



Künstliche Intelligenz Zukunftstechnologie schon heute

Gemeinschafts-Beitrag zum Bildungsportal der UBIT Steiermark
Stand. 02. September 2019. Version 3.5.

Inhalt

Künstliche Intelligenz - Zukunftstechnologie schon heute	4
Heute schon im Einsatz	4
Teil 1 von 3. Einstieg in die Begriffe	4
Ist künstliche Intelligenz stark oder schwach?	6
Der Begriff „Schwache künstliche Intelligenz“	6
Die Optimierung einer Fehlerfunktion.....	7
Der Begriff „Generelle künstliche Intelligenz“	7
Data Science	9
1. Fragestellung	9
2. Datenerhebung	9
3. Datenbereinigung	10
4. Explorative Datenanalyse	10
5. Modellbildung.....	10
6. Kommunikation der Resultate	10
Big Data	11
Volume – Variety - Velocity.....	12
Machine Learning	13
Eine kurze Definition	13
Eine schlüssige Definition – etwas länger	13
Drei Gebiete des maschinellen Lernens	14
1. Unsupervised Learning.....	14
2. Supervised Learning.....	15
3. Reinforcement Learning	17
AI Safety / AI Ethics	19
Wie sicher ist das Ergebnis vorhersagbar?	19
Wie soll optimiert werden?	19
Das Alignment Problem	20
Diskriminierung steckt schon in den Daten.....	20
Was ist wahr?	21
Mehr als nur Jobs	21
Fahrplan für den Einsatz im Unternehmen	22
So starten Sie in die Welt der KI	22

Der Trend Radar und seine vier möglichen Nutzen	22
Nutzen 1: WENIGER BRAUCHEN!.....	23
Nutzen 2: MEHR ERKENNEN!	23
Nutzen 3: MICH VERWANDELN!	23
Nutzen 4: UNS NEU ERSCHAFFEN!.....	23
Handlungsfähig bleiben heißt: einfach den nächsten Schritt setzen.....	24
Ordnung für verschiedene Funktionalitäten	25
Drei typische Verarbeitungsschritte in der Anwendung	26
Zwei Einsteiger-Beispiele	26
Einfaches Beispiel zum Sprachverständnis der Alexa Skills.....	26
Einfaches Beispiel zur Optimierung von Empfehlungen	27
Anhang	28
Das Autorenteam	28

Künstliche Intelligenz - Zukunftstechnologie schon heute

Von Clemens Istel, Leftshift One – www.leftshift.one

Künstliche Intelligenz hier, künstliche Intelligenz dort. An alle Ecken lesen wir von der Zukunftstechnologie, die unser Leben für immer verändern soll. KI durchdringt unseren Alltag, diktiert angeblich unser Konsumverhalten und ist in digitalen Bereichen längst der unschlagbare Gamechanger. Die einen bejubeln sie als Innovationstreiber, die anderen sehen die Abhängigkeit von Technik kritisch. Die Wahrheit liegt wie so oft dazwischen.

Was steckt wirklich hinter dieser mysteriösen Technologie, von der uns Bücher, Film und Fernsehen glauben machen wollen, dass sie uns Menschen in absehbarer Zukunft beherrschen könnte?

Wozu ist künstliche Intelligenz tatsächlich imstande? Wie wird sie eingesetzt und wo liegen ihre Grenzen? Die folgenden Kapitel sollen Ihnen, werte Leser, diese neuartige Technologie näherbringen. Auf den kommenden Seiten finden Sie eine ausführliche Einführung in die Welt der künstlichen Intelligenz und wie auch Sie sie für sich nutzen können.

Heute schon im Einsatz

Denn so komplex und übermächtig wie im TV ist künstliche Intelligenz eigentlich nicht. Trotzdem birgt sie enormes Potenzial und spannende Herausforderungen. Künstliche Intelligenz hilft beispielsweise in der Krebsforschung, revolutioniert den Kundenservice und kann bereits Wartungsintervalle und Betriebsstörungen vorhersagen.

Sie erkennt, wenn sie von ihrem Reisebüro ein ganz bestimmtes Angebot erwarten. An anderer Stelle findet sie anhand des Digitalisierungsindex Ihres Unternehmens den perfekten Experten aus einem umfangreichen Firmen A-Z, der exakt auf ihre Bedürfnisse reagiert. KI ermöglicht Qualitätssteigerung und sorgt für optimierte Prozesse.

Um das gesamte Potenzial von künstlicher Intelligenz zu veranschaulichen, erwarten Sie in Kapitel 3 dieses Dossiers detaillierte Best-Practice-Beispiele. Anhand mehrerer Use Cases werden hier die Wirkungsweisen von KI plastisch dargestellt.

Teil 1 von 3. Einstieg in die Begriffe

Aber beginnen wir am Anfang. Unser erstes Kapitel rollt die wichtigsten Eckpfeiler der künstlichen Intelligenz auf. Wir beleuchten ihre Bausteine und verfolgen die Entwicklung bis zum heutigen Status Quo. Dabei wird schnell deutlich, dass die fantasievollen Darstellungen aus der Popkultur noch in ferner Zukunft liegen.

Heutzutage arbeiten wir nämlich mit sogenannter schwacher künstlicher Intelligenz. Dahinter stecken primär Mathematik, Statistik und Heuristiken. Welche Unterschiede zur starken künstlichen Intelligenz aus unseren liebsten Science-Fiction-Romanen bestehen und wann wir theoretisch mit so einer Technologie rechnen können, soll im einführenden Abschnitt des ersten Kapitels erläutert werden.

Anschließend wird es Zeit, über die Grundlagen und Treiber von künstlicher Intelligenz zu sprechen. Ein weiterer Teil von Kapitel 1 befasst sich deshalb mit wichtigen Begriffen und Technologien rund um KI. Darin wird erklärt, was etwa unter Big Data zu verstehen ist und welche Rolle Data Science im Zusammenhang mit künstlicher Intelligenz spielt. Spoiler: eine große!

KI-Interessierte stolpern vermutlich auch öfter über Begriffe wie Machine Learning oder Supervised Learning. Natürlich blicken wir auch hinter diese und weitere Vorhänge. Konsequenterweise sollen in diesem Rahmen auch die Grenzen von KI aufgezeigt werden. Was leistet sie denn nun bereits wirklich? Soviel vorweg: Sie entscheidet nur, was wir sie entscheiden lassen.

Im Sinne von Ethik und Moral sollte das im Übrigen auch nicht zu viel sein. Denn bereits in der Vergangenheit mussten wir Beispiele erleben, in denen etwa schlecht programmierte KI zu Diskriminierung geführt hat. Das abschließende Thema in Kapitel 1 ist deshalb "Ethik und Security".

In Teil 2 unseres KI-Schwerpunktes werden wir aufbauend auf Kapitel 1 zeigen, wie Sie künstliche Intelligenz einfach und effizient in Unternehmen implementieren können. Wir sprechen ausführlich über Vorteile und Einsatzgebiete. Tauchen Sie mit uns heute schon in die Welt von morgen ein.

Ist künstliche Intelligenz stark oder schwach?

Von Manuel Weichselbaum, KI Forscher, Physiker, TU Graz.

Der Begriff „Schwache künstliche Intelligenz“

Von schwacher künstlicher Intelligenz („weak / narrow AI“) spricht man, wenn ein Teil des menschlichen Denkens algorithmisch nachgeahmt wird, um Lösungen für ein konkretes Problem zu finden. Im Gegensatz dazu beschreibt man künstliche Intelligenz auf oder über dem Niveau eines Menschen als starke künstliche Intelligenz. Es wird oft wie eine andere Stufe bzw. eine andere Form von Intelligenz beschrieben, doch genau definiert ist starke künstliche Intelligenz nicht.

Man verlangt jedoch eine gewisse allgemeine Problemlösungskompetenz, Anwendung von altem Wissen auf neue Probleme, schnelle Adaption an neue Umstände, logisches Denken und Planen und Umgang mit Unsicherheiten bis hin zur Fähigkeit, mit Sprache zu kommunizieren. Bisher gibt es noch keine Maschine, die den Status einer starken künstlichen Intelligenz erlangt hat. Die meisten Forscher halten aber eine Realisierung im 21. Jahrhundert, ja sogar bis 2060 für realistisch.¹ Wissenschaftler sagen voraus, dass künstliche Intelligenz den Menschen innerhalb der nächsten 10 Jahre bereits in vielen Aufgaben übertreffen wird, z.B. Sprachen übersetzen (2024), Aufsätze auf Oberstufenniveau schreiben (2026), einen Laster fahren (2027), als Verkäufer arbeiten können (2031), einen Bestseller schreiben (2049) und als Chirurg praktizieren (2053).

Sehr oft werden die gegenwärtigen Methoden der künstlichen Intelligenz als mathematische Spielerei hingestellt. Im Grunde sei das, was man künstliche Intelligenz nennt, nur „curve fitting“ – die Suche nach der Funktion, die gegebene Daten am besten approximiert. Das sei von wahrer Intelligenz noch weit entfernt und völlig neue Methoden wären nötig, um starke künstliche Intelligenz zu erreichen – die Methoden der schwachen künstlichen Intelligenz seien noch weit entfernt von der Raffiniertheit des Gehirns.

Vielleicht verstehen wir das Gehirn deshalb so schlecht, weil biologischem Denken irgendein hochkomplexes Phänomen zugrunde liegt, das man mit herkömmlichen Computern gar nicht erst simulieren kann. *Über diesen Standpunkt lässt sich nicht weiter diskutieren, denn es wird sich erst herausstellen, ob das Gehirn mit Computern nachahmbar ist oder nicht.*

Auf der anderen Seite finden Wissenschaftler immer wieder Parallelen zwischen den Methoden der schwachen künstlichen Intelligenz und der Intelligenz von Menschen. Die Neurowissenschaft und das Forschungsgebiet der künstlichen Intelligenz haben sich in den

¹ Katja Grace et al., When Will AI Exceed Human Performance? Evidence from AI Experts, 2017, <https://arxiv.org/abs/1705.08807>

letzten Jahren sogar gegenseitig geholfen.² Betrachten wir künstliche Intelligenz also genauer.

Die Optimierung einer Fehlerfunktion

Das Kernstück aller gegenwärtig weit verbreiteten Algorithmen im Bereich künstlicher Intelligenz ist die Optimierung einer Fehlerfunktion. Wenn eine Firma versucht, die Zeit der nächsten Wartung ihrer Geräte vorherzusagen, minimiert der Algorithmus den Fehler zwischen dem vorhergesagten Zeitwert und dem tatsächlichen Zeitwert laut Datensatz. Wenn ein Algorithmus Gesichter, Tiere oder Bauteile in einem Bild benennen soll, interessiert man sich für die prozentuale Genauigkeit der Vorhersage.

Auch der Youtube-Algorithmus versucht die „watch time“ des Nutzers zu maximieren. Lernen und Optimieren sind für künstliche Intelligenz Synonyme. Dieses Prinzip ist so fundamental, dass es keine Anzeichen oder Gründe gibt, dass künstliche Intelligenz irgendwann nicht mehr im Grunde die Optimierung einer Zahl sein wird, die die Leistungsfähigkeit des Systems beschreibt. Selbst Evolution basiert auf Selektion aufgrund von „fitness“ – der Zahl, die all die komplexen Faktoren des Lebens auf die Fähigkeit herunter bricht, sich fortzupflanzen und zu verbreiten.

Sind wir Menschen also – als das gängigste Beispiel von starker Intelligenz – gar nicht so anders als künstliche Intelligenz jetzt schon ist? Fehlt uns nur noch die korrekte Fehlerfunktion, die wir einer künstlichen Intelligenz zur Optimierung übergeben müssen, um den Durchbruch zu schaffen? Ist der menschliche Geist womöglich im Grunde nur „curve fitting“?

Der Begriff „Generelle künstliche Intelligenz“

In der Forschung ist der Begriff „starke künstliche Intelligenz“ kaum anzutreffen. Viel häufiger liest man von „genereller künstlicher Intelligenz“ - Artificial General Intelligence, kurz AGI. Generelle künstliche Intelligenz soll im Grunde die größten Unterschiede von schwacher zu starker künstlicher Intelligenz ausbessern, nur sind unklare Begriffe wie Bewusstsein der starken künstlichen Intelligenz vorenthalten. Eine generelle künstliche Intelligenz soll zumindest alle Aufgaben erlernen können, die auch ein Mensch schaffen kann. Dieses Ziel schreiben sich große Firmen wie Googles DeepMind, das von Elon Musk mitgegründete OpenAI und Jürgen Schmidhubers NNAISENSE auf die Fahnen. DeepMind versucht zum Beispiel, so wenig Vorwissen über das zu lösende Problem wie möglich in ihre Algorithmen bzw. Fehlerfunktionen einzubauen, um sicherzustellen, dass derselbe Algorithmus für viele verschiedene Probleme eingesetzt werden kann.

² <https://deepmind.com/blog/article/ai-and-neuroscience-virtuous-circle>

Vielleicht haben Sie von der künstlichen Intelligenz gehört, die 2016 in Korea den Go-Weltmeister Lee Sedol phänomenal besiegte. DeepMind entwickelte sie unter dem Namen AlphaGo. Ihre Weiterentwicklung AlphaZero spielt jetzt ohne nennenswerte Anpassungen auch Schach und Shogi und ist darin besser als alle Menschen und etablierten Algorithmen zuvor. Sehr ähnliche Algorithmen von DeepMind können auch den Energieverbrauch der Google-Rechenzentren optimieren³ und bei Proteinstruktur-Berechnungen in der Medizin helfen⁴.

Jedes Mal, wenn ein weiterer Durchbruch passiert, öffnen sich viele neue Lösungen für Probleme, die bisher praktisch einfach zu viel Aufwand bedeutet hätten oder bisher falsch angegangen wurden. Vielleicht hilft es sogar eines Tages, das Gehirn und viele Fragen, die wir über uns selbst haben, zu beantworten.

Selbst schwache künstliche Intelligenz kommt nicht ohne große Datenmengen aus. Blicken wir infolge also auf die Datenwissenschaften sowie einen der zentralsten Begriffe in unserer digitalisierten Zeit: Big Data.

³ <https://deepmind.com/blog/article/deepmind-ai-reduces-google-data-centre-cooling-bill-40>

⁴ <https://www.nature.com/articles/d41586-019-01357-6>

Data Science

Von Andreas Windisch, Theoretischer Physiker, Silicon Austria Labs.

Ziel von Data Science, also den Datenwissenschaften, ist es, *Informationen aus strukturierten und unstrukturierten Daten zu extrahieren*. Strukturierte Daten sind zum Beispiel Tabellen, wie sie in Datenbanken hinterlegt sind. Unstrukturierte Daten hingegen sind etwa Audioaufnahmen, Text, Bilder und dergleichen. Um Informationen aus Daten extrahieren zu können, bedient sich Data Science der Statistik und der Datenanalyse, bringt aber auch Machine Learning zur Anwendung.

Der in den Datenwissenschaften zentrale Prozess der Datenanalyse läuft dabei in mehreren Schritten ab, die wir in der Folge kurz anhand von einem Beispiel näher beleuchten wollen. Diese sind:

1. Fragestellung
2. Datenerhebung
3. Datenbereinigung
4. Explorative Datenanalyse
5. Modellbildung
6. Kommunikation der Resultate

Am Beginn steht eine Frage, die es zu erörtern gilt. Eine Frage könnte zum Beispiel die der ‚vorausschauenden Wartung‘ (predictive maintenance) eines Produktes sein. In unserem Beispiel wollen wir die Lebenserwartung von Autobatterien vorhersagen.

1. Fragestellung

Im ersten Schritt muss dazu erhoben werden, welche Informationen zur Beantwortung der Frage wichtig sind und welche Faktoren die Lebensdauer der Batterien beeinflussen können. Dabei kann es sich um Messdaten aller Art handeln, von Batteriespannungen über (Ent-) Ladezeiten, bis hin zum Einsatzort und des dort vorherrschenden Klimas, sowie auch um sonstige Formen von Informationen, wie etwa dem Fahrzeugtyp, in dem die Batterie eingesetzt wird.

2. Datenerhebung

Dies führt dann zum zweiten Schritt, bei dem die vorher definierten Daten und Parameter erhoben und akquiriert werden. Abhängig vom Problem kann dieser Schritt oft (zumindest teilweise) automatisiert werden. In unserem Beispiel könnten die Daten vom Bordcomputer des Fahrzeugs aufgezeichnet werden, die dann bei Bedarf vom Batteriehersteller eingesammelt werden.

3. Datenbereinigung

Im nächsten Schritt werden die gesammelten Rohdaten bereinigt. Bereinigen bedeutet hier, dass zum Beispiel definiert wird, wie mit fehlenden Messwerten umgegangen wird, oder wie man mit ungültigen oder inkonsistenten Dateneinträgen verfährt. Am Ende dieses Schrittes sollte, nachdem es sich in unserem Beispiel um strukturierte Daten handelt, eine geordnete Tabelle als Datensatz vorliegen.

4. Explorative Datenanalyse

Ist der Datensatz einmal bereinigt, wird eine explorative Datenanalyse angestellt. Bei dieser Analyse wird versucht, Muster oder Trends in den vorliegenden Daten zu erkennen. In unserem Beispiel könnte ein solches Muster etwa die Zeit um den Motor zu starten sein, da Batterien, die nicht mehr so leistungsfähig sind, den Motor langsamer drehen und es daher länger dauert, bis der Motor startet.

5. Modellbildung

Bei der Modellbildung werden dann die Hypothesen, die aus den bei der explorativen Analyse gewonnen Einsichten erstellt wurden, ausgiebig getestet und verfeinert.

6. Kommunikation der Resultate

Im letzten Schritt muss das Ergebnis der Analyse schließlich aufbereitet werden. Dabei entsteht oftmals ein ausführlicher wissenschaftlicher Bericht, sowie eine kompakte ‚Executive Summary‘, die die wichtigsten Einsichten, entsprechend ableitbare Maßnahmen, sowie Empfehlungen, nochmals prägnant zusammenfasst.

Mit Hilfe von Data Science und dem hier beschriebenen Prozess kann jede hochkomplexe Fragestellung analysiert werden, sofern die entsprechende Datenlage es zulässt und sofern bei der Analyse mit der notwendigen Sorgfalt gearbeitet wurde. Jeder der einzelnen Schritte muss hierbei sehr gründlich und mit größter Umsicht ausgeführt werden.

Mit der Unmenge an Daten, die wir heute zur Verfügung haben, liegt ein enormes Potential in diesem Zugang. Frei nach dem Motto ‚*Verwende die beste Hardware, die besten Programmieretechniken und die effizientesten Algorithmen um Probleme zu lösen*‘⁵ können wir mit effizienten und mächtigen Programmiersprachen wie *Python*⁶ oder *R*⁷, zusammen mit entsprechend leistungsfähigen Computern, präzise Modelle zur Verbesserung unserer Geschäftsprozesse oder Produkte konstruieren.

⁵ J. Leskovec A. Rajaraman, J. Ullman, ‚*Mining of Masive Datasets*‘, Cambridge University Press, 2nd edition, 2012

⁶ Python Software Foundation, Python Language Reference, Version 3.7, available at <http://www.python.org>

⁷ R Core Team, ‚*R: A language and environment for statistical computing*‘, R Foundation for Statistical Computing, Vienna, Austria, 2017

Big Data

Von Wolfgang Kienreich, Know-Center.

Während der Begriff "Big Data" recht neu ist, ist der Akt der Sammlung und Speicherung großer Mengen an Daten für eine spätere Analyse schon seit Jahrzehnten en vogue. Das Konzept entstand bereits in den späten 90er Jahren, wurde Anfang der 2000er Jahre populär und begann ab 2011 richtig an Fahrt zu gewinnen. Die folgende Abbildung 1 stellt dar, wie sich das Suchinteresse nach dem Thema Big Data auf Google von 2004 bis August 2019 entwickelt hat.

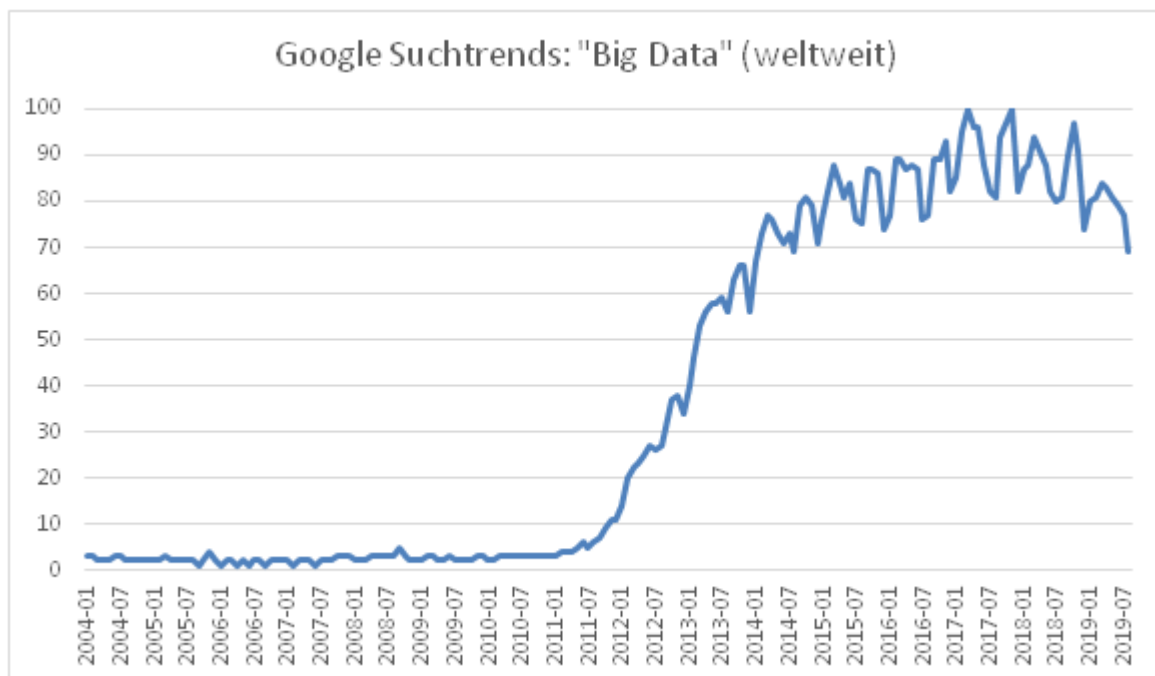


Abbildung 1 Google Suchtrends: "Big Data" (weltweit, 01/2004-08/2019)

Eine exakte Definition von Big Data ist nicht so einfach, da sich der Begriff auf viele Aspekte und Disziplinen bezieht. Im Allgemeinen versteht man unter Big Data eine Sammlung von Datensätzen mit bestimmten Eigenschaften, die aufgrund ebendieser Eigenschaften nicht mit traditionellen Datenverarbeitungstechniken verarbeitet werden können. Damit ist jedoch keine einzelne Technik oder ein besonderes Werkzeug gemeint; Big Data an sich ist zu einem viele Aspekte umfassenden Thema geworden, das verschiedenste Werkzeuge, Techniken und Frameworks umfasst, um dieser Daten Herr zu werden.

Volume – Variety - Velocity

Die meisten verwendeten Definitionen von Big Data basieren auf dem **3-V-Modell** von Gartner, das vielfach adaptiert und erweitert wurde. In der ursprünglichen Variante stellt Gartner drei zentrale Kriterien vor, die im Kern Big Data beschreiben.

Volume beschreibt dabei die schiere Menge an Daten, die aus einer Vielzahl von Quellen gesammelt und gespeichert werden können. Bisher war die Speicherung und Verarbeitung extrem großer Datenmengen ein Problem, aber mit effizienterer und fortschrittlicherer Hard- und Software ist es möglich, gigantische Datenmengen zu speichern sowie angemessene Lese-, Schreib- und Verarbeitungsgeschwindigkeiten zu gewährleisten.

Variety bezieht sich auf den Umstand, dass es Daten in allen Spielarten und Formen gibt. So etwa in strukturierten Formaten, wie in traditionellen Datenbanken, oder in unstrukturierten, wie in Textdokumenten, E-Mails, Videos, Audio und vielen anderen. Schätzungsweise 80 Prozent der Daten auf der Welt sind unstrukturiert und wurden bisher kaum bis selten einer tieferen Analyse unterzogen.

Velocity bezieht sich auf die Geschwindigkeit, mit der die Daten erzeugt, analysiert und wiederaufbereitet werden. Heute ist dies meist innerhalb von Sekundenbruchteilen, quasi in Echtzeit, möglich und wird in vielen Szenarien, zum Beispiel bei der Überwachung geschäftskritischer Prozesse, eingesetzt.

Diese klassischen Definitionskriterien des 3-V-Modells konzentrieren sich vor allem auf die skalierbare Rechenleistung, die zur Verarbeitung von Big Data nötig ist. Big Data als Themenwelt orientiert sich also eher zum technischen Handling von Daten mit diesen Eigenschaften und nicht zur Ermittlung von wertstiftenden Erkenntnissen aus diesen Daten. Big Data sind somit primär als Rohstoff für state-of-the-art Analytik-Methoden aus den Bereichen der künstlichen Intelligenz im Allgemeinen und maschinellem Lernen im Besonderen zu verstehen.

Machine Learning

Von Oliver Pimas, Know-Center und Andreas Windisch, Theoretischer Physiker, Silicon Austria Labs.

Was ist Machine Learning? Die Herausforderung bei der Beantwortung dieser Frage liegt darin, dass es sehr schwierig ist, der Tiefe und Breite des Themengebietes gerecht zu werden und den Kern der Idee, die Machine Learning ausmacht, zu skizzieren.

Zwei Definitionen von Machine Learning werden oft zur Beantwortung dieser Frage herangezogen.

Eine kurze Definition

„Machine Learning ist die Wissenschaft, die es Computern ermöglicht zu lernen, ohne dass diese explizit programmiert wurden.“

Diese (frei übersetzte) Aussage ist der Kern einer Studie von Arthur Samuel ⁸ aus dem Jahr 1959 (streng genommen hat er diese Aussage nie als solche getätigt, vielmehr handelt es sich um eine etablierte Interpretation der Hauptaussage der Studie).

Eine schlüssige Definition – etwas länger

Eine weitere Definition des (maschinellen) Lernens findet sich im Buch *„Machine Learning“* von Tom Mitchell ⁹:

„Man sagt, ein Computerprogramm lernt aus der Erfahrung ‚E‘ im Bezug auf eine Klasse von Aufgaben ‚A‘ und einem Leistungsmaß ‚L‘, wenn sich die Leistung des Programmes beim Lösen von Aufgaben der Klasse ‚A‘, bewertet durch ‚L‘, mit der Erfahrung ‚E‘ verbessert.“

Dieser zugegebenermaßen etwas sperrige Satz ist eine durchwegs schlüssige Definition, und es lohnt sich, hier eine Gedankenpause einzulegen, um kurz über die Aussage dieser Definition nachzudenken.

Sehen wir uns die Definitionen nun etwas genauer an. Der wichtigste Teil aus der ersten Definition ist die Aussage *„...ohne dass diese [Computerprogramme] explizit programmiert wurden“*. Natürlich wurde das Computerprogramm, das letztlich eine Aufgabe erlernen soll, programmiert. Der Punkt hier ist aber ein anderer: Das Programm wurde nicht geschrieben, um eine *bestimmte* Aufgabe zu lösen. Vielmehr handelt es sich um einen generischen Lösungsansatz, der in der Lage ist, *unterschiedliche* Aufgaben zu erlernen, abhängig davon welche Daten wir dem System zur Verfügung stellen.

⁸ A. L. Samuel, *‘Some Studies in Machine Learning Using the Game of Checkers’*, IBM Journal of Research and Development 3, 3, 1959

⁹ T. M. Mitchell, *‘Machine Learning’*, McGraw-Hill, Science/Engineering/Math, 1997

Nehmen wir an, wir wollten einer Maschine, also einem Computerprogramm, beibringen, handgeschriebene Ziffern von 0 bis 9 zu erkennen. Die Daten, die wir dem System dazu zur Verfügung stellen, sind dann Bilder von handgeschriebenen Ziffern, und das Programm lernt, diese zu identifizieren. Wir können demselben Programm (eventuell mit einigen wenigen Parameteränderungen) aber auch beibringen, ein Modell zu lernen, das die erzielten Verkaufspreise von Immobilien vorhersagen soll, indem wir dem Programm Informationen über bereits erfolgte Immobilienverkäufe zur Verfügung stellen.

Der Umstand, dass hier generische Programme in der Lage sind unterschiedlichste Aufgaben zu lösen, ist ein Paradigmenwechsel. Damit wurde es möglich, vor allem auch gestützt durch den rapiden Anstieg der zur Verfügung stehenden Rechenleistung über die letzten 20 Jahre, oft Ergebnisse zu erzielen, die über dem menschlichen Vermögen beim Lösen dieser Aufgaben liegen.

Die wichtige Aussage der zweiten Definition ist jene, dass die Verbesserung der Leistung eines maschinell lernenden Systems von der Erfahrung getrieben wird. In dem Beispiel mit den handgeschriebenen Ziffern gewinnt das lernende System mit jedem neuen Bild, das wir dem System zeigen, an Erfahrung und lernt, was die geeigneten Unterscheidungsmerkmale sind, die für die korrekte Identifikation einer handgeschriebenen Ziffer herangezogen werden können.

Wir können also festhalten, dass maschinelles Lernen zum einen die generische Fähigkeit des Lernens ist, zum anderen der Umstand, dass das Lernen durch Erfahrung erfolgt.

Drei Gebiete des maschinellen Lernens

Grundsätzlich werden drei große Gebiete des maschinellen Lernens unterschieden, die wir hier kurz umreißen wollen.

1. Unsupervised Learning

Unsupervised Learning, also unbeaufsichtigtes Lernen, hat zum Ziel, Muster in Datensätzen zu erkennen. Dabei kann es sich um Cluster (Anhäufung von Datenpunkten) handeln, die identifiziert werden, oder die Bestimmung der ‚dominanten‘ Eigenschaften eines Datensatzes. Wir sprechen damit von Methoden, die Strukturen in vorhandenen Daten zu identifizieren. Der Begriff „unüberwacht“ deutet bereits darauf hin, dass man bei diesen Ansätzen keine Trainingsdaten benötigt, für welche die korrekte Antwort bereits bekannt ist.

Die Daten, die wir dem System zur Verfügung stellen, tragen in diesem Zugang kein ‚Label‘ (Etikett). Das heißt, wir teilen dem System während des Lernens nicht mit, was die korrekte Antwort auf die zu bearbeitende Frage für die entsprechenden Eingangsdaten ist.

Die wahrscheinlich bekanntesten Vertreter dieser Gruppe sind sogenannten Clusteranalysen, die Daten anhand von Ähnlichkeiten organisieren. Die Idee dieser

Verfahren ist simpel: Man möchte eine Gruppe von Objekten, z.B. Textdokumente, Bilder, Messpunkte etc., in Gruppen einteilen, wobei die Ähnlichkeit innerhalb einer Gruppe maximiert und die Ähnlichkeiten zwischen den Gruppen minimiert werden sollen. Die Anzahl der Gruppen, in welche die Daten aufgeteilt werden sollen, ist häufig der einzige zu spezifizierende Parameter.

Neben Clusteranalysen werden Methoden aus diesem Bereich auch eingesetzt, um Anomalien bzw. Ausreißer zu erkennen, Daten zu komprimieren oder alternative Darstellungsformen der in den Daten enthaltenen Informationen zu generieren.

Der Begriff „Unüberwachtes Lernen“ selbst ist nicht ganz unumstritten, da einige der Ansätze und Verfahren nicht wirklich lernen.

Für Unsupervised Learning werden keine annotierten Daten, also Daten die bereits mit der korrekten Antwort versehen sind, benötigt.

2. Supervised Learning

Anders verhält es sich bei Supervised Learning, also beaufsichtigtem Lernen. Hier geben wir dem System während des Lernens, neben den Daten die das System beurteilen soll, zusätzliche Informationen über das erwünschte Ergebnis, das mit dem jeweiligen Element des Datensatzes einhergeht.

Bei Supervised Learning handelt es sich um Lernmethoden, die anhand bekannter Beispiele lernen. Der Begriff selbst bezieht sich hierbei auf die Tatsache, dass das Gelernte anhand dieser bekannten Beispiele überwacht wird.

Die Art und Weise wie ein solches Modell lernt, kann man sich analog zum Lernverhalten eines Kleinkindes vorstellen. Um einem Kind die Unterscheidung unterschiedlicher Objekte beizubringen, zeigt man ihm Beispiele. Ein Kind ist bei der Identifikation von generell anwendbaren Unterscheidungsmerkmalen äußerst schnell. Obwohl sich Oberflächenstruktur sowie Farbe eines Basketballs klar von denen anderer Ballarten (z.B. Fußball, Handball, Volleyball etc.) unterscheiden, wird ein Kind diesen als Ball erkennen.

Analog hierzu füttert man ein Modell, das Objekte auf Bildern erkennen soll, mit positiven und negativen Beispielen. Die Aufgabe für das Modell in der Trainingsphase ist, die bekannten Beispiele möglichst fehlerfrei zu unterscheiden. Um sicherzustellen, dass die Unterscheidungskriterien nicht nur für die Beispiele funktionieren, sondern generell anwendbar sind, hält man einige Daten beim sogenannten Training zurück. Man spricht von Trainings- und Testdaten.

Ein Beispiel ist in der Abbildung zu sehen, die das Prinzip des Lernens eines neuronalen Netzwerkes zeigt.

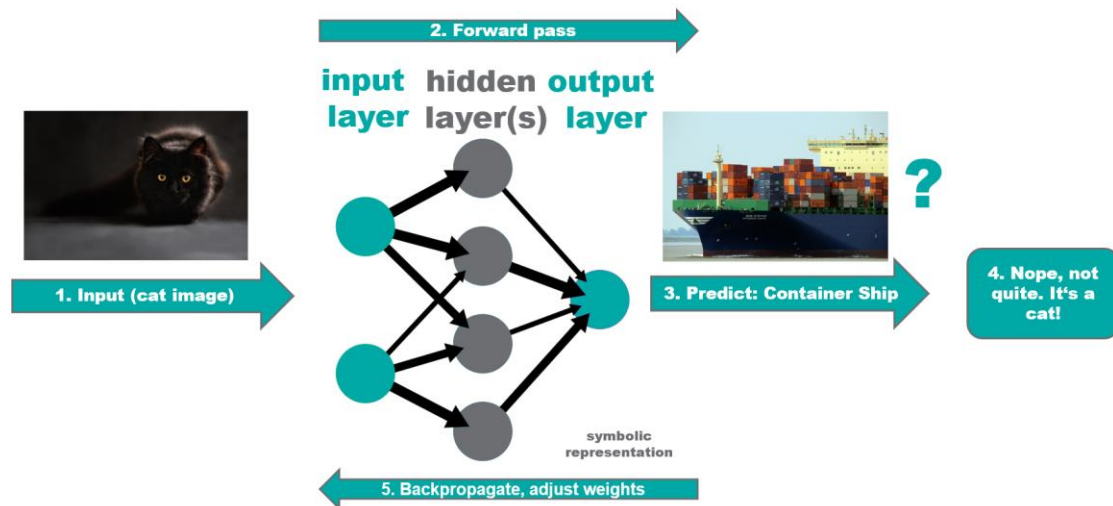


Abbildung 2 Bilderkennung durch maschinelles Lernen (© Andreas Windisch)

In dem Beispiel soll ein neuronales Netzwerk lernen, Gegenstände auf Photos zu erkennen. In der Darstellung sehen wir in der Mitte die schematische Darstellung eines neuronalen Netzwerkes. Dieses besteht aus einer Eingangsschicht (input layer), die die Bildinformationen aufnimmt. Für jedes Pixel des Bildes muss dafür ein Neuron, im Bild durch Kreise dargestellt, zur Verfügung stehen. In diesem Fall zeigen wir dem Netzwerk das Bild einer Katze. Diese Information wird an die Eingangsschicht angelegt und dann durch (Matrix) Multiplikationen und andere mathematischen Operationen auf die nachfolgenden Schichten (hidden layer(s)) übertragen. Am Ende, in der Ausgangsschicht (output layer), wird ein Label (Etikett) erzeugt, das idealerweise in diesem Fall ‚Katze‘ lauten sollte, da wir ja ein Bild einer Katze angelegt haben. In diesem Beispiel sagt das Netzwerk allerdings nicht, dass es eine Katze sieht, sondern es ist der Meinung auf dem Bild ein Containerschiff zu erkennen. Nachdem es sich hier um Supervised Learning handelt, teilen wir dem System nun aber mit, dass es sich in Wirklichkeit um eine Katze handelt. Die Zahlenwerte, mit denen wir die Bilddaten im Netzwerk bewertet haben, werden nun so angepasst, dass zukünftig die Antwort eher als ‚Katze‘ und weniger als ‚Containerschiff‘ gegeben wird.

Mit mehr und mehr Bildern, die wir dem System zeigen und ihm auch mitteilen was darauf zu sehen ist, lernt das System durch Anpassung der zur Bewertung herangezogenen Zahlen im Netzwerk (den sogenannten Gewichten) mit wachsender Erfahrung, die Gegenstände richtig einzuordnen.

Um Supervised Learning einzusetzen, benötigt man somit annotierte Trainingsdaten. Das sind Daten, die bereits mit der korrekten Antwort versehen sind.

Typische Anwendungsbeispiele von Supervised Learning sind Klassifikationsprobleme wie die Erkennung von Spam/Junk Email, Handschrift- oder Spracherkennung, sowie Regressionsprobleme wie die Preis-Absatzfunktion oder die Modellierung weiterer Zusammenhänge. Supervised Learning ist aber nicht nur auf Bilddaten oder auf das klassifizieren von Gegenständen beschränkt. Im Prinzip können mit dieser Methode sehr komplexe Zusammenhänge und Muster erkannt werden, die dem Menschen oftmals verborgen bleiben.

3. Reinforcement Learning

Die dritte Säule von Machine Learning ist ‚Reinforcement Learning‘, also bestärkendes Lernen. Hier werden Belohnungssysteme eingesetzt, um möglichst optimale Problemlösungen zu finden. Dabei trainiert man eine Entität (in der Fachsprache: „Agent“) darauf, eine bestimmte Aufgabe zu erlernen. Bei der Aufgabe kann es sich um alles Mögliche handeln, von Brettspielen bis zum aufrechten Gang eines humanoiden Roboters. Der Agent wird dazu in einer Umgebung (Environment) ausgesetzt, in der er Handlungen vornehmen kann.




Abbildung 3 Belohnungssystem bei Reinforcement Learning (Source Wikipedia, License: CC0)

Diese Handlungen können zum Beispiel das Ausführen gültiger Schachzüge sein, oder die Arme und Beine eines Roboters zu bewegen. Oder auch etwas völlig anderes, je nach Aufgabe und Problemstellung. Die Art und Weise wie dieses System nun lernt ist in dem obigen Bild dargestellt. Der Agent (dargestellt durch den Roboter) setzt Handlungen in der Umgebung und beobachtet dann (dargestellt durch das Auge im Bild), wie sich der beobachtete Zustand des Agenten (state) dadurch verändert. Diese Änderung kann zum Beispiel die veränderte Konstellation der Figuren am Schachbrett sein, oder eine neue Position des Roboters im dreidimensionalen Raum. Jede Aktion führt also zu einem messbaren neuen Status.

Je nachdem ob der aus der Handlung resultierende Zustand gut oder schlecht ist, bieten wir dem System eine Belohnung (Reward) an. Dieser fällt umso höher aus, je näher die gesetzte Handlung den Agenten ans Lernziel bringt (Schach matt, Roboter fällt nicht um, etc), kann aber ebenso gut negativ ausfallen.

Ein weiteres Beispiel für ein solches Szenario ist übrigens das aktuell heiß diskutierte autonome Fahren. Das Ziel der Fahrt kann vorab spezifiziert werden, über Sensorik wie Bild- und Tiefenkameras wird die Umgebung beobachtet und Handlungen wie Lenken oder das Betätigen von Gas- oder Bremspedal führen zu messbaren Veränderungen. Das Belohnungssystem fällt in diesem Szenario allerdings weit komplexer aus, als das noch bei unserem klassischen Brettspiel der Fall war.

Für Reinforcement Learning werden somit keine annotierten Trainingsdaten, also Daten, die bereits mit der korrekten Antwort versehen sind, benötigt. Mit diesem besonders mächtigen Ansatz kann ein unglaublich breites Spektrum an Problemen gelöst werden.

Dieser erste Überblick über das unglaublich spannende Thema des maschinellen Lernens zeigt klar: Die breite Anwendbarkeit des Zugangs, sowie die potentiell zu erreichenden Leistungen beim Lösen eines Problems, machen diese Technologie unverzichtbar um wettbewerbsfähig zu bleiben.

AI Safety / AI Ethics

Von Manuel Weichselbaum, KI Forscher, Physiker, TU Graz.

Da künstliche Intelligenz in vielen unserer Lebensbereiche immer häufiger anzutreffen ist, müssen wir diese Systeme auch auf ihre Sicherheit und Zuverlässigkeit testen. Für aktiv entscheidende Systeme wie z.B. selbstfahrende Autos sind viele moralische Fragen offen, die relevant für deren Anwendung sein werden. Wie können wir also sicherstellen, dass ein Algorithmus sich so verhalten wird, wie man es erwartet?

Ziel dieses Abschnittes ist es, das Thema einzuführen und ein Bewusstsein für die ethischen Schwierigkeiten im Umgang mit künstlicher Intelligenz zu erschaffen. Konkrete Lösungen dafür sind leider meist zu technisch oder unausgereift, um sie hier behandeln zu können. Es gibt zum Glück aber einen immer größer werdenden Anteil von Wissenschaftlern, die sich mit dem Thema Sicherheit von künstlicher Intelligenz beschäftigen.

Wie sicher ist das Ergebnis vorhersagbar?

Viele der früheren Automatisierungen hatten einen festen Ablauf und vorherbestimmte Aktionen, bei denen der Designentwurf bereits die Implementation aller Sicherheitsvorschriften sicherstellen konnte. Bei Systemen wie neuronalen Netzwerken, die in Bilderkennungssystemen in Autos und bei vielen digitalen Services mit großen Datenmengen wie Facebook, Google und Co. eingesetzt werden, ist es aber deutlich schwieriger, das Verhalten der künstlichen Intelligenz einschätzen zu können.

Trotz sorgfältiger Überprüfung bleibt die künstliche Intelligenz eine „black box“ – man kann nie mit Sicherheit wissen, was das System bei gegebenen Eingangs-Daten am Ausgang zurückgeben wird. Das kann schlimme Folgen haben, wenn möglicherweise von künstlicher Intelligenz immer mehr Menschenleben, Jobs oder sogar Wahlergebnisse abhängen.

Natürlich sind Menschen selbst auch eine „black box“ und keiner kennt die Motive, Gedanken oder zukünftigen Entscheidungen eines anderen Menschen genau. Doch künstliche Intelligenz ist eine Erfindung der Menschheit und wir haben die Möglichkeit, schon jetzt sicherzustellen, dass wir unsere Erfindung nicht eines Tages bereuen.

Wie soll optimiert werden?

Wie schon im Kapitel über starke vs. schwache künstliche Intelligenz beschrieben, ist die Fehlerfunktion unser größter Einfluss, den wir auf die Optimierungsalgorithmen haben. Wenn eine künstliche Intelligenz lernt, bekommt sie einen Datensatz und eine Fehlerfunktion, die es zu minimieren gilt. Wir haben nach erfolgreichem Lernen im Idealfall eine künstliche Intelligenz, die eben genau das Minimum des Fehlers auf diesen Datensatz

erreicht hat. Der Forschungsbereich Sicherheit und Ethik in künstlicher Intelligenz zielt darauf ab, dass Datensätze und Fehlerfunktionen richtig konstruiert und ausgewählt werden.

Dabei stellt es sich als äußerst schwierig heraus, sicherzustellen, dass menschliche Moralvorstellungen von der künstlichen Intelligenz berücksichtigt werden, bzw. zu verhindern, dass eine künstliche Intelligenz versucht, die Aufgabenstellung in einer Weise zu erfüllen, die nicht erwünscht ist. Dieses Problem ist bekannt als das "alignment problem".

Das Alignment Problem

Ein simples Beispiel ist eine künstliche Intelligenz, die bei der Aufgabe, bösartigen Krebs von gutartigen Krebs in Bildern zu unterscheiden, feststellte, dass in dem verwendeten Datensatz bei Bildern von bösartigem Krebs viel häufiger ein Maßstab eingeblendet wurde als bei Bildern von gutartigen Krebs. Diese künstliche Intelligenz begann zu "schummeln" und stellte ihre Diagnose großteils aufgrund der Anwesenheit eines Maßstabs aus, und erreichte somit gute Ergebnisse ohne jemals den Unterschied von Krebszellen zu erlernen.

Ein anderes Mal wurden Wölfe auf Bildern nicht aufgrund ihres Aussehens sondern Aufgrund von Schnee im Hintergrund erkannt. Das Problem entsteht dadurch, dass eine künstliche Intelligenz (noch) kein übergeordnetes Verständnis von Aufgabenstellungen wie Menschen hat und deshalb nicht weiß, dass sie die eigentliche Aufgabe verfehlt hat. Sie ist mit jeder Lösung mit niedrigem Wert der Fehlerfunktion zufrieden und hinterfragt diese nicht weiter.

Wenn es uns also nicht gelingt das "alignment problem" zu lösen und Fehlerfunktionen zu entwerfen, die eine künstliche Intelligenz zwingen, den Kontext und die moralischen Präferenzen von Menschen zu erlernen, sollten wir mit hoher Wahrscheinlichkeit Probleme erwarten.

Diskriminierung steckt schon in den Daten

Ein wichtiger ethischer Aspekt ist die Vermeidung von Diskriminierung beim Einsatz von künstlicher Intelligenz für soziale und berufliche Zwecke. Wenn ein Datensatz verwendet wird, der für eine gewisse Bevölkerungsgruppe wenig Daten beinhaltet oder wenn die Daten unvoreilhaft für diese Gruppe vorbelastet sind, wird die fertig trainierte künstliche Intelligenz dieselben diskriminierenden Muster erben, wie sie schon in den Daten enthalten waren.

Das tritt leider häufiger auf als man wahrnimmt. Diskriminierung ist immer noch ein großer Bestandteil unserer Gesellschaft und die Daten spiegeln das schamlos wider. Wir dürfen nicht erwarten, dass ein Algorithmus, der auf uns intelligent wirkt, automatisch auch moralisch gut ist. Die Daten bestimmen vollständig das Verhalten der künstlichen Intelligenz, es sein denn, man verändert absichtlich die Fehlerfunktion, um diskriminierendes Verhalten zu bestrafen.

Beim Einsatz von künstlicher Intelligenz im Umgang mit Entscheidungen, die das Leben von Menschen beeinflussen, sollte also aktiv überprüft werden, ob die Ergebnisse gerecht sind. Wenn Maschinen zukünftig z.B. bei der Vergabe von Krediten oder Arbeitsplätzen beratende oder bestimmende Rollen einnehmen sollten, wird diese Vorkehrung sicherlich bei der Abschaffung von sozialen Ungerechtigkeiten helfen.

Was ist wahr?

Seit der Mensch technologische Errungenschaften erlangt hat, wurden diese sowohl für Gutes als auch für Böses eingesetzt. Es wird immer realistischer, dass mit Hilfe von künstlicher Intelligenz Fälschungen von Videos, Bildern und andere Arten von Manipulationen wie „fake news“ in immer größeren Mengen mit immer weniger Aufwand produziert werden können. Es ist inzwischen möglich, echte Videos von Personen wie z.B. Ansprachen von Regierungsbeamten beinahe beliebig zu verändern und Text, Gesten und Gesichtszüge sehr glaubhaft auszutauschen. ¹⁰

Die sozialen Netzwerke tendieren im Moment dazu, bestimmte Inhalte so sehr auszubreiten, dass man z.B. von einem „viralen Video“ spricht, das binnen Tagen auf der ganzen Welt bekannt ist. Das Worst-Case-Szenario wären Fake News, die sich so weit verbreiten, dass sie gezielt großen Schaden anrichten können, selbst wenn nach kurzer Zeit die Öffentlichkeit auf die Falschheit der Information hingewiesen wird. Meist bleibt ein emotionaler Eindruck zurück, der die Meinung von Menschen nachhaltig beeinflusst und durch sachliche Information kaum wieder entfernt werden kann. Die Hoffnung bleibt, dass rechtzeitig Strategien entworfen werden, um sich gegen solche Attacken zu schützen und dass die Recherche von angeblichen Fakten so einfach und interessant gemacht wird wie der Konsum von Medien.

Mehr als nur Jobs ...

Künstliche Intelligenz wird voraussichtlich das Leben von einem Großteil der Weltbevölkerung spürbar beeinflussen. Am Offensichtlichsten ist die Veränderung von Jobs und wirtschaftlich relevanten Fähigkeiten, wie es schon öfter in Zeiten von industrieller Revolution geschehen ist. Diesmal wird aber nicht nur der physische, körperliche Teil des Menschen ersetzt bzw. erleichtert, sondern auch die mentalen, intellektuellen Fähigkeiten, die uns Menschen so einzigartig gemacht haben. Sicherzustellen, dass durch diese Technologie Krisen und soziale Ungerechtigkeit nicht überhandnehmen, ist eine Aufgabe, der wir uns unbedingt stellen sollten.

¹⁰ <https://www.ohadf.com/projects/text-based-editing/> , <https://arxiv.org/abs/1805.11714>

Fahrplan für den Einsatz im Unternehmen

So starten Sie in die Welt der KI

von Birgit & Uwe Mayer - www.mayermayer.at

Nachdem wir die ersten Begriffserläuterungen als Basis absolviert haben, wollen wir Sie einladen, sich einen einfachen Fahrplan für die Aufgabenstellung zurechtzulegen. Als Rahmen setzen wir uns das Streben, die Stärken von Mensch und Maschine zusammenzuführen. Wir sehen Daten als Rohstoff und werden sie in ihrer Menge strukturieren, um daraus eine Basis für eine intelligente Nutzung zu schaffen. Die aktuelle Chance, die es zu ergreifen gilt, ist die Optimierung der Wertschöpfungsketten.

Der Trend Radar und seine vier möglichen Nutzen¹¹

Der Trend Radar¹² bietet ganz grundsätzlich vier Quadranten an, in denen der Nutzen für das eigene Geschäftsmodell stecken kann:

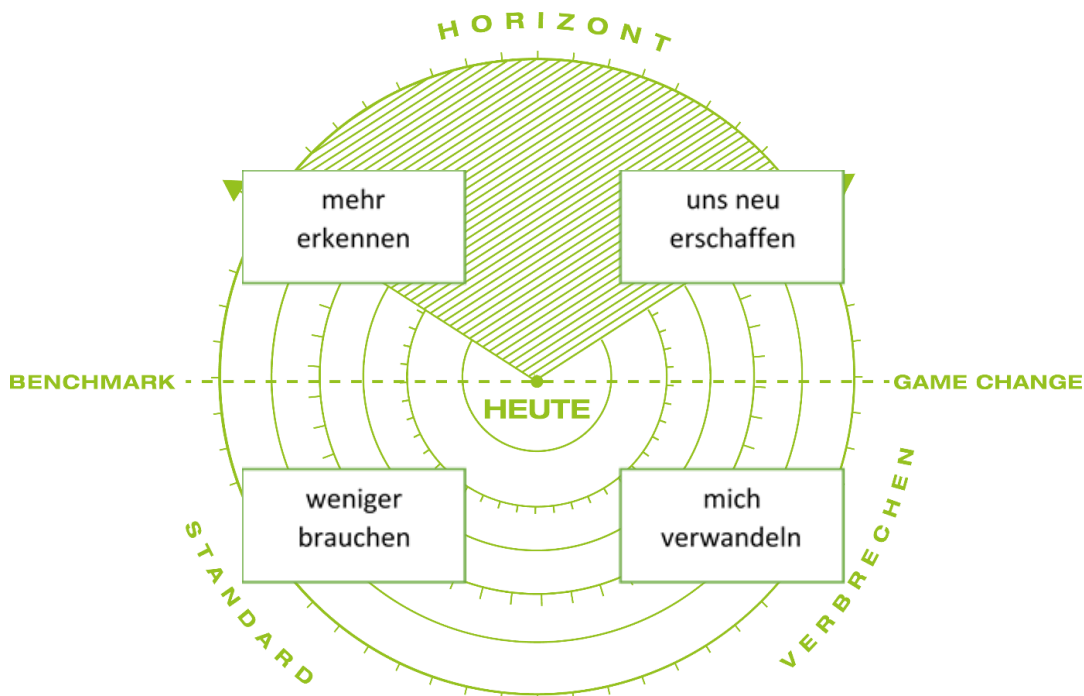


Abbildung 4 Trend Radar zeigt vier mögliche Nutzen der künstlichen Intelligenz

¹¹ Abgeleitet aus Diffusionstheorie von Everett Rogers.

¹² TrendRadar © mayermayer, Strategie.Schmiede

Nutzen 1: WENIGER BRAUCHEN!

KI kann Prozesse so unterstützen, dass weniger materielle oder menschliche Ressourcen benötigt werden. Zum Beispiel im First Level Support: Dieser Beitrag zur Einsparung von Ressourcen wird in vielen Zusammenhängen nicht als Chance, sondern als großes Risiko für die gesellschaftliche Ordnung gesehen.¹³

Nutzen 2: MEHR ERKENNEN!

KI kann aus gesammelten Daten Zusammenhänge aufzeigen und Muster erkennen. Zum Beispiel können menschliche Stimmen von Nebengeräuschen unterschieden und herausgefiltert werden: Als Nutzen können unerwünschte Ergebnisse aussortiert werden, erwünschte Ergebnisse werden forciert.¹⁴

Nutzen 3: MICH VERWANDELN!

KI kann für mich Aufgaben im Alltag erledigen. KI übersetzt zum Beispiel simultan in eine beliebige Sprache, bereitet umfangreiches Fachwissen meinem Wissensstand entsprechend auf oder unterbreitet mir Vorschläge anhand meiner Vorlieben (Stichwort Serendipity): Wenn der Nutzen von KI für mich persönlich bedeutet, dass ich von Lästigem befreit bin, stellt das eine Anforderung an mich – ich muss eine Idee davon haben, was ich mit dieser Freiheit anfangen will. Freier Zugang zu viel mehr Information kann auch den Anspruch erhöhen, etwas damit anzufangen.

Nutzen 4: UNS NEU ERSCHAFFEN!

KI kreiert einen völlig neuen Arbeitsraum. Der Wandel, den KI einleitet, fordert uns heraus, einen neuen Begriff von „Arbeit“ zu finden. Es gilt, dem menschlichen Tun einen neuen Sinn statt körperlicher Handhabung von Materie oder geistiger Verarbeitung von Information zu geben. Zum Beispiel lassen sich laut einer Studie der OECD (2018¹⁵) 46% der Wirtschaftsleistungen mit 50-70% Wahrscheinlichkeit automatisieren.

¹³ Schwierig ist in diesem Zusammenhang besonders der gesellschaftliche Reflex, in dem es um den Wettkampf geht: Darf die Maschine besser sein als der Mensch? Wir werden im 2. Kapitel detaillierter auf Aspekte dieser Diskussion eingehen.

¹⁴ Schnell berühren wir das Dilemma der Gerechtigkeit, Gleichbehandlung und damit ethischer Prinzipien.

¹⁵ <https://www.oecd.org/berlin/themen/zukunft-der-arbeit/>

Die Notwendigkeit des Erschaffens neuer Arbeitswelten beschränkt sich aber nicht nur auf herkömmliche Industrien. Ein guter Teil der datenbasierten Geschäftsmodelle sind ohne operatives menschliches Eingreifen denkbar.

Was ist also eine aktuelle Perspektive? Interaktion scheint aus heutiger Sicht (August 2019) ein Feld zu bleiben, in dem Menschen eine völlig andere Qualität erreichen als aktuell denkbare Algorithmen. Turing Tests lassen sich aus zwei Perspektiven interpretieren: Toll, es gibt Aufgaben, bei denen kein Unterschied wahrnehmbar ist. Oder toll, die Aufgaben, bei denen kein Unterschied wahrnehmbar ist, machen nur einen kleinen Prozentsatz meiner täglichen Interaktion aus.

Handlungsfähig bleiben heißt: einfach den nächsten Schritt setzen

Die vier Quadranten erscheinen jedem Leser sicherlich unterschiedlich nahe an der eigenen Arbeitsrealität und damit mehr oder weniger relevant. Und genau in der Alltagsrelevanz steckt die nächste Herausforderung: Welche Schritte setze ich heute? Und welchem Horizont sollen sie mich näherbringen?

Ordnung für verschiedene Funktionalitäten

Viele Begriffe rund um künstliche Intelligenz machen es uns nicht leichter, den Überblick zu behalten. Ein sehr gelungener Ordnungsversuch ist das Periodensystem der KI, entwickelt vom amerikanischen Informatiker Kristian Hammond ¹⁶. Er hat in Anlehnung an die Chemie den Versuch unternommen, eine Systematik für die Funktionalitäten der künstlichen Intelligenz zu konzipieren. Er bezeichnet sie als »Periodensystem der Künstlichen Intelligenz«. Eine umfangreiche deutsche Beschreibung davon hat die Bitkom ¹⁷, der Digitalverband Deutschlands veröffentlicht: <https://periodensystem-ki.de/>




Abbildung 5 Periodensystem der KI, Bitkom April 2019.¹⁸

¹⁶ <http://danielschristian.com/learning-ecosystems/2017/01/23/the-periodic-table-of-ai-hammond/>

¹⁷ <https://www.bitkom.org/>

¹⁸ Kontakt: Dr. Nabil Alsabah, Bereichsleiter Künstliche Intelligenz & Big-Data.AI Summit, Bitkom e.V. <https://www.linkedin.com/in/nabil-alsabah/>

Drei typische Verarbeitungsschritte in der Anwendung

Ein typischer Anwendungsfall für Künstliche Intelligenz gliedert sich in drei Verarbeitungsschritte:

1. **Situation einschätzen (assess, grüne Elemente links):** Daten werden erfasst, die eine bestimmte Situation beschreiben. Zum Beispiel die Verbrauchsdaten im bestehenden Fernwärmeleitsystem von Energie Graz ¹⁹.
2. **Optionen folgern (infer, gelbe & rote Elemente mittig):** Die Daten werden mit vergangenen Ereignissen und einem Zielzustand in einen Zusammenhang gebracht. Im Beispiel kann der Wärmebedarf bis zu sieben Tage im Voraus abgeschätzt werden – und zwar auf Stundenbasis.
3. **Handlung ableiten (respond, purpurne Elemente rechts):** Die beste Maßnahme wird durchgeführt. Dem Energieanbieter ermöglicht diese Prognose eine Optimierung seiner Fernwärmesysteme und -netze.

Mit diesem grundsätzlichen Verständnis der Basiselemente lassen sich die aktuellen technologischen Möglichkeiten auf die eigenen konkreten Geschäftsprozesse anwenden.

Zwei Einsteiger-Beispiele

Einfaches Beispiel zum Sprachverständnis der Alexa Skills

Die UBIT Steiermark ²⁰ hat einen ersten Versuch eines sprachgesteuerten Services 2018 mit einem Alexa Skill gestartet.

Ausgangspunkt war folgende Aufgabenstellung: Auf einer Messe soll ein Ansprechpunkt geschaffen werden, der statische Basisinformationen (FAQs wie zum Beispiel „Wo kann ich mein Gewerbe anmelden?“ oder „Wie kann ich meine Firmen A-Z Daten warten?“) unabhängig von der Besucherfrequenz bereitstellt.

Erreichbar ist der Alexa Skill über das Kommando „Alexa, öffne UBIT Steiermark.“ Es stehen rund 40 Fragen samt Antworten zur Verfügung. Die praktische Erfahrung im Einsatz zeigt, dass das Sprachverständnis sowohl akustisch als auch inhaltlich keine intuitive Bedienung unterstützt und deshalb als Start gilt, aber noch nicht als intelligent wahrgenommen werden kann.

¹⁹ GreenTech Magazin Juni 2017.

²⁰ www.ubit-stmk.at/alexa

Einfaches Beispiel zur Optimierung von Empfehlungen

Der Digi-Index der UBIT Steiermark behandelt die Herausforderung eines transparenten Matchings auf dem Markt der digitalen Dienstleistungen: Die Anbieterdaten stammen aus der vollständigen Mitgliederdatenbank in Form eines Firmen A-Z mit über 8.000 Einträgen (ständig wachsend). Die Nachfrage wird über einen Check des Digitalisierungs-Index strukturiert erfasst (Welches digitale Potential ist schon realisiert? Welches ist noch offen?). Das Ergebnis ist eine Liste von passenden Betrieben, die Leistungen in den Themenfeldern mit Potential anbieten.

In einem ersten Schritt werden definierte Fachgebiete (über 200) mit den fachlichen Problemfeldern verbunden und passende Profile als Suchergebnis ausgegeben. Geplant ist ein weiterer Ausbau in Richtung einer semantischen Suche.

<https://www.ubit-stmk.at/digi-index/>

Anhang

Fotoquelle. Pixabay. 2019

Das Autorenteam

Clemens Istel, Leftshift One.

<https://www.linkedin.com/in/clemens-istel-536213122/>

Manuel Weichselbaum, KI Forscher, Physiker, TU Graz.

<https://www.linkedin.com/in/manuel-weichselbaum-7baa88158/>

Andreas Windisch, Theoretischer Physiker, Silicon Austria Labs.

<https://www.linkedin.com/in/andreas-windisch-physics/>

Wolfgang Kienreich, Know-Center.

<https://www.linkedin.com/in/wolfgang-kienreich-8350b899/>

Oliver Pimas, Know-Center.

<https://www.linkedin.com/in/oliver-pimas-12a2888b/>

Birgit & Uwe Mayer, mayermayer Strategie.Schmiede.

<https://www.linkedin.com/in/mayeruwe/>