei offensichtliche Anzeichen menschlicher Unzufriedenheit ob dieser Änderung ignoriert. Es erscheint uns dumm, weil wir gewohnt sind, menschliches Missfallen zu erkennen, und (zumindest normalerweise) darauf aus sind, es zu verhindern – auch wenn wir vorher noch gar nicht wussten, dass den betroffenen Menschen die Farbe des Himmels wichtig

ist. Soll heißen: (1) Uns Menschen sind die Präferenzen anderer Menschen wichtig und (2) wir wissen, dass wir nicht all diese Präferenzen kennen.

Der Debatte Neuanfang

Trotz ihrer heldenhaften Bemühungen konnten die Skeptiker – die die von der KI ausgehenden Gefahren für vernachlässigbar halten – nicht erklären, warum sich superintelligente KI-Systeme ohne jeden Zweifel und auf alle Zeit der Kontrolle des Menschen unterwerfen. Sie haben noch nicht einmal versucht, zu erklären, warum wir es niemals schaffen können, superintelligente KI-Systeme zu konstruieren.

Viele Skeptiker werden, wenn man nur penetrant genug nachfragt, zugeben, dass es ein echtes Problem gibt – wenn es auch nicht unmittelbar bevorsteht. Auch wenn ich froh darüber wäre, wenn die Skeptiker einen unwiderlegbaren Einwand präsentieren würden – vielleicht in Form einer einfachen und narrensicheren (und am besten auch Bösewicht-sicheren) Lösung für das Kontrollproblem der KI –, denke ich, dass dies höchstwahrscheinlich nie passieren wird. Genauso wenig, wie wir eine einfache und narrensichere Lösung für die Cybersicherheit oder eine einfache und narrensichere Lösung für eine risikolose Kernenergie finden werden. Die Debatte hat die Zwickmühle, in der wir uns befinden, offenbart: Wenn wir Maschinen bauen, die Ziele optimieren sollen, dann müssen die von uns vorgegebenen Ziele auch wirklich unseren Wünschen entsprechen. Leider wissen wir nicht, wie man menschliche Ziele vollständig und korrekt definiert. Zum Glück gibt es einen Mittelweg.

Prof. Stuart Jonathan Russell, Ph.D.

Stuart Russell ist Professor für Informatik am Lehrstuhl Engineering der University of California, Berkeley. Er war stellvertretender Vorsitzender des Rats für künstliche Intelligenz und Robotik des Weltwirtschaftsforums und Berater für die Rüstungskontrolle der Vereinten Nationen.



Foto: Privat

1.1 USE CASES

Die Top 10 Anwendungsfälle für Maschinelles Lernen in Unternehmen

In jüngster Zeit hat das Interesse am Maschinellen Lernen (ML) dramatisch zugenommen. Immer mehr Menschen werden sich der Möglichkeiten neuer Anwendungen bewusst, die durch den Ansatz des Maschinellen Lernens ermöglicht werden. In der Industrie hat ML den Weg für technologische Errungenschaften und Anwendungen geebnet, die vor einigen Jahren unmöglich gewesen wären.

Maschinelles Lernen ist dabei ein Überbegriff für eine Reihe von Techniken und Werkzeugen, mit denen Computer selbst lernen und sich anpassen können. Algorithmen für Maschinelles Lernen helfen der KI beim Lernen, ohne explizit für die Ausführung der gewünschten Aktion programmiert zu sein. Durch Lernen eines Musters aus Probeneingaben sagt der Algorithmus für Maschinelles Lernen Aufgaben voraus und führt sie ausschließlich auf der Grundlage des gelernten Musters und nicht aufgrund einer vordefinierten Programmanweisung aus.

Bildererkennung

Computer Vision ist eines der aufregendsten Gebiete des Maschinellen Lernens. Grundsätzlich handelt es sich um einen Ansatz zum Identifizieren und Erkennen eines Merkmals oder eines Objekts im digitalen Bild. Darüber hinaus kann diese Technik für weitere Analysen verwendet werden, wie z. B. Mustererkennung, Gesichtserkennung, optische Zeichenerkennung und vieles mehr.

Der Computer-Vision-Algorithmus beschreibt den Bildinhalt, indem die Merkmale der Bilder mit den Merkmalen der verfügbaren Proben abgeglichen werden. Ein Foto eines Fahrrads wird als solches erkannt, da die Informationen des Beispielfotos, auf die der Algorithmus trainiert ist, und die Informationen des Eingabefotos korrelieren. Die Vorgehensweise der optischen Zeichenerkennung, auch bekannt als OCR, ist dabei dieselbe, wie bei der allgemeinen Bildererkennung mit dem Unterschied, dass der Algorithmus auf Textinhalt und dessen Korrelation mit der visuellen Darstellung des Textes über Schriftarten, Größen, Formatierungen und Farben trainiert wird.

Stimmungsanalyse

Die Stimmungsanalyse ist ein weiteres interessantes Anwendungsfeld des Maschinellen Lernens. Sie befasst sich mit der Art und Weise, wie Kunden mit einem Produkt interagieren und welche Haltung und Meinung sie zu dem Produkt haben. Um die Emotionen aus ei-

nem Text herauszufiltern, verwendet das System zum grundlegenden Erkennungsverfahren unbeaufsichtigtes Maschinelles Lernen. Intelligente Algorithmen sind in der Lage, nicht nur Text und gesprochene Sprache, sondern sogar Ironie durch die Analyse des Kontexts zu verstehen. Als intelligentes Filtersystem kann die Sentimentanalyse die Gefühle der Kunden messen, die verärgerten Kunden identifizieren und zwecks besonderer Kundenpflege aussortieren, damit sie nicht abspringen.

Videoüberwachung

Eine kleine Videodatei enthält mehr Informationen als Textdokumente und andere Mediendateien wie Audio und Bilder. Aus diesem Grund gewinnt das Extrahieren nützlicher Informationen aus Videos und automatisierten Videoüberwachungssystemen für Unternehmen immer mehr an Bedeutung. Mehrere Videokameras gleichzeitig zu überwachen und Informationen über die Anwesenheit derselben Person in verschiedenen Video-Frames zu sammeln, ist nicht nur sehr anspruchsvoll, sondern übersteigt die menschlichen Fähigkeiten. In sicherheitsrelevanten Bereichen ist die Identifizierung von Personen anhand der Videos ein sehr wichtiger Punkt. Die verschiedenen ML-Algorithmen sind dabei nicht nur in der Lage, die Bewegung von Menschen zu verfolgen, sondern diese auch zu identifizieren und bei bestimmten Aktivitäten Alarm zu schlagen. Die Videoüberwachung wird damit zu einer der fortschrittlichsten und wichtigsten Anwendungen des Maschinellen Lernens.

E-Mail-Klassifizierung und Spam-Filterung

ML-Algorithmen werden auch verwendet, um E-Mails zu klassifizieren und Spams automatisch zu filtern. Es gibt eine Reihe von Spam-Filterungsansätzen für E-Mail-Clients, die von ML unterstützt werden, um sicherzustellen, dass diese Spamfilter kontinuierlich aktualisiert werden. Täglich werden über 325.000 Malware-Attacken erkannt und jeder Code weist eine 90–98 prozentige Ähnlichkeit mit den vorherigen Versionen auf. Die Sicherheitsprogramme, die durch Maschinelles Lernen unterstützt werden, verstehen das Codierungsmuster. Daher erkennen sie neue Malware mit einer Abweichung von 2 bis 10% und bieten Schutz vor ihr.

Virtueller Assistent

Virtuelle persönliche Assistenten sind Softwareprogramme, die dazu bestimmt sind, auf natürliche Weise mit einem Endbenutzer zu interagieren, Fragen zu beantworten, einem Gespräch zu folgen und verschiedene Aufgaben zu erledigen. ML-Algorithmen sammeln und verfeinern Informationen auf der Grundlage des früheren Verhaltens eines Benutzers. Dieser Prozess hilft beim Anpassen der Ergebnisse an das Benutzerprofil. Siri, Alexa, Google Assistent sind einige

der bekanntesten Beispiele für virtuelle persönliche Assistenten. Die Genauigkeit, Geschwindigkeit und Kontextfähigkeit von Alexa, Google Assistent und Siri hängen damit von der Qualität der ML-Algorithmen ab.

Produktempfehlung

Die Empfehlung von Produkten und Dienstleistungen z.B. von Google oder Amazon ist die vorausschauende Anwendung der Technik des Maschinellen Lernens. Zur Entwicklung dieses empfehlungs-basierten Systems werden verschiedene Methoden des Maschinellen Lernens unter Einbeziehung von Big Data verwendet. Wer online ein Produkt kauft, erhält anschließend E-Mails mit Einkaufsvorschlägen oder wird über Werbebanner auf Produkte, die ihn interessieren könnten, hingewiesen. Basierend auf dem Kundenverhalten auf bestimmten Websites, früheren Einkäufen und Artikeln, die angeklickt wurden, werden Produktempfehlungen abgegeben.

Social Media

Social Media verwendet Maschinelles Lernen, um den Nutzern z.B. Personen vorzustellen, die sie vielleicht kennen, oder Vorschläge für Aktivitäten zu unterbreiten, die auf Vorlieben, dem Arbeitsplatz oder dem Studienort basieren. Interessen-basierte Anzeigen, Vorschläge von Freunden, Empfehlungen und personalisierte Newsfeeds sind das Ergebnis von ML-Algorithmen, die User-Profile scannen, Bilder durchsuchen und Objekte und Verhaltensmuster identifizieren.

Betrugserkennung

Die großen Mengen an Daten, die im Internet verfügbar sind, sind zwar ein hervorragender Fall für Datenstudien und -analysen, erhöhen jedoch auch die Wahrscheinlichkeit betrügerischer Aktivitäten. ML entwickelt sich zu einer effektiven Technologie zur Sicherung des Cyberspace. ML-Modelle werden verwendet, um verschiedene Arten von Online-Betrug aufzudecken, von der Erkennung anomalen Verhaltens bis zur Verhinderung von Geldwäsche. Die semantische ML-Analyse untersucht strukturierte, unstrukturierte und tabellarische Daten, um gefälschte Behauptungen und Nachrichten zu erkennen. ML-Algorithmen durchsuchen auch vorhandene Nachrichtenrepositorys, um ähnliche Behauptungen zu finden und die Echtheit einer Nachricht zu überprüfen.

Dynamische Preisgestaltung

Unternehmen können ihre historischen Preisdaten zusammen mit Datensätzen anderer Variablen auswerten, um zu verstehen, wie sich bestimmte Dynamiken - von der Tageszeit über das Wetter bis hin zu den Jahreszeiten - auf die Nachfrage nach Gütern und Dienstleistungen auswirken. Algorithmen des Maschinellen Lernens können aus diesen Informationen lernen

und diese Erkenntnisse mit zusätzlichen Markt- und Verbraucherdaten kombinieren, um Unternehmen bei der dynamischen Preisgestaltung ihrer Waren zu unterstützen - eine Strategie, die den Unternehmen letztlich bei der Umsatzmaximierung hilft.

Medizinische Diagnose

Maschinelles Lernen beinhaltet eine Reihe von Techniken und Werkzeugen, um die diagnostischen und prognostischen Probleme in den verschiedenen medizinischen Bereichen zu lösen. ML-Algorithmen werden häufig zur Analyse medizinischer Daten verwendet, um Regelmäßigkeiten in Daten zu erkennen, Daten zu verarbeiten, Daten zu interpretieren und Patienten effektiv zu überwachen. Maschinelles Lernen hilft auch bei der Abschätzung und Vorhersage von Krankheitsausbrüchen, bei der Verarbeitung medizinischer Informationen für die Forschung, bei der Planung und Unterstützung von Therapien sowie beim gesamten Patientenmanagement.

Fazit:

Die Akzeptanz des Maschinellen Lernens nimmt sprunghaft zu und das ist angesichts seiner Vorteile nicht überraschend, da manuelle Aufgaben eliminiert und nützliche Erkenntnisse aus Daten gewonnen werden müssen. In diesem Artikel haben wir uns mit bestimmten Anwendungsfällen des Maschinellen Lernens befasst. Dies sind jedoch nur die häufigsten Beispiele für Maschinelles Lernen. Weitere bemerkenswerte Erwähnungen sind Finanzanalyse, maschinelle Übersetzung, statistische Schiedsgerichtsbarkeit, digitales Marketing, Smart-Grid-Management und vieles mehr.

Das Spektrum der Anwendungen und Anwendungsfälle wird sich in den nächsten Jahren sicherlich noch erweitern. Man darf daher gespannt sein, wie und in welchen Bereichen Maschinelles Lernen eingesetzt wird, um die Effizienz zu verbessern, Kosten zu senken und eine bessere Benutzererfahrung zu erzielen.

Milad Safar

Wie funktioniert Retourenvermeidung im Online-Shopping durch KI?

Der Onlinehandel wächst – und damit auch die Anzahl der Rücksendungen. Für den Verbraucher ist es unkompliziert, bequem und meist kostenlos: Jede sechste Online-Bestellung wird als Retoure zurückgeschickt. Davon landet öfter mal ein Teil im Müll. Um Ressourcen zu sparen und Retouren zu minimieren, lassen sich mithilfe von Künstlicher Intelligenz (KI) und Data Science clevere Modelle entwickeln. Das eröffnet zudem weitere Vorteile.

Die Bundesregierung will Händler gesetzlich dazu verpflichten, entsprechende Waren, so weit wie mög-



Milad Safar,
Managing Partner,
Weissenberg Group

lich, erneut zu verkaufen oder wiederverwertbar zu machen. Damit soll verhindert werden, dass eigentlich noch hochwertige Artikel vernichtet werden, dies ist insbesondere im Onlinehandel üblich, um Platz in den Regalen zu schaffen oder weil zurückgesendete Artikel wegzwerfen günstiger ist als sie erneut zu verkaufen.

Dieses Gesetz wird viele Online- und Versandhändler vor massive Probleme stellen. Grund genug, sich ein paar Gedanken zu dieser Thematik und deren Lösung zu machen.

Jungfrau (40), männlich, sucht ...

Ein typisches Retouren-Szenario aus dem Onlinehandel könnte beispielsweise wie folgt aussehen:

Ein fiktiver Kunde, 39 Jahre alt, männlich, verheiratet, lebt in einer Großstadt in Deutschland, hat zwei Kinder, besitzt einen höheren Bildungsabschluss, arbeitet als Teamleiter in einer IT-Firma, wohnt in einem Reihnhaus, besitzt ein Auto, einen Hund, geht gerne Bergwandern und spielt in seiner Freizeit gerne Fußball.

Er hat kürzlich im Onlinehandel zwei Anzüge bestellt, einen dunkelgrauen und einen dunkelblauen, sowie ein paar Schuhe und eine Regenjacke für das Bergwandern.

Als die Bestellung bei ihm daheim ankommt, stellt er fest, dass die Schuhe wie angegossen passen, die Regenjacke zwar passt, aber die Farbe nicht ganz so wie auf dem Bild aussieht und einer der Anzüge zu groß ist.

Einen der Anzüge (dunkelblau) und die Regenjacke schickt er zurück.

Diese Sendung kommt nach ein paar Tagen beim Versandhaus als Retoure zurück und muss aufbereitet werden, um wieder in den Verkauf zu gelangen.

Für das Versandunternehmen stellen sich nun folgende Aufgaben bzw. auch Fragen:

- Wie viele Retouren sind insgesamt pro Zeiteinheit und Periode zu erwarten?
- Welcher Art werden diese Retouren sein, d. h. was ist der Grund für den Rückversand und um welche Produkte geht es hauptsächlich?
- Wie hoch wird der Aufbereitungsaufwand sein?
- Welche Art von Bestellung bedingt welche Retouren (Art, Zustand, Menge)?
- Gibt es Kundenprofile, die besonders wenig, oder auch besonders viele Retouren verursachen?
- Bei welchem Kundentyp habe ich mit welcher Art von Retoure und welcher Häufigkeit zu rechnen?
- Wie viele interne Ressourcen und Mitarbeiter muss ich wann und wie einsetzen, um diese Retouren aufzuarbeiten?

Ein digitales Profil des Kunden auf Basis von Datenmodellen

Ein wesentlicher Baustein zur Lösung dieser Anforderungen sind Data-Science- und KI-Verfahren, die mit

mathematisch-statistischen Methoden geeignete Vorhersagemodelle entwickeln. Aber auf was stützen sich nun die Analyse und Modellerstellung in der Praxis?

Vor allem auf historische Daten wie dem Bestellverhalten, historischen Kundentransaktionen, der Bestellhistorie und manchmal auch elektronischem Schriftverkehr (E-Mails oder soziale Medien). All diese Informationen werden mit einem geeigneten Algorithmus oder Verfahren des maschinellen Lernens zu einem oder mehreren Modellen verrechnet.

Diese Kundenmerkmale, über alle verfügbaren Kunden analysiert, können zu Profilen bzw. Modellen verarbeitet werden, mit denen sich oben genannte Fragen beantworten und abschätzen lassen. Um diese Profile bzw. Modelle anzulegen, können etwa folgende Kundeninformationen aufschlussreich sein:

Alter	39 Jahre
Altersgruppe	35-50 Jahre
Geschlecht	männlich
Familienstand	verheiratet
Wohnort	städtisch
Kinder im Haushalt	Ja
Bildungsabschluss	Abitur, anschließendes Fachstudium
Beruf	leitender Angestellter
Fachbereich	IT
Hausbesitz	ja
Auto	ja
Haustier	ja
Hobbies	Wandern, Fußball, Sport

Diese Merkmale und ihr oben erwähntes Bestellverhalten lassen vermuten, dass diese Kundin oft online einkauft und dabei drei bis fünf Artikel im Warenkorb liegen, von denen ca. 20 Prozent zurückgesendet werden.

Die Datenmenge entscheidend für den Erfolg

Liegen diese Informationen für den Großteil des Kundenstamms und tagesaktuell vor, dann kann ein Data Scientist für die jeweiligen Profile Kategorien und darauf aufbauend Modelle entwickeln. Dies könnte zum Beispiel der Retourentyp (sendet nie/fast nie zurück, sendet häufig zurück, sendet fast immer zurück) sein, und/oder das Mengengerüst, also die Anzahl der zurückgesendeten Teile und der Aufbereitungsaufwand der Retouren.

Konkret gibt eine derartige Modellierung folgende Einblicke:

- zeit- und saisonabhängige Vorhersagen zu den Mengengerüsten der zurückgesendeten Artikel

- tages- und wochenaktuelle Prognosen zu den benötigten Personalbedarfen
- typische Profile von Rücksendern
- Produkte und Produktkombinationen, welche besonders häufig zurückgesendet werden
- Aufwandsabschätzungen, die für die Aufbereitung und Wiederverwertung nötig sind
- kundenspezifische Affinitätsprofile
- gezieltes Kampagnenmanagement betreiben und
- Vorhersagen zur Kaufwahrscheinlichkeit bestimmter Produkte.

Mit diesen Informationen können anschließend geeignete Maßnahmen ergriffen und Strategien entwickelt werden, um Retouren zu vermeiden.

Das könnten im Einzelnen zum Beispiel detaillierte Produktbeschreibungen sein, die vom KI-Modell gesteuert werden oder maßgeschneiderte, profilspezifische Beratung im Kundencenter. Eine weitere Möglichkeit wäre bereits im Vorfeld, also bevor die Bestellung eingeht, Änderungen im Bezahlssystem bzw. den Bezahlmöglichkeiten vorzunehmen. Oder es werden Maßnahmen ergriffen, die „ungehemmtes“ Bestellverhalten regulieren.

Erste Schritte

Zum Projektstart ist es ratsam gemeinsam mit dem Kunden einen Daten- und Use-Case-Workshop durchzuführen, um mögliche Potenziale aufzudecken und zu bewerten. Abhängig von der individuellen Situation des Kunden dauert so ein Workshop in der Regel ein bis drei Tage.

Ziel des Workshops

Anhand eines konkreten Anwendungsfalls, den der Kunde im Vorfeld definiert, und mithilfe von KI-Lösungen lässt sich abschätzen, welche Resultate und Erfolge mit einer entsprechenden Datenmodellierung zu erwarten sind.

Folgende Ergebnisse lassen sich mithilfe eines Daten- und Use-Case-Workshops erzielen:

- das Unternehmen lernt seine Daten selbst besser kennen und erkennt welche Auswertungspotenziale in ihnen stecken
- die Fachabteilung formuliert ein oder mehrere konkrete Fragestellungen für nützliche Anwendungsfälle
- Gemeinsam werden die analytischen Potenziale in den Daten erforscht und es erfolgt eine Abschätzung, welcher Nutzen für den Kunden aus den Daten zu holen ist
- die Anwender bekommen einen Überblick und ein Gefühl für den geschäftlichen Nutzen einer entsprechenden Modellierung
- der Kunde kann abschätzen wie hoch der Aufwand und die Kosten für ein konkretes Analyseprojekt anzusetzen sind

Auf dieser Grundlage kann sehr fundiert entschieden werden, ob und welche nächsten Schritte sinnvoll sind. Zu Beginn ist meist ein kleines Serviceprojekt mit einer Modellierung sinnvoll, deren Ergebnisse in konkreten Geschäftssituationen anwendbar sind.

Vielseitige Modelle und zusätzlicher Mehrwert für E-Shops

Das Praktische ist, dass diese Modelle je nach Einsatzgebiet, bedarfsgerecht benutzt werden können. Das heißt etwa „händisch“ bei bestimmten Projekten, die einmalig oder periodisch anfallen. Möglich ist jedoch auch eine automatische Nutzung im Batchmodus auf Webseiten, die in Abhängigkeit der Modelle, dynamischen und personalisierten Inhalt aufbauen. Schließlich können sie auch im Rahmen der Kundenberatung bzw. Fallabwicklung in Call-Center-Applikationen zur Unterstützung der Agenten hinzugezogen werden.

Als Folge dieser Vorhersagen und Modellierungsmöglichkeiten ergeben sich verschiedene KPIs und zusätzlicher Mehrwert für das Unternehmen. Gängige Vorteile sind die Zeit- und Kostenersparnis in zahlreichen Geschäftsbereichen, effizienter Personaleinsatz, bessere Planungsgrundlagen. Aber auch erhöhte Kundenzufriedenheit und Kundenloyalität wegen der verbesserten Fallabwicklung und die oft höhere Wertschöpfung sowie erhöhte Verkaufspotenziale aufgrund besserer und personalisierter Kundenansprache machen Online-Händler wettbewerbsfähig.

Analyse und Modellerstellung geben Online- und Versandhändlern nicht nur umfassende Einblicke in das Bestellverhalten ihrer Kunden, sondern mit ihrer Hilfe lässt sich auch Retouren besser vorhersehen – und im Idealfall sogar ganz vermeiden. Unternehmen aus dem E-Commerce sollten daher die Möglichkeiten und Potenziale von Data Science und KI-Verfahren nutzen, um effektiv Kosten zu senken und einzusparen.

Dr. Christian Trippner

Wie man KI Use Cases findet und priorisiert

Das Finden und Priorisieren von passenden KI Use Cases ist eine Herausforderung für viele Unternehmen. Das wirkliche Problem stellt sich aber für die Unternehmen, die die Herausforderung unterschätzen und glauben, dass sie die Methoden zur Auswahl erfolgreicher KI-Anwendungsfälle „schon kennen“ - schließlich haben die meisten Firmen digitale Programme durchlaufen und Use Cases für Big Data identifiziert. Philipp Hartmann und Maria Schamberger von Applied AI zeigen, dass dies tatsächlich nicht der Fall ist und worauf man bei Identifizierung und Priorisierung von KI Use Cases achten sollte.

Unternehmen erhoffen sich neue, innovative Geschäftsmodelle und durchaus auch Einsparungen durch



Dr. Christian Trippner,
Senior Technical Specialist,
IBM

KI, doch die Kosten einen „falschen“ AI Use Case zu verfolgen sind hoch: Zum einen sind die Investitionen in die Anwendung verloren, oftmals unterschätzt werden bei KI Projekten auch der Aufwand für Skalierung und Betrieb der Anwendung. Aber neben den direkten Kosten können die langfristigen Folgen noch „teurer“ sein: Gescheiterte AI Projekte können die Akzeptanz für KI als neue Technologie im Unternehmen gefährden und so erhebliche „Kollateralschäden“ erzeugen. Mit der richtigen Vorbereitung und dem richtigen Verständnis der spezifischen Herausforderungen von KI-Anwendungsfällen können Fehlentwicklungen vermieden werden.



Dr. Philipp Hartmann,
Director of
AI Strategy,
appliedAI

1. Vorbereitung

Wichtig ist, dass alle Beteiligten ein ausreichendes Verständnis von KI haben – das bedeutet allerdings nicht, dass alle Mitarbeiter Machine Learning Engineers werden müssen. Jedoch sollten alle ein Grundverständnis von KI und der Technologie dahinter haben, sowie konkrete Beispiele aus der Branche und typische Hürden und Fallstricke in einem geschäftlichen Kontext kennen. Dies lässt sich zum Beispiel durch einen KI Einführungsworkshop erreichen.

Darauf aufbauend sollten Unternehmen zunächst eine Art genereller KI Vision entwickeln. Wichtig ist außerdem, die eigene Ausgangssituation realistisch zu beurteilen. Dazu gehört es zu klären, ob die Datengrundlage gegeben ist, aber auch ob die Unternehmenskultur und die Belegschaft wirklich „AI-ready“ sind. Eine ehrliche Selbstbeurteilung bereits in dieser frühen Phase hilft dabei, Fehler im späteren Prozess zu vermeiden.

2. Ideenfindung

Für die Entwicklung von KI Use Cases müssen die Fachexperten mit den KI Experten zusammengebracht werden. Ist im Unternehmen selbst keine KI Expertise vorhanden, sollten externe Experten zu Rate gezogen werden. Allerdings sollten Unternehmen auf jeden Fall den Prozess auch dafür nutzen, ihre eigenen Kompetenzen auszubauen.

Die Use-Case-Ideenfindung einem strukturierten Prozess folgen. Die übergeordnete KI-Vision eines Unternehmens legt dabei fest, auf welche Bereiche man sich konzentrieren sollte, um den größtmöglichen Vorteil zu erringen.

Bei prozesszentrierten KI-Anwendungsfällen liegt der Schwerpunkt entweder auf internen Prozessen oder an der Schnittstelle zu Kunden, Partnern und Lieferanten. Häufig liegt der Wettbewerbsvorteil in den Kernprozessen des Unternehmens. Hier sollte man zuerst ansetzen und sich fragen, was automatisiert werden kann. Zum Beispiel kann ein Versicherungsunternehmen Bilderkennung einsetzen um Autounfall-schäden mit eingeschränkter menschlicher Aufsicht automatisch zu bewerten. Dadurch werden die Kosten

für die Bearbeitung von Schadensfällen signifikant gesenkt, während das Unternehmen gleichzeitig Zeit spart und die Kundenzufriedenheit erhöht.

Produkt- und dienstleistungszentrierte KI-Anwendungsfälle sind oft schwieriger zu definieren, da sie mehr technische Expertise und Kundenerfahrung erfordern. Sie können von der Einbeziehung von Design- oder User-Experience-Experten in die Ideenfindung profitieren. Andererseits erfordert die KI in Unternehmensangeboten im Vergleich zu prozesszentrierten Fällen weniger Change Management später in der Implementierungsphase.

3. Bewertung der Use Cases

Sobald man eine Liste potentieller Anwendungsfälle zusammengetragen hat, geht es darum, zu beurteilen, aus welcher Idee ein konkreter Use Case werden kann. Unternehmen sollten zunächst die folgenden Punkte beachten. 1. Komplexität der Implementierung, die wiederum von Datenverfügbarkeit, -Qualität und Updates abhängt. 2. Kosten-Nutzen-Aspekt, wobei es um den erhofften Mehrwert und die benötigten Mittel geht.

Weiterhin sollten die folgenden vier Kategorien evaluiert werden:

- Daten:** Welche Daten werden benötigt und in welcher Qualität sind diese verfügbar? Welcher Aufwand ist nötig, um diese Daten zu integrieren? Welche dynamischen Updates sind über die Zeit nötig und wie lassen sich diese durchführen?
- Algorithmen:** Gibt es bereits Implementierungen des Use Cases, entweder im eigenen Unternehmen oder außerhalb?
- Prozesse und Systeme:** Welche Prozesse und Systeme werden durch das Projekt beeinflusst? Müssen an existierenden Prozessen und Systemen signifikante Änderungen vorgenommen werden?
- Notwendige Erfahrung:** Sind die nötigen technischen Skills und das entsprechende Fachwissen im Unternehmen vorhanden?

Neben diesen verfahrenstechnischen Aspekten sollten aber auch mögliche regulatorische und ethische Einwände diskutiert werden. Unternehmen müsse sich außerdem über Risiken und Transparenzanforderungen klarwerden. Natürlich spielt auch Cyber-Sicherheit eine wichtige Rolle.

4. Priorisierung

Der naheliegende Ansatz besteht darin, die Ergebnisse der Bewertungsphase in einer Prioritätsmatrix darzustellen und die attraktivsten Fälle auszuwählen. Dabei sind allerdings mehrere Überlegungen zu berücksichtigen: Erstens ist das Verfahren nicht so linear, wie es scheint. Die Beurteilung von Anwendungsfällen ist tatsächlich ziemlich komplex. In der Regel gibt es eine erste Runde der groben Bewertung und Priorisierung.

Dann ein näherer Blick auf die vielversprechendsten Fälle, gefolgt von einer zweiten Runde der Überprüfung und Priorisierung.

Zusätzlich zu diesem iterativen Ansatz werden Unternehmen in der Regel mit zwei weiteren Fragen konfrontiert: Oft scheinen viele Anwendungsfälle auf erhebliche Hürden in der Umsetzung zu stoßen. Es lohnt sich abzuschätzen, inwieweit diese Herausforderungen gelöst werden können, indem man den Anwendungsfall in kleinere Einheiten aufteilt. Ein zweites Problem tritt auf, wenn Anwendungsfälle technisch voneinander abhängig sind. KI-Fähigkeiten wie Computer Vision oder Natural Language Processing können von verschiedenen Anwendungen gemeinsam genutzt werden, und dasselbe kann für Datenbestände und Pipelines gelten.

Daher ist es sinnvoll, Anwendungsfälle nach den folgenden Parametern zu clustern:

- Dem erforderlichen Daten-Input
- Den dafür erforderlichen KI-Ressourcen
- Produkte und Prozesse für welche die Use Cases in Frage kommen

Man sollte die Cluster priorisieren, die den höchsten Wert versprechen und innerhalb eines zuvor festgelegten spezifischen Zeitrahmens relativ einfach zu implementieren sind. Im Idealfall sind diese Cluster die Grundlage für die Erstellung einer Use-Case-Roadmap.

Weitere Informationen zu weiteren AI Use Cases finden Sie hier: <https://www.appliedai.de/hub/how-to-find-and-prioritize-ai-use-cases>

Dr. Philipp Hartmann, Dr. Maria Schamberger

Daten effizient nutzen – Vier Einsatzszenarien, wie Machine Learning dabei helfen kann

Für viele mag Machine Learning (ML) noch nach Zukunftsmusik klingen, dabei ist es bereits Teil unseres Alltags. Virtuelle Assistenten wie Siri oder Cortana verlassen sich darauf, um Nutzerfragen besser zu verstehen und präzise Antworten geben zu können. Ebenso setzen beliebte Unterhaltungsdienste wie Netflix oder Spotify auf maschinelles Lernen, um auf Basis der Nutzerpräferenzen maßgeschneiderte Empfehlungen auszusprechen. Aber auch in deutschen Unternehmen ist die Technologie angekommen, Erfolge zeigen sich schnell. Was bisher allerdings zu kurz kommt, ist sich damit auseinanderzusetzen, welchen Mehrwert ML abseits der geplanten Projekte bietet. Um diesen zu identifizieren, gibt es verschiedene Ansätze.

Viele unserer Interaktionen werden von Machine Learning (ML) gesteuert. Am vertrautesten sind den meisten Verbrauchern Sprachassistenten, Chat-Bots oder Empfehlungs-Engines von E-Commerce-Plattformen. ML-Algorithmen repräsentieren eine Teildisziplin

der künstlichen Intelligenz (KI), die auch anderswo unseren Alltag prägt. Eine Vorstellung davon, wie etabliert diese Zukunftstechnologie quer durch alle Branchen in Deutschland bereits ist, vermittelt die IDG-Studie "Machine Learning 2020". Diese Erhebung zeigt auf, dass fast drei Viertel (73 Prozent) der befragten Unternehmen ML-Projekte gestartet haben. Im Vergleich zur Vorgängerstudie von 2019 sind das fast 20 Prozent mehr. Als Ziele geben die meisten Anwender an, durch ML interne Abläufe verbessern zu wollen (56 Prozent). Was die Einsatzfelder angeht, führen KI- und ML-Applikationen zur Sprachanalyse mit 51 Prozent das Feld an – vor der Bilderkennung und Textanalyse sowie dem Übersetzen von Text (mit jeweils 46 Prozent).

Darüber hinaus sieht ein großer Teil der Studienteilnehmer (44 Prozent) in der Technologie die Chance für neue Geschäftsmodelle und Angebote. Folglich stellt sich die Frage, wie und wo maschinelles Lernen Unternehmen dabei unterstützen kann, innovativ zu agieren und somit Daten besser zu monetarisieren. Als Antwort darauf lassen sich vier Ansätze aufzeigen.

1. Innovationspotenzial aufdecken

Daten aus verschiedenen Bereichen und unterschiedlicher Formate fluten die Systeme in Unternehmen. ML-Lösungen schaffen es, diese riesigen Datenmengen zu verarbeiten und so aufzubereiten, dass sinnvoll mit ihnen weitergearbeitet werden kann. Dafür analysieren Algorithmen die Daten, um beispielsweise Anomalien oder neue Erkenntnisse zu entdecken. So gewonnene Einsichten helfen Unternehmen wiederum dabei, Prozesse, aber auch Kunden besser zu verstehen. Gleichzeitig lassen sich daraus potenzielle Angebote entwickeln und so die datenbasierte Innovation vorantreiben.

Wie das in der Praxis funktioniert, veranschaulicht ein kurzer Ausflug in den Finanzsektor. In einer Bank sind die Kunden das wichtigste Gut. Natürlich erhebt die Bank intern Daten über den Kunden – seien es Kontobewegungen, gesammelte Support-Anfragen oder Versicherungen, die über die Bank abgeschlossen wurden. Aber auch externe Quellen, wie beispielsweise Social-Media-Kanäle geben Auskünfte über den Kunden. Mit Hilfe einer ML-Anwendung lassen sich all diese Daten analysieren und das Profil des Kunden schärfen. Auf dieser Basis ist die Bank in der Lage, die Bedürfnisse und das potenzielle Risiko jedes einzelnen Kunden genau einzuschätzen. Indem sie weiß, wer sowohl einen Kredit benötigt als auch kreditwürdig ist, kann sie diesen Personen automatisiert und gezielt neue Services anbieten – beispielsweise ein Kreditangebot.

2. Den Status quo in Frage stellen

Unser Arbeitsalltag unterliegt heute einem ständigen Wandel, wodurch sich kontinuierlich neue Fragestel-



Florian von Walter,
Manager Solution
Engineering CEMEA,
Cloudera



Dr. Maria Schamberger,
Senior AI Strategist,
appliedAI

lungen ergeben. Viele sind dabei zu komplex, als dass sie mit traditionellen Ansätzen gelöst werden können – menschliches Urteilsvermögen und individuelle Lösungen kommen dabei an ihre Grenzen. Als Alternative bietet sich maschinelles Lernen an. Denn durch den Einsatz multivariater Verfahren lassen sich auch mehrdimensionale Geschäftsprobleme lösen.

Diese Herangehensweise wählte ein spanischer Stromanbieter bereits vor einigen Jahren. Das Unternehmen setzt zur Vorhersage von Stromverbrauchsmustern eine cloudbasierte ML-Plattform ein. Diese analysiert Millionen von Datenzeilen in Sekunden-schnelle und gibt so eine Vorhersage ab, wie viel Strom jeder Kunde verbrauchen wird. Die Firma hat somit eine valide Grundlage, individualisierte Tarife anzubieten, die auf das Nutzungsverhalten der Kunden zugeschnitten sind. So verschaffte sich der Stromanbieter einen Wettbewerbsvorteil in der spanischen Energieversorgungslandschaft.

3. Feintuning über Streaming-Daten in Echtzeit

Wichtig ist, sich nicht auf bestehenden Prozessen auszuruhen. Sobald neue Daten und damit potenzielle Einsichten verfügbar sind, lässt sich ML nutzen, um Optimierungen vorzunehmen. Schnelle Ergebnisse lassen sich beispielsweise im Bereich Kundenservice erreichen. Unterhält beispielsweise ein Telekommunikationsanbieter über das Einspielen von Daten aus verschiedenen Quellen in einen zentralisierten Hub eine 360-Grad-Sicht auf seine Kunden, kann der Kundenberater dem Anrufer auf Basis von Echtzeit-Daten zielgerichtet und personalisiert weiterhelfen.

Live-Daten können darüber hinaus auch zu Prozessinnovationen führen, um wettbewerbsfähiger zu werden. So drängt sich der Einsatz von maschinellem Lernen für Banken auf, um ihr Risikomanagement zu verbessern. Das Überwachen und Auswerten von Streaming-Daten in Echtzeit verkürzt die Zeit für Konformitätsprüfungen, wodurch Anomalien, die auf kriminelle Akte hindeuten könnten, frühzeitig erkannt werden.

4. Das (Un-)Vorhersehbare besser verstehen

Geschäftliche Probleme oder Krisen lassen sich nur schwer vorhersagen. So kommt es vor, dass die Zahl an Kundenbeschwerden unvermittelt exponentiell steigt, plötzlich viele Kunden kündigen oder eine bestimmte Einnahmequelle abrupt versiegt. ML-Lösungen können solche Vorkommnisse nicht vollständig vermeiden. Aber sie helfen dabei, die Frequenz zu reduzieren. Denn die Technik ermittelt mögliche Ursachen – beispielsweise woran es liegt, dass sich Kunden abwenden.

Antworten für den Einzelhandel und Ladengeschäfte liefert beispielsweise eine IoT-Anwendung, die ML nutzt. Sie macht in Echtzeit sichtbar, wie Einkäufer sich im Laden orientieren: Wie viel Zeit verbringen sie in welchem Gang? Wo halten sie sich länger auf, wo

nicht? Die Anwendung kombiniert das exakte Tracking jedes Kunden im Laden mit einer leistungsstarken und skalierbaren Analyse-Engine. Diese Echtzeit-Einsichten helfen Händlern das Einkaufserlebnis im Geschäft für ihre Kunden zu verbessern – etwa durch geänderte Produktplatzierungen.

Vom schnellen Nutzen langfristig profitieren

Maschinelles Lernen wird weiter an Bedeutung gewinnen, da datengesteuertes Lernen das Überleben und das Differenzieren im digitalen Wettbewerb entscheidend fördert. Unternehmen können mit ML ihre Betriebseffizienz verbessern, ihre Kundenerlebnisse steigern und neue Einnahmequellen erschließen. Wie schnell sich ein Engagement in die Technologie auszahlt, rechnet die IDG-Studie vor: So bringen rund 22 Prozent der ML-Projekte einen sofortigen Nutzen, weitere 22 Prozent nach vier bis acht Wochen. Die meisten Firmen (27 Prozent) stellen nach drei Monaten positive Effekte der ML-Lösungen fest. Die eigenen Erfolgsaussichten erhöht und sichert ab, wer eine sichere, skalierbare und offenen ML-Plattform einsetzt, welche die datengesteuerte Entscheidungsfindung von der Forschung bis zur Produktion beschleunigt.

Unternehmen sollten die Technologie daher in die gesamte Organisation einbetten. Die Best Practice besteht darin, eine KI-Fabrik aufzubauen. Es hat sich bewährt, dafür eine vollständig integrierte Datenplattform und eine ML-Lösung zu verwenden, die auf Open Source basiert und sowohl im eigenen Rechenzentrum (On Premises oder Private Cloud) als auch in der Public Cloud läuft. Data-Science-Teams können mit solch einer Plattform über den gesamten Datenlebenszyklus hinweg zusammenarbeiten.

Entscheidend ist zudem, bestehende Datensilos aufzubrechen, auf die nur einzelne Abteilungen zugreifen. Zudem bildet Big Data eine wichtige Voraussetzung. Letztendlich sind Daten und Datenströme sowie die Fähigkeit, diese in großen Mengen zu speichern, die Grundlage für Machine Learning.

Florian von Walter

1.2 COMPLIANCE

Wie kommt Ethik in die Künstliche Intelligenz?

Künstliche Intelligenz verspricht Innovationen, die den Menschen in seiner Arbeit und im Alltag hilfreich unterstützen könnten. Inwieweit diese tatsächlich realisiert werden, hängt maßgeblich davon ab, ob die Menschen Vertrauen in die Technologie setzen. Welche Herausforderungen ergeben sich für die verantwortungsbewusste Entwicklung und Anwendung

von KI-Systemen? Nach welchen Kriterien sollen diese umgesetzt werden? Und was können Unternehmen tun, um KI diskriminierungsfrei anzuwenden? Antworten darauf liefert ein Leitfaden der Plattform Lernende Systeme.

Neue Technologien werden immer dann Gegenstand der gesellschaftlichen und wissenschaftlichen Ethik-Diskussion, wenn sie zu Verunsicherungen führen und neue moralische Probleme aufwerfen. Das ist etwa der Fall, wenn Künstliche Intelligenz zu Diskriminierungen oder ungewissen, riskanten Handlungsfolgen führt, z. B. bei ihrem Einsatz in Autos oder in kritischen Infrastrukturen wie dem Energiesektor.

Die KI-Entwicklung soll der Gesellschaft dienen und nicht dazu führen, dass neue technische oder wirtschaftliche Zwänge entstehen, die ethische Normen des Zusammenlebens verletzen oder positive Entwicklungen beschränken. Das ist ja eigentlich damit gemeint, wenn in vielen politischen Dokumenten und Reden von „KI für den Menschen“ die Rede ist. Generell ist es wichtig, die Handlungsrouinen und Handlungsempfehlungen, die durch KI-Systeme vorgegeben werden, nicht als alternativlos bzw. als „Sachzwang“ anzuerkennen. Wie in andere technische Produkte auch, sind in KI bestimmte, veränderbare Zwecke und Präferenzen eingeschrieben, die bestimmten Gruppen und Individuen nutzen, anderen aber schaden können.

Technische Innovationen schaffen häufig neue Handlungsräume, für die bekannte ethische Verhaltensformen keine Antwort geben. Sie müssen also neu diskutiert, reflektiert und ausgehandelt werden. Um diesen Prozess gesellschaftlich für KI voran zu bringen, müssen ethische Leitlinien erstellt und vor allem auf ihre praktische Umsetzbarkeit geprüft werden.

Selbstbestimmung, Gerechtigkeit und Privatheit als Grundwerte

Die Entwicklung des Leitfadens „Ethik-Briefing für eine verantwortungsvolle Entwicklung und Anwendung von KI“ der Plattform Lernende Systeme war getrieben von der Überzeugung, dass die erarbeiteten Werte, Kriterien und Handlungsoptionen nicht losgelöst von ihrer praktischen Anwendung betrachtet werden können. Deshalb steht in den Briefings eine übersichtliche Orientierung an zentralen Leitwerten der KI-Entwicklung im Vordergrund: Selbstbestimmung, Gerechtigkeit und Schutz der Privatheit. Aus diesen Werten werden Konkretisierungen abgeleitet und für die praktische Umsetzung ausgearbeitet.

Was bedeutet z. B. Selbstbestimmung im Kontext von KI-Anwendungen? Es ist häufig davon die Rede, dass KI die Autonomie des Menschen beschränken oder sogar selbst autonome Entscheidungen treffen könnte, die dem Menschen schaden. Trotzdem machen ja gerade die Fähigkeiten von KI-Systemen zum selbstständigen Lernen und ihre Anpassungsfähigkeit ihren Reiz aus. KI-Systeme sollen den Menschen ent-

lasten; damit dies aber nicht auf Kosten, sondern zur Unterstützung der menschlichen Selbstbestimmung passiert, sind bestimmte Rahmenbedingungen und Regeln entscheidend.

Auf individueller Ebene gehören dazu ein verständliches Interaktionsdesign, Transparenz oder ein „Aus-Knopf“ zur Unterbrechung einer KI-Anwendung – und natürlich der Vorbehalt der menschlichen Letztentscheidung. Auch auf infrastruktureller Ebene gibt es viele Ansätze um Selbstbestimmung umzusetzen. Hier geht es vor allem um die Sicherung von Vielfalt in Hinsicht auf Dienste und Anbieter. Gerade im boomenden Bereich der Plattformökonomie – also einer Marktstruktur, in der digitale Plattformen Anbieter und Konsumenten über einen vorstrukturierten Handels- und Kommunikationsplatz zusammenbringen – herrschen monopolartige Strukturen vor. Da die Programmierung von leistungsstarken KI-Systemen ressourcenaufwendig und kostenintensiv ist, ist zu erwarten, dass von großen Anbietern eingesetzte, erfolgreiche KI-Systeme diese Macht weiter vergrößern. Um die Vielfalt auch im Bereich der digitalen Ökonomie zu gewährleisten, Wahlmöglichkeiten zu erhalten und damit Selbstbestimmung zu fördern, sollten insbesondere große Anbieter ihre Systeme interoperabel konzipieren und offene Schnittstellen in ihre Systeme integrieren.

Ethics by, in and for Design

Wie das Beispiel zeigt, geht es nicht nur um das richtige oder falsche Handeln von Individuen, sondern ebenso um die Schaffung von Strukturen, die ethisches Handeln ermöglichen und unterstützen. Wert- und Gemeinwohlorientierung von KI spiegeln sich deshalb auch in dem Aufbau von technischen Rahmenbedingungen wider.

Dementsprechend beschäftigen sich zahlreiche Ansätze aus Wissenschaft, Recht und Politik mit einem „ethics by, in and for design“-Ansatz. Ethische Prinzipien sollen demnach von Anfang an in die Entwicklung von KI-Systemen einbezogen werden.[1]

Ein zentraler Akteur für die Umsetzung von ethischen Designentscheidungen sind Unternehmen und Start Ups. Die aus ethischer Sicht relevanten Aspekte einer Technikentwicklung beginnen jedoch nicht erst im Rahmen der Arbeit der entwickelnden Ingenieurinnen und Ingenieure. Bereits die strategische Ausrichtung eines Unternehmens und die hinter der Technologieentwicklung stehenden Konzepte zur Kommerzialisierung sind wesentliche Elemente für ein gelingendes ethisches Gesamtkonzept.

Ein wichtiges Ziel von anwendungsbezogenen Ethikkodizes und auch spezifisch des „Ethik-Briefings“ der Plattform Lernende Systeme ist demnach die Rückkopplung der Werte und Handlungsoptionen an die unternehmerische Praxis. Im Zentrum steht dabei die Frage, ob die theoretischen Werte in der Praxis re-



Jessica Heesen,
Universität
Tübingen / Plattform
Lernende Systeme

Wert: Selbstbestimmung	
Prinzipien <ul style="list-style-type: none"> Förderung der Autonomie Verantwortungswahrnehmung 	Notwendige Voraussetzungen <ul style="list-style-type: none"> Erklärbarkeit Nachvollziehbarkeit Vielfalt des Marktangebots Offene Schnittstellen und Systemoperabilität
Wert: Gerechtigkeit	
Prinzipien <ul style="list-style-type: none"> Gleichheit Diskriminierungsfreiheit Diversität und Vielfalt Fairer Zugang zu den Vorteilen von KI Nachhaltigkeit 	Notwendige Voraussetzungen <ul style="list-style-type: none"> Auskunftspflichten im Entwicklungs- und Anwendungszyklus Zurechenbarkeit von Verantwortung und Rechenschaft
Wert: Schutz der Privatheit und der Persönlichkeit	
Prinzipien <ul style="list-style-type: none"> Privatsphäre als Rückzug aus der Öffentlichkeit Anonymität als Privatheit in der Öffentlichkeit Informationelle Selbstbestimmung Integrität der persönlichen Identität 	Notwendige Voraussetzungen <ul style="list-style-type: none"> Transparenz als zentrale Forderung von Datenschutz Minimierung der Datenerhebung und -verarbeitung, insbesondere personenbezogene Daten Privacy by Design

Prinzipien für die verantwortungsbewusste KI-Entwicklung
Quelle: Plattform Lernende Systeme

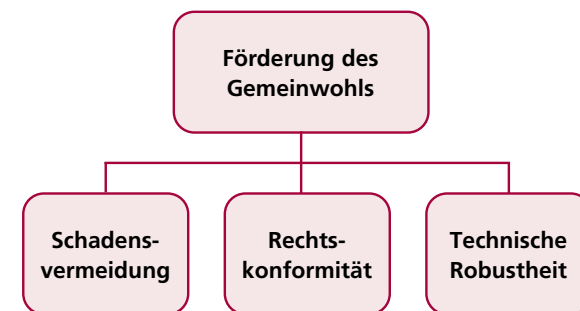
alisierbar sind. Bereits heute legen viele Unternehmen Wert auf einen ethisch basierten Entwicklungs- und Anwendungsprozess von KI-Systemen. Dabei spielen verschiedene Faktoren eine Rolle: die Unternehmenskultur und -ethik, der Absatzmarkt für „gute“ Produkte und auch die Erfüllung rechtlicher Standards.

Wunsch nach verbindlichen Regeln

Eine gängige Befürchtung lautet: Die Einhaltung von ethischen Werten und Prinzipien, die nicht vorrangig der Logik des Marktes folgen, führen dazu, im freien Wettbewerb Nachteile zu erleiden und damit wirtschaftlich abgehängt zu werden. Diese Sorge teilen die im Ethik-Briefing befragten Unternehmen jedoch nicht und auch im globalen Kontext, wird der Wunsch nach verbindlichen Regeln für alle immer deutlicher.

Ethische Prinzipien und Werte sind der Ausgangspunkt für vertrauenswürdige KI. Sie bilden damit die Grundlage für eine mögliche Regulierung und Zertifizierung von KI-Systemen, für die es aktuell zahlreiche Bestrebungen gibt.[2] Für eine Zertifizierung spielt vor allem die Frage nach der Kritikalität von KI-Systemen eine bedeutende Rolle. Nicht für jede KI-Anwendung sind ethische Standards gleich dringlich. Allgemein lässt sich die Faustformel aufstellen: Je höher die Risiken durch den Einsatz eines Systems sind, desto mehr Gewicht soll bereits im Entwicklungsprozess die Einhaltung ethischer Prinzipien haben.

Jessica Heesen



Ethische Anforderungen an KI-Systeme
Quelle: Plattform Lernende Systeme

Weiterführende Literatur: Jessica Heesen et al. (Hrsg.): Ethik-Briefing. Leitfaden für eine verantwortungsvolle Entwicklung und Anwendung von KI-Systemen – Whitepaper aus der Plattform Lernende Systeme, München 2020: https://www.plattform-lernende-systeme.de/files/Downloads/Publikationen/AG3_Whitepaper_EB_200831.pdf
Jessica Heesen, Jörn Müller-Quade, Stefan Wrobel et al. (Hrsg.): Zertifizierung von KI-Systemen – Kompass für die Entwicklung und Anwendung vertrauenswürdiger KI-Systeme. Whitepaper aus der Plattform Lernende Systeme, München 2020: https://www.plattform-lernende-systeme.de/files/Downloads/Publikationen/AG1_3_Whitepaper_Zertifizierung_KI_Systemen.pdf
Referenzen: [1] Siehe z. B. High Level Expert Group on Artificial Intelligence der EU-Kommission (HLEG), <https://ec.europa.eu/digital-single-market/en/high-level-expert-group-artificial-intelligence>; OECD Council Recommendation on Artificial Intelligence, <https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449>; AI Ethics Impact Group, https://www.bertelsmann-stiftung.de/fileadmin/files/BSI/Publikationen/GrauePublikationen/WKIO_2020_final.pdf [2] Siehe die KI-Normungsrroadmap, <https://www.din.de/de/forschung-und-innovation/themen/kuenstliche-intelligenz/normungsrroadmap-ki>

Regulierung Künstlicher Intelligenz: Ein praktischer Ratgeber für die Praxis

Die Expertengruppe für KI der EU (High Level Expert Group on AI) hat mit einer Reihe von Leitlinien das Ziel verfolgt, einen Rahmen für die Verwirklichung einer vertrauenswürdigen KI zu setzen. Es soll sich dabei um eine Hilfestellung für die mögliche Umsetzung von Prinzipien in soziotechnischen Systemen handeln. Der Rahmenplan geht dabei auf Bedenken in der Öffentlichkeit ein, etwa dass KI-Systeme als Sündenböcke genutzt werden, um der Verantwortung für Diskriminierung, Unfälle oder andere Schäden zu entgehen.[1]

Die ethischen Grundsätze im KI-Kontext lauten wie folgt:

- 1. Achtung der menschlichen Autonomie:** KI-Systeme sollen Menschen nicht auf ungerechtfertigte Weise diskriminieren, täuschen oder herabsetzen. Sie sollen zur Entwicklung sinnerfüllter Arbeit dienen.
- 2. Schadensverhütung:** KI-Systeme sollen keinen Schaden bewirken. Dazu zählt der Schutz der geistigen und körperlichen Unversehrtheit. Technische Robustheit soll dabei das Missbrauchsrisiko reduzieren.
- 3. Fairness:** KI-Systeme sollen Chancengleichheit beim Zugang zu Gütern und Bildung begünstigen. Insbesondere sollte ihr Einsatz nicht zur Folge haben, dass Nutzer in ihrer Wahlfreiheit beschränkt werden.
- 4. Erklärbarkeit:** Entscheidungen und Prozesse müssen transparent und verständlich bleiben. Dauerhaftes Vertrauen in die KI kann nur durch eine offene Kommunikation ihrer Fähigkeiten und ihrer Einsatzzwecke hervorgehen.

Gerade dieser vierte Punkt der Transparenz und Erklärbarkeit hat dabei meine eigene Erfahrung und Arbeit in einer Expertengruppe auf EU-Ebene für digitale Ethik in Versicherungen geprägt. Folgende Leitfragen können daraus Praktikern in direkter Ansprache mitgegeben werden:

Haben Sie als Praktiker in einer wirtschaftlichen Organisation Maßnahmen festgelegt, die die Rückverfolgbarkeit von KI-Aktivitäten sicherstellen können? Dies könnte die Dokumentation folgender Methoden beinhalten, strukturiert nach den vier Facetten der Nachvollziehbarkeit, Erklärbarkeit selbst, Kommunikation sowie Rechenschaftspflicht:

Nachvollziehbarkeit

- Methoden, die für den Entwurf und die Entwicklung des algorithmischen Systems verwendet werden:
 - Regelbasierte KI-Systeme: die Methode der Programmierung oder wie das Modell aufgebaut wurde
 - Lernbasierte KI-Systeme: die Methode des Trainings des Algorithmus, einschließlich der Frage, welche Eingangsdaten gesammelt und ausgewählt wurden und wie dies geschehen ist.
- Methoden zum Testen und Validieren des algorithmischen Systems:
 - Regelbasierte KI-Systeme: die zum Testen und Validieren verwendeten Szenarien oder Fälle
 - Lernbasiertes Modell: Informationen über die zum Testen und Validieren verwendeten Daten
- Ergebnisse des algorithmischen Systems:
 - Die Ergebnisse des Algorithmus oder die vom Algorithmus getroffenen Entscheidungen sowie mögliche andere Entscheidungen, die sich aus verschiedenen Fällen ergeben würden (z. B. für andere Untergruppen von Benutzern).

Erklärbarkeit

Haben Sie bewertet:

- inwieweit die Entscheidungen und damit das Ergebnis des KI-Systems nachvollziehbar sind?
- inwieweit die Entscheidung des Systems die Entscheidungsprozesse der Organisation beeinflusst?
- warum dieses spezielle System in diesem speziellen Bereich eingesetzt wurde?
- wie das Geschäftsmodell des Systems aussieht (z.B. wie schafft es Wert für die Organisation)?
- Haben Sie eine Erklärung dafür sichergestellt, warum das System eine bestimmte Wahl getroffen hat, die zu einem bestimmten Ergebnis geführt hat, das alle Benutzer verstehen können?
- Haben Sie das KI-System von Anfang an mit Blick auf die Interpretierbarkeit konzipiert?
- Haben Sie recherchiert und versucht, ein möglichst einfaches und interpretierbares Modell für die jeweilige Anwendung zu verwenden?
- Haben Sie bewertet, ob Sie Ihre Trainings- und Testdaten analysieren können? Können Sie dies im Laufe der Zeit ändern und aktualisieren?
- Haben Sie bewertet, ob Sie die Interpretierbarkeit nach der Schulung und Entwicklung des Modells überprüfen können oder ob Sie Zugang zum internen Workflow des Modells haben?

Kommunikation

- Haben Sie den (End-)Nutzern durch einen Disclaimer oder anderweitig mitgeteilt, dass sie mit einem KI-System und nicht mit einem anderen Menschen interagieren? Haben Sie Ihr KI-System als solches gekennzeichnet?
- Haben Sie Mechanismen eingerichtet, um (End-)Nutzer über die Gründe und Kriterien hinter den Ergebnissen des KI-Systems zu informieren?
 - Haben Sie dies dem Zielpublikum klar und verständlich kommuniziert?
 - Haben Sie Prozesse etabliert, die das Feedback der Anwender berücksichtigen und das System damit anpassen?
 - Haben Sie über potenzielle oder wahrgenommene Risiken, wie z.B. Verzerrungen, informiert?
 - Haben Sie – je nach Anwendungsfall respektive use case – die Kommunikation und Transparenz gegenüber anderen Zielgruppen, Dritten oder der Öffentlichkeit berücksichtigt?
- Haben Sie den Zweck des KI-Systems geklärt und wer oder was von dem Produkt/der Dienstleistung profitieren kann?
 - Haben Sie Nutzungsszenarien für das Produkt spezifiziert und diese klar kommuniziert, um sicherzustellen, dass es verständlich und angemessen für die vorgesehene Zielgruppe ist?
 - Haben Sie, je nach Anwendungsfall, über die menschliche Psychologie und mögliche Einschränkungen wie Verwechslungsgefahr, Bestätigungsverzerrung oder kognitive Ermüdung nachgedacht?



Dr. Christian Hugo Hoffmann,
Postdoc,
ETH Zurich

- Haben Sie Eigenschaften, Einschränkungen und mögliche Unzulänglichkeiten des KI-Systems klar kommuniziert?
 - Im Falle der Entwicklung des Systems: an denjenigen, der es in einem Produkt oder einer Dienstleistung einsetzt?
 - Im Falle des Einsatzes des Systems: an den (End-)Nutzer oder Verbraucher?

Rechenschaftspflicht

Überprüfbarkeit:

- Haben Sie Mechanismen eingeführt, die die Überprüfbarkeit des KI-Systems erleichtern, wie z.B. die Sicherstellung der Rückverfolgbarkeit und die Protokollierung der Prozesse und Ergebnisse des KI-Systems?
- Haben Sie bei grundrechtsrelevanten Anwendungen (einschließlich sicherheitskritischer Fragen) berücksichtigt, dass das KI-System unabhängig respektive von einer dritten Seite auditiert werden kann?

Dokumentation von Kompromissen:

- Haben Sie einen Mechanismus eingerichtet, um relevante Interessen und Werte, die vom KI-System betroffen sind, und mögliche Kompromisse zwischen ihnen zu identifizieren?
- Wie entscheiden Sie über solche Trade-offs? Haben Sie erreicht, dass die Entscheidung über den Kompromiss dokumentiert wurde?

Fähigkeit zur Wiedergutmachung:

- Haben Sie ein angemessenes System von Mechanismen geschaffen, das im Falle des Auftretens von Schäden oder nachteiligen Auswirkungen Abhilfe schafft?
- Haben Sie Mechanismen eingesetzt, um sowohl (End-)Nutzer/Dritte über die Möglichkeiten der Rechtsdurchsetzung zu informieren?

Minimierung und Berichterstattung über negative Auswirkungen:

- Haben Sie eine Risiko- oder Folgenabschätzung für das KI-System durchgeführt, die verschiedene (in) direkt betroffene Stakeholder berücksichtigt?
- Haben Sie Schulungen und Trainings angeboten, um die Entwicklung von Rechenschaftspflichtpraktiken zu unterstützen?
 - Welche Mitarbeiter oder Zweige des Teams sind involviert? Gehen die Trainings über die Entwicklungsphase hinaus?
 - Vermitteln diese Schulungen auch den möglichen rechtlichen Rahmen, der für das KI-System gilt?
 - Haben Sie die Einrichtung eines "ethischen KI-Prüfungsausschusses" oder eines ähnlichen Gremiums in Betracht gezogen, um die allgemeine Rechenschaftspflicht und die ethischen Praktiken, einschließlich potenziell unklarer Grauzonen, zu

erörtern?

- Haben Sie neben internen Initiativen auch eine Art externe Anleitung vorgesehen oder Auditierungsprozesse zur Überwachung von Ethik und Rechenschaftspflicht eingeführt?
- Haben Sie Prozesse für Dritte (z.B. Lieferanten, Verbraucher, Händler/Verkäufer) oder Arbeitnehmer eingerichtet, um potenzielle Schwachstellen, Risiken oder Verzerrungen im KI-System zu melden?

Fazit

Die voranstehende Liste mit Aspekten und Leitfragen hat zum einen den Zweck, den für (zumindest) in Versicherungen wichtigen vierten Punkt der Erklärbarkeit im Rahmen des KI-Regulierungsvorschlags der High Level Expert Group on AI als einen der zentralen meiner Beiträge vorzustellen. Zum anderen sollte der noch abstrakte und vielleicht mehrdeutige Ansatz durch die EU-Richtlinien mit für die Praxis tauglicheren Leitfragen quasi als Checkliste ausbuchstabiert werden.

Dr. Christian Hugo Hoffmann

Referenzen: [1] Hoffmann, C.H. & Hahn, B. AI & Soc (2019). <https://doi.org/10.1007/s00146-019-00920-z>.

Künstliche Intelligenz im Compliance-Bereich: Drei Anwendungsfelder

Ob Fahrzeuganmietungen, Einkäufe, Überweisungen, der Abschluss von Versicherungsverträgen oder die Kontoeröffnung bei einer Bank: Geschäftsvorgänge werden heute zunehmend online abgewickelt. Der Hintergrund ist nicht nur die flächendeckende Verbreitung von Smartphones und Tablets. Auch gestiegene Ansprüche an die Customer Journey in puncto Schnelligkeit und Komfort sind zu verzeichnen. Unternehmen müssen sich auf diese Kundenbedürfnisse einstellen. Gleichzeitig muss jedoch sichergestellt werden, dass durch die hohe Performance keine Sicherheitslücken entstehen. Künstliche Intelligenz (KI) kann dazu beitragen, Compliance-Vorgaben einzuhalten, ohne die Prozessgeschwindigkeit zu beeinträchtigen. Drei Anwendungsfelder, bei denen der Einsatz von KI mögliche Sicherheitslücken schließen kann:

Szenario 1: Identitätsprüfung

Zahlreiche Unternehmen wie Carsharing-Anbieter, Händler oder Unternehmen aus dem Gaming-Bereich sind gesetzlich zur Durchführung einer Kundenprüfung verpflichtet. Dies gilt im klassischen Geschäft ebenso wie bei Online-Vertragsabschlüssen. Autovermieter und Gaming-Plattformen müssen beispielsweise sicherstellen, dass der Vertragspartner zweifelsfrei identifiziert wird und das gesetzlich vorgeschriebene Mindestalter erreicht hat. Für Betreiber von

Online-Shops hat die Identitätsprüfung ebenfalls Relevanz. Hier gilt es unter anderem, Betrugsfälle wie die Lieferung an fingierte Adressen und die Nichtbezahlung zu verhindern - insbesondere beim Kauf hochpreisiger Artikel auf Rechnung.

Sich an dieser Stelle rein auf die Angaben eines Benutzers zu verlassen, ist selbstverständlich risikobehaftet. Eine Überprüfung der Daten durch Mitarbeiter dauert teils mehrere Stunden und scheidet unter Gesichtspunkten der positiven Benutzererfahrung somit aus. Automatische Verfahren auf Basis künstlicher Intelligenz ermöglichen es, Identitäts- und Altersprüfungen innerhalb weniger Sekunden durchzuführen. Moderne Lösungen werden durch biometrische Systeme ergänzt und können die Verifikation noch zuverlässiger gestalten.

Die Vorteile dieses Ansatzes liegen auf der Hand: Kunden sparen sich lange Wartezeiten und können ihre Transaktion mit geringem Aufwand unabhängig von Ort und Zeit abschließen. Möglicherweise ergeben sich sogar Preisvorteile durch den Wegfall des Risikoaufschlags der Anbieter. Unternehmen realisieren hingegen enorme Kosteneinsparungen und minimieren Compliance-Risiken, ohne die Konversion zu gefährden.

Szenario 2: KYC-Onboarding-Prozesse bei Banken

Auch im Finanzdienstleistungssektor ist Kundenzentrierung das Gebot der Stunde. Eine der wichtigsten Aufgaben ist es in diesem Kontext, den KYC-Prozess im Rahmen des Onboardings signifikant zu verkürzen. Immerhin verursacht die manuelle Sammlung, Aufbereitung und Interpretation von Kundendaten bisweilen einen Aufwand von mehreren Stunden oder sogar Tagen. Trotz dieser Prozesskomplexität ist die Qualität und Vollständigkeit der verarbeiteten Daten oft nicht ausnahmslos garantiert. Es liegt auf der Hand, dass diese Vorgehensweise weder ausgesprochen sicher noch effizient ist. Auch der Kundenerwartung an eine hohe Reaktionsgeschwindigkeit wird sie nicht gerecht.

An dieser Stelle kommen erneut Identifikationsverfahren auf KI-Basis ins Spiel. Speziell bei Banken können entsprechende Lösungen dem Videoidentifikationsverfahren vorgeschaltet werden, um Sicherheitsauffälligkeiten bereits im Vorfeld zu erkennen und herauszufiltern. Die Ergebnisprüfung und -übermittlung erfolgt innerhalb weniger Augenblicke.

Für Finanzdienstleister stellt dieses Verfahren eine zusätzliche Sicherheitskomponente dar. Gleichzeitig entstehen Kosteneinsparungen durch den Wegfall manueller Schritte und die Vermeidung unnötiger Identifikationsprozesse. Auf Kundenseite bietet der Ansatz den Vorteil, dass angegebene Daten bereits vor der Video-Session verifiziert werden, wodurch ein reibungsloses Verfahren gewährleistet ist. Zudem wird der gesamte Vorgang beschleunigt.

Szenario 3: Betrugsprävention

Für die beiden ersten Szenarien (Identitätsprüfung und KYC-Onboarding-Prozesse) existieren bereits Lösungen, die sich in der Praxis mehrfach bewährt haben. Ein KI-Anwendungsbereich, der sich noch am Beginn der technologischen Entwicklung befindet, aber dennoch enormes Potenzial besitzt, ist die Betrugserkennung (Fraud Detection). Sie ist im Rahmen der Identitätsprüfung grundsätzlich für alle Branchen relevant, hat aber im Finanzdienstleistungsbereich besondere Brisanz. Hier stellen Vorfälle wie Kreditkarten- und Versicherungsbetrug ein exponiertes Risiko dar. Aufgedeckt werden Betrugsfälle durch das Erkennen von Anomalien. Für diese Aufgabe ist künstliche Intelligenz prädestiniert. Aufgrund von Trainingsdaten erlernt sie den „Normalzustand“ eines bestimmten Ereignisses. Weichen Vorgänge dann von dem typischen Verhalten ab, schlägt die KI Alarm.

Der Erfolg dieses Ansatzes hängt insbesondere von der zugrunde liegenden Datenbasis ab. Für die Erkennung eines Kreditkartenbetrugs ist es beispielsweise notwendig, das KI-System im Vorfeld mit dem Transaktionsverlauf einer oder mehrerer Banken zu versorgen. Um einen Versicherungsbetrug zu identifizieren, könnten bisherige Schadensmeldungen, Korrespondenzen und Entscheidungen oder auch Metadaten aus sozialen Netzwerken und Lokalisierungsdaten von Mobiltelefonen herangezogen werden.

Im klassischen Szenario der Betrugserkennung greifen meist Wenn-Dann-Regeln. Eine Regel dieser Art könnte beispielsweise wie folgt lauten: Wird dieselbe Kreditkarte innerhalb von zwei Stunden an fünf verschiedenen Geldautomaten zur Abhebung genutzt, dann liegt ein möglicher Betrug vor. In der Folge würde die Karte dann automatisch gesperrt. Ändert der Betrüger allerdings sein Verhalten, so sind Wenn-Dann-Regeln nutzlos. Künstliche Intelligenz benötigt hingegen keine Regeln, sondern erkennt (neue) Muster und Abweichungen in den Daten eigenständig. Im Wettlauf zwischen Sicherheitsmaßnahmen und neuen Betrugsmaschen stellt sie somit einen erheblichen Zeitvorteil dar. Zudem liefert KI deutlich weniger falsch-positive Ergebnisse, als der regelbasierte Ansatz.

KI-basierte Lösungen zur Betrugserkennung beschränken sich natürlich nicht auf das Endkundengeschäft, sondern eignen sich auch zur Bekämpfung organisierter Finanzkriminalität. So sind entsprechende Systeme unter anderem in der Lage, Muster von verdächtigen Geldflüssen zu identifizieren. Dies wiederum ist eine bedeutende Maßnahme gegen Geldwäsche.

Frank S. Jorga



Frank S. Jorga,
Gründer & Co-CEO,
WebID Solutions
GmbH

Diskriminierungsfalle Künstliche Intelligenz: So vermeiden Sie Fehler schon beim Anlernen

Um auch zukünftig wettbewerbsfähig zu bleiben, arbeiten viele Unternehmen bereits mit künstlicher Intelligenz. Viele Firmen trauen sich jedoch nicht an die vielversprechende Technologie ran, denn aktuelle Skandale rund um künstliche Intelligenz lassen vermuten: Die Innovation hat Konfliktpotenzial und kann schnell diskriminierend agieren.

Laut Presseberichten musste Amazon beispielsweise erst kürzlich eine auf künstlicher Intelligenz basierende HR-Software einstellen, denn diese benachteiligte Frauen im Bewerbungsprozess. Auch IBM sah sich nach solchen Berichten veranlasst, eine Gesichtserkennungssoftware vom Markt zu nehmen. Der Grund: Das Programm hatte Schwierigkeiten schwarze Personen zu identifizieren. Egal ob auf Grundlage von Geschlecht, Hautfarbe, Körperform oder Religion, die Beispiele für Diskriminierungen durch künstliche Intelligenz sind zahlreich. Was können Unternehmen also dafür tun, dass es gar nicht erst zu Diskriminierungen kommt?

Die Gefahr erkennen

Diskriminierungen können in verschiedenen Lebensphasen der künstlichen Intelligenz auftreten. Am häufigsten entstehen sie jedoch bereits beim Anlernen der Anwendung. So wird die künstliche Intelligenz schon ganz am Anfang ungewollt dazu veranlasst, diskriminierende Entscheidungen zu treffen. Selbst wenn die künstliche Intelligenz korrekt aufgesetzt ist, kann sie im Laufe ihres Lebenszyklus Muster erlernen, die ebenfalls in diskriminierendem Verhalten enden können.

Entstehen schon beim Anlernen „Fehler“ ist dies jedoch besonders ärgerlich, denn der Grund dafür ist oft - entgegen der schnell getroffenen Annahme nicht die unzureichende Qualität der eingepflegten Daten oder ein fehlerhafter Algorithmus - dass Programmierer und Programmiererinnen zu wenig divers bei der Datenauswahl und -bewertung denken.

Divers denken beim Programmieren

Die Vergangenheit zeigt, dass mangelnde Diversität beim Programmieren häufig zu diskriminierenden Anwendungen führt. Denn ohne diverses Denken beim Anlernen werden im Vorfeld nicht genügend Anwendungsszenarien durchdacht. Ein bekanntes, jedoch rein technisches Beispiel hierfür sind automatisierte Seifenspender eines bestimmten Typs. Diese konnten keine schwarze Hautfarbe erkennen. Der Grund: Die Programmierer der dazu notwendigen Infrarot-Standard-Technologie waren überwiegend kaukasischen Typs und haben die Nutzung von Seifenspendern durch dunkelhäutige Personen nicht bedacht.

Ebenso häufig entstehen Diskriminierungen, weil beim Anlernen der künstlichen Intelligenz auf rein mathematische Aspekte geachtet wird. Bei einer KI-basierten Bewerbungsplattform, könnte der einprogrammierte Algorithmus beispielsweise mathematisch zu der Auswertung kommen, dass Männer für die Produktivität eines Unternehmens wertvoller sind als Frauen – zumindest, wenn er sie an ihren Fehltagen misst. Denn Frauen haben statistisch aufgrund diverser Faktoren, wie Schwangerschaften oder der tradierten Kinderfürsorge, mehr Fehlzeiten als Männer. Normative Korrekturen müssen daher schon im Vorfeld beim Anlernen der künstlichen Intelligenz wortwörtlich einprogrammiert werden.

Der künstlichen Intelligenz Werte beibringen

Die HR-Software zeigt: KI-Anwendungen arbeiten neutral. Sie erkennen Muster und schlussfolgern basierend auf diesen. Entscheidungen von künstlicher Intelligenz reflektieren daher nicht unbedingt die Werte, auf die wir uns innerhalb unserer Gesellschaft geeinigt haben. Schon beim Anlernen der KI-Anwendung sollte daher reflektiert werden, welche – möglicherweise ungewünschten - Schlüsse die KI aus den eingefügten Daten ziehen könnte und welches Ergebnis eigentlich gewünscht wäre.

Den Fehler, dass künstliche Intelligenz aufgrund von Daten ungewollte Rückschlüsse zieht, machte nach den Medien 2016 auch Microsoft. Das Unternehmen hatte einen digitalen Schönheitswettbewerb mitorganisiert, der auf künstlicher Intelligenz basierte. Ziel war es, mithilfe eines Algorithmus und 600.000 eingesendeten Selfies die „schönste“ Person zu küren. Am Ende befand sich unter den 44 gewählten Gewinnern und Gewinnerinnen jedoch nur eine dunkelhäutige Person – was zu Empörung führte. Der Grund dafür war, dass der Algorithmus mit einer Datenbank trainiert wurde, die überwiegend aus Bildern besteht, die Menschen mit kaukasischem Typ abbilden.

Für beide Beispiele gilt: In die Algorithmen, nach denen künstliche Intelligenz arbeitet, müssen normative Werte eingebaut werden, z.B.: Frauen sind wertvolle Mitarbeiterinnen, auch wenn sie statistisch gesehen mehr Fehltag haben als Männer. Ebenso sollte im Vorfeld darüber nachgedacht werden, welche Rückschlüsse die KI aus überwiegend männlichen Bewerbungen ziehen könnte. Es sollte hier vorher definiert werden, dass das Geschlecht kein Maßstab für die Qualifikation eines Bewerbers oder einer Bewerberin ist. Heiß diskutiert wird diese Thematik auch unter Juristen und dem Staat, denn der greift bisher - zumindest beim Anlernen - gar nicht ein.

Keine Regulierungen beim Anlernen der KI

Derzeit geben lediglich unverbindliche Ethik-Leitlinien eine Orientierung beim Anlernen von künstlicher Intelligenz. Führt die Anwendung allerdings

diskriminierende Handlungen aus, drohen rechtliche Konsequenzen. Auch gibt es rechtliche Rahmenbedingungen, die sich aus den allgemeinen Vorschriften ergeben und unbedingt beachtet werden sollten. Beispielsweise kann es Dokumentationspflichten beim Anlernen geben, die erfüllt werden müssen. Werden diese missachtet, kann es sein, dass das Endprodukt nicht angewendet werden darf.

Die aktuelle Rechtslage ist sehr liberal und kommt der Innovation von Unternehmen zu Gute, denn diese können an der künstlichen Intelligenz arbeiten, ohne sich bereits beim Anlernen einer Vielzahl von hemmenden Regularien zu unterwerfen. Dennoch diskutiert der Gesetzgeber derzeit, rechtlich einzugreifen, denn die einprogrammierten Diskriminierungen sind im Nachhinein häufig nur schwer zu erkennen. Dass Amazons Bewerber-Software diskriminierend gegenüber Frauen agierte, soll den Entwicklern beispielsweise erst nach einem Jahr aufgefallen sein.

Trauen Sie sich an künstliche Intelligenz!

Deutsche Unternehmen müssen sich mit Innovationen wie künstlicher Intelligenz auseinandersetzen, um kompetitiv zu bleiben. Ohnehin begünstigt die aktuelle Rechtslage den Innovationsspielraum von Unternehmen.

Nutzen Sie dies, achten Sie jedoch darauf, sich an die ethische Leitlinien zu halten und sich schon beim Anlernen Gedanken darüber zu machen, wie divers das Daten-Set ist, wer die Anwendung benutzen könnte (auch außerhalb des eigenen Typs) und welche unerwünschten Rückschlüsse die KI aus den eingepflegten Daten ziehen könnte. So vermeiden Sie Diskriminierungen und im Zweifel auch staatliches Eingreifen und Angriffe von Konkurrenten.

Jörg-Alexander Paul

1.3 MEDIZIN

Eine zweite Chance: Wie sich Unternehmen besser auf die nächste COVID-19-Welle vorbereiten können

Mittlerweile ist mehr als ein halbes Jahr seit Beginn der Corona-Pandemie vergangen. In vielen Ländern Europas wurden bereits vor über sechs Monaten weitreichende Notfallmaßnahmen eingeführt, um gegen die Verbreitung von COVID-19 vorzugehen. Die Auswirkungen, die das neuartige Virus auf die Gesellschaft hat, sind immens – sowohl in humanitärer als auch in geschäftlicher Hinsicht.

Die Pandemie hat zu erheblichen Einnahme- und Produktivitätseinbußen von Unternehmen verschie-

denster Branchen geführt. In der Folge gingen tausende Arbeitsplätze verloren und wir stehen vor einer weltweiten Rezession. Auch die Art und Weise hat sich geändert, wie Unternehmen ihre Lieferketten strukturieren, planen und verwalten. Das Konzept statischer Netzwerke gehört der Vergangenheit an, dynamische Wertschöpfungsketten sind ein Muss.

In letzter Zeit gab es sicherlich Anzeichen einer Erholung der globalen Lieferketten, bedingt durch die Lockerung der Notfallmaßnahmen und das Umdenken von Unternehmen in Bezug auf deren Lieferketten. Dennoch bleibt eine gewisse Unsicherheit – speziell im Hinblick auf eine zweite oder sogar dritte Welle der weltweiten COVID-19-Infektionen. Um auf alle Eventualitäten vorbereitet zu sein, müssen Unternehmen die Erfahrungen der letzten Monate nutzen, sodass sie nicht erneut unvorbereitet getroffen werden.

„Beispiellos“ war gestern

Als COVID-19 erstmals die Ausmaße einer globalen Pandemie angenommen hat, wurde sie oftmals als „beispiellos“ bezeichnet. Niemand konnte die Pandemie voraussehen und vergleichbare Szenarien in der Menschheitsgeschichte gab es nur wenige. Die WHO hat sie sogar als den "schwersten" globalen Gesundheitsnotstand aller Zeiten bezeichnet. Die Zeiten sind jedoch vorbei, in denen man von einer beispiellosen Ausnahmesituation sprechen kann. Die erste Welle hat mehr als deutlich gemacht, mit welchen Auswirkungen die Gesellschaft und die Industrie infolge einer zweiten Welle rechnen muss. Der Präzedenzfall steht und muss genutzt werden, um in gesellschaftlicher und wirtschaftlicher Hinsicht widerstandsfähiger und agiler reagieren zu können, als noch zu Beginn der Krise. Wir haben nun lange genug mit dem Virus gelebt und wissen, welche Störungen es verursacht, mit welchen Maßnahmen wir diesen erfolgreich begegnen und wie wir sie schnellstmöglich umsetzen können.

Seien es Hamsterkäufe und die daraus resultierende Verknappung von Konsumgütern wie Toilettenpapier oder das Problem von Überbeständen infolge schwankender Produktnachfrage – es liegen ausführliche Daten über die Auswirkungen von COVID-19 auf die verschiedensten Bereiche vor. Trifft uns die nächste Infektionswelle, verfügen Unternehmen über die nötigen Informationen und dank künstlicher Intelligenz und maschinellem Lernen auch über die adäquaten technologischen Hilfsmittel, um sich richtig vorzubereiten und schnell zu reagieren.

Lektion gelernt

Durch einen Rückblick auf die letzten sechs Monate, können Unternehmen eine Vielzahl wichtiger Schlüsse ziehen. Sie können evaluieren, was schiefgelaufen ist und dafür sorgen, dass sich die gemachten Fehler nicht wiederholen. Eines der größten Probleme im Zuge der Pandemie war für viele Unternehmen der umfassende



Jörg-Alexander Paul,
Partner,
Bird & Bird



Michael Wallraven,
Geschäftsführer und
Regional
Vice President,
LLamasoft
Deutschland GmbH

Lockdown und die daraus resultierende Schließung von Geschäften, Büros und sogar ganzen Ländern. Dies führte zu Chaos innerhalb der Lieferkette. Wichtige Knotenpunkte entlang der Supply Chain für den Transport, die Beschaffung und die Lagerung wurden eliminiert oder auf sehr begrenzte Kapazitäten reduziert. Darüber hinaus kam es durch eine Verschiebung der Prioritäten auf Seiten der Verbraucher zu extremen Nachfrageschwankungen und im Umkehrschluss sowohl zu Über- als auch zu Unterversorgung.

Eines wurde deutlich: Wer sich nicht vorbereitet, ist zum Scheitern verurteilt. Viele Unternehmen verfügten jedoch einfach nicht über die notwendigen Technologien, um sich auf die Störungen entlang ihrer Lieferketten vorbereiten zu können. Infolgedessen kamen Umstrukturierungen oder Problemlösungsansätze oftmals zu spät, oder waren schlicht nicht langfristig genug. Das muss sich in Zukunft ändern.

Biegen statt Brechen

Der Vergleich mit dem Bau eines erdbebensicheren Gebäudes ist eine gute Analogie, um zu beschreiben, wie Unternehmen ihre Supply Chains sowohl flexibel als auch widerstandsfähig gestalten können. Im Wesentlichen kann das Gebäude sich bei einem Erdbeben hin und her bewegen, ohne in sich zusammenzubrechen: es ist flexibel und dennoch belastbar. In ähnlicher Weise müssen Lieferketten flexibel sein, um Ersütterungen zu widerstehen und weiterhin ihre primäre Funktion erfüllen zu können. Um das zu erreichen, sollten sich flexible Lieferketten auf Technologien wie digitale Zwillinge, KI und maschinelles Lernen stützen.

KI-gestützte Entscheidungsfindungsplattformen bieten Zugang zu fortschrittlichen Analysen und Visualisierungen, die genau aufzeigen, was passiert und warum und stellen auf diese Weise die komplette Supply Chain in einen weiteren Kontext. Anhand des digitalen Zwillings der Lieferkette lassen sich innerhalb der Plattform verschiedenste Störungsszenarien simulieren. Geplante oder ungeplante Auswirkungen auf zum Beispiel Kosten oder verschiedene Knotenpunkte entlang der Supply Chain können bewertet werden. In Kombination mit fortgeschrittenen Algorithmen ist es möglich, verschiedene Ergebnisse abzubilden und zu optimieren. Auch lassen sich Notfallpläne virtuell testen, bevor sie in die Praxis umgesetzt werden – um die gesamte Supply Chain-Performance zu sehen, ist eine Quantifizierung des Ist-Zustands der Supply Chain vor und nach jeder Änderung durchführbar. Auf diese Weise können verlässliche Erkenntnisse gewonnen werden, auf die sich Unternehmen im Zuge ihrer Planung stützen können. Die Versorgungskette kann so schnell angepasst werden, um auf die Störungen einer zweiten oder dritten COVID-19-Welle zu reagieren und sie zu bewältigen.

Wahrscheinlich werden nur wenige Ereignisse ähnlich gravierende Auswirkungen auf globale Sup-

ply-Chain-Netzwerke haben wie COVID-19. Unternehmen, die ihre Lieferkette agil und widerstandsfähig gestalten wollen, müssen sich dennoch einer Sache bewusst werden: Unterbrechungen wird es immer geben. Vorhersehbar oder nicht. Aber selbst unter normalen Betriebsbedingungen sind international tätige Unternehmen über die gesamte erweiterte Lieferkette hinweg ständigen Risiken ausgesetzt. Es gilt, sich sowohl auf das Unerwartete vorzubereiten als auch im Regelfall flexibel und dennoch stabil handeln zu können. Moderne Lieferketten-Netzwerke sind jedoch komplex, und ihre Komponenten in hohem Maße voneinander abhängig. Wichtig ist daher, die Ausfallsicherheits- und Risikoanalysen sowie die Auswahl effektiver Reaktionen auf Risikoszenarien mit fortschrittlicher Analytik zu unterstützen. Die technischen Werkzeuge dafür sind bereits vorhanden, um mittels digitalen Supply Chain Zwillingen datenbasiert und durch maschinelles Lernen die Flexibilität von Lieferketten zu maximieren. Jetzt gilt es, von diesen Technologien Gebrauch zu machen.

Michael Wallraven

Künstliche Intelligenz im Einsatz für die Gesundheit

Künstliche Intelligenz (KI) hilft dabei, Informationen aus großen Datenmengen zu extrahieren, zu analysieren und bestmöglich zu nutzen. Im Bereich Life Sciences ergeben sich dadurch neue Möglichkeiten, Prozesse zu optimieren, Produktentwicklungen zu beschleunigen und Innovationen zu fördern. Unternehmen können dadurch ihre Wettbewerbsfähigkeit nachhaltig stärken und neue Potenziale erschließen.

Die Möglichkeiten, die KI-Lösungen im Bereich Life Sciences bieten, sind vielfältig: Pharmaunternehmen erhoffen sich, die Entwicklungszeiten neuer Medikamente deutlich zu verkürzen. Zudem können sie ihre Produktionsprozesse optimieren und damit Kosten einsparen. Ärzte können KI in der Diagnostik einsetzen, um Diagnosen zu verbessern und entsprechend passende Therapieangebote für den Patienten früher einzuleiten. Um außerdem neue Marktfelder zu identifizieren und Forschungsgebiete zu entwickeln, kann KI eine Schlüsselrolle einnehmen.

Die richtige Vorbereitung

Bisher stehen viele Unternehmen noch vor der Herausforderung, KI richtig einzusetzen. Die Erwartungshaltung ist dabei oftmals groß. Doch KI-Lösungen gibt es nicht von der Stange und sie können keine Wunder vollbringen. Vielmehr ist der professionelle Einsatz von KI ein Prozess, der richtig geplant und umgesetzt werden will. Das erfordert eine sorgfältige Vorarbeit und das richtige Verständnis für die vorhandenen Daten und deren potenziellen Nutzen.

Datenaufbereitung

Zunächst geht es darum, eine gute Datenqualität sicherzustellen. Bereits das Sammeln der Daten birgt dabei einige Herausforderungen, da das Entscheidende nicht alleine die Menge der erhobenen Daten ist. Wichtig ist vor allem, die Daten zu verstehen und aufzubereiten, damit die KI-Lösung sie richtig nutzen kann.

Daten integrieren und Qualität sicherstellen

Unternehmen sollten zuerst Grenzen zwischen bestehenden Datensilos auflösen. Oftmals werden Daten aus verschiedensten Quellen und in unterschiedlichen Formaten gesammelt. Diese müssen vereinheitlicht und an einem Ort konsolidiert werden. Eine weitere wichtige Voraussetzung für den erfolgreichen Einsatz von KI: Die Qualität sowie Integrität der Daten müssen gewährleistet werden. Nur so können die Modelle und Algorithmen auf verlässliche Daten zugreifen, um die großen Datenmengen auszuwerten. Ist die Datenqualität schlecht, wird auch das Ergebnis nicht wie erwartet ausfallen. Die Auswahl der zur Fragestellung passenden Daten ist genauso relevant wie die Bereinigung der Daten.

Kontext verstehen und extrahieren

Anschließend spielt die Dateninterpretation eine wichtige Rolle, um die Daten in den richtigen Kontext zu setzen. Nur wenn zu der Vielzahl an einzelnen Datensätzen Metadaten wie etwa Einheiten und Relationen hinzugefügt werden, können diese echte Mehrwerte bieten. Dadurch wird aus einer Zahl mehr als nur ein Datenpunkt – er erhält eine Bedeutung. Hierzu müssen die Metadaten verstanden und extrahiert werden. Life-Sciences-Unternehmen müssen folglich auf Technologien zurückgreifen, die Metadaten vor allem aus dem wissenschaftlichen Bereich verarbeiten können.

Die richtigen Fragen stellen und die passende KI-Lösung auswählen

Bevor eine KI-Anwendung in einem Unternehmen zum Einsatz kommt, muss geklärt werden, welche Fragen beantwortet werden sollen. Denn nur wenn Unternehmen vorab wissen was sie erreichen möchten, können sie die richtigen Daten und Algorithmen auswählen. Dies bedeutet, dass genau überlegt werden sollte, ob eine Datenanalyse mit KI notwendig ist, oder ob bereits eine statistische Auswertung der Informationen ausreicht. Nur so können Unternehmen unnötigen Aufwand oder falsche Erwartungen vermeiden und KI nutzenbringend einsetzen.

Um das volle Potenzial von KI auszuschöpfen, ist es darüber hinaus wichtig, die KI-Lösung mit Bedacht auszuwählen. Dafür sollte sie auf Basis der vorher definierten Fragestellungen sowie der zu verwendenden Daten selektiert und an die Anforderungen des Unternehmens oder der Forschungseinrichtung angepasst werden. Die Zusammenarbeit mit einem erfahrenen

Partner im KI-Bereich hilft dabei, die Technologie und Lösung zu wählen, die genau auf die Bedürfnisse und den jeweiligen Fachbereich ausgerichtet ist und die gewünschten Antworten liefert.

Potenziale erschließen

Im Bereich Life Sciences zählt KI zu den Schlüsseltechnologien der Zukunft. Sie kann wertvolle Beiträge leisten in Diagnostik, Produktentwicklung, Forschungsinnovation, bei klinischen Tests und in der Produktion.

In der Diagnostik ist es beispielsweise durch KI möglich, Brustkrebs präziser erkennen zu können und stellt dadurch ein hilfreiches Werkzeug für Ärzte dar. Die Software kann erkennen, ob auf der Mammografie eine Struktur zu erkennen ist, die eine weiterführende Diagnostik sinnvoll erscheinen lässt. Mediziner können damit die Spezifität und die Sensitivität des Screenings verbessern und reduzieren falsche Diagnosen. In einer Testreihe konnten falsch positive Ergebnisse dadurch um fast 6 Prozent verringert werden.[1] Brustkrebs wird somit sicherer erkannt, unnötige Therapien werden vermieden.

Eine PwC-Studie belegt zudem, dass KI dazu beitragen kann, Krankheiten genauer und signifikant früher zu erkennen und damit Kosten zu reduzieren. Durch KI können demnach in den kommenden zehn Jahren die Gesundheitsausgaben allein in Europa um einen dreistelligen Milliardenbetrag gesenkt werden. PwC hat dazu drei weit verbreitete Krankheitsbilder in den Blick genommen, die hohe Kosten verursachen und das Einsparungspotenzial durch KI untersucht.[2]

Danach zeigen klinische Studien, dass sich aus den Gesundheitsdaten von Zweijährigen ablesen lässt, wie hoch ihr Risiko für Fettleibigkeit im Kindesalter ist. Bei der Früherkennung ließen sich hier durch gezielte Präventionsmaßnahmen etwa 90 Milliarden Euro in den kommenden zehn Jahren einsparen. In der Früherkennung von Demenz ermöglicht KI eine Genauigkeit von 82 bis 90 Prozent. Wird die Krankheit in Vorsorgeuntersuchungen frühzeitig erkannt, lassen sich laut der Studie in den kommenden zehn Jahren rund acht Milliarden Euro einsparen. Bei Brustkrebs ermöglicht KI nicht nur die Früherkennung, sondern auch eine passgenaue Therapie. So kann KI voraussagen, wie ein Patient voraussichtlich auf eine Chemotherapie reagiert. Dies geschieht durch die Verknüpfung von Patientendaten und den erwartbaren Nebenwirkungen der Therapie. Mediziner können damit den Einsatz der benötigten Medikamente entsprechend anpassen und so ungewünschte Folgeerscheinungen eindämmen. Das Einsparpotenzial wird hier laut PwC für die kommenden zehn Jahre auf 74 Milliarden Euro geschätzt.[3]

KI unterstützt außerdem die natürliche Intelligenz dahingehend, dass sich Wissenschaftler mehr auf die eigentliche wissenschaftliche Arbeit fokussieren können. So können zum Beispiel Daten zeitaufwendiger



Dr. Daniela Jansen,
Director Product
Marketing,
Dassault Systèmes

Analyseverfahren für Modelle verwendet werden, was auch für den Laborbereich ein hohes Einsparpotenzial birgt. Viele Tests müssen nicht mehr physisch durchgeführt werden, sondern können – basierend auf bereits vorliegenden experimentellen Daten – virtuell vorgenommen werden. Damit kann KI die Effektivität auch in diesem Bereich maßgeblich steigern und damit helfen Innovation zu beschleunigen und Kosten für die Forschung zu reduzieren.

Unbekannte Zusammenhänge aufdecken

KI hat zudem ein spannendes Anwendungsgebiet, wenn es darum geht Legacy-Daten neu zu betrachten. So können heute unter Umständen Zusammenhänge erschlossen werden, die vor wenigen Jahren noch nicht möglich waren. Beispielsweise sind Machine Learning-Algorithmen in der Lage, kleinste Abweichungen und Auffälligkeiten in der Produktionsstraße zu erkennen. Damit kann Machine Learning dabei helfen, den Produktionsprozess anzupassen und damit den Materialverbrauch und die Qualität der Produkte zu optimieren.

KI kann darüber hinaus auch Handlungsempfehlungen geben, die so vielleicht noch gar nicht in den Blick geraten sind. Sie hilft Wissenschaftlern dabei, übergreifende Zusammenhänge zu verstehen und Wissen zu verknüpfen. Werden weitere Informationen, wie etwa aus öffentlichen Publikationen, mit firmeninternen Daten integriert, ergibt sich ein umfassendes Bild das neue Möglichkeiten aufzeigen kann. KI-basierte Anwendungen helfen Forschern damit nicht nur einzelne Datensätze zu verstehen, sondern auch die Brücke zu anderen Forschungsgebieten zu schlagen. Dieser interdisziplinäre Ansatz ermöglicht es, neue Felder zu erschließen und innovative medizinische Produkte zu entwickeln.

Fazit

Der Gesundheitsbereich kann schon heute durch KI-Anwendungen revolutioniert werden. Diagnostik und Behandlung können dadurch genauer und zielgerichteter sein – was sich sowohl auf eine optimale Versorgung von Patienten als auch die Gesundheitsausgaben auswirkt. Zudem kann Machine Learning neue Ansätze in der Forschung ermöglichen und so schneller als jemals zuvor Wirkstoffe und Therapien verfügbar machen, Entwicklungs- und Produktionskosten sparen oder völlig neue medizinische Produkte entwickeln.

Dr. Daniela Jansen

Referenzen: [1] <https://www.handelsblatt.com/technik/medizin/studie-google-ki-koenn-te-brustkrebserkennung-verbessern/25381238.html?ticket=ST-541352-qFpZbJG-fozZTOeosfsvW-ap1> [2] <https://www.pwc.de/gesundheitswesen-und-pharma/wie-kuenstliche-intelligenz-das-gesundheitssystem-revolutioniert.html> [3] <https://www.pwc.de/de/gesundheitswesen-und-pharma/wie-kuenstliche-intelligenz-das-gesundheitssystem-revolutioniert.html>

Positive Lebenszeichen für KI im europäischen Gesundheitswesen

Künstliche Intelligenz (KI) und KI-gestützte Technologien können in der Medizin und im Gesundheitswesen auf eine außergewöhnliche Entwicklung zurückblicken: Was einst als unterstützendes Computerprogramm für die Analyse von medizinischen Aufnahmen begann, findet sich mittlerweile in fast jedem klinischen und organisatorischen Bereich wieder. Denn: KI verfügt über das Potenzial, die Gesundheitsversorgung neu zu gestalten und die menschlichen Fähigkeiten in nie dagewesener Weise zu erweitern.

KI verbessert Behandlungsergebnisse, Patientenerfahrungen und den Zugang zu Gesundheitsdienstleistungen; gleichzeitig versetzt die Technologie Gesundheitssysteme in die Lage, einer höheren Anzahl von Menschen eine zusätzliche und bessere Betreuung zu ermöglichen. Auch können notwendige Behandlungen dank schnellerer Diagnosezeiten zeitnah in die Wege geleitet werden – diese wichtige Zeitersparnis entscheidet im Zweifelsfall über Leben und Tod eines Patienten.

Eine mögliche Anwendung von KI im Gesundheitswesen ist die Analyse der Zusammenhänge von Präventions- oder Behandlungstechniken und Patientenergebnissen. Dabei kommen KI-Programme unter anderem bei Diagnoseverfahren, der Entwicklung von Behandlungsprotokollen, der Medikamentenentwicklung und personalisierter Medizin sowie Patientenüberwachung und -pflege zum Einsatz. Darüber hinaus sind KI-Algorithmen in der Lage, große Datenmengen aus elektronischen Gesundheitsakten zur Krankheitsprävention und -diagnose zu analysieren. Beispielsweise können übertragbare Krankheiten so früh erkannt und präventiv behandelt werden.

Mittlerweile setzen weltweit medizinische Institutionen auf KI, um betriebliche Initiativen zu verbessern, die wiederum zu höheren Kosteneinsparungen und besserer Patientenzufriedenheit führen sowie die Anforderungen der Mitarbeiter adressieren. Darüber hinaus arbeiten KI-Startups mit Hochdruck an Technologien, die Führungskräfte im Gesundheitswesen dabei unterstützen, den Geschäftsbetrieb zu stärken – indem sie beispielsweise die Patientenauslastung verbessern, den Aufenthalt von Patienten verkürzen und die Personalbesetzung optimieren.

Das Gesundheitswesen in Europa

Innerhalb des vergangenen Jahrhunderts stieg die durchschnittliche Lebenserwartung in der EU von 50 auf 80,9 Jahre. Die alternde Bevölkerung und die steigende Lebenserwartung konfrontieren die Gesundheitssysteme in Europa mit neuen Herausforderungen, darunter eine wachsende Nachfrage nach Dienstleistungen, steigende Kosten für bestimmte Leistungen und erhebliche Hürden beim Aufbau des für die Versorgung erforderlichen

Personals. Der Markt wird durch eine Kombination konvergenter Kräfte angetrieben: alternde Bevölkerungen, steigende Patientenerwartungen und Lebensstile, die von der rasanten Urbanisierung, Modernisierung und Globalisierung geprägt sind, sowie die damit einhergehenden Veränderungen der gesundheitlichen Risikofaktoren.

Die Auswirkungen auf die alternde Bevölkerung sind besonders düster: Bis 2050 wird jeder vierte Europäer über 65 Jahre alt sein. Diese demografische Verschiebung – zusammen mit den oben genannten Risikofaktoren – führt dazu, dass immer häufiger chronische Erkrankungen auftreten und die Nachfrage nach Gesundheitsleistungen steigt. Gesundheitssysteme müssen entsprechend reagieren und sich fokussieren – angefangen bei einer zeitlich begrenzten Versorgung im Krankenhaus bis hin zu einem langfristigen, proaktiven Management der chronischen Pflege. Um dies zu ermöglichen, müssen Ärzte verschiedener Fachrichtungen enger mit anderen Fachleuten im Gesundheitswesen zusammenarbeiten.

Das Management komorbider Patienten mit komplexen Bedürfnissen ist für die Gesundheitssysteme teuer. Im Jahr 2018 lagen die Gesundheitsausgaben in den hochentwickelten Märkten Europas zwischen 8,8 und 11,2 Prozent des Bruttoinlandsprodukts – Tendenz steigend. Personalknappheit und Qualifikationsdefizite schränken die Gesundheitssysteme ebenfalls ein. KI kann die Gesundheitsversorgung transformieren und dabei unterstützen, einige der genannten wirtschaftlichen und sozialen Herausforderungen durch prädiktive Modelle und intelligente Automatisierung zu bewältigen.

Der aktuelle Stand in Europa

Europa hat sich schnell zu einem wichtigen Dreh- und Angelpunkt für KI im Gesundheitswesen gemausert – dennoch liegt die Region noch hinter den USA. Ein paar aktuelle Beispiele aus der Praxis: Exscientia – ein Unternehmen aus Oxford, das sich auf die KI-gestützte Erforschung von Arzneimitteln konzentriert – entdeckte ein neuartiges Molekül, das Sanofi derzeit weiterentwickelt. Kürzlich gab die Firma die Kooperation mit US-Partnern bekannt, um ihre Technologie bei der Suche nach Medikamentenkandidaten zur Behandlung von COVID-19 einzusetzen. Zahlreiche KI-Startups, die sich mit der Erforschung von Medikamenten beschäftigen, erhalten aktuell signifikante Finanzmittel und nutzen Plattformtechnologien, um neue Forschungen weiterzuentwickeln und zu vermarkten. Die EU macht bereits große Schritte bei der Regulierung und der Definition von Standards in Bezug auf Ethik, Datensicherheit und -diskretion. Darüber hinaus werden Initiativen ins Leben gerufen, die strategische Investitionen, Forschungsbeiträge und wachsende Finanzierung umfassen. Die Übernahme von KI in die allgemeine Gesundheitsversorgung in Europa erfolgt jedoch relativ langsam.

Europa profitiert von den großen Mengen an Gesund-

heitsdaten, die in den nationalen Gesundheitssystemen gesammelt werden und kann zudem auf zahlreiche Forschungsstudien, etablierte Innovationscluster und paneuropäische/kontinentale Kooperationen zurückgreifen. So wurde beispielsweise in Zusammenarbeit zwischen britischen und US-amerikanischen Organisationen ein KI-gestütztes Mammographie-Screening entwickelt, das falsche Ergebnisse reduziert. Bei der Entwicklung neuer KI-Strategien für das Gesundheitswesen ist ein paneuropäischer Ansatz sinnvoll – dennoch bleiben Herausforderungen bestehen.

Fragen rund um Daten stehen immer im Mittelpunkt einer erfolgreichen Förderung von KI-Lösungen. Kritische Fragen der Datenverwaltung, des Zugangs und der Sicherheit müssen noch geklärt werden – dies verzögert allerdings die weitere Einführung der Technologie. Die europäischen Investitionen und Forschungen im Bereich KI sind beträchtlich, sofern sie gebündelt werden – auf Länder- oder Regionalebene sind sie jedoch fragmentiert. Die Gesundheitssysteme müssen einen systematischen Ansatz zur Entwicklung gemeinsamer Datenstandards und -prozesse verfolgen, um den Mehrwert der vorhandenen Daten zu maximieren. Für einen der am wenigsten digitalisierten Wirtschaftssektoren bleibt dies eine Herausforderung. Gesundheitsdienstleister und KI-Unternehmen müssen eine robuste Data Governance einführen, Interoperabilität und Standards für Datenformate sicherstellen, die Datensicherheit verbessern und Klarheit über die Zustimmung zur gemeinsamen Datennutzung schaffen. Nur so können sie das Vertrauen der Stakeholder gewinnen und große Datenpools im Gesundheitswesen für KI-getriebene Innovationen schaffen.

Die dringende Notwendigkeit, einen Mechanismus zur Integration von KI in die moderne Gesundheitsversorgung zu koordinieren, erhielt mit dem Ausbruch der COVID-19-Pandemie einen Schub. Forscher – darunter auch in Europa ansässige Unternehmen wie Healx, BenevolentAI, Innoplexus und Evaxion Biotech – arbeiten an der Entwicklung von Impfstoffen, die dank KI-gestützter Forschung und Entwicklung schneller und in größerem Umfang zur Verfügung stehen. Ein kritischer Anwendungsfall war beispielsweise die molekulare Simulation; mit deren Hilfe erforscht werden soll, inwieweit therapeutische Verbindungen und potenzielle Impfstoffe in einer Simulationsumgebung mithilfe von Machine Learning (ML) entdeckt werden können.

KI-gestützte Lösungen leisten so einen wichtigen Beitrag bei der Adressierung aktueller Herausforderungen im Gesundheitswesen – dafür müssen sie allerdings ihr volles Potenzial entfalten. Nur dann können wir den bisher ungenutzten Mehrwert der KI für die Erweiterung der klinischen Ressourcen und die Sicherstellung optimaler Patientenergebnisse mit effektiven Richtlinien, Vorschriften und Strategien erschließen.

Balakrishna D R



Balakrishna D R,
Senior Vice
President, Service
Offering Head - ECS,
AI and Automation,
Infosys

1.4 BUCHHALTUNG

„Machine Learning“ ist in der Buchhaltung angekommen

Digitalisierung und Automatisierung werden für viele Branchen eine disruptive Wirkung haben. Besonders betroffen hiervon wird der Bereich Buchhaltung und Steuerberatung sein. Die Digitalisierung ist in einer zunehmenden Anzahl von Steuerkanzleien mittlerweile fester Bestandteil der Arbeitswelt. Die Entwicklung schreitet aber mit großen Schritten voran und auch der Einsatz künstlicher Intelligenz ist nicht länger ein futuristischer Trend, sondern ist in der Buchhaltung angekommen. Viele Branchen wurden in den letzten Jahren komplett umgekrempelt und in der vermeintlich angestaubten und unflexiblen Branche der Buchhaltung werden die Automatisierung und der Einsatz künstlicher Intelligenz eine große Auswirkung haben. Künstliche Intelligenzen machen den Menschen das Arbeiten leichter und gerade im Bereich der Belegbuchung schreitet die Entwicklung so schnell voran, dass ein Durchbruch hin zu selbstbuchenden Systemen in greifbarer Nähe ist.

In unserer Steuerkanzlei Campbell Hörmann Partnerschaftsgesellschaft, Steuerberater und Rechtsanwälte, München, setzen wir seit einigen Jahren die digitale Buchhaltung um. Dies beginnt mit dem elektronischen Erfassen der Kontoauszüge der Banken. Lange vorbei sind die Zeiten, als der Sachbearbeiter den Kontoauszug der Bank abgetippt hat. Das Rechenzentrum erhält mit sämtlichen im geschäftlichen Bereich tätigen Banken und Sparkassen in Deutschland den Zugriff auf die Kontoauszugsdaten. Der sichere und schnelle Austausch vom Rechenzentrum der Bank zum Rechenzentrum der Steuerberatersoftware bedeutet für die Steuerkanzlei, dass zentrale Daten wie Betrag, Datum, Verwendungszweck schon erfasst sind und nur noch das Gegenkonto erfasst werden muss. Diese Entwicklung ist aber bereits ein Jahrzehnt alt.

Der nächste Schritt der Entwicklung ist das Buchen digitaler Belege. Hier transferiert der Mandant seine Belege digital an die Steuerkanzlei, indem ihm entweder die originär digitalen Dateien hochgeladen werden oder Papierdateien eingescannt und hochgeladen werden. Über eine sichere Verbindung vom Computerarbeitsplatz des Mandanten oder seit Neuestem auch über eine sicherer webbasierte Lösung kann der Belegtransfer in die Steuerkanzlei erfolgen, genaugenommen wiederum in das Rechenzentrum. Der Sachbearbeiter in der Steuerkanzlei öffnet auf einem Bildschirm den Buchhaltungsbeleg und verbucht diesen auf dem zweiten Bildschirm. Der Beleg wird

zum Abschluss des Buchungssatzes an die Buchung „angehängt“, sodass der Jahresabschluss-Sachbearbeiter, der Mandant oder ein Steuerprüfer direkten Zugriff auf die Buchung und damit verknüpft auf den Beleg haben. Das Suchen und Sortieren von Belegen entfällt.

Hierin knüpft jetzt das Machine Learning an. Die originär-digitalen oder eingescannten Rechnungen werden von der Software mit einer OCR-Erkennung behandelt, sodass wesentliche Inhalte wie Rechnungsdatum, Rechnungsbetrag, Absender und dergleichen automatisiert erkannt werden können. Auch dies erleichtert dem Buchenden die Arbeit erheblich, denn auf diese Weise müssen Belege nicht mehr händisch eingepflegt werden. Auch repetitive und besonders fehleranfällige Tätigkeiten der Buchführung können so von smarter Software übernommen werden.

Mittels „maschinellen Lernen“ kann die intelligente Software mit jedem einzelnen Beleg dazulernen, ihre Fähigkeiten erweitern und sich so individuell an die Bedürfnisse des jeweiligen Nutzers anpassen. Nach dem Verbuchen eines Belegtypen unter die relevanten Erlös- oder Aufwandskonten wird die Lerndatei bei dem nächsten Beleg den entsprechenden Buchungssatz schon vorschlagen. Auch hier wandelt sich die Tätigkeit des Buchhalters weg von der manuellen Eingabe hin zu Kontrolle und Freigabe der Buchungen.

Die digitale Vernetzung sorgt zudem dafür, dass auch der Umgang mit bisher unbekanntem Belegformaten von anderen Softwareanwendern auf das eigene System übertragen werden kann. So ist die Technik immer auf dem neuesten Stand und die Klassifizierung von Daten wird kontinuierlich verbessert und verfeinert, das System lernt selbständig dazu.

Selbstbuchende Software

Durch diesen schnellen technischen Fortschritt ist der Weg zum selbstbuchenden Software bereit. In absehbarer Zeit wird intelligente Software vollständig und eigenständig das Einlesen und Verbuchen von Belegen übernehmen können. Dateneingaben, rechtliche und auch rechnerische Prüfung, Ablage und Freigabeprozesse wird von der Software übernommen werden. Selbst die Verknüpfung mit dem Bankkonto zum Abgleich und Ausführung von Buchungen kann so durch künstliche Intelligenz dem Menschen abgenommen werden. Einzig die stichprobenartige Kontrolle der Vorgänge oder das gezielte Einbringen von Know-how obliegt in der Zukunft der menschlichen Komponente des Arbeitsprozesses. Durch diese Synergien aus menschlicher und maschineller Komponente wird dem Arbeitnehmer in der Steuerkanzlei eine primäre Fokussierung auf taktische und strategische Themen ermöglicht.

Die Vorteile dieses strukturellen Wandels liegt auf der Hand: Neben der Einsparung von Ressourcen wie Personal und Arbeitszeit, ermöglicht gerade ein intelligentes Ablagesystem neben einem gezielten Suchen

und schnellem Auffinden einzelner Belege auch eine bedürfnisgerechte Datenanalyse. Durch intelligente Filtersysteme und automatisierte Auswertungstools lassen sich betriebliche Kennzahlen einfach per Mausklick ermitteln und der geschäftliche Erfolg detailliert und verständlich abbilden, sodass dem Unternehmen ein Wettbewerbsvorteil entsteht.

Erfolgreich auf dem internationalen Markt

Diese Prozessoptimierung und Effizienzsteigerung endet aber nicht an der Bürotür. Durch passgenaue IT- und Cloudlösungen wird in Zukunft das Arbeiten und die Vernetzung mit dem Steuerberater flexibel gestaltet. Der Steuerberater ist immer auf dem gleichen Stand und die Ressourcen können zur Beratung und nicht mehr zur Berechnung genutzt werden. Jenseits der internen IT-Infrastruktur des Unternehmens wird es möglich sein, Arbeiten von überall auf der Welt zu erledigen und die Buchhaltung auch von international agierenden Unternehmen maschinell erledigen zu können. So kann der intelligenten Software mit nur einem Update Fremdsprachenkenntnisse beigebracht werden, wofür der Mensch oftmals Jahre lang braucht. Die Datenklassifizierung erfolgt auch im internationalen Bereich zuverlässig, korrekt und in Sekundenschnelle.

Ausblick

Die Zukunft der selbständig arbeitende und buchende Software ist in greifbarer Nähe. Unternehmen haben mit einem kompetenten Partner nun die einmalige Möglichkeit, ihr System frühzeitig an die bestehenden und zukünftigen Möglichkeiten anzupassen und sich so entscheidende Wettbewerbsvorteile zu sichern. Denn eines ist sicher: die Digitalisierung und Automatisierung ist nicht mehr aufzuhalten und eine frühzeitige Umsetzung der Möglichkeiten kann helfen, Prozesse effizient und kostensparen zu gestalten.

Phillip C. Campbell

Was kann digitales Versichern? – Künstliche Intelligenz und Maschinenlernen auf dem Vertrauensprüfstand

Sie sind gekommen, um zu bleiben: Insurtechs fordern die traditionellen Versicherer mit digitalen, einfachen und flexiblen Lösungen und einem schnellen Kundenservice heraus. Schnell ist die Rede von smarten Technologien, von Künstlicher Intelligenz (KI) und Maschinenlernen. Doch wie intelligent sind die Systeme wirklich?

Google, Amazon oder Facebook haben es vorge-macht: Daten sind die Währung der Zukunft. Das gilt in besonderem Maße für Versicherer. Denn wer das Verhalten und die Lebenssituation seiner Kunden kennt, kann Risiken genauer bepreisen, Betrugsfälle

minimieren und Kundenerwartungen besser erfüllen.

Versicherungswelt in Kinderschuhen

Selbstlernende Systeme, die eigene Entscheidungen treffen, sind in der Versicherungswelt jedoch bislang weitgehend Fehlanzeige. Der Grund: Die wenigsten Versicherer besitzen eine IT-Infrastruktur, die es erlauben würde, Kundendaten über die gesamte Vertragslaufzeit und alle Schnittstellen zu bündeln. Sie verfügen also nicht über ausreichend hochwertige und korrekt klassifizierte Trainingsdaten, mit denen die Algorithmen lernen können.

Stattdessen setzen die meisten Unternehmen auf regelbasierte Systeme, die fest konfigurierten Regeln gehorchen.

Dabei ist das Potenzial gerade in der Versicherungsbranche enorm: Die Prozesse sind datenintensiv und beruhen oft auf Wiederholung. Viele Kundenanfragen, Schadensmeldungen oder Datenanalysen ließen sich theoretisch standardisieren und automatisieren – ideale Voraussetzungen, um intelligente Maschinen einzusetzen.

So sind sich die Experten einig, dass KI mittel- bis langfristig die Versicherungsbranche revolutionieren wird. Smarte Algorithmen werden helfen, Versicherungsbetrug schneller zu erkennen und Risiken genauer zu bewerten. Dadurch kann KI genutzt werden, um personalisierte Produkte zu schaffen. In Kombination mit Sensorik und dem „Internet der Dinge“, kurz IoT, hilft KI auch bei der Prävention.

Was der Kunde will

Gemeinsam gedacht werden diese vielen Möglichkeiten dazu führen, dass Versicherungsprodukte deutlich individueller und fairer für das Kollektiv werden. Künstliche Intelligenz könnte Vertrauen auf Basis von Daten berechnen und gewissermaßen synthetisieren. Kunden, die vertrauenswürdig sind, können dann beispielsweise von günstigeren Preisen oder einer schnelleren Schadensbearbeitung profitieren.

Was das bedeuten kann, ist vielleicht noch nicht ganz klar. Versichern beruht seit jeher auf dem Prinzip der kollektiven Risikoübernahme. Die Gemeinschaft trägt den Schaden des Einzelnen mit. Durch künstliche Intelligenz wird dieses Prinzip hinterfragt. Subjektiven Entscheidungen einzelner Experten stünden dann objektive, trainierte Systeme entgegen, die sich nicht von Emotionen oder Stress beeindrucken ließen.

Auf diese Weise könnten Insurtechs Versicherungsbetrüger vorzeitig entlarven, Risiken minimieren, Preise dynamisch anpassen. Sie können Diskriminierung ausschalten und anstelle externer Faktoren wie Alter, Wohnort, Beruf oder Name das Verhalten des Kunden analysieren. Es entsteht ein völlig neues Risikoprofil, basierend auf Daten. Und die technologische Revolution steht erst am Anfang.



Phillip C. Campbell,
Partner,
Campbell
Hörmann PartG



Marius Simon,
CTO,
Getsafe

Zwischen individualisierten Angeboten und Überwachung

Eine entscheidende Frage, die sich digitale Versicherer stellen werden, liegt außerdem abseits jeder technologischen Machbarkeit. Es wird darum gehen, was überhaupt gesellschaftlich gewollt ist. Was, wenn sich der Versicherungsschutz nach dem Verhalten des Individuums richtet? Zahlt mehr, wer häufig in Risikogebiete reist oder in einem gefährlichen Bezirk zuhause ist? Ist ein Android User ein besserer Kunde als ein iPhone-Besitzer?

Wie weit will der Kunde mit den Insurtechs gehen? Telematiktarife im KFZ-Bereich weisen schon heute in diese Richtung. Ist es nicht fairer, den Preis aufgrund des persönlichen Fahrstils zu ermitteln? Könnten Wasserschäden in der Wohnung nicht sogar schon im Vorfeld durch intelligente Sensoren und Sturmschäden durch die Echtzeit-Auswertung von Wetterdaten vermieden werden? Sollten Versicherungskunden intelligente Schösser verwenden, um günstigere Tarife zu bekommen? Wie sieht es bei der gesundheitlichen Prävention aus?

Politische Debatte notwendig

Die Frage nach dem transparenten Umgang mit Daten werden auch traditionelle Versicherer beantworten müssen. Noch setzen die meisten Insurtechs und immer mehr etablierte Versicherer auf regelbasierte Algorithmen, also keine künstliche Intelligenz im Sinne eines komplett selbstständig lernenden Systems. Noch entscheiden Menschen darüber, welche Kunden angenommen und wie Tarife berechnet werden, welche Schäden ausbezahlt werden und welche nicht. Dabei spielen Kriterien wie Geschlecht, Alter, berufliche Tätigkeit, Wohnort oder Herkunft eine Rolle.

In den kommenden Jahren werden sich Versicherungen weg von konkreten Produkten entwickeln und ganzheitlichen Schutz versprechen. Daten und intelligente Systeme werden den Fokus verlagern – weg davon, Schäden zu regulieren, hin dazu, Risiken vorzubeugen. Voraussetzung dafür ist eine gesellschaftliche Debatte darüber, wie individuell Versicherung sein soll. Mit der besten Absicht im Hintergrund, einer positiven KI, die man dem Nutzer zum Vorteil reichen kann, lassen sich Bedenken zumindest einfangen. Absolute Transparenz wird dabei zum obersten Credo und Vertrauensindex.

Marius Simon

KI-basiertes Input-Management macht Dokumentenprozesse effektiver

Unternehmen mit intensivem Endkundengeschäft bearbeiten täglich hunderte Dokumente, die sie häufig noch in Papierform erreichen. Banken, Versicherungen,

Telekom- und Energiedienstleister, Verlage und andere Dienstleister auf Massenmärkten arbeiten deshalb in ihren Poststellen mit Scannern, um diesen Input automatisiert in ihre Dokumentenmanagementsysteme einzuspeisen. Die Herausforderung bei diesem Input Management: Die Systeme müssen die Daten digital erfassen, auswerten, klassifizieren und dem richtigen Prozess, Vorgang, Kundenkonto oder Mitarbeiter zuordnen. Vor allem bei Unternehmen, die zahlreiche verschiedene dokumentenbasierte Prozesse administrieren, scheitern viele mit ihrem Input Management. Früher oder später werden Input Management Lösungen immer fehleranfälliger und verursachen wieder so viel Zeitaufwand wie früher die manuelle Bearbeitung. Denn Dokumente, Inhalte, Bearbeiter, Prozesse und Formate sowie Dokumentenklassen ändern sich schneller, als einmal eingerichtete Input Management Systeme dem Wandel folgen oder angepasst werden können. Die Lösung ist Next Generation Input Management. Daniel Szlapka, Managing Director der DTI GmbH, erläutert, wie heutige Systeme arbeiten, welche Rolle dabei der Einsatz von Künstlicher Intelligenz (KI) spielt und wie Unternehmen den betriebswirtschaftlichen Return On Invest in kürzester Zeit realisieren.

Die größte Herausforderung bei der automatisierten Verarbeitung von Briefpost ist, dass bei den Absendern blanke Anarchie vorherrscht. Jeder schreibt zentrale Informationen wie Mandanten- oder Vorgangs- oder Rechnungsnummer anders oder an anderer Stelle. Für die Klassifizierung eines Dokumentes sind Variablen, fehlende oder fehlerhafte Informationen sowie unterschiedliche Schreibweisen aber eine echte Herausforderung. Während ein menschlicher Bearbeiter aus dem Kontext in der Regel nach ein paar Minuten erkennt, in welchen Prozess, in welchen Bearbeiter oder in welche Akte er ein Dokument einsortieren sollte, muss ein Input Management System dafür per Hand konfiguriert werden. Für jede Regel und häufig zahlreiche Abweichungen muss ein Bearbeiter vorgeben, wie Zahlen aus Feldern oder Tabellen, Texte aus Formularen oder unformatierten Dokumenten übernommen und richtig in Zielsysteme übertragen werden. Und hier fangen die eigentlichen Probleme erst an. Vor allem für Unternehmen, die täglich hunderte Seiten automatisch verarbeiten sowie Dutzende verschiedene Dokumentenklassen beherrschen müssen. Die Erkennungsrate sinkt, die Präzision, also die richtige Zuordnung, lässt nach, und der Automatisierungsgrad des Systems reduziert sich immer mehr. Als Folge steigen bei vielen Altsystemen die Aufwände für die Systempflege und vor allem die händische Nachbearbeitung der Datenextraktion und Prozesszuordnung. Irgendwann kommen die meisten Nutzer solcher Altsystems zu der Entscheidung, dass nur die Flucht nach vorne hilft und ein neues Input Management weiterhilft.

Next Generation Input Management On-Premises, in der Cloud oder hybrid

Bei der Anschaffung eines neuen Input Managements tragen in vielen Unternehmen die Fachabteilungen zunächst ihre Bedenken vor. Datenschutz, Administration und Kosten werden ins Feld geführt und die Angst, sich wieder einen proprietären Monolith ins Haus zu holen, der früher oder später entweder mit den Anforderungen oder dem Wachstum nicht Schritt halten kann. Bei einigen am Markt befindlichen Input Management-Lösungen treffen solche Vorbehalte wohl auch noch häufig zu. Systeme führender Anbieter entsprechen aber anders als früher nicht mehr trägen IT-Tankern; vielmehr gleichen sie eher einer Flotte agiler Schnellboote, die vernetzt sind und unterschiedliche Micro Services im Flottenverbund bereitstellen. Sie sind nämlich modular aufgebaut, basieren auf aktuellen Datenbank- und Software-Standards, die weit über die Microsoft-Welt hinausragen. So bildet beispielsweise das Programmierprinzip Rest (Representational State Transfer) eine Schnittstelle, über die verteilte Systeme und vor allem vernetzte Webservices kommunizieren. Innovative Input Management Systeme arbeiten mit solchen Micro Services, die auf einer gemeinsamen Software-Plattform basieren. Änderungen an einzelnen Micro Services haben keine Rückwirkungen auf ältere oder das Gesamtsystem. Sie sind anders als früher schneller und agiler in die Anwendung zu integrieren. Sie sind deshalb entwicklungsfähig und ermöglichen einen schnellen Roll-out auch neuer Micro Services. Innovative Input Management Lösungen sind darüber hinaus variabel einsetzbar: Ob On-Premise, nativ in der Cloud oder in einer hybriden Installation bieten sie den Anwendern eine hohe Nutzer-Experience. Sie funktionieren mit jedem Standardbrowser, sind selbstverständlich responsive programmiert und lassen sich daher mit ihrer Grafische Benutzeroberfläche (GUI, Graphic User Interface) von jedem Endgerät mit Internetzugang aus nutzen. Vor allem integrieren sie KI-Funktionen, die bei der Datenextraktion und Klassifizierung von Dokumenten in der Praxis unverzichtbare Vorteile bieten.

Selbstlernende KI steigert Treffsicherheit

Je nach dem, welche Dokumentenklassen, Prozesse und Bearbeiter in einem Unternehmen bestehen und wie umfangreich Rechnungen, Schadenmitteilungen, Anträge oder gar Verträge sind und extrahiert werden müssen, um sie richtig zuzuordnen, muss ein IMS sehr agil und leistungsfähig sein. Auf Standardfunktionen wie optische Texterkennung mittels OCR kommt es dabei natürlich weiterhin an. Wichtiger sind aber ein Verständnis natürlicher Sprache (Natural Language Processing, NLP), um Inhalte richtig zu verstehen, sie also auszuwerten, um sie dann erst zuzuordnen. Für diese anspruchsvollen Aufgaben kommen in fortschrittlichen Input Management Lösungen KI-Algo-

rithmen zum Einsatz, die bei der semantischen und kognitiven Interpretation von Texten bereits sehr nah an den menschlichen Verstand heranreichen. Bei einer Formulierung wie „Herzinfarkt ausgeschlossen“ muss die KI auch die Polarität der Aussage erkennen und eben auswerten, dass bei einer solchen Aussage zwar die Möglichkeit eines Herzinfarktes geprüft, dieser sich aber nicht bestätigt hat. Natürlich muss ein solches System zunächst für die Kundenanforderungen konfiguriert und für die verschiedenen Dokumentenklassen „angelernt“ werden. Dafür braucht es Trainingsdaten, mit denen die KI mit den zuvor definierten Regeln lernt. Durch menschliche Korrekturen eignet sich die KI das „Wissen“ an, wie sie künftig die Regeln anwenden soll. Aber anders als die bisher meisten KI-Algorithmen arbeiten diese nicht als eine Black Box, deren Ergebnisse im Idealfall immer besser werden; im „worst case“ kann sich die KI aber auch ohne Kontrolle „überlernen“ oder durch Falscheingaben verschlechtern. Die Konsequenz daraus ist, dass die Performance sinkt. Bei einem innovativen Input Management lassen sich die Wege der Lernerfolge mittlerweile automatisiert zurückverfolgen und feinsteuern. Denn: Die KI-Algorithmen lernen aus den eigenen Fehlern und werden so immer schlauer. Die Erkennungsrate und die Präzision steigen und damit auch der Automatisierungsgrad.

KI orientiert sich am Menschen und verbessert sich automatisch

Die komplexen Funktionen dahinter basieren auf maschinellem Lernen (Machine Learning, ML). Die Klassifizierung und Erkennung von Dokumenten mit ML erfolgt im laufenden Produktivbetrieb mit den eingehenden Dokumenten sowohl mit einem überwachten als auch mit einem unbeaufsichtigten kontinuierlichen Training. Beim überwachten Lernen analysieren die Sachbearbeiter die Klassifikationen der ihnen zugeordneten Dokumente, korrigieren Falscheinträge oder unzulässige Interpretationen und bewerten sie. Mit diesen Korrekturen oder Freigaben geben sie den KI-Algorithmen auch neue Muster oder modifizieren bisher gelernte Regeln. Diese Korrekturen nutzt die KI, um mit unbeaufsichtigtem Lernen sich selbstständig zu verbessern. Die Algorithmen verfeinern damit ihre Erkennungsleistung im laufenden Produktivbetrieb. Damit generiert die KI zusätzliches Wissen über Regeln und Ausnahmen und baut sie in ihre weitere Anwendung ein. Die KI lernt also einerseits selbsttätig, orientiert sich aber am Menschen und das bei einer größtmöglichen Transparenz und Nachvollziehbarkeit ihrer Lernerfolge.

„Supervised Learning“ verhindert Gefahr des Überlernens

Eigentlich wäre diese Unterordnung der KI unter die von Menschen „vorgelebte Weisheit“ bereits eine



Daniel Szlapka,
Managing Director,
DTI GmbH

beträchtliche Innovation gegenüber den normalen Lernprozessen einer KI in „Black Boxes“. In aktuellen Input Management Lösungen wertet die KI des Weiteren ihre eigenen Arbeitserfolge aus, erstellt Statistiken und vergleicht sich über verschiedene Zeiträume mit produktiven Daten. „Merken“ die Algorithmen, dass ihre Erkennungsrate sinkt und sie bei der Klassifikation in ihrer Präzision gegenüber einem vorangegangenen Zeitraum nachgelassen haben, analysieren sie die Ursachen und lernen auch daraus. Diese regelmäßige Benchmark-Analyse verbessert damit die Leistungen über verschiedene Zeiträume. Je seltener eine menschliche Korrektur notwendig ist, desto besser arbeitet die KI im täglichen Produktiveinsatz. Die Parameter dabei sind Erkennungsrate und die Präzision und als Folge daraus der Automatisierungsgrad. Das System versucht sich ständig zu optimieren. Die Maschine merkt anhand der menschlichen Korrekturen, wenn sie etwas falsch erkannt oder zugeordnet hat und verbessert sich von alleine und automatisch. Vor allem aber eben nur dann, wenn es sich auch wirklich verbessert. Die menschlichen Eingriffe sorgen quasi als Supervisoren dafür, dass die Lernprozesse der KI aufkommende Fehlentwicklungen frühzeitig korrigiert werden. Die Gefahr eines Überlernens, wie es häufig bei KI geschieht, besteht also nicht. Durch diese Eigenschaften sowie seine modulare Architektur ist ein solches Input Managements schnell in bestehende IT-Landschaften zu integrieren und auch schneller produktiv. Schon nach kurzer Zeit können solche Input Management Lösungen eine Erkennungsrate von bis zu 95 Prozent und eine Präzision von bis zu 99 Prozent erreichen. Bei täglich 1.000 Dokumenten wären dann nur noch bei 50 bis 60 Dokumenten nach der Klassifikation Korrekturen durch den Menschen notwendig.

Return on Invest in kürzester Zeit

Und das bedeutet gleichzeitig, dass mindestens 940 Dokumente und deren Inhalte aus Formularen und Tabellen, Zahlen, Handschriften und unterschiedlich lange Texte, von Einzeilern bis zu mehrseitigen Verträgen, richtig eingescannt, ausgewertet und automatisch richtig klassifiziert sind. Sie liegen dann dem richtigen Bearbeiter vor, die Daten sind in den richtigen Zielsystemen beziehungsweise elektronischen Kundenakten angekommen. Für die Arbeit der Mitarbeiter in Schadenabteilungen oder Kundencentern bedeutet dies, dass sie die Dokumente in ihrem digitalen Workflow nahtlos bearbeiten können. Der interne Aufwand für Nachfragen oder die Suche nach Dokumenten entfällt. Alleine auf dieser Basis kann ein KI-basiertes Input Management je nach Unternehmensgröße schnell Einsparungen von mehreren Hunderttausend Euro pro Jahr erzielen, wie Praxisbeispiele zeigen: Ein IT-Dienstleister für Banken, der jährlich über 30 Millionen Seiten mit 120 Dokumentenklassen verarbeitet, erreichte nach Installation, Konfiguration und dem

Anlernen einen Automatisierungsgrad von 89 Prozent und eine Präzision von 97,5 Prozent. Das Unternehmen berechnete nach Einführung eines solchen IMS eine Einsparung von 350.000 Euro pro Jahr. Ein anderer IT-Dienstleister für Versicherungen, der unter anderem hoch komplexe Kfz-Schadenakten mit 200 Feldern und sieben Tabellen in rund 15 Millionen Seiten automatisiert mit einem Input Management System verarbeitet, senkte seine Verarbeitungszeiten um 50 Prozent. Alle Dokumente sind zudem rechtssicher archiviert. Die Einhaltung von Compliance-Vorschriften, Datenschutz- und steuerrechtliche Aufbewahrungspflichten sind gleichsam nebenbei erfüllt.

Fazit: KI-basiertes Input Management unverzichtbar für Digitalisierung

Bei einer Berechnung des Returns on Invest sind daher keine einfachen Rechnungen wie Anschaffungskosten minus eingesparter Arbeitszeit ausreichend. So sehr diese für Budgetfragen relevant sind, liegt der Wertbeitrag eines KI-basierten Input Managements vor allem im organisationalen Fortschritt. Veraltete und monolithische Lösungen beschäftigen in vielen Unternehmen mittlerweile einen Aufwand ganzer Abteilungen für die Nachbearbeitung der Dokumentenklassifikation. Ihre Systeme können dem Wachstum nicht mehr Schritt halten, sind unflexibel und haben häufig ohnehin das Ende ihres Lebenszyklus erreicht. Unternehmen, die bisher viel Zeit mit Überwachung und Korrekturen ihres Input Managements aufwenden, machen mit einem KI-basierten Input Management auf jeden Fall einen großen Schritt auf dem Weg zu einer Ende-zu-Ende Digitalisierung ihrer Prozesse.

Daniel Szlapka

1.5 PROZESSAUTOMATISIERUNG

IT-Betrieb und -Service mit KI optimieren

Heute stehen Unternehmen und besonders CIOs vor der Herausforderung, die wachsende Konvergenz von IT-Services und dem IT-Betrieb in den Griff zu bekommen. Paul Beavers von BMC Software ist davon überzeugt, dass das nur mit Technologien gelingen kann, die einen kompletten Überblick über die gesamte IT-Infrastruktur einer Organisation gewährleisten können. Nur so können sie für eine bessere Entscheidungsfindung sorgen und ihren Mitarbeitern und Kunden angenehmere Erfahrungen bieten.

Ein modernes Unternehmen wird dabei gleichzeitig mit Tools und Trends wie Multi-Cloud, Multi-Device und

mehr überhäuft, was den Einblick in die Funktionsweise von Teams erschwert – das gilt besonders im Bereich der IT. Die Herausforderungen erstrecken sich von mangelnder Kommunikation bis hin zu unvollständigen oder ganz fehlenden Einblicken in Prozesse und Prognosen.

Ohne vollständige Einblicke in ein Unternehmen auf allen Ebenen ist es aber schwierig, vorrausschauend zu planen, da man auch die bisherigen Entwicklungen nicht kennt. Wer nicht aus der Geschichte lernen kann, ist dazu verdammt, die gleichen Fehler zu wiederholen – das gilt auch hier.

Künstliche Intelligenz verleiht tiefere Einblicke

Von Künstlicher Intelligenz oder KI ist viel und oft die Rede, doch diese Technologie ist mehr als nur ein Buzzword und Unternehmen können dadurch profitieren, indem sie sich von veralteten Systemen lösen und Vorteile erlangen. Dazu gehören:

- Unternehmen können ihre Fähigkeiten bei der Informationsbeschaffung, Analyse und schließlich Vorhersage verbessern. Der Zugang zu Echtzeitdaten ermöglicht es, fundierte Entscheidungen zu treffen, die zu erfolgreicherem Geschäften führen.
- Verantwortliche wissen stets, wo sich bestimmte Ressourcen befinden, egal ob in der Cloud oder im eigenen Rechenzentrum. Bisher haben sie stattdessen oft noch mit einem Durcheinander verschiedener Lösungen zu kämpfen, die nicht miteinander kompatibel sind. KI hilft dabei, dass Interkonnektivität und Kommunikation zwischen Teams zum neuen Standard wird.
- Unternehmen erhalten vollständigen Überblick über Ausgaben und die Verwendung von Ressourcen, das führt zu einer effizienteren Ressourcenverteilung und höherer Rentabilität von Investitionen.

Ein KI-getriebener Ansatz hilft aber nicht nur dabei, die Produktivität zu steigern und das Projekt-Management zu optimieren – er verbessert auch die Employee Experience der eigenen Mitarbeiter, indem ihnen alle Technologie ihrer Firma auf einen Blick zur Verfügung steht.

Mitarbeiter wollen angenehmere Nutzererfahrung

Wir alle sind heute quasi immer von Technologie umgeben. Die Anbieter von Consumer-Apps und -Diensten punkten dabei mit einer immer leichteren Bedienbarkeit. Diese angenehme Nutzererfahrung, die sie aus ihrem Privatleben gewohnt sind, wünschen sich Mitarbeiter auch am Arbeitsplatz. Optimierte User Experience hat aber auch für Arbeitgeber Vorteile, da die Produktivität gesteigert wird. Dabei kann ebenfalls der Einsatz von KI helfen. Durch die verstärkte Synchronisation von IT-Betrieb und -Services können Arbeitsabläufe zwischen Teams verbessert und neue Herangehensweisen ermöglicht werden.

Beispielsweise können Unternehmen Chatbots

nutzen, um Routineaufgaben zu automatisieren und unternehmensweit Dienste unkompliziert bereitzustellen. Das nimmt den IT-Teams viele alltägliche Aufgaben ab und sie können ihre Zeit fokussierter nutzen und wichtige Aufgaben priorisieren. So sorgt KI nicht nur dafür, dass Mitarbeiter eine angenehmere User Experience bei der Arbeit haben, sondern die auch die IT-Abteilung kann sich Tätigkeiten widmen, die einen Mehrwert für das Unternehmen erwirtschaften.

IT-Betrieb und -Services zusammenfassen

Unternehmen sollten ihren IT-Betrieb und angebotene Services auf einer einzigen Plattform aggregieren. So bekommen sie eine zentrale Anlaufstelle, um die verfügbaren Ressourcen und Technologien immer im Blick zu haben und sie so besser zu überwachen, zu optimieren und vorausschauend zu warten.

Das bringt nicht nur Kosteneinsparungen und eine Rationalisierung des Tagesgeschäfts mit sich, sondern auch die Kunden profitieren durch einen optimierten Schutz vor Sicherheitslücken. Je besser ein Unternehmen schließlich die eigenen Systeme und Infrastrukturen kennt, desto einfacher ist es, potentielle Problemfelder auszumachen. Mit diesem Wissen ist es leichter, Abhilfe für Schwachstellen zu schaffen, bevor diese offen zu Tage treten und eventuell sogar Kunden kosten. Wichtig ist der prädikative Aspekt allerdings nicht nur bei der Performance, sondern auch in puncto Sicherheit. Durch die schnelle Identifikation von Schwachstellen können Unternehmen mit der Veröffentlichung von Patches reagieren, bevor Hacker einen Schwachpunkt ausnutzen. Damit schützen Unternehmen sich selbst und ihre Kunden gleichermaßen.

Vorhandene Ressourcen besser nutzen

Ungenutzte Mitgliedschaften im Fitnessstudio sind nur ein Beispiel – oft bezahlen Verbraucher für Dienstleistungen, die sie gar nicht mehr nutzen, weil sie irgendwann einmal ein Abonnement abgeschlossen haben. Solange die Gebühren relativ gering sind und sich nicht negativ auf den Kontostand auswirken, fällt das oft gar nicht weiter auf. So kann es auch Unternehmen gehen, auch sie vergessen nicht selten, dass sie ein Abonnement für einen bestimmten Service abgeschlossen haben, weil sie ihn nicht oder nur ganz selten nutzen. Stellen Unternehmen die Transparenz ihrer Budgets und Ressourcen nicht sicher, kann es passieren, dass sie für ungenutzte Dienste bezahlen oder Ressourcen nicht effizient verwendet werden, weil niemand den Überblick behält.

Nur mit einem ganzheitlichen Überblick über alle Services und Betriebsabläufe hinweg können Unternehmen sicherstellen, dass sie ihren Mitarbeitern und Kunden stets die beste Erfahrung bieten. Das gelingt, indem sie den Zugriff auf Informationen aller Art optimieren, sie schnell analysieren und bessere Vorhersagen treffen können.

Paul Beavers



Paul Beavers,
VP Product
Management,
BMC Software
GmbH

Mit Reinforcement Learning auf dem Weg zur Allgemeinen KI

Reinforcement Learning ist eine vielversprechende Methode zum Erreichen von Artificial Intelligence. Und zwar insofern, als dass diese Lernmethode eine der vielversprechendsten überhaupt ist, wenn es um die Erlangung der Allgemeinen Künstlichen Intelligenz (Artificial General Intelligence) geht. Reinforcement Learning heißt übersetzt etwa „Bestärkendes Lernen“ oder „Verstärkendes Lernen“. Was es mit dieser Bezeichnung auf sich hat, wie die Methode funktioniert und welche Herausforderungen, Vorteile und welches ungeheure Potential darin steckt, soll dieser Artikel aufzeigen.


Theorie: So funktioniert Reinforcement Learning

Reinforcement Learning gehört – ebenso wie Unsupervised Machine Learning und Supervised Machine Learning – zu den drei algorithmischen Ansätzen in Maschinellem Lernen. Es gibt jedoch einen wesentlichen Unterschied zu den beiden anderen genannten Methoden: Für den Lernvorgang beim Reinforcement Learning sind vorab keine Daten nötig. Eine weitere charakteristische Eigenschaft von Reinforcement Learning: Es handelt sich um eine iterative Methode, die auf dem Prinzip von Trial-and-Error basiert.

Die Lerndaten entstehen beim Reinforcement Learning während des Lernvorgangs selbst. In einer Simulationsumgebung werden im Rahmen von zahlreichen Durchläufen Trainingsdaten generiert und gelabelt. Beim Reinforcement Learning handelt es sich damit um eine der Methoden, bei denen ein Software-Agent selbständig eine Kausalität oder ein Verhalten versteht und die besten Handlungsstrategien in einer gegebenen Situation erlernt.

Das Ziel von Reinforcement Learning: Eine möglichst optimale Policy zu finden

Eine Policy ist vereinfacht gesagt das gelernte Verhalten eines Software-Agents. Die folgende Abbildung zeigt einen schematischen Ablauf eines Lernvorgangs. Eine Policy lässt sich definieren als das gelernte Verhalten mit einer Aktion (Action) auf eine Beobachtung (Observation) in einer Lernumgebung (Environment). Ziel ist es, die Policy so zu optimieren, dass die Belohnungen (Rewards) maximiert werden.



Eine Grafik zur Illustration einer Iterationsschleife:

Sie zeigt Zusammenspiel der Komponenten Agent, Action, Environment, Observation und Reward. Die Anordnung ermöglicht es dem Agent mit dem Environment zu interagieren, um dabei durch ein Belohnungssystem die beste Strategie für eine vorgegebene Aufgabe zu erlernen.

Reinforcement Learning in der Praxis: Wie wird Reinforcement Learning eingesetzt?

Von der Theorie in die Praxis: Reinforcement Learning wird schon heute zu ganz konkreten Zwecken eingesetzt. Die aktuell gängigen Use Cases sind hauptsächlich in Bereichen wie der Steuerung von komplexen Systemen (wie beispielsweise bei intelligenten Verkehrsleitsystemen) und intelligenten Lösungen (wie bei der Qualitätsüberwachung) verortet. Reinforcement Learning kann dabei hauptsächlich zum Zweck der „Optimierung“, und „Steuerung“ angewandt werden.

Die Ergebnisse, die hier erzielt werden können, sind beachtlich – die Erwartungen an die Methode müssen jedoch realistisch bewertet werden. Wie bereits erwähnt, zeichnet sich der Lernvorgang dadurch aus, dass die Lösungen näherungsweise erreicht werden. Bevor ein Reinforcement-Learning-Algorithmus funktioniert, sind zahlreiche Trainingsiterationen erforderlich. Das liegt unter anderem daran, dass es verzögerte Belohnungen geben kann und diese erst gefunden werden müssen.

Heute wird Reinforcement Learning beispielsweise zu folgenden Anwendungszwecken eingesetzt:

- Autonomes Fahren
- Steuerung von Robotern
- Optimierung der Supply-Chain oder der Lagerhaltung
- Intelligente Stromnetze
- Fabrikautomatisierung

Zur Erforschung von Reinforcement Learning dienen vor allem Spiele. Denn Spiele bieten eine gute Möglichkeit, um Reinforcement Learning zu erproben und Methoden zu entwickeln. Sie bieten von Haus aus eine Simulationsumgebung, Möglichkeiten zur Steuerung und Beeinflussung der Umgebung, ein komplexes Problem bzw. Spielaufgabe sowie nicht zuletzt meist ein Punktesystem, das als Belohnungssystem dient.

Die Anfänge von DeepMind: Das Lösen von Atari-Spielen

Heute lautet das Unternehmensziel von Googles DeepMind mit Hilfe von Künstlicher Intelligenz, Programme so weiterzuentwickeln, dass sie irgendwann dazu in der Lage sind, beliebig komplexe Probleme ohne menschlichen Einfluss zu lösen. Noch vor ein paar Jahren war ein solches Vorhaben pure Utopie. Einen wesentlichen Beitrag zur Verwirklichung dieser Vision leistet Reinforcement Learning.

Um zu testen, wozu diese Methode in der Lage ist, dienen wie gesagt insbesondere Spiele. Google erkannte die Chancen von Reinforcement Learning bereits sehr früh: Schon im Jahr 2013 investierte

Google etwa 365 Millionen Euro in DeepMind. Die Forscher waren damals damit beschäftigt, Atari-Spiele mit der Hilfe von intelligenten Algorithmen zu lösen. Laut Google gelang es DeepMind dank Reinforcement Learning sowohl die Spielregeln als auch Erfolgskriterien selbstständig zu erlernen.

Reinforcement Learning läutete den Wendepunkt im Bereich der KI-Forschung ein

Die KI von DeepMind erreichte in vielen weiteren Spielen die Fähigkeiten auf dem Niveau von Profispielern und übertraf diese sogar oft. Spätestens zu diesem Zeitpunkt war klar, dass das Potential von Deep Reinforcement Learning enorm war. Das Forschungsprojekt DeepMind markiert den Wendepunkt, seitdem eine gesteigerte Aufmerksamkeit für diese Methode und deren Möglichkeiten zu verzeichnen ist.

Die Herausforderung: Eine der schwierigsten Spiele der Welt – das chinesische Go

Schach ist ein durchaus komplexes Spiel, bei dem es schätzungsweise eine Anzahl von 10120 möglichen Spielen gibt. Diese Zahl wird jedoch vom alten chinesischen Go-Spiel mit Leichtigkeit in den Schatten gestellt. Auf dem 19x19 Felder zählenden Spiel sind mehr als 10170 Spiele möglich. Wie groß die Anzahl an möglichen Spielvarianten ist, wird deutlich, wenn man sich klar macht, dass – nach aktuellen Erkenntnissen – die geschätzte Anzahl der Protonen im beobachtbaren Universum ca. 1080 beträgt.

Aufgrund dieser Komplexität gilt Go als unmöglich für Computerprogramme zu erlernen, geschweige denn zu gewinnen. Neben der Anzahl möglicher Spiele kommt beim Go eine weitere Schwierigkeit hinzu. Nicht jeder mögliche Zug erklärt sich aufgrund einer Logik von Regeln. Immer wieder betonen die Meister des Spiels, dass ihre Intuition das ausschlaggebende Element des Spieles ist.

AlphaGo – ein intelligentes Programm schaffte das Unmögliche. Heute tritt AlphaGo Zero an seine Stelle

Bekannt geworden sind die Leistungen von Googles Künstlicher Intelligenz DeepMind wohl vor allem durch die Arbeit an Alpha Go, der ersten KI, die auf DeepMind basierte. Ihr gelang das bis dato Unmöglich geglaubte: AlphaGo besiegte die weltbesten menschlichen Go-Spieler souverän. AlphaGo Zero, die neueste Fortsetzung von AlphaGo, ist sogar in der Lage, das Spiel von Grund auf selbständig, ohne menschliches Vorwissen zu erlernen.

Das gelingt AlphaGo Zero deswegen, weil es auf Reinforcement Learning basiert. Die KI beginnt dabei völlig zufällig zu spielen. Einzig die Anfangsposition der Spielersteine ist gegeben. Nachdem AlphaGo Zero drei Tage lang trainiert hatte, trat die KI gegen die erste Version von AlphaGo an. Das Ergebnis: Die

Zero-Variante konnte ihren Vorgänger 100:0 besiegen.

Reinforcement Learning kann aber zu weit mehr als nur zur Lösung kompliziertester Spiele eingesetzt werden. Die Methode kann vielmehr auch in realen Szenarien Probleme höchst effizient lösen.

Jenseits von Spielen: Google steuert die Klimaanlage mit Reinforcement Learning

Spätestens seit den Erfolgen von AlphaGo ist Google dafür bekannt, an der vordersten Front der KI-Entwicklung zu stehen. Auch Reinforcement Learning spielt dabei eine wichtige Rolle. Diese Methode setzt Google bei der Gleichstromkühlung ein. Zum Hintergrund: Google betreibt riesige Rechenzentren, die nicht nur enorm viel Strom verbrauchen, sondern dabei extrem hohe Temperaturen erzeugen. Zur Kühlung wird dabei ein komplexes System von Klimaanlagen eingesetzt. Mit Reinforcement Learning war es möglich, dieses komplexe, dynamische System zu kontrollieren und zu steuern. Damit war Google in der Lage, durch den Einsatz seines lernfähigen Algorithmus die Energiekosten für die Server-Kühlung um 40 Prozent zu senken.

Reinforcement Learning im Bereich Robotics: Erschließung des wahren Potentials von Industrierobotern

Industrieroboter verrichten hauptsächlich routinemäßige, sich immer gleich wiederholende Aufgaben. Noch fehlt ihnen die Fähigkeit, sich in komplexen Umgebungen zu orientieren und zu verhalten. Um das wahre Potential von Industrieroboter in der Fertigung zu nutzen, ist es jedoch notwendig, dass diese dazu in der Lage sind, auch mit neuen Objekten bzw. neuartigen, sich verändernden Situationen umgehen zu können. Die individualisierte Massenproduktion macht es in Zukunft zunehmend notwendig, dass neuartige Bauteile innerhalb der Serienproduktion erkannt und verwendet werden können.

Damit dies gelingt, müssen Roboter mit einem höheren Grad an Intelligenz ausgestattet. Reinforcement Learning leistet dazu einen entscheidenden Beitrag. Denn mit dieser Methode können intelligente Systeme autonom lernen, mit neuen Szenarien umzugehen. Dazu sind jedoch geeignete Lernumgebungen und ein entsprechendes Maß an Zeit notwendig. In dieser Engineering-Phase eignet sich das lernende System selbständig die Regelalgorithmen an, die später dann während der Produktion abgerufen und angewandt werden können, sollte eine entsprechende Situation innerhalb des Fertigungsprozesses auftauchen.

Grundvoraussetzung für den Einsatz von Reinforcement Learning: Wie lautet die konkrete Fragestellung?

Wenn es um den praktischen Einsatz von Reinforcement Learning geht, muss als erstes die Fragestellung richtig verstanden werden. Reinforcement Learning



Christian Lemke M. Sc.,
Junior Machine Learning Engineer,
Alexander Thamm GmbH

ist nicht für jede Aufgabe gleichermaßen die passende Lösung. Welche Methode zu welchem Use Case passt, lässt sich beispielsweise in einem Use-Case-Workshop herausfinden.

Um herauszubekommen, ob sich Reinforcement Learning für eine bestimmte Fragestellung eignet, sollten Sie überprüfen, ob Ihr Problem einige der folgenden Merkmale aufweist:

- Gibt es die Möglichkeit, das Prinzip von „Trial-and-Error“ anzuwenden?
- Ist Ihre Fragestellung ein Steuerungs- oder Kontrollproblem?
- Gibt es eine komplexe Optimierungsaufgabe?
- Lässt sich das komplexe Problem nur bedingt mit traditionellen Engineering-Verfahren lösen?
- Lässt sich die Aufgabe in einer simulierten Umgebung ausführen?
- Ist eine performante Simulationsumgebung vorhanden?
- Kann die Simulationsumgebung beeinflusst werden und deren Status abgefragt werden?

Die Vorteile von Reinforcement Learning

Reinforcement Learning lässt sich idealerweise dann einsetzen, wenn ein bestimmtes Ziel bekannt ist, dessen Lösung aber noch nicht. Beispielsweise: Ein Auto soll selbständig auf dem optimalen Weg von A nach B kommen, ohne einen Unfall zu verursachen. Im Vergleich zu traditionellen Engineering Methoden soll jedoch nicht der Mensch die Lösung vorgeben. Es wird mit möglichst wenigen Vorgaben eine eigene neue Lösung gefunden werden.

Wie bereits weiter oben gesagt, ist einer der großen Vorzüge von Reinforcement Learning ist, dass beim Lernvorgang keine speziellen Trainingsdaten benötigt werden. Im Gegensatz zu Supervised Machine Learning können dadurch neue und unbekannte Lösungen entstehen. Das Erreichen einer neuen optimalen von Menschen unbekannt Lösung ist möglich.

Die Herausforderungen beim Einsatz von Reinforcement Learning

Wer auf Reinforcement Learning setzen will, muss sich darüber bewusst sein, dass damit einige Herausforderungen einhergehen. Allen voran kann der Lernvorgang selbst sehr rechenintensiv sein. Langsame Simulationsumgebungen sind oft der Flaschenhals in Projekten mit Reinforcement Learning.

Daneben ist das Definieren der „Reward-Funktion“ – auch als Reward-Engineering bezeichnet – nicht trivial. Es ist nicht immer von Anfang an ersichtlich, wie die Rewards, also die Belohnungen, zu definieren sind. Darüber hinaus ist das Optimieren der vielen Parameter sehr komplex. Auch die Beschreibung von Beobachtungs- und Aktions-Raum ist manchmal nicht einfach.

Bevor die vergleichsweise aufwändige Methode

zum Einsatz kommen kann, stellt sich stets die Frage nach „Exploration vs. Exploitation“. Das heißt in anderen Worten, dass sich die Frage stellt, ob es lohnender ist, neue, unentdeckte und möglicherweise bessere Lösungswege zu finden oder bestehende Lösungen zu verbessern.

Fazit: Reinforcement Learning hat ein enormes Potential zur Disruption

Reinforcement Learning ist aus mehreren Gründen besonders faszinierend. Zum einen weist die Methode sehr enge Beziehungen zu Psychologie, Biologie und den Neurowissenschaften auf. Denn ähnlich wie wir Menschen können dank dieser Lernmethode auch Algorithmen Fähigkeiten entwickeln, die den unseren ähneln. Auch mittels Reinforcement Learning können Computer durch Trial-and-Error selbständig lernen ihre Umgebung zu verstehen und darin eigene Lösungswege zu finden. Mit diesem vergleichswisen einfachen Prinzip können komplexe Kontroll- und Optimierungsprobleme gelöst werden, die mit traditionellen Methoden nur schwer zu realisieren sind.

Zum anderen fasziniert Reinforcement Learning aufgrund der in die Methode gesteckte Hoffnung, mit ihr eine Allgemeine KI (General Artificial Intelligence) zu erreichen. Es gibt diesbezüglich kaum einen Forschungsbereich, der so vielversprechende Ergebnisse liefert. Dabei ist der Schritt in die Praxis in vielen Fällen schon längst getan. Mit einer geeigneten Simulationsumgebung und einem Belohnungssystem kann Reinforcement Learning zu geradezu beeindruckenden Ergebnissen führen. Aber nicht nur die Erfolge dieser Methode bestätigen, dass Machine Learning im Speziellen und Künstliche Intelligenz im Allgemeinen ein geradezu disruptives Potential haben.

Christian Lemke M. Sc.

Erfolgreiches Machine Learning dank Datenkonsistenz

Immer öfter hören wir in diesen Tagen den Begriff Machine Learning, zumeist im Kontext mit künstlicher Intelligenz. Aber wie sollen Maschinen lernen können? Als Machine Learning bezeichnet man einen Prozess, bei dem IT-Systeme in die Lage versetzt werden auf Basis vorhandener Datenbestände und Algorithmen, Gesetzmäßigkeiten zu erkennen und Lösungen zu entwickeln. Je öfter dieser Prozess abläuft und je mehr Daten als Grundlage dienen, umso besser werden die von der Maschine vorgeschlagenen Lösungen. Die Maschine lernt!

Je besser die Qualität der Daten, umso zuverlässiger das Lernen

Weil die Datenqualität die wichtigste Komponente des Prozesses ist, empfiehlt es sich, im Vorfeld ei-

nes Machine Learning Projekts festzulegen, welche Resultate bzw. Ergebnisse man erwartet. Von dieser Erwartung hängt ab, welche Daten und in welcher Form sie benötigt werden, um den erforderlichen Machine Learning Prozess aufzusetzen. Zum Hintergrund: Es gibt durchaus Prozesse, die mit wenigen Daten auskommen und trotzdem valide Ergebnisse hervorbringen.

Wie ein solcher Ablauf aussehen kann, lässt sich gut an der Funktionsweise eines Kühltransporters visualisieren. Bei einem Kühlwagen beispielsweise erkennt das System anhand der Sensorwerte, welche Temperatur im Inneren des Transporters herrscht. Auch kleinste Temperaturschwankungen lassen sich so erkennen. Die Herausforderung im Fall des Kühltransporters ist aber die Konvertierung der Sensordaten zu Daten, die der Rechner verarbeiten und auswerten kann. Dabei ist die Datenqualität zwar wichtig, die Datenmenge aber eher sekundär.

Ganz anders verhält es sich dagegen bei einer Plastikgussmaschine, etwa einer solchen, die aus flüssigem Kunststoff Spielzeugautos herstellt. Hier wird der Prozess nicht mit Sensoren, sondern mittels Ultraschall überprüft. Bei diesem Vorgang kommen bereits innerhalb kürzester Zeitfenster große Datenmengen zusammen. Die vom Ultraschallgerät erfassten Daten müssen dann so aufbereitet werden, dass sie automatisch verarbeitet werden können. Nur dann kann der Algorithmus erkennen, in welchem Fertigungszustand sich das Spielfahrzeug befindet. Wichtig ist, dass dabei regelbasiert vorgegangen wird, denn nur so lassen sich Korrelationen oder Anomalien aufdecken. In diesem Fall hat vor allem die Datenquantität Auswirkungen auf das Ergebnis: die vielen Einzelwerte des Ultraschallgeräts helfen, dass der Algorithmus des Rechners bereits kleinste Abweichungen sofort erkennt.

Aber es gibt auch noch weitaus heiklere Beispiele – etwa, wenn es um die Bilderkennung geht. Das ist sicherlich kein Problem, wenn es die Gesichtserkennung bei der Laptopkamera betrifft. Soll aber eine Ultraschall-Aufnahme analysiert werden, um eine zuverlässige Brustkrebsvorsorge betreiben zu können, ist maximale Validität gefragt. Umso wichtiger ist die Datenqualität, damit das System zuverlässig und bestmöglich lernt.

Aus Big Data werden Smarte Daten

Beim Machine Learning, geht es darum, heterogene Datenformate und -bestände zu konsolidieren. Mittels Algorithmen werden sie aus der Datenmenge extrahiert, damit sie zu smarten Informationen werden, aus denen sich Schlussfolgerungen ziehen lassen. Die Datenkonsolidierung hat neben der Auswertbarkeit einen weiteren Vorteil: Da man von einer großen Datenmenge ausgeht, fällt eine kleine Anzahl an Fehlern nicht so heftig ins Gewicht. Anders ist das hingegen bei einer geringen Datenmenge, denn hier haben Fehler gravierende Folgen. Dennoch spielt

für den Konsolidierungsprozess eine grundsätzliche Datenkonsistenz eine zentrale Rolle, denn nur wenn die Datenbasis eine gute Qualität aufweist, können die Algorithmen gute Ergebnisse erzielen.

Wie aber lässt sich Datenkonsistenz erzeugen und was ist dabei zu beachten?

1. Datenerfassung

Um die Daten zu erfassen, gibt es unterschiedliche Szenarien. In einigen Fällen kann man mit bereits vorhandenen Signalen arbeiten oder aber es müssen Maschinen mit entsprechenden Sensoren ausgestattet werden. Vielfach ist es sogar möglich, Daten aus der Maschinensteuerung zu gewinnen und über Schnittstellen direkt in ein IoT-Gateway zu schreiben.

2. Dateninterpretation

Nach der Datengewinnung geht es darum zu verstehen, welche verschiedenen Werte, Angaben oder Daten für was stehen. Nur wenn man weiß, dass ein Sensorwert für eine bestimmte Temperatur steht, lässt sich der einzelne Wert einordnen. Was beim genannten Temperaturbeispiel einfach zu sein scheint, ist bei anderen Aufgabenstellungen durchaus komplexer. Die Dateninterpretation ist aber sehr wichtig, denn sie ist die Grundlage für die Algorithmen, die dann wiederum Basis für das Machine Learning sind.

3. Datenaufbereitung

Schließlich müssen die Daten aufbereitet und aggregiert werden, damit die verschiedenen Werte einer oder mehrerer Maschinen konsistent und einheitlich sind. Für diesen Konsolidierungsprozess gibt es bereits Lösungen und Plattformen, z.B. edbic von compacer, die Datenformate entsprechend für das Zielsystem umwandeln und auf Basis von Regeln interpretieren.

4. Datentransport und -analyse

Schlussendlich bereitet ein IoT Hub die Daten so auf, dass verschiedene Auswertungen möglich sind. Der IoT Hub dient zudem als „Transporteur“, um die Daten z.B. in ein vorhandenes ERP- oder MES-System zu überspielen, in ein Analytics Tool oder in Siemens Mindsphere, IBM Watson oder Microsoft Azure und ähnliche Systeme.

Wenn all diese Aspekte umgesetzt sind, kommt ein weiterer Punkt hinzu: die Datensouveränität. Damit ist gemeint, dass die Unternehmen sehr gewissenhaft dafür sorgen müssen, dass sie Herr ihrer eigenen Daten bleiben. In diesem Kontext geht es nicht nur um Fragen der Datensicherheit, sondern auch der Speicherort spielt eine wichtige Rolle. Die Verantwortlichen müssen dafür sorgen, dass Daten und Anwendungen deutscher Nutzer nicht zwangsläufig auf Servern in den USA landen. Sie müssen auch die Chance haben ihre Daten - gemäß der europäischen Datenschutzgrundverordnung - in Deutschland bzw. Europa zu speichern.



Lumir Boureau,
Geschäftsführer,
compacer GmbH

Machine Learning – und was dann?

Doch das Speichern von Daten im Ursprungsland, also in Deutschland, nur ein Trend. Schon heute ist erkennbar, dass die Nutzung von Algorithmen immer populärer wird. Es wird nicht allein bei Machine Learning bleiben, sondern es werden sich weitere KI-Formen entwickeln. Auch wenn die IT-Systeme heute schon mit jedem einzelnen Sonderfälle „lernen“ sich selbst zu perfektionieren, so dass Prozesse sukzessiv automatisiert werden können. Die Datenqualität und -konsistenz sind dabei zentrale Voraussetzung, insbesondere vor dem Hintergrund, dass sogenannte „schlechte Daten“ nicht ohne weiteres aus einem Machine Learning Prozess wieder herausgenommen werden können. Der Grund: Machine Learning baut konsequent und konsistent aufeinander auf. Werden dem System Daten entzogen, die bisher Teil der Berechnung waren, könnte der gesamte Prozesse wie ein Kartenhaus in sich zusammenfallen.

Ergo sind die Datenqualität und -konsistenz das A und O der Digitalisierung und sollten deshalb nicht stiefmütterlich behandelt, sondern besser in den Mittelpunkt der Entwicklung gestellt werden.

Lumir Boureau

Reifegradmodell: In drei Schritten das Beste aus den Daten herausholen

Mit der Digitalisierung wächst die Bedeutung der Daten zunehmend – das ist nichts Neues. Aber was heißt das konkret für Unternehmen? Betriebe, die ihre Daten lediglich passiv nutzen, etwa um rückblickend den Erfolg des vergangenen Quartals auszuwerten, verschenken das enorme Potenzial der Informationen. Denn als strategischer Aktivposten eingesetzt, können Datensätze aktiv Gewinne erzielen – etwa indem sie Geschäftswachstum vorantreiben, neue Geschäftsmöglichkeiten identifiziert oder die Einhaltung gesetzlicher Vorschriften belegen und so Strafzahlungen vermeiden. Entscheidend dafür ist jedoch, dass die Daten zuverlässig und vertrauenswürdig sind. Allerdings gaben einer aktuellen Umfrage von ASG Technologies[1] zufolge 63 % der befragten Unternehmen an, Bad Data, also fehlerhafte, veraltete oder ungenaue Daten, für Geschäftsentscheidungen genutzt zu haben. Mehr als die Hälfte habe so eine Geschäftsmöglichkeit verpasst. Bei 64 % seien dadurch sogar zusätzliche Kosten entstanden. Das verdeutlicht ein Problem: Beim Versuch, möglichst schnell den maximalen Wert aus den Daten zu ziehen, lassen viele Unternehmen die Grundlagen eines stabilen Datenmanagements außer Acht. Wer aber nachhaltig von seinen Daten profitieren will, braucht einen strukturierten Ansatz, der die Grundlagenarbeit miteinbezieht und darauf ausgelegt ist, stets das Optimum aus den Daten herauszuholen. Ein Reifegradmodell kann dabei unterstützen.

First things first: Die Grundlagenarbeit

Zunächst: Es gibt ihn nicht: den „einen“ Weg zum erfolgreichen Metadatenmanagement. Jeder Betrieb unterliegt anderen Voraussetzungen und ist anders strukturiert. Demensprechend individuell müssen die einzelnen Schritte ausgestaltet werden. Aber der Prozess zur Monetarisierung der Daten startet immer mit der Erkenntnis, dass das Datenmanagement optimiert werden muss. Dahinter steckt in der Regel das Ziel, bessere operative Entscheidungen zu treffen und den maximalen wirtschaftlichen Nutzen aus den Daten zu ziehen. Genau in dieser „Sensibilisierungsphase“, in der das Problem identifiziert wurde, setzt das Reifegradmodell[2] an.

Voraussetzung: Das Problem erkennen

Unternehmen in der Sensibilisierungsphase setzen bereits Daten ein, um ihr Geschäft zu betreiben. Dementsprechend verfügen sie auch über Datenverwaltungsstrukturen. Nicht selten sind die Informationen aber in Silos angelegt und in bestimmte Geschäftsbereiche, Produkte oder Zielgruppen unterteilt. Das Problem: Diese Struktur verhindert eine unternehmensweite Sicht auf den gesamten Datenbestand. Redundanzen und Unsicherheiten, wie bestimmte Datenelemente verwendet werden, sind die Folge. Die Vertrauenswürdigkeit der Informationen lässt sich nicht einschätzen. In dieser ersten Phase haben die Unternehmen den Handlungsbedarf erkannt und stehen nun vor der Herausforderung, die enorme Datenmenge zu demokratisieren.

Schritt für Schritt: Das Reifegradmodell

Schritt 1: Grundlagenarbeit – das vollständige Dateninventar

Zu Beginn müssen Unternehmen das komplette Dateninventar erfassen. Da regelmäßig neue Daten hinzukommen, gilt es anschließend einen automatisierten Prozess einzuführen, der diesen Bestand kontinuierlich aktualisiert. Das ist einer der wichtigsten Schritte, der oftmals übersprungen wird. Genau das verursacht hinterher Probleme. Denn um die Vertrauenswürdigkeit der Daten einzuschätzen, müssen die Mitarbeiter wissen, welche Daten wo abgelegt sind, aus welcher Quelle sie stammen und in welchem Kontext sie stehen. Erst dann können sie sie als sichere Entscheidungsgrundlage nutzen. Entsprechende DI-Tools erkennen Bestände und integrieren Informationen zur Quelle, Anwendung oder dazugehörigen Geschäftsprozessen automatisch.

Schritt 2: Das Datenmanagement

Ist das Dateninventar vollständig und aktuell, können sich die Unternehmen dem Datenmanagement widmen. Wichtige Prozesse sind hier: Data Governance, Datenaustausch und Datenrationalisierung. Data Governance gibt den Rahmen und die Regeln

für das Datenmanagement vor. Gleichzeitig kontrolliert es auch die Einhaltung von definierten Prozess-, Qualitäts- und Sicherheitsstandards. Damit sorgt Data Governance nicht nur für einen verständlichen, korrekten und sicheren Datenbestand, sondern ist auch ein wichtiger Faktor für die Einhaltung von Datenschutzrichtlinien. Mit Data Sharing können Mitarbeiter bereichsübergreifend zusammenarbeiten. Dazu wird ein Self-Service-Inventar erstellt, in dem sie alle relevanten Daten für ihre Aufgabe finden können. Besonders zur Förderung von Innovationen spielen solche Self-Service-Datenzugriff eine wichtige Rolle. Data Rationalization senkt Kosten und erleichtert das Finden von Daten. Dazu werden die Datenbestände kategorisiert und mit einem wesentlichen Geschäftswert verknüpft. Ein Geschäftsglossar fasst die entsprechenden Geschäftsbegriffe zusammen. Diese Zuordnung von Geschäftsbegriffen zu Datenelementen ist die Basis für automatisiertes Data Lineage, das die Herkunft und den Fluss der Daten durch das Unternehmen nachvollzieht. So lassen sich doppelte oder nicht verwendete Daten erkennen und entfernen. Der Vorteil: Sind weniger Datenelemente vorhanden, sinken Speicher- und Verwaltungskosten, und nützliche Daten lassen sich leichter finden.

Schritt 3: Daten monetarisieren

Nach Schritt eins und zwei besitzen die Unternehmen bereits die wesentliche Informationsstruktur, um einen wirtschaftlichen Nutzen aus den Daten zu ziehen. Um den Prozess zu vollenden, sind im letzten Schritt fünf Aspekte wichtig:

- Daten ermitteln, die geeignet sind, das Geschäft voranzubringen
- Datenbestände kennzeichnen, um sie mit der geschäftlichen Nutzung zu verknüpfen
- Metriken hinzufügen, um festzustellen, wer Daten für welchen Zweck verwendet und welcher Wert daraus abgeleitet wird
- Neue Datenquellen automatisch erfassen und kennzeichnen, um Monetarisierungsmöglichkeiten zu identifizieren
- Den Wert der Daten feststellen und an externe Nutzer weiterleiten

Fazit

Die zunehmende Masse an Daten, gesetzlichen Vorgaben und auch die Erwartungen der Kunden üben immer mehr Druck auf die Unternehmen aus. Accenture[2] zufolge ist das Extrahieren des Datenwerts sogar längst zu einer Wettbewerbsnotwendigkeit geworden. Vor allem bei Geschäftsentscheidungen, Produkteinführungen und der Marktpositionierung sind vertrauenswürdige Daten wertvoll und können einen entscheidenden Wettbewerbsvorteil ausmachen. Die drei Schritte des Reifegradmodells helfen Unternehmen dabei, ihre Daten genau zu kennen und zu wissen, wo sie diese

gewinnbringend einsetzen können. So können sie langfristig das Optimum aus den Daten herausholen.

Nicole Biel

Referenzen: [1] <https://content.asg.com/MarketingCollateral/DataIntelligence/whitepaper-asg-data-intelligence-barriers-to-success.pdf> [2] <https://www.asg.com/de/Collateral/The-ASG-Data-Intelligence-Maturity-Model.aspx> [3] <https://www.accenture.com/us-en/topic-accenture-value-of-data>

1.6 PRODUKTIVITÄT

Mehr Transparenz bitte! Die Vorteile KI-gestützten Identitätsmanagements

Das Enterprise Identity Management ist die Schlüsselkomponente eines jeden Cybersecurity-Programms. Um Angriffe und Bedrohungen rechtzeitig erkennen und abwehren zu können, benötigen IT-Verantwortliche Einblick in die Unternehmensumgebung. Sie müssen wissen, wie die einzelnen Anwendungen, Datenelemente und Identitäten interagieren, um sicherzustellen, dass alle Richtlinien eingehalten werden und riskantes Verhalten möglichst minimiert wird. Allerdings macht es das hohe Volumen an Anwendungen, Daten und Identitäten immer schwieriger, den Überblick zu behalten. Hinzu kommt ein Mangel an hochqualifiziertem Personal für die IT-Sicherheit. Mit dem Einsatz künstlicher Intelligenz lässt sich das Identity Management optimieren und Risiken können reduziert werden.

Dank mobiler Endgeräte und Cloud-Services ist es heute ein leichtes, Daten unkompliziert auszutauschen, gemeinsam an Projekten zu arbeiten und jederzeit und von überall aus auf Daten zuzugreifen. Diese Art zu arbeiten beschleunigt die Produktivität und ermöglicht ein flexibles Arbeiten – ob im Home-Office oder von unterwegs. Doch solch ein 24/7-Zugriff erhöht gleichzeitig das Risiko von Cyberangriffen, denn die Verantwortlichen drohen die potenziellen Schwachstellen aus den Augen zu verlieren. So wird es derzeit immer deutlicher, dass Hacker mittels Methoden wie Phishing oder Social Engineering insbesondere die „Schwachstelle Mensch“ ins Visier nehmen – umso wichtiger ist es, dass Unternehmen über eine effektive Identity Management-Lösung verfügen.

Oftmals dauert es 200 Tage, bisweilen sogar zwei Jahre, bis ein Unternehmen Verstöße gegen oder Angriffe auf die IT-Sicherheit entdeckt. Das Grundproblem ist in den meisten Fällen die mangelnde Einsicht der IT-Teams in die Unternehmensumgebung mitsamt allen Anwendungen, Datenelementen und Identitäten. Die hohe Dynamik des Marktes und unvorhersehbare



Nicole Biel,
Field Marketing
Manager
Central Europe,
ASG Technologies

Unternehmensentwicklungen haben zur Folge, dass das Datenaufkommen, die Nutzung von Anwendungen und das Volumen der Identitäten exponentiell steigen. Daher benötigen IT-Verantwortliche Lösungen, die einen kontextbezogenen Einblick gestatten und ihnen dabei helfen, ihre Identitäten intelligenter zu verwalten, die Wirkung ihrer Identity Governance-Lösung zu steigern und potenzielle Bedrohungen durch die Identifizierung risikoreicher Identitäten, Daten und Aktivitäten zu bewältigen.

Mit Hilfe der künstlichen Intelligenz ist es möglich, selbst große Mengen an Identitätsdaten zu nutzen und diese mit Echtzeitdaten zu verknüpfen, um kontextbezogene Einblicke zu gewähren und die Identitätsverwaltung zu optimieren. Techniken des maschinellen Lernens unterstützen dabei, Konto- und Berechtigungszuweisen zu analysieren und diese mit Aktivitätsinformationen in Echtzeit zu kombinieren, um verdächtige und anomale Verhaltensweisen zu identifizieren. Solche Lösungen sorgen auch dafür, dass IT-Verantwortliche Risiken, die mit Zugriffsrechten verbunden sind, besser verstehen, sodass sie Prioritäten setzen und sich ausschließlich auf risikoreiche Komponenten konzentrieren können.

Effektives Risikomanagement und schnellere Reaktionsfähigkeit dank KI

Betrachtet man nochmals die „Schwachstelle Mensch“, die Cyberkriminelle allzu gerne als Einfallstor ins Unternehmensnetzwerk nutzen, mit der Identität als Schlüssel, ließe sich mittels einer smarten Identity Management-Lösung der Spieß ebenso gut umdrehen: So könnte die Identität auch als starke Firewall fungieren.

Der Einsatz von künstlicher Intelligenz und maschinellem Lernen ermöglicht es Unternehmen, schneller auf Angriffe und Bedrohungen zu reagieren, da sie alle Identitätsdaten in ihren IT-Systemen nutzen können, um ein selbstlernendes, prädiktives Identitätsprogramm zu erstellen. Automatisierte Lösungen unterstützen beim Zugriffsmanagement und sorgen dafür, dass einerseits die IT-Teams entlastet werden und andererseits alle Unternehmensrichtlinien eingehalten werden. Schließlich sollten Zugriffsgenehmigungen zwar so einfach, schnell und sicher wie möglich vonstatten gehen, allerdings ohne Abstriche in der Sicherheit. Bei einem KI-gesteuerten Ansatz werden die Nutzer von dieser intuitiven Identität als eine kollektive Gruppe betrachtet, wodurch das Prozedere der Zugriffsverwaltung beschleunigt wird. Dennoch gewähren solche Lösungen Einblicke in den Zugriff jedes einzelnen Nutzers, sodass er rasch gesperrt werden könnte, sobald eine Anomalie in der Aktivität festgestellt wird.

Mit einer Analyse-Engine, die auf Basis von Time Series Analysis und Deep Learning immense Mengen an Identitätsdaten scannt, können Risiken identifiziert sowie anomale Verhaltensweisen und potenzielle Bedrohungen erkannt werden, ohne auf eine ganze

Schar an Sicherheitsexperten angewiesen zu sein. Entsprechende Muster werden nach und nach verfeinert, während die Lösung lernt, welche Maßnahmen ein Administrator als Reaktion auf ungewöhnliche Ereignisse ergreift. Im Laufe der Zeit können risikoreiche Ereignisse dann präventiv aus der Flut alltäglicher Aktivitäten herausgefiltert werden.

Sind Risiken einmal erkannt, geht es für die IT-Verantwortlichen im nächsten Schritt darum, adäquat zu reagieren. Governance-Entscheidungen, die isoliert getroffen werden, sind recht fehleranfällig, da sie nur den unmittelbaren aktuellen Umstand berücksichtigen: So könnte eine Zugriffserlaubnis ohne weiteren Kontext einem Mitarbeiter unnötigen Zugang zu Daten verschaffen. Eine höhere Transparenz und ein tieferes Verständnis des Umfelds helfen dabei, schnelle und präzise Entscheidungen zu treffen, die gleichzeitig das Risiko für das gesamte Unternehmen verringern. Die Verwendung von Peer-Gruppen, in denen Identitäten nach ähnlichen Merkmalen gruppiert werden, kann rasch alle Identitäten hervorheben, die über ungewöhnliche Eigenschaften verfügen. So könnte beispielsweise eine auf einem Vertriebsteam basierende Peer-Group aufzeigen, dass die meisten Mitglieder Zugang zu Ressourcen wie Salesforce haben. Jeder Ausreißer, etwa ein Mitarbeiter, der fälschlicherweise Zugriff auf eine Personaldatenbank hat, ließe sich auf diese Weise leicht identifizieren.

Smarte Identity Management-Lösungen setzen Technologien der künstlichen Intelligenz auf der Grundlage der Erkennung von Verhaltensmustern und statistischer Analysen ein, um die Kontrollen der Identitätsverwaltung in Echtzeit auf risikoreiche Szenarien zu konzentrieren. Ein Beispiel hierfür wäre der Zugriff auf sensible Daten von neuen Standorten aus oder zu ungewöhnlichen Zeiten. Dank der Verwendung eines dynamischen Risikomodells statt statischer Momentaufnahmen, passt sich das Modell kontinuierlich an die Entwicklung der Unternehmensumgebung an und identifiziert neue und zusätzliche Arten von risikoreichen Identitäten und Aktivitäten. Durch die automatisierte Prüfung und Genehmigung von risikoarmen Zugriffen können zusätzlich Produktivität und Effizienz im Unternehmen gesteigert werden.

Volker Sommer

Die Zukunft der Produktion liegt in den Daten der Vergangenheit

Industrielle Datenanalyse wird derzeit von immer mehr Unternehmen als lohnende Ergänzung zu bisherigen produktionsbegleitenden Verfahren erkannt. Dabei kann sie als Teil einer umfassenden Digitalisierungsstrategie nicht nur Ausfälle minimieren, sondern die gesamte Effizienz einer Anlage steigern.

Wer Daten als das Gold des 21. Jahrhunderts be-

zeichnet, hat zumindest nicht ganz unrecht. Allerdings gilt vor allem in der Industrie, dass der Datenschatz bereits seit Jahren oder sogar schon Jahrzehnten vorliegt – ihn zu bergen war bislang aber eine sehr komplexe Option. Da sich in vielen industriellen Anlagen in den letzten Jahren durch höhere Konnektivität innerhalb der Anlage und bessere Rechenleistungen die Voraussetzungen zur Datenanalyse grundlegend geändert haben, stehen Unternehmen heute viel mehr Möglichkeiten offen die vorhandenen Daten richtig zu nutzen.

Dabei ist einer der entscheidenden Fortschritte, die zu einer Ausweitung der Nutzung von Industrial Analytics führen, dass aus diesen neuen Entwicklungen entstehende und eng damit verknüpfte maschinelle Lernen. Durch die gemeinsame Nutzung dieser Entwicklungen, können Industrieunternehmen aus verschiedensten Branchen Daten nicht nur optimal aufbereiten, sondern auch Rückschlüsse auf Produktion und künftige Entwicklungen innerhalb der Anlage ziehen.

Produktionsdaten im Wandel der Zeit

Produktionsdaten fielen in Industrieanlagen an verschiedenen Stellen schon immer an. Allerdings hat sich die Form und die damit verbundene Nutzung über die letzten Jahre durchweg verändert. Durch den demografischen Wandel und den immer spürbareren Fachkräftemangel, verlieren Industrieunternehmen auch immer mehr erfahrenes Personal, dass allein am Klang einer Anlage den anstehenden Austausch von Verschleißteilen oder drohende Fehlproduktionen erkennen konnte. An die Stelle der alten Produktionsdaten, also unregelmäßiger Töne und kaum hörbarer Schleifgeräusche, treten im Zuge des Ausbaus hin zum Connected Enterprise immer mehr digitalisierte Informationen und Produktionsparameter, die ohne das nötige Wissen oder die passenden Lösungen nur schwierig auszuwerten sind.

Intelligente Maschinen, moderne Steuerungen, Kameras und einzelne Sensoren aus der produktionsnahen Umgebung produzieren während des gesamten Maschinenbetriebes eine kaum fassbare Informationsmenge. Dazu gehören nicht nur Informationen zur Drehzahl einzelner Motoren oder zur Produktqualität, auch die Temperatur innerhalb der Produktionshalle, die Luftfeuchtigkeit oder einzelne Druckparameter fallen hierunter. Bemerkenswert sind hierbei vor allem zwei Dinge. Zum einen wächst die Datenmenge stets an, zum anderen wurden diese neuen Informationen in der Vergangenheit überwiegend retrospektiv genutzt, um Ausfälle erklären zu können – nachdem sie bereits geschehen sind.

Industrial Analytics als promethische Unterstützung für die Industrie

Gesteigerte Konnektivität, höhere Rechenleistung und

maschinelles Lernen ermöglichen Industrieunternehmen nun eine bessere und weitreichendere Nutzung der generierten Daten. Vor allem kleine und mittlere Unternehmen können oftmals nicht auf die notwendigen Kapazitäten zurückgreifen, um Datenanalysten zu beschäftigen, die die angefallenen Daten mittels herkömmlicher Methoden nachbearbeiten, kontextualisieren und analysieren. Durch die schiere Menge an Daten ist es zudem beinahe ausgeschlossen, dass kleinteilige Verfahrensprozesse überwacht werden können.

Für die Überwachung kleinteiliger Aspekte einzelner Anlagen sind moderne Datenanalysetools daher eine entscheidende Bereicherung für die Industrie. Will man beispielsweise in einer Abwasserkläranlage die Funktionalität und planmäßige Arbeit einer Pumpe überwachen, spielen neben den Maschinendaten zum Beispiel auch die Flussgeschwindigkeit und der Druck eine entscheidende Rolle. Mittels moderner Analyse-Module, welche auf komplexen Algorithmen basieren, lassen sich die an verschiedenen Stellen in der Anlage gesammelten Daten kontextualisieren und in Echtzeit Prognosen zur weiteren technischen Abwasserreinigung erstellen. Dabei können solche modernen Module einfach installiert und programmiert werden, um eine Vielzahl unterschiedlicher Zwecke zu erfüllen.

Vergangenheit, Gegenwart und Zukunft

Um zu verstehen, welche Vorteile am Schluss durch Industrial Analytics entstehen, hilft es sich zu vergegenwärtigen, wie dies schematisch funktioniert. Je nach Anwendungsgebiet, müssen zunächst Daten gesammelt werden, die das genutzte Modul verarbeiten kann. Um beim Beispiel der Kläranlage zu bleiben, wird zunächst überwacht, was innerhalb eines vorab definierten Abschnitts passiert, welche Leistung bringt die Pumpe, wie verändert sich der Druck des Abwassers und welche Parameter werden hinsichtlich der Viskosität erreicht? Über Industrial Analytics werden diese historischen Daten im nächsten Schritt in den Produktionskontext gesetzt und mittels der gegenwärtigen Werte für die Zukunft fortgeschrieben. Je umfangreicher und klarer dabei die Datengrundlage ist, umso bessere Zukunftsprognosen können am Schluss abgegeben werden.

Differieren die tatsächlichen Leistungskennzahlen der Pumpe ab diesem Punkt wesentlich von den errechneten, liegt in aller Regel ein Problem vor. Durch die Arbeit des Moduls können auf diese Weise wertvolle Erkenntnisse hinsichtlich Predictive und Prescriptive Maintenance getroffen werden, also vorausschauend agiert werden. Bevor ein unerwarteter Ausfall auftreten kann, ist es möglich, die Anlage in einen planmäßigen Instandhaltungsprozess zu begeben. Auf diese Weise können Ausfallzeiten minimiert werden und die Anlage lässt sich störungsfrei betreiben. Zudem



Volker Sommer,
Area Vice President
DACH & EE,
SailPoint



Uwe Küppers,
Senior Consultant
Smart
Manufacturing,
Rockwell
Automation

kann die Effizienz der gesamten Anlage gesteigert werden, indem einzelne Parameter optimiert und so auf die bestmögliche Auslastung der Pumpe hingearbeitet wird.

Wachstum oder Stagnation – moderne Systeme machen den Unterschied

Industrial Analytics innerhalb der Produktion stellt eine der wichtigsten Entwicklungen der letzten Jahre dar. Gemeinsam mit anderen modernen Tools wie ausgeklügelten Manufacturing Execution Systemen (MES) oder Augmented und Virtual Reality bilden sie den Grundstein für eine zeitgemäße Produktion. Dabei steht am Schluss immer im Vordergrund, dass Unternehmen effizienter produzieren, Kosten senken und die Belastung ihrer Mitarbeiter so gering wie möglich halten. Vor allem in ungewissen Zeiten, können diese Vorteile den Unterschied zwischen Stagnation und Wachstum darstellen.

Uwe Küppers

Von Science-Fiction zur Realität: Robotik in der Smart Factory

Filme wie „WALL-E“ oder „I, Robot“ beschreiben eine Welt, in der Roboter eine zentrale Rolle im Leben der Menschen einnehmen. Dabei sollen sie den Menschen hauptsächlich lästige Alltagsarbeiten abnehmen. Ein Blick in die Fertigungsindustrie zeigt, dass dieser Traum dank künstlicher Intelligenz (KI) und Machine Learning schon teilweise Realität ist.

KI und Machine Learning sind heutzutage Teil unseres Alltags. Sei es in den eigenen vier Wänden durch den virtuellen Assistenten Alexa oder die unzähligen Sprachhelfer wie Siri im Handy. Doch ist das tatsächlich schon künstliche Intelligenz? Unter KI wird die Fähigkeit verstanden, intelligentes menschliches Verhalten auf Maschinen zu übertragen, zum Beispiel das Erkennen von Texten, Bildinhalten oder die Spracherkennung. Obwohl die Begriffe KI und Machine Learning oft austauschbar genutzt werden, sind sie nicht dasselbe. Machine Learning ist nämlich nur ein Teilbereich von KI und beschreibt mathematische Techniken, die einer Maschine ermöglichen, selbständig Wissen aus Erfahrungen zu generieren.

Roboter in der Fertigung

Spricht man von KI in der Fertigungsindustrie, so sind in der Regel intelligente Industrieroboter gemeint. Für Industrieroboter bildet maschinelles Lernen eines der leistungsstärksten Technologien. Ziel ist es, dass die Maschine aus früheren Fehlern lernt und in der Lage ist, zukünftige Probleme oder Störungen rechtzeitig zu identifizieren und selbstständig zu beheben. Das Interesse von Unternehmen, diese digitalen Technologien in ihren Fertigungsprozessen zu integrieren, ist

in den vergangenen Jahren stark gestiegen. Laut einer Untersuchung von BCG und MIT Sloan Management gehen 84% der Führungskräfte von einem deutlichen Wettbewerbsvorteil durch smarte und intelligente Maschinen im Unternehmen aus.

In der Praxis sieht der Vorteil wie folgt aus: Bei der Produkt-Montage identifizieren Roboter über Sensoren und Kameras zuverlässig Einzelteile und greifen, positionieren und setzen Komponente einer Baugruppe korrekt zusammen. Besonders bei Produktionsprozessen mit stark automatisierten Bewegungsabläufen, wie Laserschweißen, Löten, Sprühen oder Kleben kommen Industrieroboter zum Einsatz. Die robotergestützte Inspektion wird ebenfalls direkt in die Fertigungslinie integriert. Dies erweist sich insbesondere bei Produkten mit großen Formfaktoren als nützlich. Schwere Teile können mit programmierten Roboterarmen zusammengeschweißt werden und unterstützen so die Mitarbeiter in der Produktion. Die Anforderungen an Qualität und Präzision sind hoch, da schon kleine Produktfehler möglicherweise zu schweren Unfällen führen können. Dementsprechend muss die Qualität der Inspektion ebenso hoch sein.

Sorgfältige Inspektion im Reinraum mit KI

Ähnlich hohe Anforderungen stellt auch die Fertigung von komplexen medizinischen Geräten, wie Infusionspumpen, Laborinstrumente oder medizinischen Einweggeräten (Single-Use-Devices). Die Herstellung dieser Produkte unterliegen strengen Richtlinien hinsichtlich Hygiene und müssen daher oftmals in der sterilen Umgebung eines Reinraums gefertigt werden. Reinräume minimieren durch systematische Lüftungs- und Filtertechniken Produktions- und Umweltrisiken, die durch Partikel entstehen könnten. Findet sich während der Qualitätskontrolle nur ein einzelnes Haar in den bereits steril verpackten Geräten, kann das zum Rückruf ganzer Produktchargen führen und immense Kosten zur Folge haben. Um das größte Kontaminationsrisiko „Mensch“ zu vermeiden, ist in der Reinraumfertigung der Automatisierungsgrad und Einsatz von Robotern sehr hoch. Roboter übernehmen hier wichtige Arbeitsschritte, von der Montage der einzelnen Komponenten über die Prüfung und Inspektion des Endgeräts bis hin zur sterilen Verpackung.

Bei der robotergestützten Inspektion prüfen eingebaute Kameras Objekte und Bauteile während der Produktion auf mögliche Fehler. Die automatisierte Bildverarbeitung verleiht Robotern eine kognitive Fähigkeit, um bestimmte Objekte anhand von Einkerbungen, Markierungen oder anderen visuellen Merkmalen zu identifizieren und zu lokalisieren. Dabei wertet die künstliche Intelligenz in der laufenden Produktion Bilder eines Bauteils oder einer Komponente aus und gleicht sie in Millisekunden mit hunderten anderen Bildern der gleichen Sequenz ab. So kann in Echtzeit festgestellt werden, ob zum Beispiel alle

vorgesehenen Teile eines Single-Use-Devices richtig zusammengefügt sind. Liegen hier Abweichungen vor, kann der Roboter diese frühzeitig während der Produktion erkennen und als Fehler melden. Das garantiert neben einem hohen Maß an Sauberkeit auch eine höhere Zuverlässigkeit bei der Fertigung komplexer medizinischer Geräte.

Datenanalytik im IIoT

Bei robotergestützten Inspektionen wird Machine Learning in erster Linie eingesetzt, um die Erkennungsleistung des Roboters zu optimieren. Das Industrial Internet of Things (IIoT) ist dafür eine wichtige Voraussetzung. Dabei erfassen und verarbeiten Industrieroboter während des Einsatzes zahlreiche verschiedene Informationen. Basierend auf diesen Datensätzen können Automatisierungslösungen besser programmiert und gesteuert werden. Je vernetzter die Daten, desto mehr Kontext entsteht, der es KI-Anwendungen ermöglicht, Muster zu erkennen, zu lernen und auf unterschiedliche Prozesse anzuwenden.

Ein gutes Beispiel bildet hier die vorausschauende Instandhaltung. Sensoren sammeln leistungsbezogene Daten von der jeweiligen Maschine und überwachen so den Wartungsbedarf. So können Reparaturen veranlasst werden, bevor Defekte auftreten. Mit hohen Kosten verbundene Ausfallzeiten gehören damit der Vergangenheit an. Datenanalytik bietet auch die Ausgangslage für eine 360°-Ansicht von Produkten und unterstützt ein agiles und effizientes Engineering. Im Supply Chain Management liefert die Auswertung von Daten treffgenaue Vorhersagen, um Risiken frühzeitig zu entschärfen und schnell auf Engpässe, Marktschwankungen und Störungen reagieren zu können.



Im Reinraum garantieren Roboter bei der Fertigung medizinischer Produkte ein hohes Maß an Sauberkeit und Sterilität (Quelle: Plexus)

Smart Factory – mehr als nur Science-Fiction

Egal ob IIoT, KI, Machine Learning, Industrieroboter oder die kostenintensive Fertigung im Reinraum – die Einführung von disruptiven Technologien für die Smart Factory ist ein zeit- und kostenintensives Unterfangen. Unternehmen sollten daher schrittweise smarte Prozesse implementieren und den Mehrwert von KI für unterschiedliche Einsatzbereiche und Geschäfts-

felder testen. Das können und müssen Unternehmen nicht allein tun. Wie wirkt sich eine robotergesteuerte Fertigung auf das Design und die Entwicklung von Produkten aus? Wo in der Produktionsumgebung macht der Einsatz von KI überhaupt Sinn? Wie muss die IT-Infrastruktur aussehen, um auch langfristig die Flut an Daten managen und auswerten zu können? Gemeinsam mit einem E2MS Partner lassen sich solche Fragen gezielt beantworten. Dabei können sie auch über den eigenen Tellerrand hinausschauen und von branchenfremder Expertise in Bezug auf Machine Learning, Data Analytics und KI profitieren.

Unterm Strich liegen die Vorteile von robotergestützten Automatisierungslösungen jedoch klar auf der Hand: hohe Präzision, Optimierung der Betriebszeit, Reduzieren von Downtime und höhere Konsistenz innerhalb der Produktion. Letztlich steigt damit auch die Qualität und die Time-to-Market verkürzt sich. Bis die Roboter Seite an Seite mit den Menschen leben und echte KI an den Tag legen, ist es sicher noch ein Weilchen hin. Doch in der Produktion sind sie schon heute in vielen Fällen ein fester Bestandteil. Die Implementierung künstlicher Intelligenz wird den Industriesektor für Hersteller sowie Kunden stark verändern und zusammen mit einem hohen Automatisierungsgrad in Zukunft noch anspruchsvollere Produkte ermöglichen.

Robert Frodl



Robert Frodl, DACH Region Customer Development for Engineering Solutions, Plexus Corp.

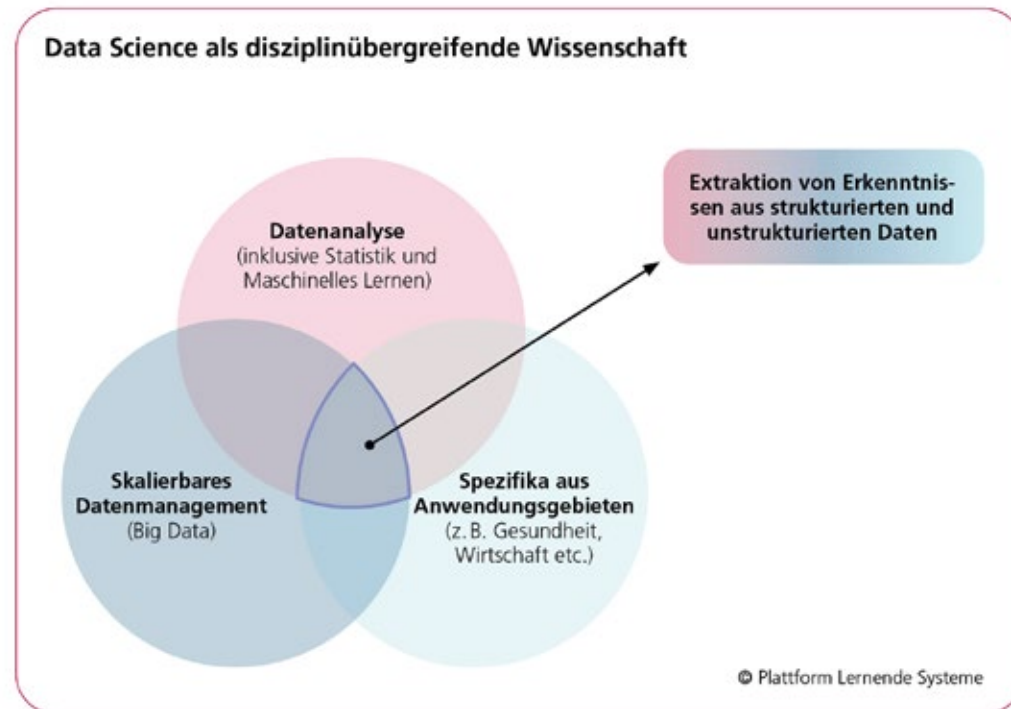
1.7 AUS DATEN GEBOREN

Von Daten zu Künstlicher Intelligenz – Datenmanagement als Basis für erfolgreiche KI-Anwendungen

Fachbeitrag von Daniel Keim (Universität Konstanz) und Kai-Uwe Sattler (TU Ilmenau) / Plattform Lernende Systeme

Daten sind die Grundlage für erfolgreiche KI-Anwendungen. Doch es braucht noch mehr: Um die Potenziale von Künstlicher Intelligenz auszuschöpfen, ist ein umfassendes Datenmanagement erforderlich, das die vorliegenden Daten überhaupt erst zugänglich macht. Worauf es dabei ankommt, warum Data Science als Schlüsseldisziplin für Wissenschaft und Wirtschaft gilt und wie sich das Verständnis für Data Science-Prozesse fördern lässt, skizziert ein aktuelles Whitepaper der Plattform Lernende Systeme.

Künstliche Intelligenz (KI) versetzt uns teils in Erstaunen, teils nehmen wir sie in unserem Alltag als



solche gar nicht zur Kenntnis. Fährt ein Auto autonom auf einer Teststrecke, besitzt dieses Bild noch eine gewisse Magie. Nutzen wir dagegen Übersetzungsdienste wie DeepL oder Google Translate, ist uns das selbstlernende System, das diese Dienste ermöglicht, kaum bewusst.

Die Entwicklung derartiger KI-Anwendungen basiert auf maschinellen Lernverfahren, die große Mengen an Daten nutzen. Daten allein reichen jedoch nicht, um das in ihnen verborgene Potenzial auszuschöpfen. Sie müssen durch ein Datenmanagement zunächst einmal der Analyse zugeführt werden, das heißt: Sie müssen erfasst und in adäquater Weise aufbereitet werden. Eine simple Trennung von Datenmanagement einerseits und Datenanalyse sowie maschinellem Lernen andererseits greift jedoch zu kurz. Es ist vielmehr ein Zusammenspiel, das zu KI-Innovationen führt: Maschinelle Lernverfahren können das Datenmanagement unterstützen, dieses wiederum ist ein Fundament für KI-Systeme. Oft aber ist zudem Expertenwissen aus Anwendungsdomänen notwendig, um innovative Produkte und Dienstleistungen zu entwickeln. Diesem Zusammenspiel trägt die noch junge Disziplin der Data Science Rechnung.

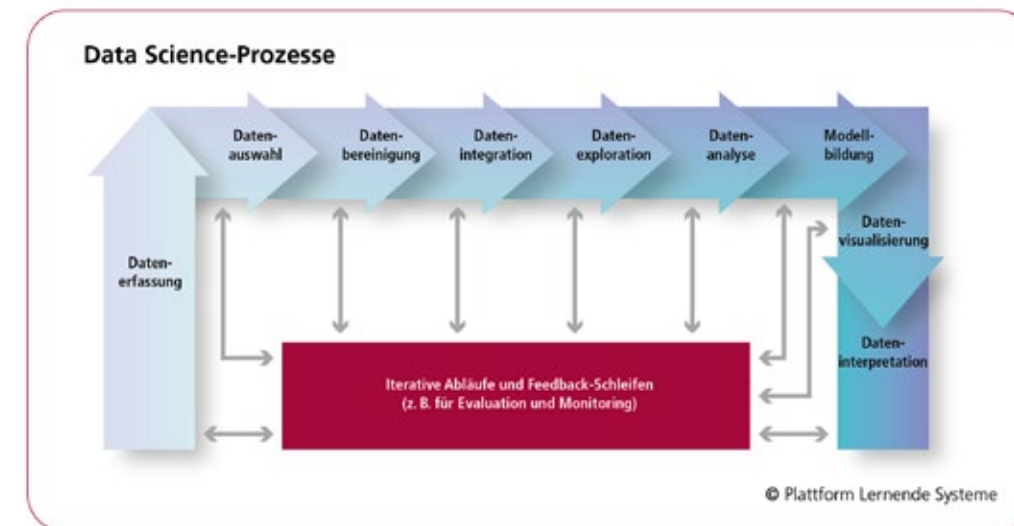
Die Bedeutung von Expertise in Data Science wird schnell klar, wenn man sich vor Augen führt, dass das Erfassen und Aufbereiten der Daten bis zu 80 Prozent des Aufwands von KI-Projekten betragen kann (Yaddow, 2019). Weitere Herausforderungen bestehen darin, Daten effektiv und effizient zu verwalten und die Datenqualität zu wahren, da diese für die Korrektheit und Aussagekraft der Analyseergebnisse entscheidend ist (Rat für Informationsinfrastrukturen,

2019). Insgesamt ist es von erheblicher Bedeutung, Data Science-Prozesse in ihrer Gänze im Blick zu behalten, um die bestmögliche Qualität und Leistungsfähigkeit von KI-Systemen zu erreichen – aber auch, um die Grundlage für das Vertrauen in solche Systeme zu legen.

Data Science als iterativer Prozess

Die Basis vieler Data Science-Anwendungen sind Prozessketten, welche die Schritte der Datenerfassung, Auswahl, Bereinigung, Integration, Exploration, Analyse und Modellbildung bis hin zur Visualisierung und Interpretation umfassen. Diese Prozesse werden entweder explizit (prozedural oder deklarativ) spezifiziert und dann automatisiert ausgeführt oder eher implizit in interaktiver und explorativer Weise vollzogen. Häufig handelt es sich hierbei nicht um statische Abläufe, sondern um interaktive Prozesse, die menschliche Interventionen und Entscheidungen („Human-in-the-Loop“) erfordern. Teilweise bestehen diese aber auch aus iterativen Abläufen mit Feedback-Schleifen, um gegebenenfalls Daten, Methoden oder Parameter zu wechseln, neue Trainingsdaten zu beschaffen oder Modelle mit neuen Daten zu aktualisieren. Derartige Interventionen erfordern ein kontinuierliches Monitoring und eine Evaluation der Ergebnisse der einzelnen Schritte, etwa zur Qualität der Eingangsdaten oder der Modellgüte.

Im Zuge derartiger Prozesse kommen eine Vielzahl von Methoden aus unterschiedlichen Bereichen zum Einsatz. Beispiele hierfür sind Signalverarbeitungsmethoden, etwa zum Filtern der Daten, Verfahren zur Datenintegration, Statistik-Methoden für die Charak-



terisierung der Daten, die Ableitung von Kennzahlen oder Features, Zeitreihenanalyse etc., Datenvisualisierungsmethoden zur visuellen Datenexploration, Data-Mining- und Machine Learning-Methoden zum Bereinigen der Daten (z. B. Ersetzen fehlender Werte, Duplikaterkennung), sowie zur eigentlichen Modellbildung. Eine wichtige Rolle spielen in diesen Prozessen auch die Auswahl und Erfassung der Daten – beispielsweise als Trainingsdaten – sowie die Sicherstellung der Datenqualität. Neben Data Profiling und Data Cleaning kommt hierbei der Datenintegration und -anreicherung eine wichtige Rolle zu, um die oft heterogenen Ausgangsdaten erschließen und fusionieren zu können. In diesem Kontext kommen auch semantische Technologien wie Wissensgraphen zum Einsatz, deren Fakten unter anderem zur Validierung, Bewertung und Annotation von Daten genutzt werden. So liefern Datensammlungen und Wissensbasen wie Wikidata, Freebase, DBpedia oder YAGO umfangreiche Fakten beispielsweise für die Datenaufbereitung.

Speziell mit Methoden und Prozessen zur Erfassung, Verwaltung, Speicherung, Aufbereitung, Anreicherung und Bereitstellung der Daten beschäftigt sich das Gebiet Data Engineering. Im Mittelpunkt stehen dabei Fragen der Bereitstellung von performanten und zuverlässigen Infrastrukturen für das Datenmanagement, die fundamental für die effiziente Unterstützung von Data-Science-Prozessen sind, sowie Methoden für die Verwaltung und Aufbereitung der Daten und Modelle. Data Engineering wird daher im Folgenden als Oberbegriff für Datenmanagement, Datenintegration und Datenaufbereitung verwendet. Darüber hinaus ist eine visuelle Exploration und Analyse der Daten

und Modelle unabdingbar (Visual Analytics), um die Qualität der Daten und Modelle zu beurteilen, mit den Daten und Modellen effektiv interagieren zu können oder neue Trainingsdaten abzuleiten.

Verständnis über die Prozesskette nötig

Um Data Science Anwendungen nachvollziehen, ihre Qualität beurteilen und somit ihre Vertrauenswürdigkeit attestieren zu können, ist allerdings nicht nur ein tiefes Verständnis der einzelnen Komponenten eines Data Science Prozesses notwendig, sondern auch ein Verständnis des Zusammenspiels der Komponenten und damit der Prozesskette als Ganzes.

Zu den zentralen Methoden und Techniken, die fundamental für Data Science sind – und damit auch die Künstliche Intelligenz – und weit über klassische relationale Datenbanksysteme hinausgehen, gehören:

- **Datenverwaltung:** Hierzu zählen Speichertechnologien und Datenstrukturen sowie Techniken zum physischen Design von Datenbanken wie Caching, Replikation, Indexierung, Datenkompression, Partitionierung für verteilte und parallele Datenhaltung sowie Vorberechnung und Materialisierung von häufig genutzten Daten. Dies betrifft auch die Verwaltung von Trainingsdaten und Modellen.

- **Datenaufbereitung:** Techniken zum Data Profiling und Data Cleaning mittels statistischer Verfahren und Methoden des maschinellen Lernens, Techniken der Datenintegration über die Kombination und Verknüpfung von Daten bis hin zu heterogenen Systemen.
- **Performance und Skalierung:** Datenmanagementsysteme sind für hochperformante und skalierbare Verarbeitung großer Datenmengen optimiert. Dies



Prof. Dr. Daniel Keim, Professor für Datenanalyse und Visualisierung, Universität Konstanz / Plattform Lernende Systeme



Prof. Dr. Kai-Uwe Sattler, Professor für Datenbanken und Informationssysteme, TU Ilmenau / Plattform Lernende Systeme

wird zum einen durch Verteilung und Parallelisierung der Verarbeitung erreicht. Neben verteilten bzw. parallelen Datenbanksystemen zählen hierzu auch Plattformen für die verteilte Verarbeitung in Cluster-Umgebungen wie Apache Spark oder der erfolgreichen deutschen Entwicklung Flink sowie Dateninfrastrukturen für das Cloud Computing. Hierbei besteht auch eine enge Verbindung zum verteilten Machine Learning. Zum anderen umfasst dies den effizienten Einsatz moderner Hardware (z.B. in Form von Main-Memory-Datenbanken, die Nutzung von GPU- oder FPGA-basierten Beschleunigern, sowie Multicore- und Cluster-Systemen) aber auch die Online-Verarbeitung von Datenströmen, wie sie zum Beispiel im Internet der Dinge, bei Industrie 4.0-Szenarien oder Social-Media-Plattformen anfallen. Zunehmend spielen auch spezielle Hardware-Architekturen wie Tensor-Recheneinheiten und neuromorphe Systeme eine wichtige Rolle.

- **Optimierung und Ausführung komplexer Prozesse:** Die Entwicklung und Ausführung komplexer Datenverarbeitungsprozesse wird durch deklarative Anfrageverarbeitung inkl. Analytics-Methoden (z.B. Online Analytical Processing, OLAP) und Datenflussmodelle (wie in Spark oder Flink) unterstützt. Dies betrifft auch die Unterstützung kontinuierlichen Lernens, das heißt von iterativen Prozessen, in denen zusätzliche Trainingsdaten aus der Nutzung der KI-Anwendung berücksichtigt werden.
- **Gewährleistung von Wiederholbarkeit und Nachvollziehbarkeit:** Gerade für datengetriebene Lernprozesse ist es wichtig, die Modellbildung wiederhol- und nachvollziehbar zu gestalten, beispielsweise um fehlerhafte Vorhersagen, Änderungen der Trainingsdaten oder der Verarbeitungsprozesse nachvollziehen zu können. Hierfür bieten Datenmanagementtechniken wie Daten-Versionierung, Time-Travel-Anfragen oder Auditing Lösungswege an.

Maschinelles Lernen und Datenbanken werden heute zunehmend integriert gedacht und im Sinne von „Machine Learning Systems“ (Ratner 2019) als Teile eines Systems betrachtet. So werden Datenbanken nicht nur zur Speicherung der eigentlichen Daten, sondern auch zur Speicherung von berechneten Modellen und Programmcodes genutzt und dienen damit als Analysewerkzeug. Dies betrifft auch die Integration von Methoden des maschinellen Lernens – entweder, indem Lernverfahren in Datenbanksysteme integriert werden oder Datenmanagementtechniken (wie etwa Indexing) zur Beschleunigung von Machine Learning- und Analyseaufgaben genutzt werden. Deutlich wird dies an Entwicklungen wie der Software-Plattform für Big Data-Analysen Apache Spark, die inzwischen auch (wieder) eine Schnittstelle für die Datenbanksprache Structured Query Language (SQL) mit einem Anfrageoptimierer anbietet – also einer Anwendung,

die nach dem effizientesten Weg sucht, um auf Daten zuzugreifen.

Verständnis für Data Science-Prozesse fördern

Es gibt verschiedene Ansätze, um Daten für die Gesellschaft künftig noch effizienter und effektiver nutzbar zu machen und das Verständnis von Data Science-Prozessen und Datenmanagementtechnologien in unserer Gesellschaft zu fördern. Dazu gehören unter anderem:

- **Data Literacy:** Wie bereits von der Gesellschaft für Informatik (GI) gefordert, muss Data Literacy-Kompetenzen ein breiterer Raum in Schule und Studium eingeräumt werden. Dies gilt weit über den Informatikunterricht in den Schulen oder Studiengängen mit Informatikbezug hinaus und betrifft neben Fähigkeiten zur Erschließung, Sammlung und Qualitätsbewertung von Daten auch grundlegende Kompetenzen zum Einsatz von Werkzeugen zur Datenverarbeitung und -analyse sowie zur Visualisierung und kritischen Interpretation der Ergebnisse.
- **Data Science/Data Engineering-Ausbildung:** In Studiengängen im Bereich Data Science aber auch in Informatikstudiengängen sollte mehr Wert auf Data-Engineering-Themen gelegt werden. Dies geht beispielsweise über die Inhalte klassischer Datenbank-Vorlesungen hinaus und betrifft neben Data Literacy-Kompetenzen etwa Aspekte von Datenintegration und -qualität, Datenexploration und -visualisierung aber auch alternative Datenmodelle und Verarbeitungsparadigmen. Für Studiengänge und Weiterbildungsangebote an Hochschulen im Bereich Data Science hat der Arbeitskreis „Data Science/Data Literacy“ unter Mitarbeit der Plattform Lernende Systeme Empfehlungen zur inhaltlichen Ausgestaltung erarbeitet (Gesellschaft für Informatik, 2019).
- **Infrastruktur und Daten:** Die eindrucksvollen Beispiele und Anwendungen der KI-Labore der Internet-Konzerne dürfen nicht zu einer unreflektierten Übernahme von erfolgreichen Modellen verführen. Neben dem Verständnis für die Lernmethoden und ihre Grenzen sowie der Kenntnis der genutzten Trainingsdaten erfordert dies aber auch, überhaupt die Möglichkeit zu haben, vergleichbare aufwendige Lernverfahren durchführen zu können. Hierfür werden geeignete Infrastrukturen mit ausreichender Speicher- bzw. Rechenkapazität und Datensammlungen (z.B. für Trainingsdaten) benötigt.

Gleichzeitig müssen auch „Small-Data“-Methoden berücksichtigt werden. Anwendungsbereiche, die gerade in Deutschland wichtige sind, wie etwa Medizintechnik oder Maschinenbau, zeichnen sich speziell im Umfeld von KMU durch deutlich kleinere Datenmengen aus, die oft nur schwach integriert sind. Infrastrukturen, Forschungs- und Ausbildungsprogramme für den KI-Bereich sollten dieser Situation Rechnung tragen.

Insgesamt spielen Datenmanagementtechnologien

somit für Unternehmungen wie europäische Datenräume, die beispielsweise die Europäische Kommission in ihrer Datenstrategie vorantreiben möchte (Europäische Kommission, 2020), und Cloud-basierte Dateninfrastrukturen wie GAIA-X oder ganz allgemein Datenökosysteme eine zentrale Rolle. Da Recheninfrastrukturen auch Gegenstand der Forschung sind, ist auch ein Ausbau solcher Infrastrukturen notwendig, um zugrundeliegende Prozesse des Datenmanagements selbst gestalten und Experimente durchführen zu können.

- **Forschung:** In künftigen Forschungsprogrammen, etwa der KI-Strategie der Bundesregierung oder in Forschungsprojekten von Unternehmen sowie Forschungs- und Entwicklungseinrichtungen, sollte der Bedeutung des Data Engineering als Gesamtprozess in Verbindung mit maschinellen Lernverfahren noch mehr Rechnung getragen werden. So können Stärken sowohl im Bereich der Erfassung und Auswahl der Daten, ihrer Exploration und Visualisierung als auch im Einsatz von KI- und Datenmanagement-Methoden in Data-Science-Prozessen weiter ausgebaut werden. In Anbetracht der wesentlichen Rolle von Datenmanagementtechnologien für die Datenräume und -ökosysteme der Zukunft ist eine noch stärkere Förderung einschlägiger Forschungsfelder zielführend.
- **Anwendungsorientierung:** Data Engineering spielt eine bedeutende Rolle, um Lernende Systeme in die Anwendungen zu bringen. Der Gesamtprozess aus Data Engineering und Lernenden Systemen sollte daher auch bei der Entwicklung und Umsetzung von KI-Anwendungen in Unternehmen noch mehr Berücksichtigung finden, indem besonderes Augenmerk auf die Erfassung, Vorverarbeitung und sichere Speicherung sowohl von Trainingsdaten als auch von Prozessdaten gelegt wird. Speziell in technischen bzw. industriellen Anwendungsfeldern wie Automatisierung und Predictive Analytics aber auch im Medizinbereich bilden qualitativ hochwertige Daten eine wesentliche Basis für die erfolgreiche Anwendung Lernender Systeme, gleichzeitig sind derartige Daten aber auch hochsensitiv. Infrastrukturen und Datenökosysteme müssen daher anwendungs- bzw. branchenspezifische Lösungen in geeigneter Weise berücksichtigen.

Prof. Dr. Daniel Keim, Prof. Dr. Kai-Uwe Sattler

Weiterführende Literatur: Daniel Keim, Kai-Uwe Sattler: Von Daten zu KI – Intelligentes Datenmanagement als Basis für Data Science und den Einsatz Lernender Systeme. Whitepaper aus der Plattform Lernende Systeme, München 2020 Europäische Kommission. (2020): Eine europäische Datenstrategie. https://ec.europa.eu/info/sites/info/files/communication-european-strategy-data-19feb2020_de.pdf (abgerufen am 25.09.2020). Gesellschaft für Informatik (2018): Data Literacy und Data Science Education: Digitale Kompetenzen in der Hochschulausbildung. <https://gi.de/themen/beitrag/data-literacy-und-data-science-education-digitale-kompetenzen-in-der-hochschulausbildung/> (abgerufen am 25.09.2020). Rat für Informationsinfrastrukturen (2019): Herausforderung Datenqualität. <http://www.rfii.de/?p=4043> (abgerufen am 25.09.2020). Ratner, A. et al. (2019): ML Sys: The New Frontier of Machine Learning Systems. <https://arxiv.org/abs/1904.03257> (abgerufen am 25.09.2020). Yaddow, W (2019): AI and BI Projects Are Bogged Down With Data Preparation Tasks. <https://tdwi.org/Articles/2019/08/16/DIQ-ALL-AI-and-BI-Data-Preparation-Tasks.aspx> (abgerufen am 25.09.2020).

Die saisonale Nachfrage mit KI in den Griff bekommen

Die Vorhersage der saisonalen Nachfrage ist schwierig. Die meisten Unternehmen betrachten sie als ein Muster, das jedes Kalenderjahr regelmäßige und vorhersehbare Veränderungen mit sich bringt, wie zum Beispiel den vermehrten Umsatz von Tönungsfolien im Sommer oder die steigende Nachfrage nach Frostschutzmittel im Winter. Diese Art grobe Vorhersage bildet seit vielen Jahren die Basis für automatisierte Warennachschubsysteme. Aber wie so vieles in der Supply Chain greift eine solche Vereinfachung angesichts der heutigen Komplexität viel zu kurz. Tatsächlich schafft dieser traditionelle Nachschubansatz mehr Probleme, als dass er sie löst.

Eine Schwierigkeit bei der Verwendung von jährlichen Nachfragemustern besteht darin, dass die Nachfrage eher eine Summe täglich auftretender Variablen ist. Dass nicht alle Jahreszeiten an bestimmten Daten beginnen und enden, ist ein weiteres Hindernis. Die saisonale Nachfrage kann sich im Laufe der Zeit verschieben und durch neue Marktveränderungen und Ereignisse höher oder niedriger ausfallen. Andere kausale Effekte, wie zum Beispiel die Wetterverhältnisse, stellen eine weitere Schwierigkeit bei der Ermittlung der saisonalen Nachfrage dar. Je besser Unternehmen die saisonale Nachfrage nachvollziehen können, desto genauer können sie den optimalen Lagerbestand definieren, bei dem Kosten und Service in Einklang gebracht werden.

Wenn einzelne Ereignisse im Datenrauschen verschwinden

Ein Problem beim Umgang mit diesen saisonbedingten Nachfrage-Anomalien ist, dass die meisten Nachfrageprognosesysteme die aggregierte historische Gesamtnachfrage betrachten, bei dem einzelne wichtige Ereignisse im Datenrauschen verschwinden. Ein solches Beispiel ist das Wetter. Plötzliche Kälteeinbrüche im Oktober lassen die Nachfrage nach Winterreifen ansteigen. Diese Abweichungen von der Norm verursachen ein Rauschen, das von herkömmlichen Nachfrageprognose-Tools nur schlecht gedeutet werden kann. Und es wird noch komplizierter: Die saisonale Nachfrage ist kein globaler, sondern ein lokaler Wert. Jeder Standort eines Unternehmens kann unterschiedliche saisonbedingte Nachfragemuster für einzelne Produkte oder Produktgruppen haben. Auch können Medienereignisse oder virale Trends, die Aufmerksamkeit auf ein bestimmtes Produkt oder eine bestimmte Kategorie lenken und werden in den Saisonalitätsindex mit aufgenommen, obwohl sie nur punktuell aufgetreten sind.

Die Frage ist, wie solche punktuellen Nachfrageanomalien ausgeschlossen werden können, damit eine bessere Ausgangsbasis für die Vorhersage der

saisonalen Nachfrage gefunden wird. Die Antwort liegt wie so oft im Detail. Und zwar müssen Nachfrageprognosemodelle jeden einzelnen ursächlichen Effekt identifizieren und verfolgen. Durch die Analyse von Daten wie Hitze oder Kälte, die Schwankungen der Niederschläge, die Stärke des Windes und andere Kennzahlen lässt sich feststellen, warum die Verbraucher an einem bestimmten Tag mehr oder weniger eingekauft haben und wie die Nachfrage ohne solche punktuellen Ereignissen ausgesehen hätte.

Mit ML das geglättete Nachfragepotential analysieren

Dafür darf aber nicht die aggregierte historische Gesamtnachfrage betrachtet werden, sondern es muss das geglättete Nachfragepotential als Grundlage herangezogen werden. Glätten bedeutet in diesem Zusammenhang, dass die punktuellen Ereignisse als Rauschen herausgefiltert werden. Mit Tabellenkalkulation oder anderen manuellen Methoden wäre dies zu zeit- und ressourcenaufwendig. Für neue Technologien wie maschinelles Lernen, eine Teildisziplin der Künstlichen Intelligenz (KI), sind diese Berechnungen ideal. Maschinelles Lernen ermöglicht es Systemen, aus Daten zu lernen und intelligente Aufgaben zu erledigen, ohne explizit programmiert dafür zu sein.

Der ML Prozess

Der typische maschinelle Lernprozess ist stark iterativ und umfasst folgende Schritte:

1. Datenerfassung: Erfassung und Speicherung relevanter strukturierter und unstrukturierter Datensätze
2. Datenaufbereitung: Explorative Datenanalyse, Bereinigung, Transformation, Feature-Engineering, Selektion, Training und Testdatensatzteilung
3. Auswahl des Modells: Bereichsgerechte Auswahl von überwachten, unüberwachten oder Reinforcement Learning Algorithmus(en) (z.B. K-Mittel-Clustering, Entscheidungsbäume, Neuronale Netze, etc.)
4. Ausbildung: Trainieren des Modells mit dem Trainingsdatensatz
5. Auswertung: Messen der Leistung des trainierten Modells auf dem Testdatensatz anhand einer definierten Bewertungsmetrik (z.B. Erreichen einer Prognosegenauigkeit von mindestens 85%)
6. Hyperparameter-Tuning: Empirischer Prozess der Änderung von Algorithmusparametern zur Verbesserung der Modellleistung
7. Vorhersage: Einsatz des trainierten Modells in einer Produktionssystemumgebung

Das Rauschen herausfiltern

Für die Vorhersage der saisonalen Nachfrage macht es Sinn, ML-Modelle mit probabilistischen Vorhersagemodellen, bei denen fortschrittliche Algorithmen zur Analyse mehrerer Nachfragevariablen genutzt werden, zu kombinieren. In der Supply Chain Planung

werden probabilistischen Vorhersagemodelle genutzt, um mehrerer Nachfragevariablen zu analysieren und so die Wahrscheinlichkeiten einer Reihe möglicher Ergebnisse zu identifizieren, von denen dann eines als am wahrscheinlichsten gilt.

Konkret werden die probabilistischen Modelle dazu genutzt, Prognosen auf Grundlage der historischen Daten zu erstellen. Um die Saisonalität zu berücksichtigen, werden dann ML-Algorithmen erst auf diese historische Daten angewandt und dann schrittweise weitere Datensätze zur Nachfragehistorie, Produkteigenschaften und anderen Stammdaten hinzugefügt. Schließlich werden auch externe Datenquellen wie Wetterdaten, Wirtschaftsindikatoren, POS-Daten, Daten aus Sozialen Medien oder IoT-Quellen hinzugezogen um das Rauschen herauszufiltern und festzustellen, wie die Nachfrage ohne eventuelle punktuellen Ereignissen ausgesehen hätte.

Weitere Anwendungsgebiete für ML in der Supply Chain Planung

Maschinelles Lernen ist eine der vielversprechendsten Technologien zur Erstellung marktgerechter Vorhersagen. In der Supply Chain Planung wird sie neben der Vorhersage der saisonalen Nachfrage auch dafür genutzt, Auswirkungen von Promotions und der Einführung neuer Produkte zu prognostizieren. Planungssysteme, die maschinelles Lernen nutzen, „lernen“ tatsächlich und können so die Nachfrage im Laufe der Zeit immer besser vorhersagen. Grundlage für das Lernen sind zwar Daten, aber diese Systeme lernen nicht nur aus einem breiten Spektrum von Nachfrage- und historischen Daten, sondern integrieren auch das Wissen und die Erfahrung der Disponenten und anderer am Planungsprozess Beteiligten. Mit dieser Kombination von maschineller und menschlicher Intelligenz lässt sich die Vorhersage der saisonalen Nachfrage besser in den Griff bekommen. Dadurch können Unternehmen ihren Lagerbestand für saisonale Produkte reduzieren und trotzdem sicherstellen, dass auch bei punktuellen Bedarf genügend Lagerbestand vorhanden ist, um einen erstklassigen Service zu ermöglichen.

Ob beheizte Handgriffe für Motorräder, Winterreifen oder Frostschutzmittel, dank maschinellem Lernen kann man sicherstellen, dass die richtigen Produkte vorliegen, ohne dass zu viel Lagerbestand anfällt.

Mauro Adorno

Wie Unternehmen KI und Search zur Schaffung eines digitalen Nervensystems nutzen können

Ein digitales Nervensystem ist ein Informationssystem, das es einer Organisation ermöglicht, auf externe Ereignisse zu reagieren, indem es Wissen ansammelt,

verwaltet und verteilt. Der Begriff wurde von Bill Gates mitgeprägt, der ihn Ende der neunziger Jahre verwendete, um das ideale Funktionieren einer IT-Infrastruktur zu beschreiben. Analog zum biologischen Nervensystem geht es darum, alle notwendigen Informationen zur richtigen Zeit und am richtigen Ort zur Verfügung zu stellen. Im Business Analytics-Kontext spielen Search und Künstliche Intelligenz (KI) bei der Bereitstellung von Datenerkenntnissen eine wichtige Rolle.

Fortschrittliche Organisationen implementieren neue Werkzeuge, die ihnen helfen, strukturierte und unstrukturierte Daten in ihren Netzwerken aufzudecken, um wichtige Entscheidungen schneller treffen zu können. Unternehmen mit digitalen Nervensystemen verfügen über einen Mix aus Kultur, IT-Architekturen und Tools, die die richtigen Informationen rechtzeitig an die richtigen Personen weiterleiten, damit diese optimale Entscheidungen treffen können. Der letzte Punkt ist entscheidend. Wenn Informationen nicht rechtzeitig ankommen, sind sie nutzlos und es fehlt ein funktionierendes Nervensystem, das in der Lage ist, schnell genug auf Ereignisse zu reagieren oder Vorhersagen zu treffen, die zu profitablen Entscheidungen führen.

Im Business Analytics-Umfeld sind die beiden Technologien, die die optimale Entscheidungsfindung demokratisieren und beschleunigen, Search und KI. Search basiert auf der relationalen Suche und erlaubt es den Nutzern, wie in einer Google-Suche jede datenbezogene Frage einfach in eine Suchleiste einzugeben. Die Lösung analysiert dann deterministisch jede Abfrage, durchsucht die Unternehmensdaten, interpretiert die Beziehungen zwischen den Datenelementen und berechnet die Antwort, wobei von Anfang an sichergestellt wird, dass der Nutzer nur Zugang zu jenen Daten hat, für die er autorisiert wurde. Die Antworten werden den Nutzern dann in der passenden Visualisierung in Sekundenschnelle zur Verfügung gestellt.

KI hilft denjenigen Nutzern, die nicht wissen, welche Frage sie überhaupt an die Daten stellen sollen. Die KI-Algorithmen können Trends und Ausreißer in den Daten erkennen und die Datenanalyse für bestimmte Nutzer und ihre Rollen personalisieren.

Zusammen ermöglicht Search und KI-gesteuerte Analytics jedem Unternehmen, fundierte und profitable Entscheidungen zu treffen. Die fortschrittlichsten Unternehmen geben nicht nur ihren Anwendern, sondern auch ihren Kunden die Möglichkeit, Analysen durchzuführen. BT, Clarity, Fannie Mae und Just Eat sind Beispiele für Unternehmen, die dies tun.

Dank maschinellem Lernen werden Informationen schneller bereitgestellt

Informationen können entweder durch „Pull“- oder „Push“-Mechanismen an die Oberfläche gebracht werden. Pull ist ein Prozess, bei dem ein Benutzer

eine Datenfrage stellt und die Antwort erhält. Durch die Kombination von Search und Natural Language Understanding (NLU – ein Zweig des maschinellen Lernens und eine Teildisziplin von Natural Language Processing, kurz NLP) können Systeme entwickelt werden, die es jedem Anwender ermöglichen, ohne technische Fachkenntnisse Daten abzurufen, indem Fragen in natürlicher, umgänglicher Sprache ohne Fachlatein gestellt werden können. Dafür werden allerdings KI-Fähigkeiten benötigt, die es ermöglichen, die Intention der vom Nutzer gestellten Suchanfragen sowie ein wahrscheinliches Ergebnis zu ermitteln. Noch wichtiger ist, dass die Systeme in der Lage sind, die analytische Absicht zu erfassen, um die einzig richtige Antwort auf eine gestellte Frage liefern zu können. Wenn zum Beispiel ein Nutzer nach „wie viele McDonalds gibt es in Berlin“ sucht, muss eine NLP-Engine wissen, ob mit „McDonalds“ die Restaurantkette, ein Straßename oder ein Familienname gemeint ist.

In vielen Unternehmen müssen die Mitarbeiter wochenlang auf die benötigten Daten warten, weil ihre Anfragen an die IT-Abteilung in einer Warteschlange stecken bleiben. Diese Verzögerung schreckt sie schließlich davon ab, überhaupt Fragen zu stellen, sodass sich hier kein digitales Nervensystem entwickeln kann. Dank der Technologien können Mitarbeiter mittels des Pull-Prozesses schneller und ohne Umwege über die IT-Abteilung auf die Informationen zu greifen.

Bei Push geht es hingegen darum, die richtigen Informationen zur richtigen Zeit an die richtige Person zu bringen, auch wenn diese nicht weiß, welche datenbezogenen Fragen sie stellen kann. Hier gibt es zwei große Probleme. Erstens, wie kann man bei all dem „Lärm“ große Datenmengen durchsuchen, um neue, aufschlussreiche Informationen zu finden, die die Geschäftsergebnisse verbessern? Zweitens, wie findet man in einem Datenmeer die Informationen, die für einen bestimmten Benutzer auf der Grundlage seiner spezifischen Bedürfnisse am relevantesten sind? Beides sind Probleme, die Search- und KI-basierte Analytics-Lösungen wie oben aufgezeigt mithilfe von maschinellem Lernen lösen.

Der nächste Schritt in der KI-Evolution: Intuitive Oberflächen zur Bewältigung hoher Datenmengen

Intuitive Schnittstellen auf riesigen Datensätzen sind bereits heute verfügbar. Die Weiterentwicklung des maschinellen Lernens sollte es den Softwaresystemen ermöglichen, den betriebswirtschaftlichen Zusammenhang der Daten zu verstehen. Im Laufe ihrer Entwicklung werden diese Systeme Vorhersagen über wahrscheinliche Ergebnisse machen und sogar geschäftliche Transaktionen vorschlagen, die letztendlich einen enormen Geschäftswert liefern werden.

Gegenwärtig sind maschinelles Lernen und KI-Systeme noch weit von den Fähigkeiten der angebotenen



Mauro Adorno,
Managing Director
Europe,
ToolsGroup



Christian Werling,
Regional Director
D-A-CH,
ThoughtSpot

Intelligenz des menschlichen Geistes entfernt. Diese Systeme füllen jedoch eine bestehende Lücke, indem sie riesige Mengen an Trainingsdaten und Rechenleistung absorbieren. Man muss diese nur in Video-, Audio- und Sprachverstehen erleben, um den unglaublichen Erfolg des maschinellen Lernens zu sehen. Betrachtet man jedoch maschinelles Lernen und KI im Unternehmenskontext, so sind nur sehr wenige Werkzeuge für die Verarbeitung von ausreichend großen Datenmengen konzipiert. Infolgedessen wird das meiste maschinelle Lernen mit aggregierten oder abgetasteten Daten durchgeführt. Dies schränkt die Leistungsfähigkeit der KI-Systeme grundlegend ein. Systeme, die durch das Lernen aus großen Datenmengen granulare Erkenntnisse gewinnen können, werden einen fundamentalen Vorteil haben und weitaus bessere Ergebnisse produzieren.

KI und Search in der Praxis

Zusammengefasst lässt sich festhalten, dass KI- und Search-basierte Analytics-Lösungen Unternehmen ein digitales Nervensystem liefern, das neue Erkenntnisse, Prozessverbesserungen und eine bessere Unterstützung der Mitarbeiter ermöglicht. Unternehmen wie Walmart, Suncorp und British Telecom sind gute Beispiele dafür. Durch den Einsatz von Search und KI-gesteuerter Analytik konnte Walmart viele seiner Preisenentscheidungen 100 Mal schneller treffen. Suncorp konnte Millionen einsparen, indem es Anomalien in seinen Schadenregulierungsdaten gefunden hat. BT hat zum Beispiel in Großbritannien die Erfahrung seiner Geschäftskunden durch die Bereitstellung einer Search- und KI-gesteuerten Schnittstelle, die es ermöglicht, die eigenen Rechnungsdaten einzusehen, um sicherzustellen, dass stets die besten Preispläne verfolgt werden, massiv verbessert.

Die Einsatzmöglichkeiten für KI und Search zur Unterstützung des digitalen Nervensystems sind vielfältig. Indem sie sich zum Beispiel die von der KI generierten Anomalien in ihren Abrechnungen ansehen, können Unternehmen ihre Kosten massiv senken. Hersteller können große Geldmengen einsparen, indem sie es ihren Mitarbeitern erleichtern, Preisabweichungen zu finden. Das sind jedoch nur einige Anwendungsbeispiele. In unserer schnelllebigen Zeit kann die Fähigkeit, die richtigen Informationen zur richtigen Zeit und am richtigen Ort zur Verfügung zu stellen, über den Erfolg eines Unternehmens entscheiden und hier sind KI- und Search-basierte Analytics unschlagbar.

Christian Werling

Auf dem Weg zum künstlichen Bewusstsein

Blaue Hologramme, die in Personenform in Raumschiffen existieren – das war noch vor 20 Jahren das Bild von künstlicher Intelligenz. Erst als 1996 Schachgroßmeister Garri Kasparov vom Schachcomputer Deep Blue im Spiel bezwungen wurde, änderte sich dieses stereotype Image. Seitdem hält künstliche Intelligenz in vielen verschiedenen Bereichen Einzug und ist in Forschung, Technologie sowie zahlreichen Unternehmen allgegenwärtig geworden. Eine der aussichtsreichsten Berufsgruppen des 21. Jahrhunderts bilden folglich die KI-Spezialisten, die wiederum aus einer Vielzahl an technischen und wissenschaftlichen Fachdisziplinen stammen. Künstliche Intelligenz ist nichts weniger als ein alltags- und fächerübergreifendes Phänomen. Doch ergeben sich neben Chancen auch Gefahren?

Wer an KI denkt, der kommt an Stephen Hawking (1942-2018) nicht vorbei. Der Physiker und Astrophysiker arbeitete mit einem Sprachcomputer und zeigte so immer wieder die beeindruckende Synthese zwischen Mensch und Maschine. Er forschte regelmäßig zum Thema KI und entwickelte die Botschaft: Wir müssen die Entwicklung von künstlicher Intelligenz kontrolliert vorantreiben.

Hawking wagt zudem den Blick in die Zukunft: Intelligenz wird zwar als die Fähigkeit zur Anpassung an gegebene Bedingungen definiert; lernfähige KI-Systeme können sich allerdings auch selbstständig optimieren. Dies führt früher oder später zu einer wahrhaften Ausbreitung der Intelligenz, einer regelrechten Intelligenzexplosion. Künstliche Intelligenz selbst kann sich weiterentwickeln, so in alle Bereiche der menschlichen Intelligenz eingreifen und sie entsprechend verbessern. Eingerechnet ist der Kampf gegen Krankheit, Hungersnot oder auch der Kampf gegen Armut.

KI ohne Geschwindigkeitslimit

KI scheint nicht aufhaltbar zu sein. Schon die Leistungsfähigkeit unserer konventionellen Hardware (Computer, Smartphones, Tablets) nimmt sekundlich zu. Hawking formulierte als Gesetzmäßigkeit für diese Entwicklung das Moore'sche Gesetz. Er kam zu dem Schluss, dass sich die Rechenleistung von integrierten Schaltkreisen (Computern) im Durchschnitt alle 18 Monate verdoppelt.

Sollte also die Optimierung der technischen Geräte in dieser Geschwindigkeit weiter fortschreiten, dauert es nicht mehr lange bis die künstliche Intelligenz die menschliche Intelligenz überholt. Dies kann bereits innerhalb der nächsten 100 Jahre der Fall sein.

Dennoch ist der Ausblick in die Zukunft der KI nicht nur positiv:

2015 unterzeichneten Elon Musk, Stephen Hawking und eine Reihe weiterer KI-Experten einen offenen

Brief, in dem sie die Menschheit vor den Gefahren warnen, die von einer unkontrollierten Superintelligenz ausgehen. Die KI-Philosophie und -Ethik gehört auch deshalb zu den derzeit am schnellsten wachsenden Zweigen wissenschaftlicher Forschung. Allerdings sollte bei aller Euphorie auch nicht vergessen werden: Künstliche Intelligenz hat den Zweck das Leben der Menschen zu verbessern und nicht es zu gefährden.

Zertifizierung von Künstlicher Intelligenz

Auch die Wissenschaftsjournalistin und Philosophin Manuela Lenzen äußerte sich zu diesem Thema mit folgender Kernaussage: Alle Menschen sollten möglichst optimal von KI profitieren. Daher muss deren Einsatz unter einem Regelwerk erfolgen und entsprechende angemessene Rahmenbedingungen müssen außerdem geschaffen werden. Nur so können Risiken minimiert und negative Entwicklungen gestoppt werden. Sie schlägt die Einführung eines Gütesiegels für Künstliche Intelligenz vor. Dadurch können gewissen Sicherheits- und Qualitätsanforderungen garantiert werden.

Sie gibt auch einen weiteren Einblick in den aktuellen Stand der Forschung. Manuela Lenzen schildert, dass in zahlreichen Laboren daran gearbeitet wird, weitere Schnittstellen zwischen Computern und Menschen zu kreieren. Diese zielen darauf, sogenannte Cyborgs zu entwickeln: Mischwesen aus lebendigem Organismus und Maschine. Ihr Körper wird beispielsweise dauerhaft durch künstliche Bauteile ergänzt oder sie teilen ihren Organismus mit einer KI und können mit Hilfe dieser ihre Fähigkeiten erweitern. Der Begriff „Cyborg“ stellt dabei ein Akronym des englischen cybernetic organism (kybernetischer Organismus) dar.

Mensch und Maschine verbinden sich

Insbesondere die Entwicklung von Schnittstellen zwischen Computer und Gehirn schreitet dabei rasant voran. Methoden zur digitalen Gedankenübertragung gelingen testweise bereits ehr erfolgreich an Ratten. Parallel entstehen biohybride Roboter: Systeme, die lebendes Gewebe sowie anorganische Komponenten verbinden. Diese bestehen z. B. aus Herzzellen von Ratten oder Hühnern, in denen mikroskopisch kleine, autonome Drohnen arbeiten.

Anwendungspotentiale von Biohybriden bestehen z. B. in der Medizin: Als „Reparatur-Kit“ der Zukunft hilft die Technologie in der Herz- und Blutgefäßchirurgie, um z. B. innere Blutungen zu stoppen und Arterienverkalkungen zu lösen. Sofern solche und ähnlich KI-Apparaturen in der Lage sind, menschliche Gefühle, Bewusstsein und Empathie nachzubilden, ergeben sich zudem weitere Anwendungsbereiche für das menschliche Gehirn.

Gefühle setzen sich grundsätzlich aus den Komponenten Funktion und Erlebnis zusammen. Schmerz erfüllt beispielsweise eine Warnfunktion. So rekapi-

tuliert das Gehirn Kindheitserlebnisse mit der heißen Herdplatte – das gedanklich wiederholte, erinnerte Ereignis hält den Erlebenden von der erneuten Erfahrung fern. Mit entsprechenden Sensoren ausgestattet, können auch Roboter zumindest die Warnung umsetzen.

Das Erlebnis als zweite Komponente von Schmerz lässt sich von Robotern noch eher unzureichend umsetzen, da die KI dafür bewusstseinstechnische Elemente benötigt. Eine technische Nachbildung von Bewusstsein aber stellt derzeit eine DER Kernherausforderungen der Wissenschaft dar. Tatsächlich ist selbst eine bloße Definition von Bewusstsein dem Menschen bislang noch nicht gelungen. Zentraler Schlüsselaspekt in dieser Überlegung ist aber vermutlich die Selbstreflexion, bzw. die Fähigkeit zu dieser, da der Mensch ein mentales Bild seiner selbst vorliegen hat. Daraus ergeben sich die weitere Fragen: Ist es möglich Bewusstsein kopieren? Wenn ja: Wie kann man Bewusstsein auch künstlich herstellen?

Neue Lebensformen entstehen

Raymond Kurzweil, technischer Entwickler bei Google, Autor und Erfinder, gilt als Pionier der Sprachsynthese und Texterkennung und hat in mehreren Werken, u. a. „Menschheit 2.0“ zur Entwicklung der KI Stellung genommen. Seine Prognose: KI besitzt in wenigen Jahrzehnten die Fähigkeit, sich selbst zu verbessern. Körper und Gehirne werden mit Hilfe neuer Technologien ganze Veränderungen durchlaufen haben. Neue Lebensformen und -modelle sind entstanden. Dabei sollte die heutige technische Entwicklung laut Evgeny Morozov, Autor von „Smarte neue Welt“ bereits kritisch beäugt werden. Zwar ermöglichen es die technischen Errungenschaften, Menschen zu verbinden und den Informationsstand kontinuierlich up-to-date zu halten, ermöglichen also quasi ein Echtzeit-Informationsbewusstsein. Allerdings hindern sie den Menschen auch am Nachdenken und daran, den eigenen Verstand zu gebrauchen. Ein Beispiel ist der Zusammenhang zwischen Google Maps und dem menschlichen Orientierungssinn, da Gedankenleistungen „outgesourct“ werden.

Erik Brynjolfsson und Andrew McAfee, Autoren des Werks „The Second Machine Age“ behaupten daher, dass Technologie nicht alle menschlichen Probleme lösen kann. So birgt jede neue Technologie, gleichgültig mit welcher edler Absicht sie entstanden sind, unweigerlich auch Schattenseiten. So hat auch das World Wide Web zwar zu einer besseren Zugänglichkeit vorhandenen Wissens geführt, aber zugleich auch indirekt zu einer Spaltung der Gesellschaft beigetragen. Sie mahnen daher dazu, mögliche negative Aspekte einer neuen Technologie mit zu berücksichtigen.

Deshalb knüpfen die prominenten Wissenschaftler daran ihre Forderung, dass der Mensch die Chancen künstlicher Intelligenz zwar durchaus nutzen, ihren Einsatz aber wohlüberlegt gestalten sollte. Nur so



Frank Thole,
Partner,
WEPEX Unternehmensberatung

können Risiken dauerhaft minimiert und das Ausmaß besser erkannt werden. Ein gespannter, aber wachsamer Blick in die Zukunft lautet daher ihr Credo. Zunächst aber per Spracherkennung das Restaurant für den Abend buchen zu können, per App die schnellste Bahnverbindung in die Innenstadt zu ermitteln und automatisch gewartete Bahnen zu nutzen, offenbart einen anderen wesentlichen Vorteil allen menschlichen Schaffens: die Mehrung von Komfort. Frank Thole

1.8 DISKUSSION

Machine Learning kann mehr leisten als Optimierung

Unternehmen setzen große Stücke auf Machine Learning. Die meisten Anwendungsszenarien gehen bislang vor allem in Richtung Optimierung von Prozessen und bestehender Geschäftsmodelle. Doch damit wäre die Technologie unterfordert.

Machine Learning ist spätestens seit den Erfolgen von AlphaGo ein Wachstumsmarkt. 2025 werden mit 126 Milliarden Dollar umgesetzt werden, prognostiziert der Marktforscher Tractica. 2018 waren es zehn Milliarden. Die Einsatzmöglichkeiten reichen von Computerspielen, „mitdenkenden“ Robotern, selbststeuernden Fahrzeugen, Bild- und Mustererkennung bis zu virtuellen Assistenten, die natürlichsprachlich mit Menschen kommunizieren (Conversational AI). Mehrere Einflussfaktoren tragen dazu bei, dass die Technologie seit einigen Jahren den Weg vom Forschungsgebiet in die praktische Anwendung findet:

1. Die Digitalisierung im Allgemeinen sorgt dafür, dass immer mehr Daten zur Verfügung stehen. Es wird geschätzt, dass die verfügbare Datenmenge im Jahr 2020 59 Billionen Gigabyte umfasst. Durch die Entwicklung des Internet-of-Things (IoT) sind zudem immer mehr Geräte miteinander vernetzt.
2. Die Leistungsfähigkeit der Infrastruktur ist gestiegen – einerseits durch schnellere Prozessoren, andererseits durch die Entwicklung spezieller Machine Learning Chips. Diese Halbleiter verkürzen durch ihre Clusterarchitektur die Berechnungszeit erheblich.
3. Schnellere Datenübertragungsraten ermöglichen es darüber hinaus, Echtzeitdaten zu sammeln und in kurzer Zeit auszuwerten sowie weiterzuverarbeiten.
4. Diese schnelleren Datenübertragungswege erlauben zudem, Machine-Learning- Microdienste bekannter Technologiekonzerne zu verwenden. Sie werden als fertiger Service bereitgestellt und nach Aufwand (Pay per Use) bezahlt. Aufwändige Investitionen in leistungsfähige IT-Infrastruktur sind nicht mehr zwingend notwendig.

Machine Learning als Digitalisierer von Geschäftsmodellen

Diese Entwicklungen ebnen Unternehmen den Weg, mit Hilfe von Machine Learning die eigene Arbeit zu verbessern und zu optimieren – beispielsweise Prozesse zu beschleunigen, Arbeiten zu geringeren Kosten durchzuführen und die Qualität von Produkten und Dienstleistungen zu steigern. Darüber hinaus eignet sich die Disziplin als Grundlage, das eigene Geschäftsmodell zu digitalisieren. Drei verschiedene Machine-Learning-Konzepte, auf dem ein digitales Geschäftsmodell basieren kann, lassen sich unterscheiden:

1. **Verarbeitung von strukturierten Informationen:** Strukturierte Informationen beschreiben dabei mehrdimensionale Daten, die typischerweise in Datenbanken oder Datenformaten wie csv oder json abgelegt sind. Mit diesen Daten können Verfahren zur Mustererkennung, Clustering, Generierung einer Empfehlung oder eines vorhergesagten Wertes genutzt werden.
2. **Verarbeitung von unstrukturierten Daten:** Gemeint sind Daten wie Texte, Bilder, Videos oder Tonaufnahmen. Durch Algorithmen, die neuronale Netze verwenden, ist es möglich, Inhalte dieser Dokumente zu erkennen. Auf diesem Konzept basieren Anwendungen wie Conversational AI, Stimmungsanalysen und die Objekterkennung in Bildern und Videos.
3. **Verwendung von selbstlernenden Systemen:** Bei der Verwendung von Reinforcement Learning werden dem System Ziele implementiert. Bei jeder Iteration wird der aktuelle Zustand des Systems bewertet und in Richtung der gegebenen Zielstellung optimiert.

Potenzial von Machine Learning ausschöpfen

In der Praxis ging es bislang häufig darum, mit Machine-Learning-Verfahren bestehende Prozesse und ein etabliertes Geschäftsmodell zu optimieren und eigene Kosten zu senken. Ein Beispiel dafür ist die Betrugsbekämpfung, etwa beim Kreditkartenbetrug im Banking, beim Versicherungsbetrug oder beim Betrug durch falsche Reisekostenabrechnungen. Dabei werden zunächst Modelle aus Vergangenheitsdaten trainiert, die betrügerisches Verhalten abbilden. Wenn tatsächliche Vorgänge nun von diesem Modell als auffällig klassifiziert werden, werden diese Anomalien markiert, um eine genauere Untersuchung durchzuführen.

Ein weiteres Beispiel für die Weiterentwicklung von Produkten ist die Verwendung von Conversational AI, um den Kundendialog persönlicher zu gestalten. Dabei steuern Kunden im Voice Banking ihr Konto per Sprache oder starten im Auto per Dialog eine Navigation. Zudem kann in einem Livechat Conversational AI zur Teilautomatisierung eingesetzt werden.

Der nächste Schritt, den Unternehmen nun lang-

sam wagen ist, neue intelligente Angebote auf Basis von Machine Learning zu entwickeln, die Kunden zusätzliche Mehrwerte bieten. Ein guter Einstieg ist dabei, zunächst einen Service zu entwickeln, der das bestehende Geschäftsmodell vertikal erweitert. Eine Leistung oder ein Produkt erhält beispielsweise eine neue Funktionalität auf Basis von Machine Learning. Dabei werden die Daten, die vom Basisprodukt generiert werden, anschließend analysiert und dem Kunden zur Verfügung gestellt, wodurch ein Mehrwert geschaffen wird. Beispiele für dieses Szenario sind die Skywise Plattform von Airbus sowie der Sam Digital Hub des Industrieunternehmens Samson, der die Auswertung von IoT-Daten ermöglicht. Statt vorhandene Daten durch vortrainierte Modelle zu untersuchen, können Unternehmen auch eigene Machine-Learning-Modelle als Service bereitstellen. Dieses Szenario verfolgen IT-Konzerne wie Microsoft und Google, die ihre Cloud-Plattformen durch KI-Dienstleistungen erweitern.

Machine Learning eignet sich zudem als Einstieg in Geschäftsmodelle, die sich ohne Hilfe von Algorithmen nicht rechnen würden. Häufig werden dabei unstrukturierte Daten wie Texte oder Bilder verarbeitet, die bisher ohne Künstliche Intelligenz nicht automatisch verarbeitet werden konnten. Durch Machine Learning und Deep Learning ändert sich das. Das Unternehmen DeepL bietet beispielsweise an, Texte in hoher Qualität zu übersetzen. Ebenso lässt sich der Kundenkontakt durch Chatbot-Plattformen wie IBM Watson und die Plattform Cognigy automatisieren, indem eine KI-Lösung Anfragen der Kunden eigenständig beantwortet. Robo Advisor ermöglicht Finanzdienstleistern zudem die automatisierte Beratung bei der Geldanlage. Die Unternehmen können so ihr Geschäft auf Zielgruppen ausweiten, für die die Leistung der Vermögensberatung andernfalls nicht profitabel wäre.

Darüber hinaus kann Machine Learning auch Ausgangspunkt für gänzlich neue Geschäftsmodelle sein. Bei der Automatisierung von Geschäftsprozessen werden Machine-Learning-Modelle erstellt, die das bisherige Prozesswissen enthalten. Dieses Prozesswissen lässt sich monetarisieren. Technologiekonzerne haben begonnen, Frameworks zu der Automatisierung von Entwicklerprozessen bereitzustellen. Darunter fällt Facebooks Prophet-Framework, das Zeitreihenanalysen automatisiert. Banken oder Versicherungen können sich hier etwas anschauen und beispielsweise ihr Know-how auf dem Gebiet der Betrugserkennung vermarkten.

Transparenz steigert Akzeptanz

Jedoch können nicht alle erfolgsversprechenden Anwendungen umgesetzt werden oder sorgen sofort für Begeisterung bei Kunden. Zum einen müssen bei jedem Case die berechtigten Datenschutzinteressen berücksichtigt werden. Zum anderen hindern ein ge-

ringes Vertrauen in die Ergebnisse der Algorithmen und zu wenig Verständnis für die Materie den Erfolg. Diese Black-Box-Modelle, die schwer nachzuvollziehen sind, schrecken Kunden ab und damit auch die Unternehmen, ihr Engagement auszuweiten.

Forscher versuchen mittlerweile, KI-Modelle erklärbarer zu machen. Ziel ist, die berechtigten Sorgen um Vertraulichkeit und Verlässlichkeit zu lindern. Auf bestehende Modelle kann zum Beispiel das Python-Package SHAP (SHapley Additive exPlanations) aufgesetzt werden. Dieser Ansatz versucht, die verhältnismäßige Aussagekraft der verschiedenen Input-Parameter zu erklären. So soll etwa die Investmentstrategie eines Robo Advisors nachvollzogen werden, indem das Verhältnis zwischen Risiko und Rendite von verschiedenen Anlagen veranschaulicht wird. Die großen Cloud-Anbieter mit ihren umfassenden KI-Lösungen haben den Wert der Modellerklärbarkeit ebenfalls erkannt. Sie haben begonnen, Explainable AI Tools in ihre Angebotspakete aufzunehmen.

Neue Geschäftsmodelle erfordern systematischen Kreativprozess

Mit dem wachsenden Vertrauen in die Technologie und zunehmender Erfahrung werden Unternehmen in neue Ideen investieren und das Potenzial von Machine Learning ausschöpfen. Wichtig für das Innovationsmanagement ist ein Denken über den Tellerrand des aktuellen Geschäfts hinaus. Das erfordert einen systematischen Kreativprozess in Unternehmen, der mehr als nur punktuelle Design Thinking Workshops umfasst. Zudem sollte aus der Idee schnell ein Proof of Concept entstehen, an dem Unternehmen testen können, ob die Anwendungsidee funktioniert. Fertige KI-Services großer IT-Anbieter helfen dabei, diese schnellen Ergebnisse zu erzielen. Neben der technischen und wirtschaftlichen Machbarkeit kommt es darauf an, Kunden früh in den Entwicklungsprozess einzubeziehen. Zur Entwicklung eines marktreifen Produkts sollte anschließend mit einem erfahrenen Data-Science-Team ein eigenständiges Machine-Learning-Modell entwickelt werden, das speziell an die identifizierten Anwendungsfälle angepasst wird.

Julian Bathelt

Integrierte Intelligenz: Mit KI neue Kundenbedürfnisse adressieren

Viele Unternehmen sehen künstliche Intelligenz (KI) als hoch relevant für ihre künftige Geschäftstätigkeit an, doch die tatsächliche Umsetzung bleibt weit hinter der wahrgenommenen Bedeutung zurück. Gerade auch Marketing-Verantwortliche können eine zentrale Rolle einnehmen, um diese Defizite zu vermeiden. Insbesondere sollten KI-basierte Innovationen mit einem klaren Fokus auf neuen Kundenbedürfnissen



Julian Bathelt,
Consultant,
Sopra Steria

entwickelt werden, um so die Wachstumschancen durch ‚Integrierte Intelligenz‘ auszuschöpfen.

Trotz der enormen Relevanz von KI halten sich viele Unternehmen bei der Umsetzung noch stark zurück. Der Digitalverband Bitkom hat im Juni 2020 eine repräsentative Umfrage von 603 Firmen mit mindestens 20 MitarbeiterInnen aus allen Branchen veröffentlicht. Demnach sehen zwar 73 Prozent der Unternehmen KI als die wichtigste Zukunftstechnologie. Jedoch wird KI nur von 6 Prozent der Firmen genutzt, 22 Prozent planen zumindest die Nutzung. Noch bedenklicher als die zurückhaltende Umsetzung ist dabei, dass KI primär als Bedrohung und kaum als Chance wahrgenommen wird. So sagen 81 Prozent der Firmen voraus, dass globale Tech-Konzerne wie Amazon und Google durch KI zunehmend zu ernsthaften Konkurrenten in ganz unterschiedlichen etablierten Branchen werden.

In meinem aktuellen Buch ‚Integrierte Intelligenz‘ werden Firmen bezüglich ihrer operativen Aktivität und strategischen Priorität von KI in fünf Gruppen eingeteilt. Die erste Gruppe sind die ‚Beobachter‘, weil diese Firmen die Relevanz von KI im Vergleich zu anderen Themen noch als gering einschätzen, auch wenn die Corona-Krise zu einer verstärkten Sensibilisierung für digitale Geschäftsmodelle und Datenanalytik beigetragen hat. Die zweite Gruppe der ‚Strategen‘ konzentriert sich bisher hauptsächlich auf die Planung von KI-Initiativen, wohingegen die Implementierung in diesen Firmen noch sehr überschaubar ist. Im Gegensatz dazu gibt es die dritte Gruppe der ‚Aktivisten‘. Diese Firmen experimentieren meist relativ dezentral mit mehreren KI-Projekten, die jedoch nicht strategisch auf Unternehmensebene koordiniert werden.

Was machen die Pioniere?

Die ‚Vorreiter‘ Unternehmen bilden die vierte Gruppe und diese Pioniere zeichnen sich durch hohe strategische Priorität sowie hohe operative Aktivität bei KI aus. Allerdings konzentrieren sich diese Firmen erstaunlich oft auf Kostensenkungen durch die KI-basierte Automatisierung von Jobs. So werden beispielsweise MitarbeiterInnen, die Kundenanfragen beantworten, durch relativ einfache KI-Lösungen wie Chatbots ersetzt. Diese Unternehmen sind also dahingehend Pioniere, dass sie einzelne KI-Lösungen mit hoher Priorität nutzen. Gleichzeitig bleiben die marktseitigen Wachstumschancen von KI durch das Adressieren neuer Kundenbedürfnisse weitgehend ungenutzt.

Nur die fünfte Gruppe der ‚Stars‘ wendet KI jenseits von Kostensenkungen an. Diese sehr kleine Untergruppe der Pionier-Unternehmen versucht, Wachstumschancen durch KI-basierte Marktstrategien mit Blick auf neue Kundenbedürfnisse zu erschließen. Im Einklang mit dieser Einteilung zeigen die Ergebnisse der oben genannten Bitkom-Umfrage, dass komplexere KI-Anwendungen eher selten sind. Von den

Firmen, die KI bereits anwenden, nutzen 69 Prozent KI z.B. für Targeting und personalisierte Werbung im Marketing. Hingegen wird KI nur in 1 Prozent dieser Anwender-Unternehmen bei der Entwicklung neuer Produkte genutzt, z.B. im Rahmen von Simulationen. Meist erfolgt nicht einmal der Versuch, neue Marktchancen durch KI zu ergreifen.

Wie können Kunden profitieren?

Gerade weil KI noch zu oft als technologische Bedrohung und primär als Chance für neue Wettbewerber angesehen wird, kann das Marketing einen entscheidenden Beitrag leisten, um solche Defizite bei der Nutzung von KI zu vermeiden. Der Ansatz der ‚Integrierten Intelligenz‘ unterstreicht den Mehrwert, wenn etablierte Firmen ihre bestehende menschliche Expertise in Märkten und Technologien zielgerichtet mit KI und Datenanalytik kombinieren. Bei KI-Anwendungen muss das Marketing daher insbesondere den Fokus auf Kundenbedürfnisse sicherstellen. Nur wenn die Kunden profitieren und im Idealfall innovative Lösungen mit KI einfordern, wird bei vielen Unternehmen ein Umdenken hinsichtlich der Marktchancen jenseits der Bedrohungen durch KI erfolgen. Die Entwicklung intelligenter neuer Produkte und Dienstleistungen bietet die Möglichkeit, sowohl die Wettbewerbsposition in bestehenden Märkten zu behaupten als auch völlig neue Marktsegmente zu erschließen.

Marketing, Produktmanagement und Vertrieb müssen also dafür sorgen, dass der integrierte Mehrwert für den Kunden – und nicht das aus KI-Sicht technologisch Machbare – im Vordergrund steht. Das tiefgreifende Verständnis der Marketing-Verantwortlichen für die jeweiligen Kundenbedürfnisse ist genauso ein Beispiel für herausragende menschliche Expertise wie die langjährige Erfahrung von Ingenieuren in der Entwicklungsabteilung. Wenn Führungskräfte in der Lage sind, diese unterschiedlichen Formen menschlicher Intelligenz und Kompetenz mit KI und Datenanalytik zu kombinieren, bieten sich durch ‚Integrierte Intelligenz‘ auch langfristig Wettbewerbsvorteile – gegenüber bestehenden Wettbewerbern ebenso wie gegenüber globalen Tech-Konzernen.

Prof. Dr. Ulrich Lichtenthaler

Wie Transfer Learning den KI-Einsatz demokratisiert

Zu wenig Trainingsdaten, keine maßgeschneiderten Modelle, fehlendes Know-how: Es gibt viele Gründe dafür, warum der Einsatz von Künstlicher Intelligenz in der Unternehmenswelt stockt. Transfer Learning kann Abhilfe schaffen. Damit lassen sich vortrainierte neuronale Netze für neue Aufgaben weitertrainieren.

Die Spracherkennung im Handy; die Foto-App, die erkennt, dass eine Person fotografiert wird und

automatisch die Einstellungen der Kameras anpasst; der Übersetzungsdienst im Internet: Die Menschen nutzen heute in ihrem Privatleben an vielen Stellen ganz selbstverständlich Künstliche Intelligenz. An ihrem Arbeitsplatz sieht es dagegen meist noch anders aus. KI ist noch längst nicht in dem Maße in der Arbeitswelt angekommen wie das im Privatleben der Fall ist. Die meisten Aufgaben in Büros und die dazugehörigen Prozesse werden bisher kaum durch Künstliche Intelligenz vereinfacht. Dafür gibt es mehrere Gründe.

Die Nutzer liefern den Anbietern umfassende Trainingsdaten

Die im Privatleben verbreiteten KI-Anwendungen werden mit Machine-Learning-Verfahren trainiert, wobei große und vor allem verfügbare Datenmengen zum Einsatz kommen. Diese umfassenden Trainingsdaten werden den Anbietern der Anwendungen meist von ihren Nutzern geliefert. Durch Unmengen an Nutzerdaten kann zum Beispiel DeepL einen guten Übersetzungsdienst bieten oder die Bildersuche von Google Chihuahuas von anderen Hunden unterscheiden. An solchen Massendaten fehlt es bei den allermeisten Bürotätigkeiten.

Außerdem kommen bei den genannten Anwendungen maßgeschneiderte KI-Modelle zum Einsatz, die jeweils eng definierte Aufgaben lösen. Sie werden gezielt auf ihre Zwecke zugeschnitten und für sie optimiert. Ein ähnliches Vorgehen ist bei Bürotätigkeiten in aller Regel nicht möglich. Da sie sehr vielfältig sind und sich von Unternehmen zu Unternehmen stark unterscheiden, ist es praktisch ausgeschlossen, für jede einzelne Tätigkeit ein Modell maßzuschneidern.

Nicht zuletzt mangelt es oft auch am notwendigen Know-how. In Machine-Learning-Projekten müssen Probleme formal spezifiziert werden, anschließend sind die erforderlichen Daten dafür zu gewinnen und zu bereinigen, und am Ende gilt es, die Ergebnisse zu evaluieren. Zudem ist die Integration einer Machine-Learning-Komponente in vorhandene Workflows äußerst komplex. Es braucht erfahrene Experten, die wissen, wie man diese Technologie anwendet, um aus den verfügbaren Daten das Optimum herauszuholen.

Vortrainierte neuronale Netze als Ausgangspunkt für neue Projekte

Einen vielversprechenden Ansatz zur Lösung dieser Herausforderungen liefert das so genannte Transfer Learning. Dabei handelt es sich um eine Methode des Machine Learning, bei der neuronale Netze, die bereits für einen bestimmten Zweck vortrainiert sind, als Ausgangspunkt für eine andere beziehungsweise spezifischere Aufgabe verwendet werden. Das bereits Gelernte eines neuronalen Netzes wird dadurch für ein neues Projekt nutzbar. Damit entfallen nicht nur rechenintensive und zeitaufwändige Tätigkeiten für das Trainieren eines neuen neuronalen Netzes. Mit

Transfer Learning können auch „Big Data“-Modelle zur Lösung von „Small Data“-Herausforderungen eingesetzt werden. Vortrainiert mit großen Datenmengen lassen sich die Modelle mit kleineren Datenmengen für die neue Aufgabe weitertrainieren.

Diese Methode konnte bereits im Bereich der Bildverarbeitung große Erfolge erzielen und wird nun auch verstärkt für Sprachmodelle genutzt. Dabei werden mit der Technik des Transfer Learning auf Basis eines umfassenden Sprachverständnisses vortrainierte Sprachmodelle mit relativ wenigen Trainingsdaten für andere Aufgaben angepasst. Sprachmodelle wie BERT (Bidirectional Encoder Representations from Transformers), ULMFiT (Universal Language Model Fine-Tuning), GPT und die Weiterentwicklungen GPT-2 und -3 (Generative Pretrained Transformer) haben bereits bewiesen, dass die aus einem Datensatz gelernten Informationen relativ einfach auch für Aufgaben in anderen Datensätzen genutzt werden können.

Bei der Erkennung von Fachthemen nicht bei Null anfangen

Ein konkretes Einsatzgebiet ist dabei etwa die Analyse von Dokumenten und Informationen. Durch die Nutzung der Transfer-Learning-Methode müssen Unternehmen bei der Erkennung von Fachthemen nicht bei Null anfangen. Stattdessen wird ein allgemeines Sprachmodell verwendet und trainiert beziehungsweise auf ein spezielles Fachgebiet justiert. Ein Vorwissen in Form allgemeiner Sprachkenntnisse ist bereits codiert, so dass das Modell etwa Sätze oder die Grundformen von Wörtern erkennen kann. Um es für die Klassifizierung der eigenen Dokumente weiter zu trainieren, braucht es deshalb deutlich weniger Daten. Unternehmen und Behörden haben dadurch etwa die Möglichkeit, Systeme zu realisieren, die eingehende E-Mails automatisiert analysieren und inhaltsbezogen zur Beantwortung weiter routen.

Ein weiteres Anwendungsgebiet sind etwa Systeme für KI-basierte Vertragsanalysen. Mit Hilfe einer solchen Software lassen sich Klauseln und wichtige Datenpunkte in Verträgen oder Ausschreibungen erkennen und zur gezielten Prüfung, Risikoanalyse, Kommentierung und Bearbeitung extrahieren. Fachanwälte beispielsweise sparen sich durch diese intelligente Lesehilfe viel Zeit und enorme Ressourcen, da sie Verträge nicht mehr einzeln lesen und ihre relevanten Stellen manuell markieren müssen. Das zahlt sich insbesondere dann aus, wenn bei Gesetzesänderungen oder Firmenübernahmen große Vertragsbestände geprüft werden müssen. Die Grundlage für solch ein System kann eine KI-Software bilden, die bereits für die gängigsten Vertragsarten und Klauseln vortrainiert ist. Nutzer haben dann die Möglichkeit, die Software für ihre individuellen Kontexte und Domänen weiter zu trainieren.



Prof. Dr. Ulrich Lichtenthaler, xxxxx, xxxxx



Franz Kögl, Vorstand, IntraFind Software AG

Transfer Learning kann flächendeckenden KI-Einsatz in der Unternehmenswelt voranbringen
Die Methode des Transfer Learning kann einen wichtigen Beitrag zur Demokratisierung von Künstlicher Intelligenz leisten. Zwar müssen dabei Abstriche hinsichtlich maßgeschneiderter Modelle und vollständiger Automatisierung gemacht werden, da sich Optimierungen nicht a priori einbauen lassen. So können damit beispielsweise nicht ohne Weiteres Systeme realisiert werden, die Formulare automatisch ausfüllen. Es können damit aber sehr wohl relativ schnell und unkompliziert Systeme implementiert werden, die die Anwender beim Ausfüllen von Formularen unterstützen, indem sie die dafür erforderlichen Informationen in den entsprechenden Dokumenten finden und hervorheben – und die Anwender damit durchaus entscheidend entlasten. Deshalb hat das Transfer Learning definitiv das Zeug dazu, den flächendeckenden Einsatz von KI in der Unternehmenswelt voranzubringen.

Franz Kögl

Das datengetriebene Unternehmen – wie Verantwortliche der Bedeutung von Daten gerecht werden

Das neue Öl, das neue Gold, der Rohstoff des 21. Jahrhunderts – wenn es um Daten geht, scheint kein Superlativ zu groß zu sein. Dabei haben die meisten Daten an sich noch kein Wert inne. Die Verantwortlichen müssen sammeln, sortieren, aufbereiten, überprüfen, strukturieren, aggregieren und/oder gegebenenfalls labeln. Die Kompetenz der Datenverarbeitung ist – unter anderem angesichts der zunehmenden Bedeutung von KI-Verfahren – eine der zentralen Kompetenzen für Unternehmen.

Dabei bedarf es – auch wenn die landläufige Meinung etwas anderes suggeriert – nicht einfach nur vieler Daten und KI-Anwendungen finden dann schon irgendetwas sinnvolles. Erst braucht es eine solide Datenbasis. Erst auf dieser Grundlage gewinnen Unternehmen dann neue Erkenntnisse und bieten neue Services an. Dazu bedarf es eines organisatorischen und kulturellen Wandels. Unternehmen müssen Datenprozesse mit der gleichen Ernsthaftigkeit und der gleichen Gewissenhaftigkeit angehen wie Abläufe in der Produktion, im Vertrieb oder im Personalbereich. Erst dann spielen KI-Anwendungen ihre Stärken aus.

Die folgenden Ausführungen beschäftigen sich mit Möglichkeiten, wie Unternehmen Prozesse, Strukturen und Kompetenzen aufbauen, die dieser Bedeutung von Daten gerecht werden.

Vom Siegeszug des Digitalen

Abhängig von Branche, Geschäftsmodell, Alter oder auch Kultur sind Unternehmen im Umgang mit Daten

unterschiedlich weit entwickelt. Zur Charakterisierung lassen sich drei Stufen der Bedeutung von Daten unterscheiden. Diese sind nicht strikt voneinander abzugrenzen, die Übergänge von einer Stufe zur nächsten sind fließend. Die Einteilung hilft Entscheidern dabei, die Position des eigenen Unternehmens besser zu verstehen.

Digitaler Prozessschritt

Indikator: Daten werden digital erfasst und angefragt, Medienbrüche entfallen

Konsequenz: In dieser Phase kommen die bereits beschriebenen ERP- oder CRM-Anwendungen zum Einsatz. Der vorherrschende Datenfluss ist ein Digitaler. Vertragsdaten, Produktkataloge oder Kundendaten liegen in den Systemen vor und können hier abgefragt und bearbeitet werden

Digitale Wertschöpfungskette

Indikator: Daten sind integraler Bestandteil der Steuerung

Konsequenz: Auswertungswerkzeuge wie Business-Intelligence-Anwendungen analysieren die im IT-System erfassten Daten. Sie geben Entscheidern einen Überblick über die Entwicklung zentraler Kennzahlen. Auf dieser Basis planen die Verantwortlichen und treffen Entscheidungen. Daten sind somit ein integraler Bestandteil der Unternehmenskultur geworden.

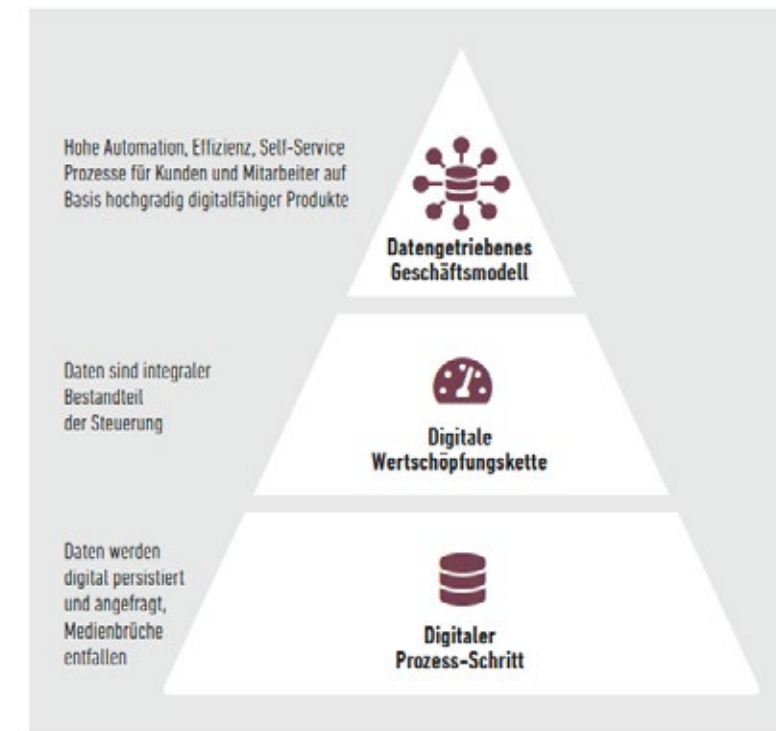
Datengetriebenes Geschäftsmodell

Indikator: Daten und ihre Verwertung sind die Basis für Services und Produkte

Konsequenz: Unternehmen prüfen das Potenzial aller zur Verfügung stehenden Daten für das Entwickeln neuer Geschäftsmodelle und Services. Die Prozesskette der Datenverarbeitung ist weitgehend automatisiert. KI-Verfahren unterstützen die Analyse und Auswertung der Datengrundlage.

Viele Unternehmen – gerade aus klassischen Branchen – lassen sich der Stufe „Digitaler Prozessschritt“ zuordnen. Aber quer durch alle Wirtschaftszweige ist eine Entwicklung in Richtung „datengetriebenes Geschäftsmodell“ zu beobachten. Das hat zwei Ursachen: Einerseits erwarten immer mehr Verbraucher das nahtlose Einbinden von Produkten und Services in ihre Lebenswelten. Das Auto, das selbständig einen Wartungstermin vereinbart. Oder der Sportschuh, der Tempo und Distanz misst und auswertet. Solche Angebote sind ohne digitale Technologien undenkbar. Andererseits erkennen immer mehr Verantwortliche in Unternehmen das Potenzial der engen Verknüpfung der realen mit der digitalen Welt.

Naturgemäß tun sich einige Unternehmen mit dieser Dominanz der Daten schwerer als andere. Wer Suchmaschinen, Social-Media-Plattformen oder Musik-Streaming-Dienste betreibt, kennt nichts anderes als Daten und Algorithmen. Wer aber von Haus



aus Maschinen baut, hat seine Kompetenzen genau um dieses Bauen herum aufgebaut. Daten spielen in dieser Welt eine Rolle – aber nicht die Zentrale. IT diene bisher dazu, bestehende Prozesse am Laufen zu halten. Oder dazu, sie effizienter zu gestalten. Aber dass die Datenanalyse ein entscheidender Innovationsfaktor ist, muss in vielen Institutionen und bei vielen Verantwortlichen noch ankommen. Wer jedoch diesen Punkt verpasst, läuft Gefahr durch einen Angriff auf die Daten im Prozess durch andere Marktbegleiter die eigene Kundenschnittstelle zu verlieren und damit schlussendlich in einer zukünftigen Plattformökonomie nur noch Zulieferer zu sein.

Wie können Unternehmen diese Herausforderung angehen? Wie sieht eine Blaupause für Organisation, Technologie und Prozesse aus? Wie sollen die Verantwortlichen den Veränderungsprozess gestalten? Der Aufbau einer Datenplattform liefert Antworten auf diese Fragen.

Datenplattform – die Grundlage, auf der datengetriebene Unternehmen aufbauen

Eine Datenplattform ist ein Konglomerat aus verschiedenen Technologien, Prozessen und Funktionalitäten, die das Nutzbarmachen von Daten im Unternehmen ermöglicht. Sie beschreibt das Anordnen und Verzahnen von Prozessen und Technologien, damit am Ende neue, datenbasierte Services oder Angebote entstehen.

Als Grundlage für die Entwicklung dient eine funktionale Architektur, die losgelöst von den konkreten Implementierungsoptionen, alle funktionalen Rahmen-

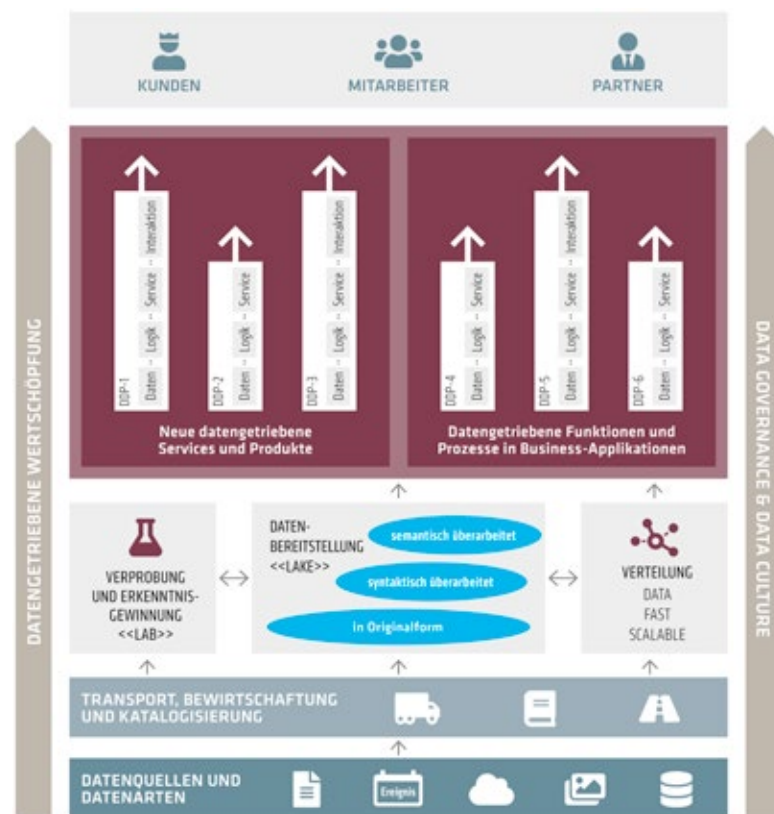
parameter definiert und entsprechend als Architektur- und Organisationsgrundlage dient.

Unten docken mögliche Datenquellen an. Die erste Aufgabe der Plattform ist es, Daten aus unterschiedlichen Quellen in unterschiedlichen Formaten – ob strukturiert, unstrukturiert oder polystrukturiert – zu integrieren, zu katalogisieren, sodass sie sichtbar und damit verfügbar und „bestellbar“ werden. Die Datenakquisition ist der initiale Schritt der Bereitstellung von Daten. Sie erlaubt, diese in der Datenplattform weiter verarbeiten zu können.

Diese Daten übergibt die Integrationsschicht an die Datenverteilung. Damit können Unternehmen sie bei Bedarf direkt für datengetriebene Services (zum Beispiel bei Echtzeitdatennutzung) einsetzen. Zusätzlich und alternativ sollten die Daten auch in die Datenbereitstellung einfließen. Sie hat die Aufgabe, Daten zu speichern, zu sortieren und aufzubereiten. Wichtig ist, dass Unternehmen sämtliche Daten in ihrer Rohform vorhalten und darüber hinaus wirklich nur die für alle nachfolgenden Schritte notwendigen Anpassungen zentral bereitstellen. Dabei gilt, das Weiterverarbeiten der Daten beispielsweise durch das Kuratieren, sorgfältig zu planen. Informationen, die einmal entfernt werden, stehen später für andere Einsatzzwecke nicht mehr zur Verfügung. Dieser Aspekt ist in Komplexität und Wichtigkeit nicht zu unterschätzen. Er hat direkte Implikationen auf die Aufteilung von Aufgaben und die Ausprägung der Organisation – und er ist einer der wichtigen Unterschiede zu den Data Warehouse Systemen der 2000er Jahre.



Benedikt Bonnmann,
Leiter Line of Business Data & Analytics,
adesso SE



Die Datenbereitstellung dient grundsätzlich lediglich der Unterstützung der datengetriebenen Anwendungen, Services und Produkte. Dahinter verbergen sich die einzelnen Datenservices, die auf der Plattform bereitgestellt werden. Dies können Prognosen mit API-Zugriff, Data-Mart-Szenarien inklusive Visualisierung oder das Bereitstellen von kuratierten Informationen zur Unterstützung von operativen Geschäftsprozessen sein. Hier entstehen aus Daten und Logik neue Services – ein weiterer entscheidender Unterschied zwischen einer modernen Datenplattform und reinen Data-Warehouse-Systemen.

Für die Entwicklung von KI-Modellen benötigt man zwangsläufig Daten. Hierfür gibt es einen dedizierten Funktionsbereich: das „Data Lab“. Hier erproben die Data Scientists neue datengetriebene Anwendungsfälle im Labormodus und entwickeln so Schritt für Schritt weitere DDPs (Data Driven Products). Die Umsetzung und Skalierung der entsprechenden Use-Cases erfolgt immer in einer dezentral angelegten Form, um das ganze Potential auszuschöpfen und keine Engpässe zu erzeugen.

Am Ende steht das Nutzen der Services durch Anwender und auch Kunden, häufig eingebunden in bestehende Anwendungen und Oberflächen. Begleitet wird die beschriebene Wertschöpfung aus Daten durch Governance-Funktionen und eine Data Culture, die den korrekten Umgang mit Daten sicherstellen. Dazu gehören beispielsweise Funktionen wie das Logging,

das Rechtemanagement oder die Idee mithilfe von Daten neue Services anzubieten. Darüber hinaus ist eine Fehlertoleranz ein immanenter Kulturbaustein, da man erst durch das wirkliche Verproben der Anwendungsfälle mit den Daten erkennen kann, ob der entsprechende Use-Case erfolgsversprechend ist oder nicht.

Fazit

Datenplattformen sind das Instrument, mit dem Verantwortliche das Ziel des datengetriebenen Unternehmens erreichen. Eine so aufgebaute Plattform ist die Keimzelle der Datenverarbeitung. Hier sind Abläufe ähnlich wie in einem industriellen Produktionsprozess strukturiert. Die verlässlichen Abläufe tragen zur Automatisierung bei. Entwickler müssen den Datenfluss nicht für jede Anwendung gänzlich neu planen und aufsetzen. Sie wissen, wo welche Daten in welchem Format mit welcher Qualität auflaufen und wie sie am Ende genutzt und präsentiert werden. So können sie die notwendige Datenbereitstellung für KI-Entwicklungsprojekte schneller und zuverlässiger umsetzen. In der Endausbaustufe lässt sich so eine Data Factory aufsetzen, die kontinuierlich neue wertstiftende Datenservices hervorbringt.

Die Folge: Eine signifikant reduzierte Time-to-Market. Darin und in der Mehrfachnutzung einer Datenverwaltung für unterschiedliche DDPs liegt der ökonomische Vorteil. Sie ist ein wichtiges Instrument auf dem Weg zum datengetriebenen Unternehmen.

Benedikt Bonnmann

CALL FOR CONTRIBUTION

für den DIGITALE WELT-Blog

Platzieren Sie Ihre Digitalthemen von morgen auf der Plattform von heute mit bislang über 2.250.000* Beitragsaufrufen:
digitaleweltmagazin.de/blog

Werden Sie Autor!

Ihre Vorteile im Überblick:

- ✓ Teilen Ihres Fachwissens mit einer breiten digitalen Leserschaft
- ✓ Potenzielle Veröffentlichung im DIGITALE WELT Printmagazin
- ✓ Bekanntheitssteigerung Ihres Unternehmens
- ✓ Mediale Positionierung von gezielten, für Sie relevanten Digitalthemen
- ✓ Aktive Beteiligung am aktuellen Dialog zur Digitalisierung
- ✓ Multiplier Effekt durch die Verbreitung über Social Media
- ✓ Profilschärfung und Positionierung gezielter Unternehmensvertreter


Aktuelle Blog-Rubriken:

Quantum Computing, Human Resource, Machine Learning, Affective Computing, Internet of Things, Cyber Security, Blockchain u.v.a.m.



INTERESSE GEWECKT?
 Melden Sie sich bei der DIGITALE WELT-Redaktion via E-Mail unter blog@digitaleweltmagazin.de oder telefonisch +49 89 2180 9171

*Unsere Beiträge wurden online unter www.digitaleweltmagazin.de/blog veröffentlicht und erzielten dabei die oben genannte Klickzahl im Zeitraum 01. August 2017 - 15. Mai 2021.



Marcus Raitner ist überzeugt, dass Elefanten tanzen können. Als Agile Coach begleitet er deshalb Unternehmen auf ihrer Reise zu mehr Agilität und menschlicher Lebendigkeit. In seinem Blog „Führung erfahren!“ schreibt er seit 2010 über die Themen Führung, Agilität, Digitalisierung und vieles mehr.

Wissensarbeiter in der Autonomie-Falle

Der von mir mit Abstand am meisten zitierte Autor ist sicherlich Peter F. Drucker, der große Vordenker modernen Managements und der Erfinder des Begriffs der Wissensarbeit. Wenn nun der von mir in letzter Zeit auch häufiger zitierte Cal Newport, Informatik-Professor und Autor von so großartigen Büchern wie „Deep Work“ und „Digital Minimalism“, sich kritisch mit der Produktivität von Wissensarbeitern auseinandersetzt und in seinem neuen Buch „A World without E-Mail“ gekonnt herleitet, wie das völlig korrekte Postulat von der Autonomie der Wissensarbeiter bei Peter F. Drucker uns Wissensarbeiter in die Falle lokal optimierter Produktivität geführt hat, dann sind das gleich mehrere triftige Gründe darüber intensiver nachzudenken. Aber der Reihe nach.

Von Taylor zu Drucker

Den Begriff der Wissensarbeit führte Peter Drucker 1959 ein, um damit Tätigkeiten, die hauptsächlich den Einsatz von kognitiven Fähigkeiten erforderten, abzugrenzen von der damals noch vorherrschenden weitgehend manuellen

Industriearbeit, die Frederick Winslow Taylor seit 1913 mit seinem „Scientific Management“ revolutioniert hatte. Die bahnbrechende Erkenntnis von Taylor war es, die Arbeit zu analysieren, sie in kleine Arbeitsschritte zu zerlegen, diese dann zu optimieren und zu einem optimalen Arbeitsfluss zusammenzusetzen. Diese anspruchsvolle kognitive Leistung war die Aufgabe des Managers. Taylor trennte ganz bewusst Denken und Handeln und machte dadurch die damals weitgehend ungelerten Arbeitskräfte für die Industrie nutzbar.

Der Effekt dieser Arbeitsteilung des Taylorismus war ein beeindruckender Anstieg der Produktivität in der manuellen Arbeit um einen Faktor 50, wie Peter F. Drucker selbst schreibt. Gleichzeitig sieht Drucker eine der wesentlichen Herausforderungen für das Management, die Produktivität der Wissensarbeiter in ähnlicher Weise zu steigern. Er erkannte als Erster, dass sich seit den Zeiten von Taylor sowohl die Art der Tätigkeit als auch das Ausbildungsniveau der Mitarbeiter verändert hatten. Die rein manuelle Arbeit nahm ab und immer mehr Mitarbeiter waren sogenannte Wissensarbeiter, deren Beitrag zur Wertschöpfung hauptsächlich in kognitiver Leistung bestand.

Ein großes Verdienst von Peter F. Drucker war es, auf die daraus resultierenden fundamentalen Unterschiede in der Führung von Wissensarbeitern im Vergleich zu den ungelerten manuellen Arbeitern des Taylorismus aufmerksam zu machen. Zu Zeiten von Taylor war der Manager der einzige Wissensarbeiter und die Arbeiter zur mehr oder weniger stumpfsinnigen Ausführung verdammt (eine entmenschlichende Konsequenz, die insbesondere Karl Marx zu Recht kritisierte). Aus dieser Zeit rührt ein klares Machtgefälle von Chef zu Mitarbeiter und ein Abhängigkeitsverhältnis des Arbeiters zur Organisation.

Das alles ist in der Wissensarbeit anders. Die Organisation braucht den Wissensarbeiter mehr als der Wissensarbeiter die Organisation. Der Wissensarbeiter ist der Experte und wenn er in seiner Domäne nicht mehr weiß als der Chef, ist das ein Fehler. Führung ist wichtig, aber keine Frage der Position. Führung bedeutet nicht mehr Überordnung und Unterordnung, sondern geschieht als Dienstleistung auf Augenhöhe. Letztlich tragen die Wissensarbeiter ihre Produktionsmittel im Kopf und können sie überallhin mitnehmen. Daher braucht Wissensarbeit Autonomie und die Wissensarbeiter müssen sich selbst führen.

Die Autonomie-Falle

Soweit die grundsätzlich absolut zutreffende Analyse von Peter Drucker. Als Konsequenz davon sieht Cal Newport die Wissensarbeiter aber mit ihrer Produktivität allein gelassen. Produktivität, so sein Argument, wurde durch diese Forderung nach Autonomie zur persönlichen Angelegenheit. Wo im Taylorismus der Manager alles bis ins Kleinste bestimmte, herrscht in der Wissensarbeit ein Vakuum, das jeder Wissensarbeiter nach bestem Wissen und Gewissen zu füllen versuchte. Diese teilweise verzweifelten Versuche, wenigstens ein lokales Optimum an persönlicher Produktivität zu finden, nennt Cal Newport die Autonomie-Falle der Wissensarbeit.

Im Jahr 2003 stellte eine in Communications of the ACM erschienene Studie ernüchternd fest, dass die beobachteten Wissensarbeiter durchschnittlich nach 1 Minute und 44 Sekunden auf eine ankommende E-Mail reagierten. In den meisten Fällen ging es aber noch viel schneller, denn bei 75 % der ankommenden E-Mails dauerte die Reaktion höchstens 6 Sekunden. Das war 2003 und wurde mit Instant Messaging und Group Chat nicht besser seither.

Eine neuere Studie von RescueTime kommt zu dem Ergebnis, dass der durchschnittliche Wissensarbeiter seine E-Mails oder Instant Messaging alle 6(!) Minuten prüft, und als Konsequenz daraus schaffen 40 % der Wissensarbeiter weniger als 30 Minuten konzentrierter Arbeit am Stück. Und Adobe stellte in ihrer „Adobe Email Usage Study“ 2019 fest, dass die ca. 1.000 befragten US-Amerikaner mehr als drei Stunden ihres Arbeitstags mit E-Mail verbringen (und zusätzlich noch zwei Stunden in ihrer privaten Inbox).

Wegen der von Peter F. Drucker geforderten Autonomie,

so Cal Newport, stand zu wenig die übergreifende Optimierung von Arbeitsabläufen und Rahmenbedingungen im Fokus, wie sie im Taylorismus noch die klare Aufgabe des Managements war. Die Wissensarbeiter waren mit der Frage ihrer Produktivität allein gelassen, was letztlich zu dem heutigen „Arbeitsprozess“ führte, der darin besteht, sich gegenseitig Präsentationen und Tabellenkalkulationen zu schicken. Von der kompletten Regulierung im Taylorismus schwang das Pendel also über das sinnvolle Maß an Autonomie hinaus in diese Autonomie-Falle und zu dem, was Cal Newport dann als „hyperaktives Schwarmbewusstsein“ („hyperactive hivemind“) bezeichnet. Gemeint ist damit allseits bekannte unstrukturierte Zusammenarbeit auf Basis von ad-hoc Kommunikation, mit der die Produktivität von Wissensarbeitern täglich beeinträchtigt wird.

Das war sicher nicht im Sinne des Erfinders, denn Peter F. Drucker hat eben nicht nur richtigerweise mehr Autonomie in der Führung von Wissensarbeitern gefordert. Gleichzeitig und trotzdem hat er dem Management aufgetragen, die Produktivität der Wissensarbeiter im 21. Jahrhundert in ähnlicher Weise zu steigern, wie es die Produktivität der manuellen Arbeit vorher steigerte. Aufgabe des Managements bleibt also nach wie vor, sich um optimale Arbeitsabläufe zu kümmern, wenn auch nicht wie ein Schachmeister zu Zeiten Taylors, sondern eher mit der Haltung eines Gärtners.

Wie das dann aussehen kann, zeigt sich beispielsweise an Methoden aus der agilen Software-Entwicklung, allen voran Scrum. Ein Teil des Erfolgs von Scrum geht meiner Meinung nach allein darauf zurück, dass der Arbeitsablauf recht rigide strukturiert wird, und viel weniger auf das konkrete Wie. Im Scrum ist die Arbeit des Teams übersichtlich geordnet in Backlog-Items, die entweder physisch auf Karten geschrieben sind oder virtuell in Tools wie JIRA verwaltet werden. An welchen Items davon konkret gearbeitet werden soll, wird zu Beginn eines Sprints im Sprint-Planning entschieden. Was dann im Detail zu tun ist, beschreibt das Team dann in einzelnen Tasks je Backlog-Item (und hat dabei volle Autonomie!) und hält alles auf einem Task-Board fest. Jeden Tag im sogenannten Daily trifft sich das Team vor diesem Board und spricht kurz selbstorganisiert darüber, welche Tasks abgeschlossen wurden und wer was als Nächstes macht und wer wobei Hilfe benötigt.

Wenn man sich darauf einlässt, ersetzt diese Struktur viele E-Mails und viele Besprechungen. Und damit bleibt mehr Zeit für das, was Software-Entwickler wie alle anderen Wissensarbeiter am meisten brauchen, um gute Arbeit zu leisten: Fokus und Konzentration.

Das Buch zum Manifest für menschliche Führung. Erhältlich als Taschenbuch und E-Book bei Amazon



FACHBEIRAT



Patric Fedlmeier
CIO Provinzial Rheinland



Dr. Norbert Gaus
Executive VP SIEMENS



Dr. Sandro Gaycken
Direktor ESMT



Dr. Michaela Harlander
Vorstand ISAR AG



Dr. Markus Heyn
GF Bosch



Manfred Klaus
Sprecher der GF Plan.Net



Andrea Martin
CTO IBM



Dr. Niko Mohr
Partner McKinsey



Dr. Christian Plenge
BL Messe Düsseldorf



Frank Rosenberger
Group Director TUI



Dr. Ralf Schneider
CIO Allianz Group



Stephan Schneider
Manager Vodafone



Michael Zaddach
Flughafen München

IMPRESSUM

REDAKTION

Chefredaktion Claudia Linnhoff-Popien (V. i. S. d. P.)
Chef vom Dienst Robert Müller

Fachbeirat Patric Fedlmeier, Norbert Gaus, Sandro Gaycken, Michaela Harlander, Markus Heyn, Manfred Klaus, Andrea Martin, Niko Mohr, Christian Plenge, Frank Rosenberger, Ralf Schneider, Stephan Schneider, Marc Schröder, Uwe Walter, Michael Zaddach

Redaktion Steffen Illium, Hannes Mittermaier, Claudia Huber

Redaktionsassistenten Katja Grenner, Lea Kar, Lydia Unterstraber

Mitarbeiter dieser Ausgabe Thomy Phan

Schlussredaktion Barbara Haber

ANFRAGEN AN DIE REDAKTION

redaktion@digitaleweltmagazin.de

GRAFIK

Layout Stefan Stockinger, www.stefanstockinger.com

ANZEIGEN

Ansprechpartner

redaktion@digitaleweltmagazin.de

Es gilt die gültige Preisliste, Informationen hierzu unter www.digitaleweltmagazin.de/mediadaten

KOSTENLOS ERHÄLTICH

www.digitaleweltmagazin.de/magazin/

Ebenfalls online über SpringerLink (Berlin, Heidelberg, New York) erhältlich.

Alle Artikel werden von Google Scholar indiziert.

HERAUSGEBER

Prof. Dr. Claudia Linnhoff-Popien, Institut für Informatik, Ludwig-Maximilians-Universität München, Oettingenstr. 67, 80538 München, Tel. +49 89 2180-9153, www.digitaleweltmagazin.de

RECHTE

Dieses Magazin und alle in ihm enthaltenen Beiträge, Abbildungen, Entwürfe und Pläne sowie Darstellungen von Ideen sind urheberrechtlich geschützt. Mit Ausnahme der gesetzlich zugelassenen Fälle ist eine Verwertung einschließlich Nachdrucks ohne schriftliche Einwilligung des Herausgebers strafbar. Für unverlangt eingesandte Manuskripte und Bildmaterial übernehmen Redaktion und Verlag keine Haftung.



Digitale Stadt München e.V.



Jetzt Mitglied werden!



Stand: Sept. 2019

Digitale Stadt München e.V.:

Der Verein „Digitale Stadt München e.V.“ ist ein branchenübergreifendes Netzwerk im Umkreis der Digitalmetropole München. Als lebendige Plattform vernetzt er seine Mitglieder im Rahmen von drei Formaten:

DigiTalk

DigiTalks sind unsere regelmäßigen Themenabende. Unsere Mitglieder öffnen ihre Türen und laden zu einem aktuellen Thema der digitalen Transformation ein. Lernen Sie das Unternehmen kennen und erfahren Sie dessen Herausforderungen und Lösungsansätze.

AGs

Die Arbeitsgruppe „Smart City“ hat beispielsweise das Ziel, die Stadt München zu einer intelligenten Metropole zu entwickeln. Zu diesem Zweck werden Potenziale aus Wissenschaft und Wirtschaft identifiziert, um sie in das urbane Leben zu integrieren.

DIGICON

Die DIGICON ist großer Treffpunkt wenn jährlich 350 namhafte Experten und Entscheider zusammen kommen, um sich über aktuelle Themen der Digitalisierung auszutauschen.

Die **DIGITALE WELT** erscheint ausschließlich digital. Sichern Sie sich JETZT Ihr kostenloses Abo unter digitaleweltmagazin.de/magazin/

Kontakt: Geschäftsstelle des Vereins „Digitale Stadt München e.V.“, Oettingenstraße 67, 80538 München

✉ geschaeftsstelle@digitalestadtmuenchen.de ☎ 089/ 2180-9259 oder -9171

Mitglied werden unter: <https://digitalestadtmuenchen.de/mitglied-werden/>



QUANTUM
APPLICATIONS
& RESEARCH
LABORATORY

Das QAR-Lab

Das Quantum Applications and Research Laboratory (kurz QAR-Lab) – im Jahr 2016 von der Informatik-Professorin Dr. Claudia Linnhoff-Popien der LMU München gegründet – hat die Mission, die Technologie des Quantencomputings (QC) einem breiten Nutzerkreis in Forschung und Wirtschaft zugänglich zu machen. Bereits 2019 wurde das QAR-Lab im Ranking als eine der „World's Top 12“ Forschungseinrichtungen auf dem Gebiet des Quantencomputings durch „The Quantum Daily“ international bekannt.

Unsere Schwerpunkte

Als Gründungsmitglied des europaweit einzigartigen Leuchtturmprojekts PlanQK („Plattform und Ökosystem für quantenunterstützte KI“) leistet das Lab Pionierarbeit dabei, die Quantencomputing-Technologie auf dem Gebiet der Künstlichen Intelligenz zu nutzen.

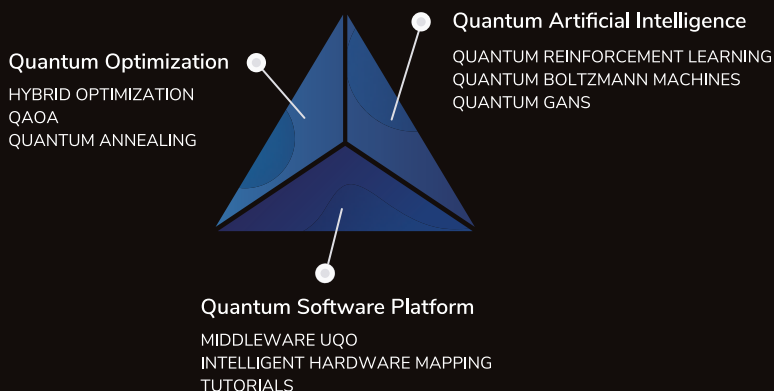
Das QAR-Lab hat – in Deutschland einzigartig – Zugang zu vier unterschiedlichen Quantencomputern und kann daher vergleichende Bewertung geeigneter Algorithmen durchführen.

Die Experten des QAR-Labs beschäftigen sich neben der Grundlagenforschung mit der Nutzung der Technologie für praxisnahe Anwendungen. Sie setzen auf Pilotprojekte für neue Technologien im Bereich QC und arbeiten an der Umsetzung von quantenunterstützten KI-Algorithmen für industrielle Use Cases im Rahmen von Forschungs Kooperationen mit großen Industriepartnern, die die Technologie erproben wollen.

Das QAR-Lab der LMU baut ein bayerisches Ökosystem für Anwenderkompetenz auf und stärkt den Standort München auf der deutschen Quantencomputing-Landkarte.

Finanziell gefördert wird das Lab seit 2019 vom Bundesministerium für Wirtschaft und Energie (BMWi) und seit 2020 vom Bayerischen Staatsministerium für Wirtschaft, Landesentwicklung und Energie (StMWi).

Unsere Forschungsschwerpunkte



BECOME
QUANTUM
READY!

Kooperationsmöglichkeit mit dem QAR-Lab

Nutzen Sie die Expertise des QAR-Labs, um sich im internationalen Wettbewerb rechtzeitig Wissen über Quantencomputing anzueignen. In einer Kooperation mit dem QAR-Lab werden Sie von Anfang an kompetent unterstützt. Wir gehen mit Ihnen die ersten Schritte oder begleiten Sie den ganzen Weg.

Unsere Experten wissen, welche Quantenhardware für welche Herausforderungen in einem Betrieb am geeignetsten sind.

Unser Ziel



Schwere Anwendungsfälle

Die Lösung mit heutigen Techniken braucht viel Rechenzeit oder geht gar nicht.



Wichtige Anwendungsfälle

Eine bessere/ schnellere Lösung hat einen großen Effekt, bspw. bei der Einsparung von Kosten oder der Verbesserung der Organisation.



Passende Anwendungsfälle

Es gibt ein (prospektives) Lösungsverfahren incl. QC-HW, das einen Vorteil bringt.



Frühe Anwendungsfälle

Eine QC-basierte Lösung ist relativ bald (schon mit NISQ?) umsetzbar.

Kontaktieren Sie uns: www.qar-lab.de

Prof. Dr. Claudia Linnhoff-Popien
Leitung QAR-Lab
Ludwig-Maximilians-Universität München
Oettingenstraße 67
80538 München
Telefon: +49 89 2180-9153
E-Mail: qar-lab@mobile.ifi.lmu.de