



HANDELS-, INDUSTRIE-, HANDWERKS-,  
TOURISMUS- UND LAND-  
WIRTSCHAFTSKAMMER BOZEN

PARTNER DER WIRTSCHAFT



# KÜNSTLICHE INTELLIGENZ VERSTEHEN UND NUTZEN

Eine Einführung  
zur Anwendung der  
Künstlichen Intelligenz

# KÜNSTLICHE INTELLIGENZ VERSTEHEN UND NUTZEN

Eine Einführung zur Anwendung der Künstlichen Intelligenz

## Herausgeber

Handelskammer Bozen  
PID – Digitales Unternehmen  
Südtiroler Straße 60  
I – 39100 Bozen  
Tel. +39 0471 945 691  
digital@handelskammer.bz.it  
www.handelskammer.bz.it

## Autoren

Univ.-Prof. Dr. Gerhard Friedrich  
Priv.-Doz. Dr. Erich Teppan

## Grafik

Werbeagentur Studio Creation Kg

1. Auflage, Juni 2022

© 2022 Handels-, Industrie-, Handwerks-,  
Tourismus- und Landwirtschaftskammer Bozen

Dieser Leitfaden wendet sich gleichermaßen an Unternehmerinnen  
als auch an Unternehmer bzw. Mitarbeiterinnen und Mitarbeiter.

Der besseren Lesbarkeit wegen wurde auf die Angabe beider Formen verzichtet.

Nachdrucke und sonstige Verbreitung – auch auszugsweise – sind nur unter Angabe der Quelle gestattet.

Quelle: „G. Friedrich & E. Teppan. Künstliche Intelligenz verstehen und nutzen – Eine Einführung  
zur Anwendung der Künstlichen Intelligenz. Handels-, Industrie-, Handwerks-, Tourismus- und  
Landwirtschaftskammer Bozen. 2022.“

# INHALT

<b>1 Künstliche Intelligenz: Grundprinzipien verstehen, Chancen erkennen, Erfolge realisieren</b>	<b>4</b>
<b>2 Was versteht man unter Künstlicher Intelligenz?</b>	<b>8</b>
2.1 Zielsetzungen und geschichtliche Einordnung	9
2.2 Der Werkzeugkasten der Künstlichen Intelligenz	11
<b>3 Modellieren und Lösen</b>	<b>12</b>
<b>4 Maschinelles Lernen</b>	<b>16</b>
4.1 Überwachtes Maschinelles Lernen	17
4.1.1 Klassifikation	17
4.1.2 Regression	19
4.1.3 Zeitreihenanalyse	20
4.1.4 Deep Learning und Neuronale Netze	21
4.2 Unüberwachtes Maschinelles Lernen	23
4.2.1 Clusteranalyse	23
4.2.2 Data Mining	24
<b>5 Wie kann ich ein erfolgversprechendes KI-Projekt erkennen und in meinem Unternehmen umsetzen?</b>	<b>26</b>
5.1 Wie kann ich ein aussichtsreiches KI-Projekt erkennen?	27
5.2 Betriebliche Einsatzgebiete	28
5.2.1 Einkauf und Logistik	29
5.2.2 Produktion	30
5.2.3 Marketing	31
5.2.4 Personal- und/oder Kundenmanagement	32
5.3 Technische Herausforderungen	33
<b>6 Anwendung von KI-Methoden auf Basis von Modellieren und Lösen</b>	<b>36</b>
6.1 Voraussetzungen für eine Anwendung	37
6.2 Stärken	38
6.3 Schwächen	38
6.4 Risikodämpfung	38
6.5 Kostentreibende bzw. -senkende Faktoren	39
6.6 Hausaufgaben des Unternehmens zur Vorbereitung der technischen Analyse	40
<b>7 Anwendung von KI-Methoden auf Basis des Maschinellen Lernens</b>	<b>41</b>
7.1 Voraussetzungen für eine Anwendung	42
7.2 Stärken	43
7.3 Schwächen	44
7.4 Risikodämpfung	44
7.5 Kostentreibende bzw. -senkende Faktoren	45
7.6 Hausaufgaben des Unternehmens zur Vorbereitung der technischen Analyse	46
<b>8 Managementaufgaben für eine erfolgreiche Einführung von KI-Methoden</b>	<b>47</b>
8.1 Organisatorische Rahmenbedingungen	48
8.2 Weitere Schritte	48
<b>9 Resümee</b>	<b>50</b>

# 1

## **Künstliche Intelligenz: Grundprinzipien verstehen, Chancen erkennen, Erfolge realisieren**

Weltweit sind sich viele Unternehmer/innen, Wissenschaftler/innen und Politiker/innen einig: die Künstliche Intelligenz (KI) wird unsere Welt signifikant verändern. Volkswirtschaften und Unternehmen investieren astronomische Summen, um einen Wettbewerbsvorteil zu erlangen. Man schätzt, dass China rund 150 Milliarden Euro in KI stecken wird. Deutschland plant KI mit drei Milliarden Euro zu unterstützen, und Bayern wird mit rund 600 Millionen Euro ein KI und SuperTech-Programm<sup>1</sup> fördern. Die *Association for Computing Machinery*<sup>2</sup> meldet häufig Erfolgsmeldungen hinsichtlich der Anwendung und Weiterentwicklung von KI.

Die Künstliche Intelligenz wird verwendet, um bestehende Prozesse hinsichtlich Produktivität, Qualität und Durchlaufzeiten zu verbessern sowie die Flexibilität zu erhöhen. Kostenreduktionen und Beschleunigungen der Prozesse um 80 % und mehr sind erzielbar. Neben der signifikanten Verbesserung von bestehenden Prozessen wird KI aber auch dazu verwendet, um neue Produkte und Dienstleistungen anzubieten. KI ermöglicht es, Prozesse, Produkte und Dienstleistungen neu zu denken. Einige klassische Vorzeiganwendungen sind:

- automatische Erkennung von Objekten in einer Qualität, die bisher nicht möglich war, z.B. um Fehler in der Produktion zu erkennen,
- vorbeugende Wartung von Produkten oder Maschinen auf Basis von umfangreichen Datenbeständen, um neue Servicedienstleistungen für Kunden anbieten zu können,
- kundenspezifische Empfehlungen von Produkten und Dienstleistungen, die das Onlinemarketing durch personalisierte Werbung revolutioniert haben,
- automatisierte Planung von Produkten und Produktionsprozessen, um die Qualität und die Produktivität signifikant zu erhöhen,
- Flexibilisierung des Produktdesigns und der Produktion um Mass Customization (Losgröße 1 zu Kosten der Massenfertigung) zu realisieren.

Diese Aufzählungen lassen sich fast beliebig lange fortsetzen. Im Grunde geht es für die meisten Unternehmen nicht mehr darum, ob sie KI einsetzen werden, sondern wo und wann sie diese Technologie einsetzen müssen, um wettbewerbsfähig zu bleiben. Die zahlreichen Fallbeispiele von erfolgreichen KI-Projekten zeigen, dass sie in vielen unterschiedlichen Bereichen eines Unternehmens einsetzbar ist. In welchen Bereichen soll man aber KI im Unternehmen nutzen bzw. deren Ausbau verstärken?

Aufgrund der Vielfalt an Anwendungsmöglichkeiten muss man sehr effizient und effektiv die wertvollsten KI-Projekte erkennen. Für die Identifikation der aussichtsreichen KI-Anwendungen ist die Beantwortung von zwei Kernfragen wesentlich:

Welche unternehmerisch wichtigen Aufgaben bieten sich an, auf Basis der aktuell zur Verfügung stehenden KI-Technologie gelöst zu werden?

Wie schwierig (d.h. wie kostenintensiv und wie risikobehaftet) ist die Lösung dieser Aufgaben mit KI?

Die Beantwortung dieser Fragen liefert eine grobe Klassifikation der Handlungsoptionen und zeigt, wo ein KI-Einsatz vorbereitet werden sollte, d.h. wo es sich lohnt, in die Erarbeitung einer möglichst sicheren Abschätzung des Kosten-Nutzen-Verhältnisses und des Realisierungszeitplans zu investieren.

<sup>1</sup> <https://www.bayern.de/hightech-agenda-bayern>

<sup>2</sup> <https://technews.acm.org>. Die *Association for Computing Machinery* ist die bedeutendste internationale Informatikvereinigung.

Für eine effiziente und auch qualitativ hochwertige Beantwortung dieser Fragen und letztlich der richtigen Auswahl der wertvollen KI-Projekte stecken viele Betriebe in einem Kompetenzdilemma:

- ▶ Betriebliche Expert/innen, die die konkrete Unternehmenspraxis hervorragend kennen, aber kein KI-Wissen besitzen, können die Möglichkeiten der Künstlichen Intelligenz schwer einschätzen. Die Bandbreite der Falscheinschätzung ist sehr groß und reicht von Überschätzung der KI als universelles Werkzeug, das alle schwierigen Probleme mühelos löst, bis hin zur grundsätzlichen Ablehnung.
- ▶ Umgekehrt kennen KI-Expert/innen zwar auf einer allgemeinen Ebene die Einsatzgebiete von KI, aber Erfolg oder Misserfolg von Anwendungen sind signifikant von der konkreten betrieblichen Praxis und dem betrieblichen Umfeld abhängig. Insbesondere benötigt man sehr tiefes Wissen über einen Betrieb, dessen Kunden und den Markt, um erfolgreiche innovative Produkte und Dienstleistungen zu kreieren. Aber genau diese neuen Produkte und Dienstleistungen haben sehr hohes Potential für ein Unternehmen.

Um nun das Potential von KI für Unternehmen möglichst gut zu nutzen, werden Personen benötigt, die sowohl fundiertes Wissen über den Betrieb als auch ein grobes Grundverständnis über KI besitzen. So können die „Diamanten“ der KI-Anwendung im Unternehmen erkannt werden. Ziel dieses Leitfadens ist es, Menschen an unterschiedlichsten Positionen in einem Unternehmen zu befähigen, erste Schritte zu einer groben Einschätzung der Anwendungsmöglichkeiten von KI in ihrem Unternehmen zu setzen. Wie kann das erreicht werden?

Ein weit verbreiteter Ansatz, um betrieblichen Expert/innen die Möglichkeiten von KI näher zu bringen, ist die Präsentation von erfolgreichen Fallbeispielen. Dieser Ansatz liefert gute Hinweise für eine konkrete Lösung einer Aufgabe durch KI. Das kann durchaus inspirierend für die Identifikation von KI-Projekten im eigenem Umfeld sein, betrachtet aber KI als Blackbox und hat einige wesentliche Einschränkungen und Fallstricke:

- ▶ Die Künstliche Intelligenz wird in vielen unterschiedlichen Branchen verwendet. Die Bandbreite ist denkbar groß und reicht von Handel über Metall- und Holzverarbeitung sowie Transport bis hin zur Produktion von Nahrungsmitteln, um nur einige Branchen zu nennen. Innerhalb einer Branche gibt es wiederum sehr spezielle Anwendungen von KI entlang der Wertschöpfungskette. Wir sehen Anwendungen abhängig von der Branche in den Bereichen Beschaffung, Logistik, Produktion, Vertrieb, Marketing und Personalwesen. Eine Präsentation von Fallbeispielen kann daher nur eine äußerst lückenhafte Darstellung des Potentials der KI sein. Darüberhinaus sind Unternehmen, selbst wenn sie in der selben Branche tätig sind, oft höchst unterschiedlich. Folglich sind erfolgreiche Anwendungsbeispiele von KI ein Anhaltspunkt, um aussichtsreiche Anwendungen zu identifizieren, aber man kann diese Fallbeispiele nur mit KI-Know-how auf die Bedürfnisse des eigenen Unternehmens umlegen. Unternehmen brauchen daher ein allgemeines Verständnis von KI.
- ▶ Erfolgreiche Fallbeispiele berichten in der Regel sehr allgemein über die Anwendung von KI und heben ihre Stärken hervor. Über die Schwächen in der Anwendung von KI-Methoden, die Herausforderungen, die zu meistern sind, und die Voraussetzungen, die notwendig sind, wird in der Regel nicht (oder nur sehr eingeschränkt) berichtet. Dies führt dazu, dass die Möglichkeiten der Technologie insbesondere von KI-Laien unrealistisch eingeschätzt bzw. die notwendigen Voraussetzungen für ihren Einsatz nicht erkannt werden. Auch wenn zum Beispiel Google es schafft, den „GO“-Weltmeister<sup>3</sup> auf Basis von KI zu schlagen, dann ist dies den massiven Ressourcen an Rechenleistung von Google geschuldet. Somit stellt sich die Frage, welche Methoden realistischerweise für ein konkretes Unternehmen mit eingeschränkten Ressourcen eingesetzt werden können. Erst wenn man ein grobes Wissen über die Stärken und Schwächen von KI-Ansätzen besitzt, kann eine realistische Einschätzung der Möglichkeiten von KI getroffen und somit die KI-Diamanten eines spezifischen Unternehmens identifiziert werden.

<sup>3</sup> „GO“ ist ein Brettspiel für zwei Spieler, das als eines der komplexesten Strategiespiele gilt.

Fallbeispiele für bestimmte Anwendungen ohne Wissen über die Methoden erlauben keine Generalisierung, die aber notwendig ist, um das Potential von KI für andere Anwendungsbereiche zu erkennen. Durch die Betrachtung von Fallbeispielen wirft man einen Blick in die Vergangenheit. Ohne Wissen über die Künstliche Intelligenz und nur gestützt auf Fallbeispiele wird man bestenfalls Ähnliches realisieren können, was andere Unternehmen schon längere Zeit erfolgreich einsetzen. Das Wissen über die KI-Technologien ermöglicht einen Blick in die Zukunft. Erst wenn man dieses Wissen besitzt, können unternehmensspezifische Chancen erkannt und neue Produkte und Dienstleistungen auf Basis von KI angeboten werden, welche die Konkurrenz noch nicht besitzt.

Um Personen in den Unternehmen zu befähigen, die wertvollen KI-Projekte zu erkennen, braucht es ein grobes Verständnis der wichtigsten Methoden. Daher müssen wir in einem praxisorientierten Leitfaden auch über diese schreiben. Wir möchten die Erklärung der wichtigsten KI-Methoden, in Anlehnung an ein berühmtes Einstein-Zitat, so einfach wie nur möglich, aber nicht einfacher gestalten. Ein mathematisches Verständnis auf dem Niveau der Oberschule sollte ausreichend sein. Folglich richtet sich der Leitfaden insbesondere an jene Personen, die die wertvollen KI-Projekte im Unternehmen erkennen möchten und auch die notwendige Neugierde besitzen, hinter die Fassade dieser Methoden zu blicken. Dies wird die Sicht auf KI nachhaltig schärfen. Diese Schärfung ermöglicht eine Präzisierung der Planungsarbeiten für einen Einstieg. Dadurch können Investitionen gesichert und Ressourcen zielgerichtet verwendet werden.

Wir beginnen in Kapitel 2 mit den Zielen und einer Standortbestimmung der KI sowie einer groben Einteilung der Werkzeuge. Daraus kann man erkennen, dass die KI-Methoden grundsätzlich in nur zwei Teilbereiche gegliedert werden können. Dies hilft, die Technologie einfach und klar zu strukturieren und zu „entmystifizieren“. KI kann als Sammlung von Software-Werkzeugen begriffen werden, die wie alle Software-Werkzeuge Stärken, Schwächen und Anwendungsvoraussetzungen besitzen.

Wer versteht, wie diese Methoden grundsätzlich funktionieren, hat bereits den ersten wichtigen Schritt gesetzt, um die wertvollen KI-Projekte im Betrieb zu erkennen. Wir werden die Einführung in diese Methoden im Kapitel 3 und 4 durch einfache Praxisbeispiele möglichst simpel gestalten.

Durch die Einführung in die zwei wichtigsten KI-Methoden sind die Voraussetzungen für Kapitel 5 geschaffen, dessen Inhalt das Erkennen und Umsetzen von wertvollen KI-Projekten ist. Wertvolle KI-Projekte erzeugen einen hohen betrieblichen Nutzen und die technischen Herausforderungen sind mit vertretbarem Aufwand bewältigbar. Der betriebliche Nutzen und die technische Herausforderung sind daher zentrale Kriterien zur Identifikation der wertvollen KI-Projekte.

Für die Beurteilung des betrieblichen Nutzens stellen wir in Kapitel 5.2 typische Einsatzgebiete von KI vor, um so die Inspiration und Kreativität bezüglich möglicher Anwendungen zu fördern. Die Einführung in die KI-Methoden erlaubt nun zu erkennen, auf welcher Basis diese Anwendungen realisiert wurden und welche Voraussetzungen folglich notwendig waren.

Für die Beurteilung der technischen Herausforderung geben wir in Kapitel 5.3 die wichtigsten Kriterien an. Diese Kriterien bilden den Kern unserer detaillierten Checklisten und Leitfäden für die Anwendung von KI.

In den Kapiteln 6 und 7 erarbeiten wir diese Checklisten und Leitfäden für den Einsatz der zwei wichtigsten Methoden der KI. Die geleistete Vorarbeit in ein grundlegendes Verständnis dieser KI-Methoden erlaubt jetzt, die Stärken und Schwächen dieser Ansätze zu erkennen. Darüber hinaus wird auch klar, welche Maßnahmen zur Risiko- und Kostendämpfung ergriffen werden können und welche Vorbereitungen zu treffen sind, sodass der Erfolg von KI-Anwendungen erreicht wird.

Eine Beschreibung der organisatorischen Rahmenbedingungen sowie der weiteren Schritte in der Umsetzung von KI-Projekten bilden den Abschluss des Leitfadens.

# 2

## Was versteht man unter Künstlicher Intelligenz?

Was Sie aus dem Kapitel mitnehmen:

- Eine Begriffsbestimmung
- Einen Überblick über die derzeit wichtigsten Methoden der KI



## 2.1 Zielsetzungen und geschichtliche Einordnung

Eine klare Definition, was Künstliche Intelligenz (KI) ist, gibt es nicht. Dies liegt nicht zuletzt daran, dass schon der Begriff *Intelligenz* sich einer klaren Definition entzieht. Was es jedoch sehr wohl gibt, ist ein allgemeines Begriffsverständnis, welches sich über die Zeit verändert bzw. erweitert hat.

Der Wunsch, denkende Maschinen zu bauen, wurde schon lange vor dem Computerzeitalter dokumentiert. Ein Beispiel dafür ist der *Schachtürke* des 18. Jahrhunderts (siehe Abbildung 1). Der Schachtürke war ein mechanisches Gerät, welches scheinbar selbstständig in der Lage war, Schach zu spielen, also die Illusion eines Schachroboters erweckte. Der Trick bestand darin, dass sich ein kleiner Mensch in der Maschine versteckt hielt, der über Hebel und dergleichen den Schachtürken bediente. Klarerweise stellte dies in keiner Weise eine KI dar, und auch der Begriff der KI existierte damals noch nicht.




Abbildung 1: Schachtürke, Bild von <https://de.wikipedia.org/wiki/Schachtürke>

Der Begriff der Künstlichen Intelligenz (engl.: *artificial intelligence (AI)*) etablierte sich Mitte des letzten Jahrhunderts in den Computerwissenschaften und geht auf die Informatikpioniere John McCarthy, Marvin Minsky, Nathan Rochester und Claude Shannon zurück. Zu dieser Zeit herrschte in der relativ jungen Wissenschaftsdisziplin Aufbruchstimmung und vieles schien sehr bald erreichbar zu sein. Das Ziel war, Computer und Algorithmen zu bauen, welche ähnlich wie Menschen denken oder im besten Fall diese sogar übertreffen. Dieses Ziel wurde mit dem Begriff **starke KI** assoziiert, d.h. die Technologie soll die kognitiven Fähigkeiten des Menschen umfassend nachbilden und sogar überbieten. Starke KI wird oft auch mit **genereller KI** gleichgesetzt. Als Paradebeispiel für starke (bzw. generelle) Künstliche Intelligenz kann hier jeder humanoide Android oder Roboter des Science-Fiction Genres dienen.

Es stellte sich bald heraus, dass die starke KI sehr schwer realisierbar ist. Deshalb konzentrierte sich die Wissenschaft hauptsächlich darauf, automatisiert Aufgaben zu lösen, für welche normalerweise höhere kognitive Fähigkeiten von Mensch oder Tier erforderlich sind. Dieses Ziel, problemspezifisch-intelligentes Lösungsverhalten zu simulieren, wird mit dem Begriff **schwache KI** benannt.

Im Standardwerk *Artificial Intelligence: A Modern Approach (Fourth Edition, 2021)* von Stuart J. Russell und Peter Norvig wird noch etwas feiner in mögliche Zielsetzungen der KI unterschieden:

- menschliches Denken (gleichzusetzen mit starker KI)
- menschliches Handeln bzw. Problemlösen
- rationales Denken
- rationales Handeln bzw. Problemlösen (gleichzusetzen mit schwacher KI)

Beginnend mit dem Begriff des menschlichen Denkens, welcher offensichtlich mit starker KI gleichzusetzen ist, stellt sich die Frage, wie wir Menschen überhaupt denken. Dies ist in der Wissenschaft bei weitem nicht geklärt. Sowohl was *menschlich* ist, als auch wie im Allgemeinen der Prozess des Denkens gemessen werden soll, ist nicht geklärt. Im Gegensatz zum Denken kann das Handeln eines intelligenten Agenten bzw. die produzierte Lösung sehr wohl gemessen und bewertet werden. Da sich *menschlich* zwecks unzureichender Definition nicht als allgemeines Bewertungskriterium für das Handeln bzw. Problemlösen eignet, stellt sich

die Frage, was als oberste Zielsetzung eines künstlichen intelligenten Systems dienen kann. Ein Konzept, welches in verschiedenen mathematischen Theorien klar definiert ist, ist jenes der *Rationalität*, welches man mitunter in der Wahrscheinlichkeitstheorie, Entscheidungstheorie oder Spieltheorie findet. Salopp formuliert, ist es rational, korrekte Lösungen zu produzieren. Es ist rational, optimale Lösungen oder Entscheidungen im Sinne eines Optimierungskriteriums zu produzieren, und es ist rational, die Wahrscheinlichkeit eines Gewinns bzw. Erfolgs zu maximieren bzw. die Wahrscheinlichkeit für Fehler zu minimieren.

Heutige KI-Systeme sind der schwachen KI zuzuordnen. Die Vision einer starken Künstlichen Intelligenz bleibt dabei weiterhin bestehen. Es ist jedoch zum aktuellen Zeitpunkt nicht klar, ob bzw. wann eine solche realisierbar sein wird.

## 2.2 Der Werkzeugkasten der Künstlichen Intelligenz

Grundsätzlich kann man in der (schwachen) KI zwei Strömungen unterscheiden (siehe Abbildung 2)<sup>4</sup>:

- die **klassische KI / Modellieren und Lösen** (manchmal auch *symbolische KI* genannt), die ein Lösen von Problemen auf Basis von Modellen, Regeln oder sonstigen Spezifikationen zum Inhalt hat, und
- das **Maschinelle Lernen** (manchmal auch *subsymbolische KI* genannt), das ein Lösen von Problemen auf Basis von beobachteten Datensätzen anstrebt.

Die oft verwendete Einteilung in symbolische vs. subsymbolische KI ist den verwendeten Methoden geschuldet. In der klassischen KI werden üblicherweise Symbole verwendet, die der Begriffswelt der Menschen entnommen sind. Im Maschinellen Lernen werden zurzeit Methoden breit angewendet, die Zusammenhänge in tausenden (numerischen) Parametern kodieren und die aktuell in den meisten Fällen keine für den Menschen verständliche Interpretation zulassen. Zur Vollständigkeit muss erwähnt werden, dass auch Methoden des Maschinellen Lernens entwickelt wurden, die auch für den Menschen interpretierbare Symbole verwenden. In den folgenden zwei Kapiteln werden ein paar Methoden im Bereich Modellieren und Lösen (MO&L) und im Bereich des Maschinellen Lernens (ML) eingeführt.

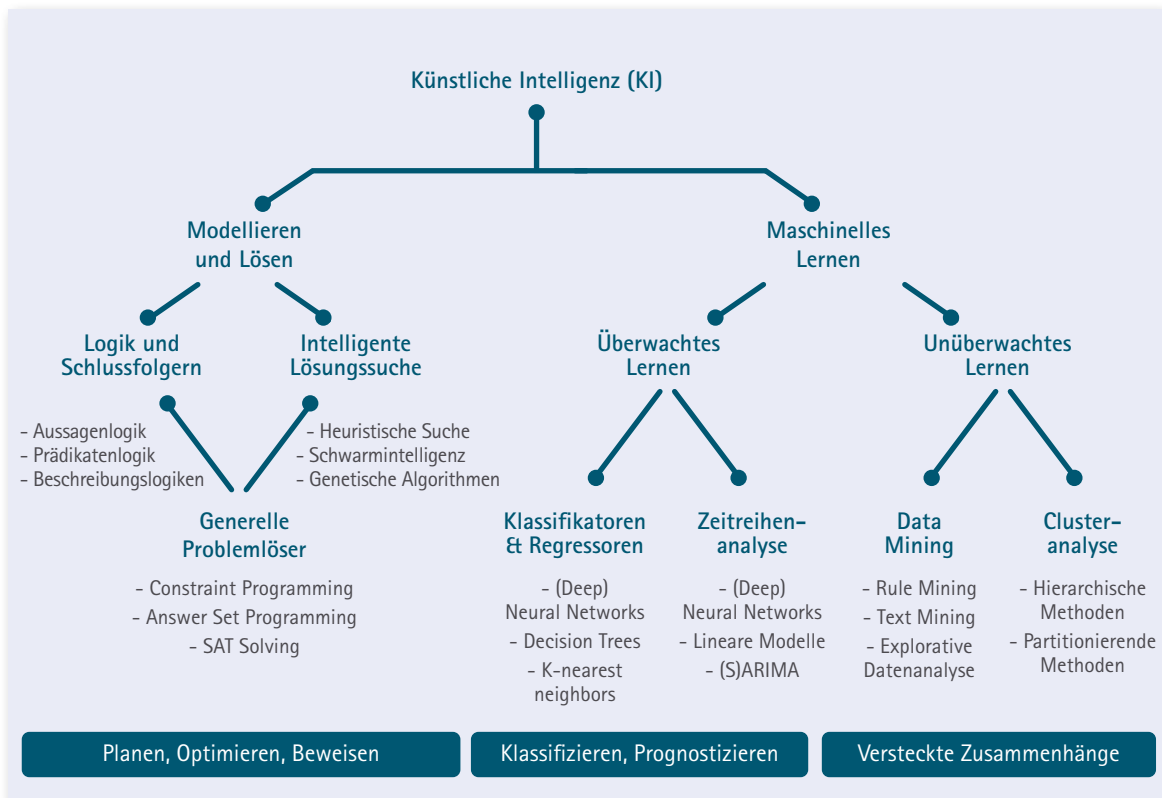


Abbildung 2: Methoden der Künstlichen Intelligenz

<sup>4</sup> An dieser Stelle sei erwähnt, dass es keine allgemein akzeptierte Einteilung der KI-Methoden gibt und dies in akademischen Kreisen teilweise kontrovers diskutiert wird. Die in diesem Kapitel vorgestellte Einteilung zielt auf Praxistauglichkeit und Verständlichkeit ab. Einige eher akademische Aspekte werden hier bewusst vernachlässigt.

# 3

## Modellieren und Lösen

Was Sie aus dem Kapitel mitnehmen:

- Sie lernen einige Methoden im Bereich Modellieren und Lösen im Detail kennen

Die zentrale Komponente jeder modellbasierten Methode ist eine Beschreibung eines Teiles der Anwendungsdomäne bzw. Welt (z.B. Verkehrsnetz, Schachregeln und Spielzustände, Beschreibungen der Funktionsweise von Produktionsmaschinen und deren mögliche Zustände, etc.). Diese Komponente wird oft *Modell*, *Spezifikation* oder *Wissensbasis* genannt. Je nachdem, in welcher Form ein solches Modell formuliert wird, können verschiedene Richtungen der klassischen KI unterschieden werden.

Einer der ältesten Zweige der (klassischen) KI findet seine Anfänge im antiken Griechenland, als Philosophen begannen, den Prozess des Denkens mittels logischer Fakten und Regeln zu modellieren. Bei dieser Methode besteht das Modell (also die Beschreibung der relevanten Aspekte einer Anwendungsdomäne bzw. Weltausschnitt) aus einer Menge von logischen Fakten und Regeln. Die zweite wichtige Komponente sind eine oder mehrere Schlussregeln, welche es ermöglichen, auf Grundlage des Modells neues Wissen zu erschließen, z.B. neue Fakten abzuleiten.

### Beispiel:

Eine sehr bekannte Schlussregel ist der *Modus Ponens*: Wenn ich weiß, dass immer wenn es regnet, der Rasen nass ist, und ich des Weiteren weiß, dass es jetzt gerade regnet, dann kann ich logisch daraus ableiten, dass der Rasen nass ist. Aus einem bekannten Faktum (*regnet*) und einer bekannten Regel (*regnet --> nass*), also dem Modell, kann mittels der Schlussregel ein weiteres Faktum (*nass*) abgeleitet werden. Diese und ähnliche Schlussregeln in verallgemeinerter Form bilden den Kern für alle KI-Systeme, welche auf klassischer Aussagenlogik, Prädikatenlogik oder moderner Beschreibungslogik basieren.

Ein weiterer wichtiger Teilbereich der klassischen KI befasst sich mit der systematischen Suche nach Zielzuständen bzw. Lösungen. Das Modell (also die Beschreibung der Anwendungsdomäne bzw. Welt) beschreibt dabei mögliche Zustände, Aktionen und daraus resultierende Zustandsänderungen<sup>5</sup>.

### Beispiel:

Nehmen wir als Beispiel die Wegeoptimierung bei Löt-Robotern, welche automatisiert auf einer Lochrasterplatte Lötstellen herstellen (siehe Abbildung 3). Die Reihenfolge, in welcher die Lötstellen abgearbeitet werden, hat einen signifikanten Einfluss darauf, wie schnell eine Platine fertig gelötet ist. Wenn sehr viele Platinen mit dem selben Lötmuster zu bearbeiten sind, stellt sich die Herausforderung der Berechnung einer möglichst optimalen Reihenfolge der Lötstellen. Dieses mathematische Optimierungsproblem ist bekannt unter dem Namen Briefträgerproblem oder auch Problem des Handlungsreisenden. Ziel ist eine möglichst schnelle (bzw. kostenoptimale) Rundreise, welche alle gegebenen Punkte genau einmal besucht und zum Schluss zum Ausgangspunkt zurückkehrt.

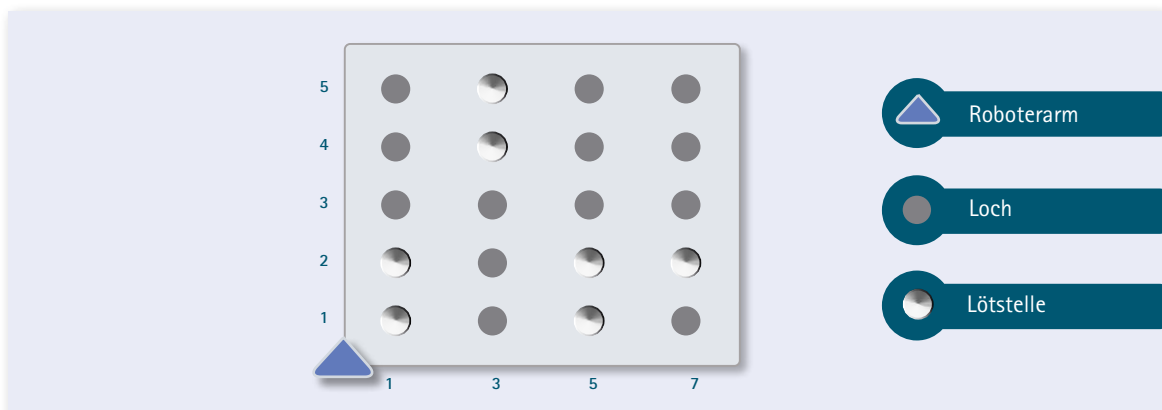


Abbildung 3: Wegeoptimierung für Löt-Roboter

<sup>5</sup> Allgemeiner betrachtet sind dies Punkte/Positionen in einem multi-dimensionalen Suchraum. D.h. Position=Zustand und Suchraum=Menge aller möglichen/relevanten Zustände.

In unserem Beispiel (siehe Abbildung 3) setzen wir voraus, dass zum (automatischen) Einspannen und Entfernen einer Platine der Roboterarm in Stellung [0,0] sein muss. Weiters nehmen wir an, dass die horizontalen Abstände zwischen zwei Löchern bzw. Lötstellen doppelt so groß sind wie die vertikalen Abstände zwischen zwei Löchern. Darüber hinaus nehmen wir an, dass die Bewegung in horizontaler und vertikaler Richtung gleichzeitig passieren kann. Folglich benötigt eine Bewegung des Roboterarms von der Ursprungsposition [horizontal=0,vertikal=0] zur Position [1,1] genau eine Zeiteinheit. Die Bewegung von [1,1] zu Position [3,2] würde zwei Zeiteinheiten benötigen da der horizontale Abstand zwei wäre und der vertikale nur eins. Im gegebenen Beispiel gibt es sieben Lötstellen ([1,1], [1,2], [3,4], [3,5], [5,1], [5,2], [7,2]). Somit gibt es schon bei diesem sehr kleinen Beispiel  $7 * 6 * 5 * 4 * 3 * 2 * 1 = 5040$  verschiedene Reihenfolgen. In der Praxis sind solche Probleme um ein Vielfaches größer, sodass das blinde Durchprobieren aller Möglichkeiten in der Praxis nicht zielführend ist.

Intelligente Suchmethoden lösen dieses Problem, indem sie die vielversprechenden Möglichkeiten zuerst untersuchen. Der Suchalgorithmus der gierigen Bestensuche (engl. *Greedy-Best-First-Search*) realisiert dies, indem schrittweise ein Suchbaum so aufgebaut wird, dass Baumerweiterungen zuerst dort passieren, wo es am aussichtsreichsten scheint. In unserem Beispiel könnte man immer die aktuell nächste Lötstelle zuerst anfahren. Ein möglicher (Teil-)Suchbaum wird in Abbildung 4 gezeigt: Nach dem Start bei [0,0] gibt es sieben Möglichkeiten. Die nächste Lötstelle ist bei [1,1]. Von [1,1] ausgehend gibt es nun sechs Möglichkeiten, den Pfad zu erweitern. Die mit dem geringsten Abstand ist [1,2]. Unter den danach fünf unbesuchten Lötstellen wäre [3,4] die nächste und so weiter. Unten am Baum angekommen, d.h. wenn der Pfad vollendet ist und alle Lötstellen besucht worden sind, hat man eine erste Lösung. Man kann jetzt weitersuchen, indem neue Pfade besucht oder erweitert werden und man dabei weitere, eventuell bessere Lösungen findet.




Abbildung 4: Möglicher (Teil-)Suchbaum für Beispiel in Abbildung 3

Eine weitere Herangehensweise, um Lösungsmöglichkeiten zielgerichtet zu durchsuchen, besteht darin, schon mit einer vollständigen Lösung zu beginnen, und diese nach und nach zu verbessern. Zum Beispiel kann man versuchen, die Lösung in Abbildung 5 dadurch zu optimieren, indem nach [5,2] zuerst Lötstelle [7,2] besucht wird und dann erst [5,1] (siehe Abbildung 6). In diesem Fall entsteht eine Lösung, welche um

eine Zeiteinheit besser ist als die Ausgangslösung<sup>6</sup>. Sowohl lokale Suche, Algorithmen der Schwarmintelligenz, genetische Algorithmen und andere evolutionäre Methoden verwenden dieses Prinzip mehr oder weniger explizit, um ausgehend von einer vorhandenen Lösung schrittweise (lokale) Veränderungen an der Lösung vorzunehmen, bis ein sogenanntes lokales Optimum erreicht ist.

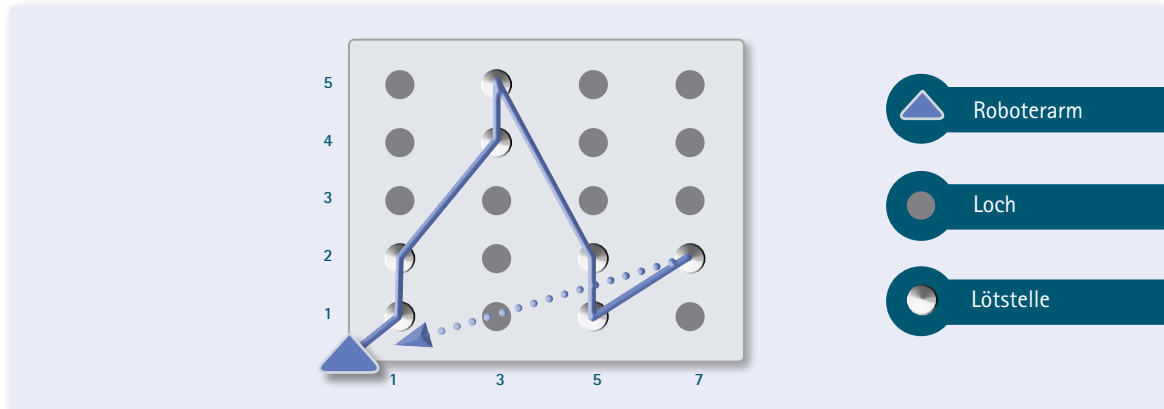


Abbildung 5: Eine mögliche Lösung für das Löt-Roboter-Problem in Abbildung 3

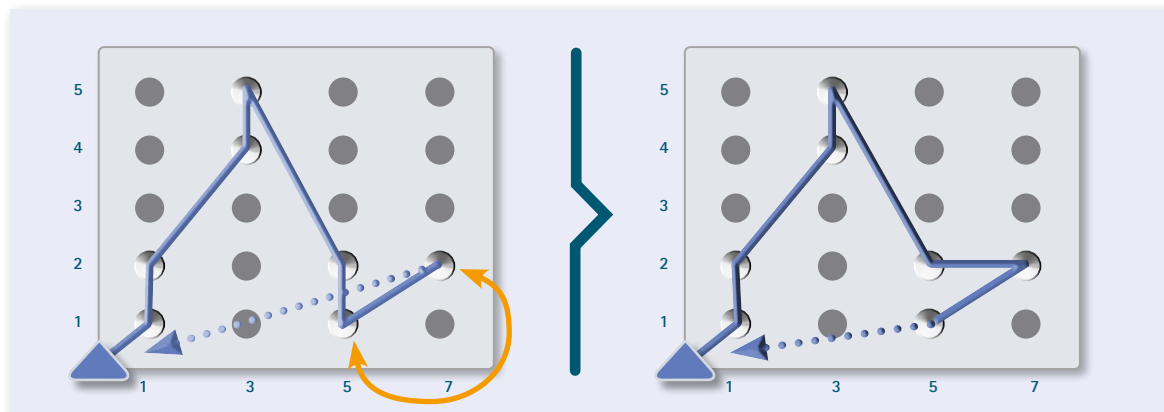


Abbildung 6: Lokale Lösungsveränderung der Lösung in Abbildung 5

Aus der Kombination von Logik und Suche haben sich generelle Problemlösungswerkzeuge entwickelt, welche heute in der Wirtschaft sehr erfolgreich für Planungs- und Optimierungsprobleme eingesetzt werden. Das Prinzip dahinter ist, dass man mit einer logikbasierten Beschreibungssprache das Modell und die Lösungskriterien darstellt. Eine intelligente Suchkomponente wendet automatisch bzw. selbstständig verschiedene Schlussregeln an, bis eine den zuvor definierten Kriterien entsprechende Lösung gefunden ist (oder bewiesen ist, dass es keine Lösung gibt).

<sup>6</sup> Lösung ist optimal.

# 4

## Maschinelles Lernen

Was Sie aus dem Kapitel mitnehmen:

- Sie lernen einige Methoden im Bereich des Maschinellen Lernens im Detail kennen



Im Gegensatz zur modellbasierten KI ist beim Maschinellen Lernen (ML) kein Modell gegeben, auf dessen Basis Schlussfolgerungen gezogen bzw. Lösungen berechnet werden können. Vielmehr ist die Erstellung eines Modells (oder Teilmodells) selbst das Ziel des Maschinellen Lernens. Dabei können wiederum grob zwei Teilgebiete unterschieden werden: **überwachtes** (engl.: *supervised*) und **unüberwachtes** (engl.: *unsupervised*) Lernen<sup>7</sup>. In beiden Fällen sind Datensätze gegeben, und es wird versucht, aus den gegebenen Daten zu lernen.

## 4.1 Überwachtes Maschinelles Lernen

Bei dieser Methode steht ein sogenannter Trainingsdatensatz zur Verfügung, welcher für eine Menge von (Trainings-)Beispielen auch die korrekte Antwort ausweist. Prinzipiell kann man sich so einen Trainingsdatensatz als Tabelle vorstellen, in der die erste Spalte eine eindeutige Kennung (Name, Nummer) des Trainingsbeispiels beinhaltet, die letzte Spalte die korrekte Antwort für das Trainingsbeispiel gibt, und die Spalten dazwischen beinhalten Werte für bestimmte Eigenschaften (engl. *Feature*), welche das Beispielobjekt näher charakterisieren.

Je nachdem, ob das vorausgesagte Merkmal einen Wert aus einer endlichen Menge von Symbolen annehmen kann (z.B. eine Teilmenge der ganzen Zahlen) oder nicht, unterscheidet man zwischen Klassifikation und Regression.

### 4.1.1 Klassifikation

Bei der Klassifikation ist die Antwort immer die Zugehörigkeit zu einer Klasse, z.B. groß/mittel/klein, rot/grün/gelb/blau. Die binäre Klassifikation stellt den Spezialfall dar, wo es nur zwei Wertausprägungen gibt, also wahr oder falsch, 1 oder 0, gehört zur Klasse oder gehört nicht zur Klasse, Spam=Ja oder Spam=Nein, u.a.

	„Black Jack“	„Casino“	„Gewinn“	„Bargeld“	„Cash“	„Kostenlos“	Spam
E-Mail 1	Ja	Ja	Ja	Nein	Ja	Nein	Ja
E-Mail 2	Ja	Ja	Nein	Ja	Nein	Nein	Ja
E-Mail 3	Nein	Ja	Ja	Ja	Nein	Nein	Ja
E-Mail 4	Nein	Nein	Ja	Ja	Ja	Nein	Ja
E-Mail 5	Nein	Nein	Nein	Nein	Nein	Nein	Nein
E-Mail 6	Nein	Nein	Nein	Nein	Nein	Ja	Nein
E-Mail 7	Nein	Nein	Nein	Nein	Ja	Nein	Nein
E-Mail 8	Nein	Nein	Nein	Ja	Nein	Nein	Nein

Tabelle 1: Beispiel Trainingsdatensatz für Spam-Klassifikation

#### Beispiel:

Tabelle 1 zeigt ein sehr stark vereinfachtes (aber prinzipiell richtiges) Beispiel für einen Trainingsdatensatz, welcher zur Erkennung von Spam-Mails herangezogen werden könnte. Im Grunde genommen überprüfen Spam-Filter, ob gewisse Alarmwörter in einer E-Mail vorkommen oder nicht. Angenommen es gab in der Vergangenheit (nur) acht E-Mails, von denen die Benutzer/innen vier als Spam erkannt hatten (Spam=Ja) und welche von einem vorgelagerten Prozess auf das Vorhandensein diverser Signalwörter (z.B.: „Cash“) überprüft wurden. Ein überwachter Lernalgorithmus kann nun mit diesem Datensatz trainiert werden, um zu lernen, wie auf Grund des Vorhandenseins der Signalwörter „Black Jack“, ..., „Kostenlos“ vorausgesagt werden kann, ob eine gegebene E-Mail Spam ist oder nicht.

<sup>7</sup> Verstärkendes (engl.: *reinforcement*) Lernen stellt eine Spezialform des Maschinellen Lernens dar, welche sowohl Aspekte der zustandsbasierten Suche als auch des überwachtes und unüberwachtes Lernens beinhaltet.

Einen sehr einfachen Algorithmus stellt in diesem Zusammenhang die *Methode der nächsten Nachbarn* dar. Das Prinzip ist so einfach wie effektiv: Ein neues, noch zu klassifizierendes Beispielobjekt (in unserem Fall eine neue E-Mail) wird auf Grund der Eigenschaftswerte mit den Beispielen im Trainingsdatensatz verglichen. Die ähnlichsten Beispiele dienen dann der Vorhersage für das neue Beispiel, in dem z.B. der häufigste Wert verwendet wird.

	„Black Jack“	„Casino“	„Gewinn“	„Bargeld“	„Cash“	„Kostenlos“	Spam	Gleiche Merkmale mit der neuen E-Mail
E-Mail 1	Ja	Ja	Ja	Nein	Ja	Nein	Ja	4
E-Mail 2	Ja	Ja	Ja	Ja	Nein	Nein	Ja	4
E-Mail 3	Nein	Ja	Ja	Ja	Nein	Nein	Ja	3
E-Mail 4	Nein	Nein	Ja	Ja	Ja	Nein	Ja	5
E-Mail 5	Nein	Nein	Nein	Nein	Nein	Nein	Nein	2
E-Mail 6	Nein	Nein	Nein	Nein	Nein	Ja	Nein	1
E-Mail 7	Nein	Nein	Nein	Nein	Ja	Nein	Nein	3
E-Mail 8	Nein	Nein	Nein	Ja	Nein	Nein	Nein	3

neue E-Mail	Ja	Nein	Ja	Ja	Ja	Nein	???	Ja
-------------	----	------	----	----	----	------	-----	----

Tabelle 2: Beispiel für Spam-Klassifikation für eine neue E-Mail

Tabelle 2 zeigt die Berechnung basierend auf drei nächsten Nachbarn für exemplarische Werte einer fiktiven neuen E-Mail. Der Vergleich der Eigenschaftswerte identifiziert E-Mail 1, 2 und 4 als die drei E-Mails, welche am ähnlichsten sind. Die Ähnlichkeit ist in diesem Fall durch die Anzahl an gleichen Eigenschaftswerten gegeben. E-Mail 4 ist also die nächste mit einer Ähnlichkeit von 5. E-Mail 1 und 2 haben noch eine Ähnlichkeit von 4. Da die Mehrheit dieser E-Mails (in diesem Fall sogar alle) als Spam klassifiziert sind, wird auch die neue E-Mail als Spam klassifiziert. Das Lernen bzw. Trainieren bei dieser Methode beschränkt sich auf das Abspeichern des Datensatzes und das Ausprobieren, welche Anzahl an nächsten Nachbarn im Durchschnitt die besten Ergebnisse liefert.

Um die Generalität von überwachtem Maschinellen Lernen, im Speziellen von Klassifikationsmethoden, zu zeigen, soll an dieser Stelle noch ein weiteres Beispiel angeführt werden. Die automatische Bilderkennung ist ein typischer Anwendungsfall für überwachtes Lernen. Hierbei geht es darum, ein System mittels einer Menge von zuvor aufbereiteten<sup>8</sup> Bildern (also der Trainingsdatensatz) so zu trainieren, dass es danach bei Vorlage bzw. Eingabe eines neuen, noch unklassifizierten Bildes automatisch entscheiden kann, ob ein zuvor eintrainierter Objekttyp auf dem Bild gegeben ist oder nicht.

### Beispiel:

Eine der ersten Anwendungen für die Bilderkennung war die automatische Ziffernerkennung. Im einfachsten Fall verwendet man zum Training Schwarz-Weiß-Bilder. Abbildung 7 zeigt, wie solche Bilder mit 8x8 Pixel<sup>9</sup> im Rahmen eines Trainingsdatensatzes verwendet werden. Jedes der 64 Pixel hat entweder einen Wert von 0=weiß oder 1=schwarz. Der Trainingsdatensatz besteht also aus einer Tabelle mit 66 Spalten, wobei die erste Spalte nur der eindeutigen Identifikation des Trainingsbeispiels dient und die letzte Spalte die korrekte Antwort ausweist. Jede Zeile enthält die Informationen für ein Trainingsbild. Der Vergleich mit der in diesem Kapitel schon besprochenen Spam-Klassifikation von E-Mails zeigt, dass auch die Bilderkennung im Grunde das gleiche Problem darstellt und somit die selben Methoden zur Anwendung kommen können.

<sup>8</sup> normieren, zentrieren, Umwandlung in schwarz-weiß, Veränderung der Auflösung, etc.

<sup>9</sup> In der Realität werden meist Bilder von etwas höherer Auflösung genommen, was aber auch das Lernen bzw. Trainieren aufwendiger macht.

B <sub>i</sub>	1	2	3	4	5	6	7	8
1								
2								
3								
4								
5								
6								
7								
8								

B <sub>i</sub>	1	2	3	4	5	6	7	8
1	0	0	1	1	1	1	0	0
2	0	0	1	0	0	0	0	0
3	0	0	1	0	0	0	0	0
4	0	0	1	1	1	1	0	0
5	0	0	1	0	0	1	0	0
6	0	0	1	0	0	1	0	0
7	0	0	1	1	1	1	0	0
8	0	0	0	0	0	0	0	0

	1	2	3	4	5	6	7	8	...	57	58	59	60	61	62	63	64	Ziffer	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
B <sub>i</sub>	0	0	1	1	1	1	0	0	...	0	0	0	0	0	0	0	0	6	
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...

Abbildung 7: Prinzip der automatischen Ziffererkennung

## 4.1.2 Regression

Wenn das vorausgesagte Merkmal einen kontinuierlichen Wert hat, typischerweise in Form einer Dezimalzahl, wie z.B. Temperatur, Größe, Gewicht, etc., spricht man von Regression. Auch die Regression hat zum Ziel, einen Eigenschaftswert auf Grund von anderen Eigenschaftswerten vorauszusagen. Man spricht in diesem Kontext sehr oft auch von unabhängigen Variablen (die gegebenen Merkmale) und einer abhängigen Variable (das vorauszusagende Merkmal).

### Beispiel:

Nehmen wir an, wir wollen das Gewicht einer Person ausschließlich auf Grund ihrer Größe schätzen bzw. voraussagen und haben dazu den Trainingsdatensatz in Tabelle 3 erhoben. Grundsätzlich kann die Methode der nächsten Nachbarn auch für Regressionsprobleme verwendet werden. Bei der Verwendung dieser Methode bietet es sich jedoch an, den Mittelwert der nächsten Nachbarn statt den häufigsten Wert zu verwenden. Wenn man nun z.B. das (unbekannte) Gewicht einer Person mit einer Körpergröße von 180 cm schätzen will und man dabei drei nächste Nachbarn verwendet, sind die Personen 4, 6 und 8 von ähnlichster Größe und das entsprechende arithmetische Mittel des Gewichts ist  $(73,6 + 81,6 + 78,8)/3 = 78$ .

	Größe (cm)	Gewicht (kg)
Person 1	188,4	81,8
Person 2	187,0	78,6
Person 3	157,1	60,2
Person 4	174,6	73,6
Person 5	159,3	59,2
Person 6	185,9	81,6
Person 7	154,3	55,8
Person 8	185,0	78,8

Tabelle 3: Beispieldaten für Regression

Sollte ein linearer Zusammenhang zwischen den Variablen bzw. Merkmalen angenommen werden können, z.B. durch Sichtung einer Punktwolke wie in Abbildung 8, so können auch sogenannte lineare Modelle zur Schätzung verwendet werden. Im zweidimensionalen Fall wie in unserem Beispiel (d.h. nur zwei Variablen bzw. Merkmale) entspricht ein lineares Modell einer Trendgeraden<sup>10</sup>, welche so in die Punktwolke gelegt wird, dass die Abstände der Punkte zur Geraden minimiert werden. Beispielsweise wäre der Schätzwert für 180 cm laut der (intuitiv) eingezeichneten Trendgeraden in Abbildung 9 bei etwa 76.

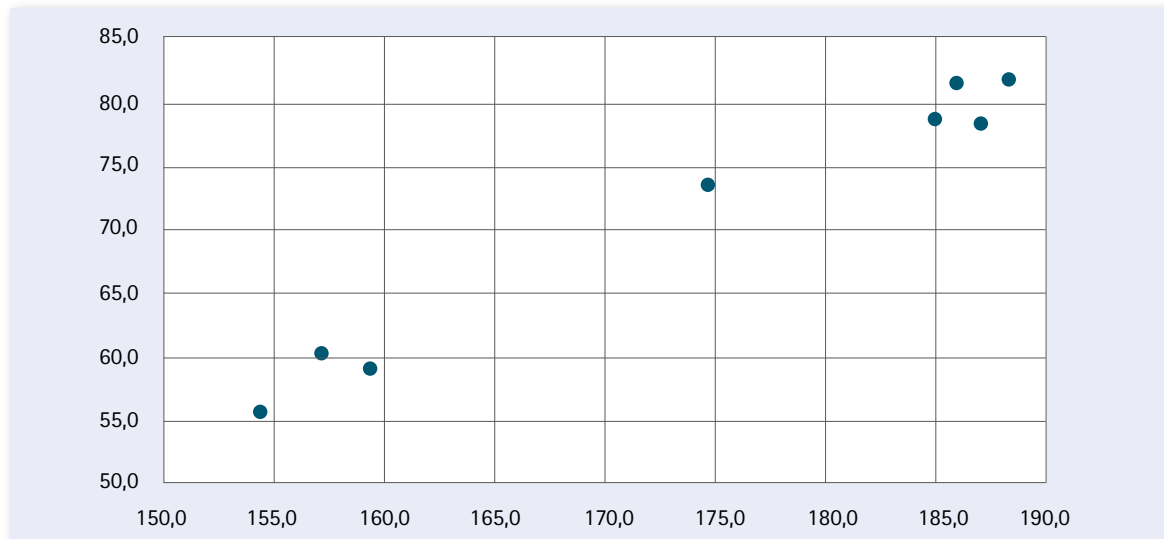


Abbildung 8: Punktwolke zu Beispieldaten in Tabelle 3




Abbildung 9: Punktwolke und Trendgerade zu Beispieldaten in Tabelle 3

### 4.1.3 Zeitreihenanalyse

Einen weiteren, immer wichtigeren Bereich des überwachten Lernens stellt die Zeitreihenanalyse dar. Eine Zeitreihe ist eine Menge von Werten, welche zu verschiedenen Zeitpunkten gemessen bzw. erhoben werden. Ein typisches Beispiel sind Wetterdaten, welche im Laufe des Jahres erhoben werden. Andere Beispiele sind Aktienkurse oder alle möglichen physikalischen Größen (Temperatur, Druck, Feuchtigkeit, etc.), die mit Sensoren zu diversen Zwecken periodisch gemessen werden.

<sup>10</sup> Bei mehr als zwei Dimensionen hat man eine (Hyper-)Ebene statt der Geraden.

Im Gegensatz zu vielen anderen Datensätzen stellen Zeitreihen insofern eine Besonderheit dar, als dass die einzelnen Daten in einem zeitlichen Zusammenhang stehen. Zum Beispiel ist die Außentemperatur an einem Tag abhängig von den Außentemperaturen der Tage davor. Sozusagen ist die Zeitreihenanalyse eine Autoregression, was soviel bedeutet, als dass das vorauszusagende Merkmal mitunter vom vorauszusagenden Merkmal selbst abhängt. Ist eine Zeitreihe (also eine Menge von Werten, die in zeitlichem Zusammenhang stehen) gegeben, versucht die Zeitreihenanalyse die Frage zu beantworten, wie sich die Werte in der Zukunft weiterentwickeln werden (siehe Abbildung 10). Die Zeitreihe stellt in diesem Fall den Trainingsdatensatz dar, welcher genutzt werden kann, um Methoden des überwachten Lernens anzuwenden.




Abbildung 10: Problem der Zeitreihenanalyse

#### 4.1.4 Deep Learning und Neuronale Netze

Neben den relativ einfachen (jedoch sehr oft ausreichenden) Verfahren wie die nächste-Nachbarn-Methode oder lineare Modelle gibt es sowohl für die Regression als auch für die Klassifikation viele weitere Verfahren, welche besonders bei nicht-linearen Zusammenhängen Anwendung finden. Als zurzeit prominenteste Vertreter sind hierbei künstliche neuronale Netze (KNN) zu nennen. Je nach Netzwerkarchitektur, können neuronale Netze auf sehr komplexe Klassifikations- und Regressionsprobleme angewendet werden.

Die grundlegende Idee neuronaler Netze stammt von biologischen Gehirnen, wo man derzeit davon ausgeht, dass Wissen und Intelligenz verteilt in einem Netzwerk aus Neuronen gespeichert wird. Das einzelne Neuron ist relativ einfach und verfügt nur über sehr beschränkte Fähigkeiten der Informationsverarbeitung. Durch das Zusammenspiel vieler Neuronen, in dem eingegangene Signale geringfügig verändert an andere Neuronen weitergegeben werden, entstehen komplexe kognitive Fähigkeiten. Das Lernen besteht dabei zu einem wesentlichen Teil darin, die weitergeleiteten Signale zu verstärken oder abzuschwächen.

Abbildung 11 zeigt ein sehr einfaches KNN. Grundsätzlich sind in jedem KNN die Neuronen in Schichten organisiert. Die Neuronen der Eingabeschicht übernehmen die Eingabewerte (z.B. Eigenschaften bzw. Merkmale eines zu klassifizierenden Objektes). Die Neuronen der Ausgabeschicht produzieren die eigentlichen Ausgabewerte (z.B. Ergebnis der Klassifizierung). Dazwischen kann es noch weitere, sogenannte versteckte Schichten von Neuronen geben. In unserem Beispielnetzwerk in Abbildung 11 gibt es genau eine versteckte Schicht mit zwei (versteckten) Neuronen. Wenn das Netzwerk sehr viele versteckte Schichten besitzt, spricht man in diesem Kontext auch von einem **Deep Neural Net** und beim Lernen bzw. Training mittels eines solchen auch von **Deep Learning**. Deep Neural Nets können mehr als 20 Schichten mit tausenden von Neuronen beinhalten.

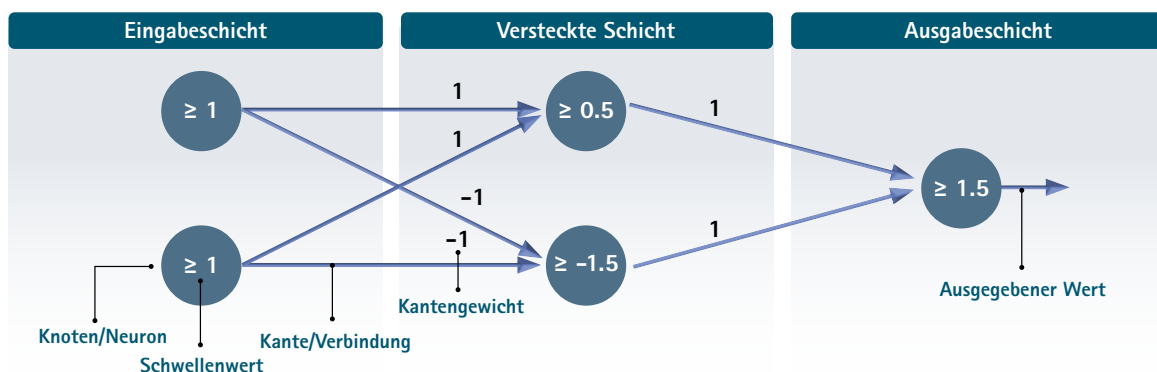


Abbildung 11: Einfaches neuronales Netzwerk

Wieviele Schichten ein KNN besitzt, wieviele Neuronen darin existieren, und wie diese miteinander verbunden sind, stellt die Architektur des KNNs dar. Abbildung 11 stellt ein sogenanntes *Fully Connected Feed Forward KNN* dar. Das bedeutet, dass Neuronen einer Schicht mit allen Neuronen der nächsten Schicht verbunden sind und Signale nur an diese weitergeben werden. Daneben gibt es noch viele andere Architekturen, wie z.B. *Recurrent KNNs*, wo Neuronen Signale auch an Neuronen untergeordneter Schichten zurückgeben können. Die Architektur eines KNN ist abhängig vom Problem, welches zu Lösen ist, und muss von einem/r Ingenieur/in vorgegeben werden.

Des Weiteren gibt es verschiedene Typen von Neuronen, welche sich unter anderem darin unterscheiden, wie an einem Neuron anliegende gewichtete Signale zu einem Ausgangssignal verarbeitet werden. Sehr einfache Neuronen verwenden eine binäre Schwellenwertfunktion. Solche Neuronen können nur zwei Werte produzieren, nämlich 0 und 1. Wenn die Summe der gewichteten Eingangssignale größer als ein gegebener Schwellenwert ist, wird 1 als Ausgangssignal produziert, ansonsten 0. Die Ausgangssignale liegen danach verstärkt oder abgeschwächt als Eingangssignal an den verbundenen Neuronen an. Die Verstärkungen bzw. Abschwächungen erfolgen über die Verbindungen und sind in Form von Kantengewichten, mit denen die Werte multipliziert werden, vorliegend.

In allen modernen KNN-Ansätzen erfolgt das Lernen durch das (automatische) Einstellen der „richtigen“ numerischen Kantengewichte und Schwellenwerte in der Trainings- bzw. der Lernphase. Die Architektur wird nicht verändert. Deep Neural Networks können tausende numerische Gewichte umfassen. Daraus folgt, dass in KNNs das Wissen in Form der Netzwerkarchitektur und der numerischen Gewichte kodiert ist. Symbolisches Wissen, wie es der Mensch z.B. in der Weitergabe des Wissens oder in der Begründung von Schlussfolgerungen verwendet, wird in KNNs nicht dargestellt.

### Beispiel:

In Abbildung 12 wird gezeigt, wie die Berechnung des Ausgabewerts auf unserem Netzwerk aus Abbildung 11 funktioniert, wenn als Eingabe 0 bei Neuron (a) anliegt und 1 bei Neuron (b)<sup>11</sup>. Da der Schwellenwert von 1 in Neuron (a) nicht erreicht wird, ist das Ausgangssignal von (a) gleich 0. Folglich wird von (a) auch 0 an die verbundenen Neuronen (c) und (d) weitergegeben und mit den Gewichten 1 bzw. -1 multipliziert ( $0*1=0$  und  $0*(-1)=0$ ). Bei Neuron (b) wird der Schwellenwert erreicht, sodass das Ausgangssignal 1 ist. Dieser Wert wird direkt an Neuron (c) weitergegeben ( $1*1=1$ ) und negativ an Neuron (d) gegeben ( $1*(-1)=-1$ ). Bei Neuron (c) wird unterdessen der Schwellenwert erreicht, da die Summe der anliegenden Eingangssignale  $0+1=1$  ist und der Schwellenwert 0.5 beträgt. Auch der Schwellenwert in Neuron (d) wird erreicht, da  $-1+0=-1$  größer als  $-1.5$  ist. Somit sind die Ausgabesignale der Neuronen (c) und (d) jeweils 1. Als weitere Konsequenz liegen diese Signale als Eingangssignale bei Neuron (e). Da auch in Neuron (e) der Schwellenwert von 1.5 erreicht wird ( $1+1=2$ ) besitzt Neuron (e), welches unser einziges Ausgabeneuron ist, das Ausgangssignal 1. Wenn man an die Neuronen (a) und (b) jeweils ein Eingangssignal von 1 anlegen würde, würde die Ausgabe von Neuron (e) gleich 0 sein. Auch beim Anlegen von 0 an (a) und 0 an (b) wäre die Ausgabe (0).

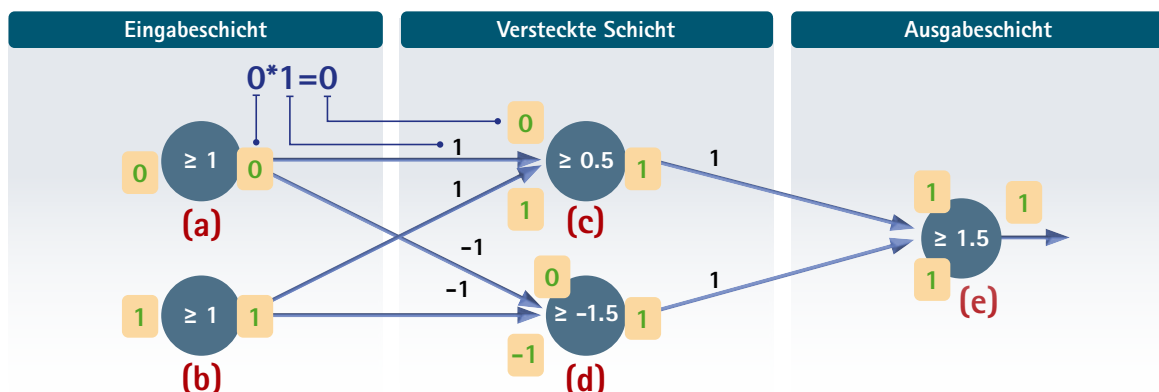


Abbildung 12: Beispielberechnungen für ein KNN

<sup>11</sup> Im Allgemeinen können sowohl für die Eingabewerte, die Kantengewichte als auch für die Schwellenwerte beliebige numerische Werte verwendet werden.

Um ein anderes Verhalten des KNNs zu erreichen, müssen die Kantengewichte und/oder Schwellenwerte verändert werden. Dies, also die Adaptierung der Gewichte und Schwellenwerte, ist genau jener Prozess, der beim Trainieren eines KNN mittels eines Trainingsdatensatzes durchgeführt wird.

An dieser Stelle soll noch erwähnt werden, dass aus praktischer Sicht die Wahl der Klassifikations- bzw. Regressionsmethode ein untergeordnetes Problem darstellt. Das primäre Problem besteht typischerweise im Erstellen des Trainingsdatensatzes<sup>12</sup>, was das Auswählen, Bereinigen, Korrigieren und Normieren der Merkmale und Werte beinhaltet. Sobald ein Trainingsdatensatz in ausreichender Qualität vorliegt, können alle möglichen Methoden, Architekturen, etc. darauf ausprobiert werden.

## 4.2 Unüberwachtes Maschinelles Lernen

Im Gegensatz zum überwachten Maschinellen Lernen, wo ein (Trainings-)Datensatz existiert, welcher auch die korrekten Antworten für die Trainingsbeispiele umfasst, enthalten Datensätze für unüberwachtes Lernen keine Informationen über korrekte Antworten. Der Lernprozess ist auch nicht mit dem Training beim überwachten Maschinellen Lernen vergleichbar. Vielmehr handelt es sich beim unüberwachten Maschinellen Lernen um das automatisierte Finden von versteckten Zusammenhängen in einem Datensatz. Was es in den meisten Fällen trotzdem braucht, ist ein Datensatz, welcher ähnlich strukturiert ist wie ein Trainingsdatensatz, d.h. die erste Spalte benennt ein Objekt bzw. Beispiel, und danach folgen weitere Spalten, welche Eigenschaftswerte für die einzelnen Objekte bzw. Beispiele enthalten. Je nachdem, auf welche Art von Zusammenhang untersucht wird, kommen verschiedene Methoden zur Anwendung. Zwei in diesem Kontext wichtige Bereiche sind **Data Mining** und die **Clusteranalyse** (engl.: *Clustering*)<sup>13</sup>.

### 4.2.1 Clusteranalyse

Bei der Clusteranalyse geht es darum, die Objekte bzw. Beispiele im Datensatz auf Grund ihrer Eigenschaftswerte in Klassen einzuteilen. Dabei gilt das Prinzip, dass nach erfolgter Klasseneinteilung (Clustering) die Objekte im selben Cluster maximal ähnlich, jedoch verschiedene Cluster (bzw. die Objekte in verschiedenen Clustern) maximal unähnlich sein sollten.

Es gibt sehr viele verschiedene Cluster-Methoden, welche sich unter anderem darin unterscheiden, ob die erwartete Anzahl an Clustern schon vorgegeben wird oder nicht, ob ein Objekt nur einem einzigen Cluster zugeordnet werden kann oder auch mehreren, oder wie die Ähnlichkeit bzw. Distanz zwischen zwei Objekten berechnet wird. Für den zweidimensionalen Fall (also, wenn Objekte nur zwei Eigenschaften haben) kann man das Prinzip sehr verständlich grafisch darstellen.

#### Beispiel:

Nehmen wir einen Auszug einer fiktiven Kundendatenbank, in welcher neben einer Kundennummer auch gespeichert wird, wie alt ein Kunde ist und wieviel Umsatz dieser gebracht hat (also die Eigenschaften<sup>14</sup>). Abbildung 13 zeigt den Datensatz, das entsprechende Punktdiagramm und die Cluster. Offensichtlich kann man laut den identifizierten Clustern vier Kundentypen unterscheiden, was z.B. für eine Marketingstrategie eine entscheidende Information wäre.

<sup>12</sup> Aus Verständlichkeitsgründen wird in diesem Leitfadens nicht auf die Aufteilung des Datensatzes in Trainings-, Validierungs- und Testdatensatz eingegangen.

<sup>13</sup> Sehr oft wird die Clusteranalyse als eine Art von Data Mining beschrieben, womit Data Mining in gewisser Weise als Synonym für unüberwachtes Maschinelles Lernen zu sehen wäre. Aus Gründen der Verständlichkeit und der Generalität unterscheiden wir in diesem Leitfadens zwischen den Begriffen Data Mining, Clusteranalyse und überwachtes Maschinelles Lernen.

<sup>14</sup> Manchmal auch Merkmal, Attribut oder Feature genannt

Kunde	Alter	Umsatz
1	42	2716
2	40	6579
3	53	7533
4	23	2152
5	24	1506
6	29	1520
7	19	2993
8	43	6323
9	48	7622
10	46	2282
11	43	1756
12	53	2783
13	20	2842
14	28	1596
15	27	5642
16	45	7441
17	54	6079
18	44	6127
19	21	6329
20	24	7808
21	31	6336
22	20	5533

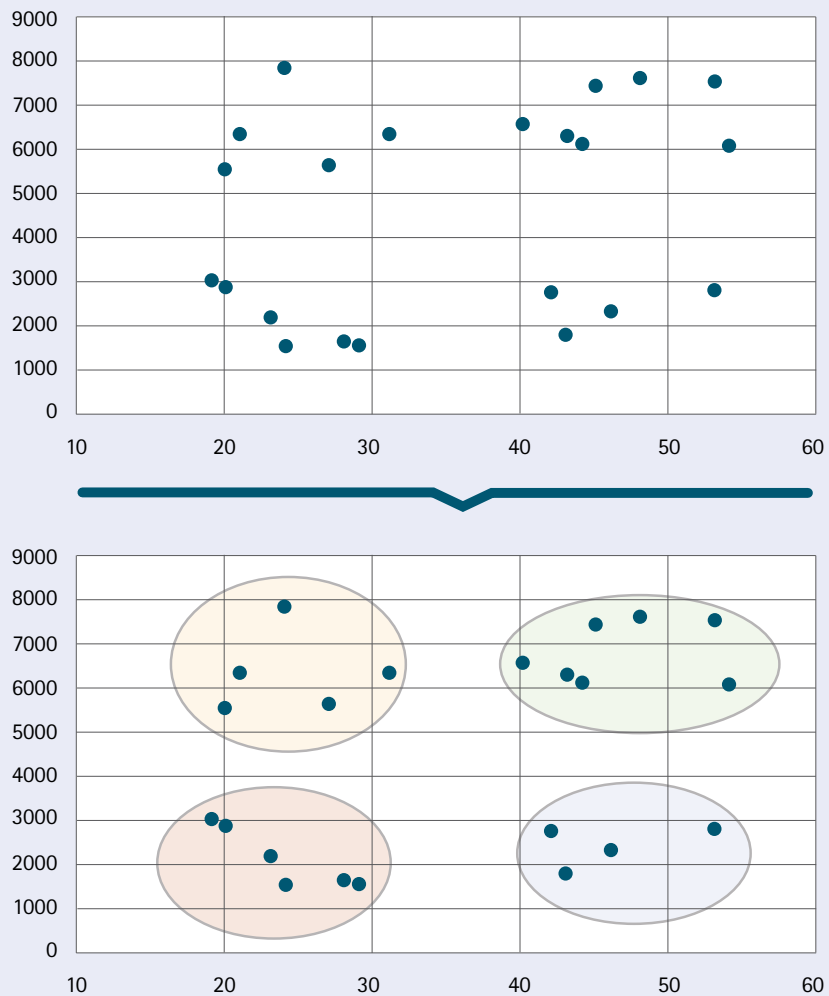


Abbildung 13: Beispiel für Clusteranalyse

## 4.2.2 Data Mining

Anders als bei der Clusteranalyse, wo man Objekte gruppiert, können in Bereichen des Data Mining die zu findenden Informationen komplexer sein und sowohl versteckte Zusammenhänge zwischen den Zeilen eines Datensatzes (Objekte), den Spalten (Eigenschaften bzw. Features) oder beides betreffen. Ein solches Teilgebiet ist das **Rule Mining**, also das Finden von Regeln in Datensätzen. Ein bekanntes Einsatzgebiet für **Rule Mining** ist die Warenkorbanalyse.

### Beispiel:

Viele Handelsbetriebe erheben die Daten von Kunden, insbesondere wann welche Einkäufe getätigt wurden. Diese gespeicherten Warenkörbe können bei näherer Betrachtung Zusammenhänge offenbaren, welche z.B. durch gezielte Kundenwerbung oder ähnliche verkaufsfördernde Maßnahmen genutzt werden können. Tabelle 4 zeigt, wie so ein Datensatz aufgebaut ist<sup>15</sup>.

<sup>15</sup> In der Praxis bestehen solche Datensätze oft aus tausenden von Spalten und hunderttausenden von Zeilen.



Warenkorb	Produkt 1	Produkt 2	Produkt 3	Produkt 4	Produkt 5	Produkt 6	Produkt 7
1	1	0	0	1	0	1	0
2	1	1	1	0	0	0	0
3	0	0	1	1	1	0	0
4	1	0	0	1	0	1	0
5	0	1	0	0	1	0	1
6	1	0	0	1	0	1	0
7	1	0	0	0	1	0	0
8	0	1	0	1	0	0	0
9	1	0	1	1	0	0	1
10	0	0	0	0	1	1	1

Tabelle 4: Beispieldatensatz für Warenkorbanalyse

In unserem kleinen Beispiel haben wir zehn Warenkörbe, und es gibt in diesem Fall nur sieben Produkte, die gekauft werden können. Jede Zeile (bis auf die erste) stellt einen Warenkorb dar, wobei '1' bedeutet, dass sich das Produkt im Warenkorb befunden hat und '0' wenn nicht. Durch die Anwendung von Algorithmen wie dem *Apriori-Algorithmus* ist es möglich effizient (d.h. auch bei sehr großen Datensätzen) zu berechnen, welche Produkte sehr häufig gemeinsam gekauft werden, um daraus Regeln abzuleiten.

In unserem Beispieldatensatz in Tabelle 4 befinden sich die Produkte 1, 4 und 6 relativ häufig gemeinsam in einem Warenkorb, nämlich in 30 % der Fälle. Eine daraus abgeleitete Regel könnte also lauten: wenn Produkt 1 und Produkt 4, dann auch Produkt 6. Diese Regel wäre voraussichtlich zu 75 % korrekt, da Warenkorb 9 zwar Produkt 1 und 4 beinhaltet, jedoch nicht Produkt 6. Eine Regel mit den selben drei Produkten, welche laut Datensatz aber immer stimmt, wäre: wenn Produkt 6 und Produkt 4, dann auch Produkt 1.

Ein grobes Verständnis der beiden in ihrem Grundprinzip sehr gegensätzlichen KI-Ansätze Modellieren und Lösen vs. Maschinelles Lernen bildet nun das Fundament für eine solide, fundierte Beurteilung der Anwendungsmöglichkeiten in der Praxis.

# 5

## Wie kann ich ein erfolgversprechendes KI-Projekt erkennen und in meinem Unternehmen umsetzen?

### Was Sie aus dem Kapitel mitnehmen:

- Klassifikationsraster zur Identifikation der erfolgversprechenden KI-Projekte
- Typische betriebliche Einsatzgebiete von KI
- Kriterien, die den Grad der technischen Herausforderung für KI-Projekte bestimmen

Die Künstliche Intelligenz in einem Unternehmen einzuführen, ist ein Innovationsprojekt. Üblicherweise müssen bei Innovationsprojekten neben den technischen Herausforderungen auch betriebswirtschaftliche und organisatorische Aufgaben bewältigt werden, um den Erfolg sicherzustellen. In den folgenden Kapiteln konzentrieren wir uns auf die technischen Aspekte hinsichtlich der Einführung von KI-Methoden und verweisen die Leser/innen auf die ergänzende Literatur im Bereich des Innovationsmanagements<sup>16</sup>.

## 5.1 Wie kann ich ein aussichtsreiches KI-Projekt erkennen?

Für eine Investitionsentscheidung wird eine möglichst präzise Kosten-Nutzen-Analyse sowie Risikoanalyse benötigt – dies gilt auch für die Einführung eines KI-Projektes. Die Künstliche Intelligenz kann aber in vielen verschiedenen Prozessen, Produkten und Dienstleistungen eines Unternehmens eingesetzt werden, sodass man sich sinnvollerweise auf die aussichtsreichen Projekte konzentrieren muss. Betrachtet man den *betrieblichen Nutzen* und die *technische Herausforderung*, können mögliche Projekte in einem Projektportfolio (siehe Abbildung 14) folgendermaßen klassifiziert werden.

### Umsetzen:

Bei diesen Projekten wird ein hoher betrieblicher Nutzen erwartet, wobei die technische Herausforderung als gering eingeschätzt wird. Für diese Projekte sollte eine detaillierte Kosten-Nutzen-Untersuchung erfolgen, um eine Investitionsentscheidung zu treffen.

### Forschen:

Bei diesen Projekten wird ein hoher betrieblicher Nutzen erwartet, allerdings wird die aktuelle technische Herausforderung als hoch eingeschätzt. Hohe technische Herausforderungen bedeutet in der Regel hohes Risiko hinsichtlich der Erfüllung der technischen Zielsetzungen. Diese Projekte sind Kandidaten für anwendungsorientierte Forschungsarbeiten oder -kooperationen. Ziel dieser Arbeiten ist eine Reduktion des Risikos hinsichtlich der Abschätzung der technischen Machbarkeit und der Kosten einer Realisierung. Dadurch wird eine fundierte Kosten-Nutzen-Untersuchung vorbereitet und deren Genauigkeit verbessert. Möglicherweise zeigt das Forschungsprojekt aber auch, dass aktuell keine Umsetzung möglich oder sinnvoll ist.

		technische Herausforderung	
		hoch	gering
betrieblicher Nutzen	hoch	forschen	umsetzen
	gering	vermeiden	beobachten

Abbildung 14: Projektportfolio

### Beobachten:

Bei diesen Projekten wird sowohl der betriebliche Nutzen als auch die technische Herausforderung als gering eingestuft. Sie haben aus aktueller Sicht geringe Priorität. Möglicherweise gewinnen diese Vorhaben im Rahmen von anderen Projekten oder aufgrund von betrieblichen Veränderungen an Bedeutung.

### Vermeiden:

Diese Projekte haben einen geringen betrieblichen Nutzen und sind zur Zeit technisch schwierig zu realisieren. Damit sie für eine Umsetzung in Betracht gezogen werden, müssen sich sowohl der betriebliche Nutzen als auch die aktuell verfügbare Technologie ändern.

<sup>16</sup> Z.B. *Innovationsmanagement* von Hauschildt, Salomo, Schultz und Koch, 6. Auflage, 2016, Vahlen ISBN 978-3- 8006-4728-6

Für die Erstellung eines unternehmensspezifischen Projektportfolios sind konsequenterweise folgende Schritte durchzuführen:

1. Identifikation von möglichen KI-Anwendungen
2. Beurteilung des betrieblichen Nutzens dieser Anwendungen
3. Beurteilung der technischen Herausforderungen dieser Anwendungen

Bei diesen Schritten ist insbesondere Schritt 1 von zentraler Bedeutung. Einerseits sollten keine KI-Anwendungen mit hohem betrieblichem Nutzen übersehen werden, andererseits wäre es ineffizient, sich mit Anwendungen zu befassen, die aus technischer Sicht vollkommen unrealistisch sind oder von denen klar ist, dass sie keinen betrieblichen Nutzen bringen. Für das Erkennen von erfolgversprechenden KI-Anwendungen wird daher ein ungefähres Verständnis der Möglichkeiten der Technologie benötigt, aber insbesondere auch profundes Wissen über das Unternehmen und dessen Umfeld, wie z.B. Kunden, Lieferanten, betriebliche Prozesse und technische Verfahren. Für eine realistische Einschätzung der Möglichkeiten ist es unerlässlich, grob abschätzen zu können, welche Methode grundsätzlich in Frage kommt, und welche Voraussetzungen für eine Anwendung zu erfüllen sind.

Üblicherweise wird auf Grund der Breite des notwendigen Wissens die Identifikation von KI-Projekten in multidisziplinären Teams durchgeführt. Für die erfolgreiche Kommunikation in diesen Teams ist ein gegenseitiges Grundverständnis notwendig.

Um obige Schritte zu unterstützen, werden wir im Folgenden einerseits die typischen betrieblichen Einsatzgebiete der Künstlichen Intelligenz skizzieren, um so Anregungen für mögliche Anwendungen zu geben und andererseits auf die technischen Herausforderungen eines Einsatzes von KI eingehen sowie Indikatoren formulieren, die den Grad der technischen Herausforderung anzeigen.

## 5.2 Betriebliche Einsatzgebiete

Methoden der Künstlichen Intelligenz haben in vielen Anwendungsfeldern Einzug gehalten und dieser Trend wird sich fortsetzen. In vielen Bereichen entlang der Wertschöpfungskette (siehe Abbildung 15) werden heute schon KI-Werkzeuge eingesetzt. Aufgrund der Fülle von Anwendungen kann an dieser Stelle nur ein Überblick gegeben werden. Im Internet und in der Literatur finden sich zahlreiche Beschreibungen von erfolgreichen KI-Anwendungen.

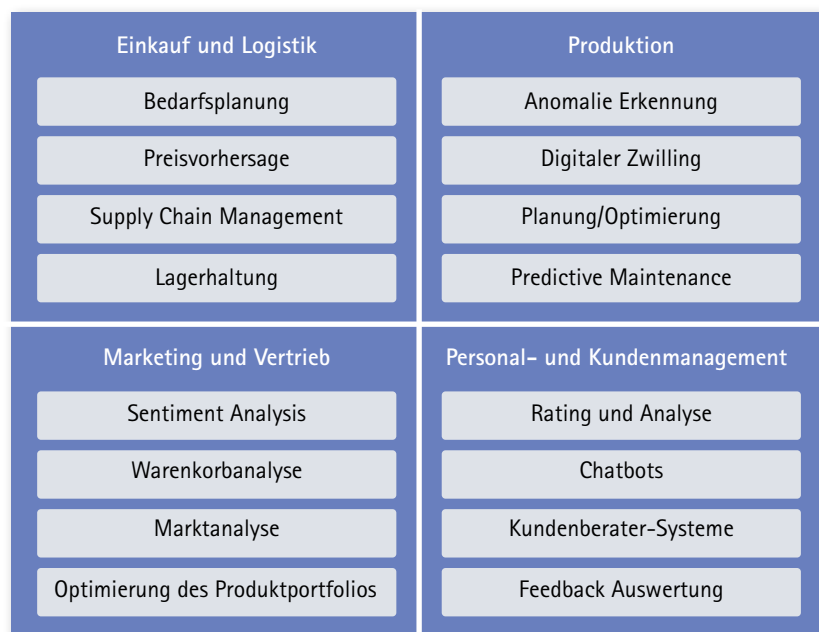


Abbildung 15: Typische Einsatzgebiete von KI in der Wertschöpfungskette

## 5.2.1 Einkauf und Logistik

### Preis- und Auftragsentwicklung:

Im Bereich Einkauf ist es für viele Betriebe wichtig, Preisentwicklungen und Auftragslagen vorherzusagen, um sowohl den Bedarf für die Zukunft korrekt zu planen als auch zu günstigen Konditionen einzukaufen. Aufbauend auf Daten der Vergangenheit, können dazu Methoden des (überwachten) Maschinellen Lernens im Speziellen der Zeitreihenanalyse herangezogen werden. KI-Methoden werden im Einkauf auch verwendet, um Einkaufspreise in Real-Zeit im Internet zu beobachten und um Vorhersagen über deren Entwicklung zu tätigen. Auf Basis dieser Ergebnisse werden Empfehlungen an das Einkaufsmanagement erstellt. Im Bereich der Autoindustrie werden aus den Benutzerdaten der Online-Konfiguratoren Vorhersagen über die zu erwartenden Bestellungen generiert.

### Bedarfsplanung:

Bei der Bedarfsplanung kommen sowohl die Methoden von ML als auch die Methoden von MO&L zum Einsatz. ML wird verwendet, um auf Basis von historischen Verbrauchszahlen den zukünftigen Bedarf zu errechnen. Der MO&L-Ansatz kann in Kombination mit einer detaillierten Produktionsplanung angewendet werden. Die Simulation der Produktionsabläufe auf Basis einer optimierten Produktionsplanung liefert den Bedarf an Material, Energie und Personal für die Beschaffung. Diese vorausschauende Planung ermöglicht auch eine frühzeitige und optimierte Integration der Zulieferer.

### Flexibles Supply Chain Management:

Neben der klassischen Planung ermöglicht KI auch, flexibel auf Störungen zu reagieren. Sollte es in der Produktion zu Beeinträchtigungen kommen, werden alternative Produktionsprozesse automatisch errechnet. Bei Unternehmen mit mehreren Produktionsstandorten können auch fabrikübergreifende Störungsbehebungen erzeugt werden. Von diesen angepassten Produktionsplänen werden automatisch die benötigten Mengen errechnet und die Zulieferungen der Lieferanten koordiniert.

### Lagermanagement:

KI spielt auch eine zunehmende Rolle in der Automatisierung des Lagerbetriebes. Roboter übernehmen immer mehr die Ein- und Auslagerung von Waren und die Zusammenstellung und Verpackung von Warenpaketen. Im Bereich der Inhouse-Logistik werden verstärkt autonom agierende Transportroboter verwendet, um die firmeninternen Transporte abzuwickeln. Durch KI in Kombination mit neuester Sensortechnologie konnten die Kosten des Einsatzes von Transportrobotern deutlich reduziert und gleichzeitig deren Flexibilität und Fähigkeiten erhöht werden. Roboter können sich frei in zugewiesenen Räumen bewegen und einfache Lade- und Entladeoperationen durchführen. Die Optimierung dieser Transporte ist ein wichtiges Anwendungsfeld von KI.

### Transportlogistik:

Weitere zahlreiche Anwendungen von KI finden sich in Transport- und Logistikunternehmen sowie im Flottenmanagement und der Routenplanung. Die Bandbreite ist denkbar groß und reicht von der klassischen Auslieferung von Gütern bis hin zum Management von Luxuslimousinen. Produktivitätssteigerungen von bis zu 100 % werden berichtet.

KI-Anwendungen finden sich auch bei der Optimierung des Bahngüterverkehrs. So wird die Technologie dazu verwendet, flexibel auf Störungen im Güterverkehr zu reagieren. Es werden automatisch alternative Zusammenstellungen von Zügen und Routen berechnet, sodass die Auswirkungen der Störungen möglichst minimiert werden.

## 5.2.2 Produktion

### Produktionsplanung:

Scheduling und Reihenfolgeplanung sind klassische Anwendungsfelder von KI-Methoden aus dem Bereich MO&L. Anwendungen finden sich in allen Varianten von Produktionssystemen, wie Linien-, Montage- oder Werkstattfertigung. Teilweise werden ganze Produktionsstätten im Detail im Computer nachgebaut, um Prozesse möglichst realitätsnah simulieren und planen zu können. Diese sogenannten digitalen Zwillinge werden mit KI-basierten Planungsmethoden kombiniert, sodass alternative Pläne evaluiert und optimiert werden. Dadurch wird eine Verbesserung der Durchlaufzeiten und der Liefertreue erreicht.

Neben den Produktionsprozessen werden auch die Konfigurationen von Maschinen und Fabriken optimiert. Abhängig vom Produktmix wird der Maschinenpark und die Bearbeitungsfähigkeit von Maschinen angepasst, um vorgegebene Zielwerte zu erreichen.

### Flexible Fertigung und Mass Customization:

KI-basierte Planung ermöglicht, flexibel auf Störungen zu reagieren. Im Fall von Ausfällen von Maschinen können automatisch Umplanungen durchgeführt werden, sodass die Auswirkungen auf die Liefertreue minimiert werden. Diese flexible Planung ist auch ein wichtiger Baustein für die Realisierung von kundenindividueller Fertigung zu möglichst geringen Kosten – idealerweise zu den Kosten der Massenfertigung. In der Betriebswirtschaft ist dieses Produktionsprinzip als Mass Customization bekannt.

Für die Realisierung von Mass Customization wird KI sowohl für die Produktplanung als auch für die Produktionsplanung verwendet. Konfigurationssysteme auf Basis von MO&L werden eingesetzt, um kundenindividuelle Produkte zu planen. Die Bandbreite der Anwendung ist sehr hoch und reicht von Möbeln und Autos bis hin zu Sicherheits- und Steuerungssystemen. Daraus resultiert eine hohe Variantenvielfalt, die in der Produktion beherrscht werden muss. Bei manchen Herstellern von Autos werden in einem Jahr nie zwei gleiche Autos gefertigt. Um mit dieser Variantenvielfalt in der Produktion umgehen zu können, kommen KI-Systeme zur Planung und Steuerung von flexiblen Fertigungen zum Einsatz. Dadurch können Herstellkosten so reduziert werden, dass kundenindividuelle Produkte marktfähig sind.

### Monitoring und Wartung:

Ein weiteres klassisches Anwendungsgebiet der Künstlichen Intelligenz ist die vorbeugende Wartung und Diagnose von Maschinen. KI wird in diesem Bereich schon seit über 30 Jahren erfolgreich eingesetzt, wobei sowohl ML als auch MO&L zum Einsatz kommen. Siemens verwendet einen klassischen regelbasierten Ansatz zum Monitoring von Turbinen und Generatoren. Das Wissen von Expert/innen wird in Form von Regeln kodiert, die von Softwareentwickler/innen erstellt werden. In den letzten Jahren wurde Monitoring und vorbeugende Wartung aber immer mehr eine Domäne von ML. Die Anwendungen von ML für Monitoring und vorbeugende Wartung sind sehr breit gestreut und umfassen zahlreiche Produktionsmaschinen.

Durch KI können Wartungsintervalle von Maschinen so gelegt werden, dass die Produktion möglichst wenig beeinträchtigt wird. Vorbeugende Wartung geht Hand in Hand mit automatisierter Produktionsplanung. Einerseits erkennt die Technologie, dass Wartung in einem Intervall notwendig ist, um einen teuren Ausfall einer Maschine zu vermeiden, andererseits kann sie den optimalen Zeitpunkt einer Wartung bestimmen, sodass die Produktion möglichst wenig beeinträchtigt wird.

### Virtuelle Sensoren:

ML eröffnet die Möglichkeit, sogenannte virtuelle Sensoren in die Produktion einzuführen. Informationen von bestehenden Sensoren werden verwendet, um das Verhalten von virtuellen Sensoren auf Basis von ML zu trainieren. Diese virtuellen Sensoren liefern in weiterer Folge wichtige Informationen zur Steuerung der Produktionsprozesse.

### Objekt- und Bilderkennung:

Insbesondere die signifikanten Verbesserungen der Bild- und Objekterkennung durch ML ermöglichen zahlreiche Anwendungen in der Produktion. KI-basierte Bilderkennung wird sehr erfolgreich in der Qualitätssicherung verwendet, um fehlerhafte Produkte und Produktionsabläufe zu identifizieren. Die Breite dieser Anwendungsmöglichkeiten ist enorm hoch und reicht von der Erkennung von Oberflächenfehlern bis hin zur Klassifikation der Qualität von Gemüse.

### Roboter:

Ein weiteres höchst erfolgreiches Einsatzgebiet der Künstlichen Intelligenz ist die Robotik. Roboter können durch KI flexibler in der Produktion eingesetzt werden und übernehmen einfache Aufgaben bei der Montage, bei der Beschickung von Maschinen oder bei der Zusammenstellung von Lieferungen. Durch neueste Robotertechnologie können Menschen und Roboter kooperativ in einem Fertigungsbereich arbeiten. Die sichere Zusammenarbeit zwischen Mensch und Roboter steht hier im Vordergrund. Dies wird durch eine Kombination von Sensorsystemen und KI erreicht.

## 5.2.3 Marketing

### Analyse des Kaufverhaltens:

Das Käuferverhalten zu analysieren wurde schon lange mit konventionellen Mitteln der Statistik bewerkstelligt. Künstliche Intelligenz, und dabei speziell das Maschinelle Lernen, bieten weitergehende Methoden um Transaktionsdaten zu analysieren. Hier kommen vor allem Methoden des Data Mining zum Einsatz, um versteckte Zusammenhänge und Kausalitäten zu entdecken.

### Erkennen von Kundensegmenten:

Methoden des unüberwachten Lernens, im Speziellen Clustering, können dazu verwendet werden, Kunden in Gruppen einzuteilen, um so leichter Produkt- und Preisdifferenzierungen vornehmen zu können oder spezielle Werbestrategien zu entwickeln. Überwachte Lernmethoden können dann angewendet werden, um den Typus eines Kunden schnell zu identifizieren (z.B. beim Surfen auf der Unternehmenswebseite oder im Onlineshop). In Abhängigkeit vom Typus wird angepasste Werbung geschaltet. Diese Methode hat bei einem US-Wahlkampf zweifelhafte Berühmtheit erlangt.

### Big Data:

Heutige Systeme zur Kundenanalyse und zur Analyse des Kaufverhaltens können (bzw. müssen) sehr oft mit Big Data umgehen. Bei Big Data handelt es sich nicht einfach nur um viele Daten, sondern um Daten, welche aus völlig verschiedenen Datenquellen mit unterschiedlichen Datenformaten und Datenqualitäten stammen. Diese Daten zu bereinigen und sinnvoll zusammenzuführen ist eine sehr komplexe Aufgabe, bietet jedoch die Chance, an Informationen zu gelangen, welche ansonsten nicht vorliegen. Ein Beispiel dafür sind Standort- und Bewegungsdaten von Smartphones, welche, wenn sie mit herkömmlichen Kunden- und Kaufdaten verknüpft werden, oft sehr viel tiefere Schlussfolgerungen zulassen.

### Stimmungslage der Kunden:

Sentiment-Analyse verwendet Methoden des Maschinellen Lernens (z.B. *Natural Language Processing*, *Text Mining*) um automatisiert Stimmungslagen, Einstellungen oder Emotionen von Kunden bezüglich eines Themas, eines Produkts oder eines Unternehmens zu erheben. Dies kann auf Foreninhalte, auf soziale Netzwerke oder Ähnlichem angewendet werden.

### Marktanalysen:

Zu wissen, wie sich ein Markt entwickelt, welche Markttrends zu erkennen sind, wie sich das Zielgruppenverhalten ändert, oder auch welche zukünftigen Märkte gerade entstehen, sind Fragen, welche teilweise mit KI-Unterstützung beantwortet werden können. Ein Beispiel dafür ist Google Trends. Google Trends ist ein Service, welcher Daten über die Häufigkeiten von Suchbegriffen zur Verfügung stellt. Diese Daten können auch z.B. nach Regionen gefiltert werden, was in manchen Märkten sehr effektiv zur Analyse eingesetzt werden kann.

### Portfoliooptimierung und Preisgestaltung:

Aufbauend auf Kunden- und Marktanalysen können das angebotene Produktportfolio und die Preise so gestaltet werden, dass z.B. die Gewinnchancen maximiert oder andere Optimierungskriterien erfüllt werden. Da dies teilweise klassische Optimierungsprobleme darstellen, können modellbasierte Methoden verwendet werden.

## 5.2.4 Personal- und/oder Kundenmanagement

### Human Resources Analytics:

Schon herkömmliche Methoden des Personalmanagements nutzen vorhandene Daten, wie zum Beispiel Fortbildungstage von Mitarbeiter/innen oder Abschlussnoten von Personen im Bewerbungsverfahren, um einfache Statistiken (z.B. Durchschnittsnote der Personen im Bewerbungsverfahren) zu erstellen. KI-Methoden können die Möglichkeiten signifikant erweitern, indem automatisch Lebensläufe analysiert werden, um z.B. Bewerber/innen zu reihen, den Erfolg der Kandidat/innen zu prognostizieren oder die besten Weiterbildungsmaßnahmen für Mitarbeiter/innen zu identifizieren.

### Kunden-Rating und Bonitätsprüfungen:

Banken setzen schon sehr lange Software zur Bonitätsprüfung und zur Einschätzung des Risikos eines Kreditausfalls ein. Methoden der Künstlichen Intelligenz haben diese Möglichkeiten erweitert. Damit ein Unternehmen mittels KI-Methoden Kunden einstufen und das Risiko eines Zahlungsausfalls einschätzen kann, bedarf es lediglich eines Kundendatensatzes, welcher neben demografischen und persönlichen Daten auch Daten zur Zahlungstreue beinhaltet. Diese Informationen können dann verwendet werden, um angepasste Konditionen anzubieten.

### Expertensysteme:

Eine der erfolgreichsten Anwendungen der Künstlichen Intelligenz der jüngeren Vergangenheit sind Experten- bzw. Beratersysteme, um interessante Produkte in einem riesigen Produktsortiment zu finden. Ein Beispiel ist Amazon, wo Kunden über den Hinweis „Kunden, die jenes Produkt gekauft haben, haben auch dieses Produkt gekauft“, auf für sie interessante Waren hingewiesen werden. Aber auch auf vielen anderen Homepages sind spezielle Beratersysteme (*Recommender-Systeme*) zu finden, welche eine virtuelle Produktberatung ermöglichen, oder es erleichtern, die passenden Produkte in einem unübersichtlichen oder riesigen Produktsortiment zu finden. Ein Beispiel sind Banken und Versicherungen. Einerseits werden dem Kunden virtuelle Beratersysteme über die Homepage zur Verfügung gestellt, um zum Kunden passende Produkte zu finden. Andererseits verwenden viele Außendienstmitarbeiter/innen spezielle Beratersoftware, um bei Kundengesprächen die Vielfalt und die Komplexität von Finanz- und Versicherungsprodukten zu bewältigen.

### Chatbots:

Eine Variante von virtuellen Beratersystemen sind Chatbots. Solche Systeme benutzen Methoden der Sprachanalyse (engl.: *Natural Language Processing*), um mit Kunden bzw. Usern in natürlicher Sprache



zu kommunizieren. Somit können gewisse Kundeninteraktionen automatisiert werden, wie z.B. das Beantworten von häufig gestellten Fragen. Dadurch können in vielen Fällen Kosten eingespart und Services verbessert werden.

## 5.3 Technische Herausforderungen

In diesem Kapitel werden wir nun Indikatoren für die technischen Herausforderungen von Anwendungen formulieren. KI-Methoden dienen dazu, gewünschte Funktionen zu realisieren (siehe Abbildung 16). So gesehen gibt es keinen Unterschied zu herkömmlich programmierter Software. Der Unterschied in den Methoden und Ansätzen besteht darin, wie diese Funktion realisiert wird. Die KI-Methoden zielen auf einen möglichst breiten Einsatz. Beispielsweise kann die zu realisierende Funktion ein Empfehlungssystem für Produkte sein. Die Inputs wären in diesem Fall das bisherige Verhalten aller Kunden, die konkreten Wünsche eines Kunden und die Produktdatenbank. Ein möglicher Output wäre eine gereichte Liste an Kaufempfehlungen.

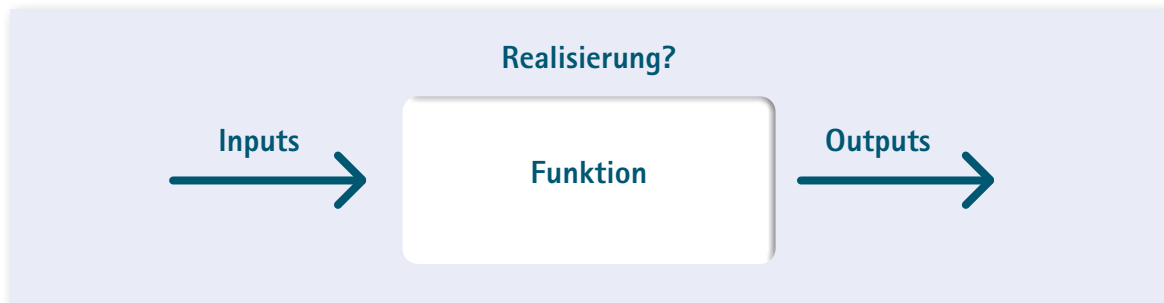


Abbildung 16: Funktion, die ein gewünschtes Input-Output-Verhalten realisiert

Die zu realisierende Funktion kann aber auch die Steuerung eines Roboters implementieren. Inputs wären in diesem Fall die Menge an Sensorinformationen und der Auftrag an den Roboter. Der Output ist eine Sequenz an Steuerungskommandos an die Motoren des Roboters.

Wie bereits im Kapitel 2.2 dargestellt, können die Methoden der KI zur Realisierung solcher Funktionen aktuell in zwei Gruppen unterteilt werden:

1. In jene Gruppe von Methoden (MO&L), in denen Menschen für *alle* zulässigen Inputs einen Output *spezifizieren*. Diese Spezifikation erfolgt z.B. durch Regeln, Gesetze, Prozesse oder Algorithmen. Im Idealfall wird beschrieben, *was* eine Lösung ist. *Wie* eine Lösung gefunden wird, erledigt die KI-Methode von selbst. Hierbei entfällt das Programmieren eines Algorithmus zur Lösungssuche.

2. In jene Gruppe von Methoden (ML), in denen die Funktion auf Basis von Beobachtungen bzw. Datensätzen gelernt wird, d.h. automatisch *erzeugt* wird. Diese Beobachtungen sind nur eine *unvollständige* Spezifikation der Funktion.

Jede dieser Methoden besitzt Vor- und Nachteile sowie Voraussetzungen für eine Anwendung. Zur Beurteilung der Vor- und Nachteile sind die gewünschten betrieblichen Anforderungen an die zu realisierende Funktion von Bedeutung. Diese Anforderungen haben erhebliche Auswirkungen auf die technischen Herausforderungen.

Die wichtigsten grundsätzlichen Anforderungen und Eigenschaften an die Realisierung einer Funktion sind:

#### Korrektheit:

Muss die Realisierung der Funktion immer einen richtigen Output generieren? Z.B.: Ist es gefordert, dass wenn ein Kamerasystem zur Erkennung von fehlerhaften Werkstücken einen Fehler erkennt, tatsächlich ein Fehler vorliegt oder werden gelegentliche falsche Meldungen toleriert? D.h. ein Fehler wird gemeldet, obwohl das Werkstück in Ordnung ist.

#### Vollständigkeit:

Muss die Realisierung der Funktion für alle Inputs einen Output generieren? Z.B.: Muss die Erkennung von fehlerhaften Werkstücken immer einen Fehler melden, wenn das Kamerabild ein fehlerhaftes Werkstück enthält, oder darf das System fehlerhafte Werkstücke übersehen?

#### Echtzeitanforderung:

Müssen Outputs innerhalb einer definierten Zeitspanne erzeugt werden? Z.B.: Muss ein Kamerasystem zur Erkennung von fehlerhaften Werkstücken innerhalb einer bestimmten Zeitspanne reagieren?

#### Qualitätsgarantien:

Muss die Funktion immer den optimalen Output generieren? Z.B.: Muss ein Produktionsplanungsprogramm immer den optimalen Produktionsplan liefern, oder genügt ein Plan, der nahe beim Optimum liegt?

#### Erklärungsfähigkeit:

Müssen die Outputs der Funktion in einer für den Menschen verständlichen Form nachvollziehbar sein? D.h. kann die Berechnung eines Outputs bzw. dessen Nicht-Berechnung so erklärt werden, dass diese Erklärung von Menschen akzeptiert wird?

Diese grundsätzlichen Anforderungen werden vom Anwendungsfeld und den Zielen der Anwendung bestimmt. Diese Anforderungen bestimmen signifikant die Kosten. Abhängig von der verwendeten KI-Methode sind unterschiedliche Kosten zu erwarten. Folgende Kostenfaktoren sind zu beachten:

#### Personalkosten in der Entwicklung:

Jene Personalkosten, die bei einer ersten Realisierung der Funktion anfallen.

#### Personalkosten in der Wartung:

Jene Personalkosten, die für die Anpassung der realisierten Funktion notwendig sind.

#### Berechnungskosten für Entwicklung und Wartung:

Jene Kosten für Computerressourcen, die zur Entwicklung einer Funktion benötigt werden.

#### Berechnungskosten im produktiven Betrieb:

Jene Kosten für Computerressourcen, die im laufenden Betrieb der produktiven Anwendung der realisierten Funktion entstehen.

Die Kosten für Entwicklungswerkzeuge sind abhängig von der KI-Methode und der Anwendung. In den meisten Fällen sind diese Kosten vergleichsweise gering.

Wie üblich können die Kosten abhängig vom Grad der Individualität der zu lösenden Aufgabe durch Zukäufe von Systemen und Dienstleistungen reduziert werden. Handelt es sich um eine für das Unternehmen maßgeschneiderte Lösung, dann sind die Entwicklungskosten im Vergleich zu einer Massen-Software hoch, jedoch kann durch maßgeschneiderte Software ein strategischer Wettbewerbsvorteil erzielt werden.

Im Folgenden werden wir jeweils Checklisten und Leitfäden für die beiden wichtigsten Methodenbereiche der KI geben:

- Implementierung der Funktion durch eine Spezifikation des Input-Output-Verhaltens (I/O) (MO&L)
- Erzeugung der Funktion durch Maschinelles Lernen auf Basis von Daten

Diese Checklisten und Leitfäden basieren auf dem aktuellen Stand der Wissenschaft. Obwohl diese rückblickend auch über die letzten Jahrzehnte Gültigkeit besitzen, sind Veränderungen nicht ausgeschlossen. Insbesondere die Integration der beiden angesprochenen Methodenbereiche ist ein wichtiges Ziel aktueller Forschungsvorhaben.

Das Ergebnis dieser Checklisten ist eine grobe Einschätzung der technischen Herausforderung, um eine konkrete Aufgabe zu lösen.

Diese Checklisten sind folgendermaßen strukturiert:

1. Voraussetzungen für eine Anwendung
2. Stärken/Schwächen/Risikodämpfung
3. Kostentreibende bzw. -senkende Faktoren
4. Hausaufgaben des Unternehmens zur Vorbereitung der technischen Analyse

# 6

## Anwendung von KI-Methoden auf Basis von Modellieren und Lösen

Was Sie aus dem Kapitel mitnehmen:

- Voraussetzungen für die Anwendung des MO&L-Ansatzes
- Wesentliche Kriterien, die den Grad der technischen Herausforderung für die Anwendung dieses Ansatzes bestimmen
- Vorbereitungen zur Anwendung dieses Ansatzes

## 6.1 Voraussetzungen für eine Anwendung

MO&L setzt voraus, dass ein Mensch für *alle* zulässigen Inputs spezifizieren kann, was der gewünschte Output der zu realisierenden Funktion ist. In diesem Fall spezifiziert der Mensch vollständig das I/O-Verhalten der gewünschten Funktion (Abbildung 16).

Indikatoren und Fragen zur Prüfung dieser Voraussetzungen sind:

▶ Können die Fachexpert/innen Regeln, Formeln, Modelle oder Prozesse formulieren, sodass für alle zulässigen Inputs entschieden werden kann, ob der Output korrekt ist? Solche Beschreibungen existieren üblicherweise im Bereich der Konstruktion von technischen Systemen. Die Gesetze der Physik und Chemie sowie das Wissen der Ingenieurdisziplinen spezifizieren, wann ein technisches System die Spezifikation eines Kunden erfüllt. Ähnliches gilt im Bereich der Produktion: die Produktionsprozesse definieren, welche Fertigungsschritte durchlaufen werden müssen, um ein korrekt gefertigtes Produkt zu erhalten. Ändern sich die technischen Möglichkeiten von Fertigungsmaschinen oder ändern sich die Kundenspezifikation, so können Fachexpert/innen auf Basis des Fachwissens, das in Regeln, Formeln und Gesetzen formuliert ist, Lösungen erzeugen.

Für manche Bereiche ist aber solch eine allgemeine Spezifikation nur sehr schwer zu formulieren, oder es ist unmöglich, sie zu erstellen. Beispielsweise erfordert die visuelle Kontrolle oft sehr viel Erfahrung. Ob z.B. die Insektenstiche in einem Lederstück die Verarbeitung dieses Materials zu einem Luxusuhr-Armband zulassen, ist nur sehr schwer allgemein beschreibbar und erfordert den Aufbau von Erfahrung durch praktische Einschulung. Ein Experte erkennt auf Basis seiner Erfahrung die Qualität. Diese Erfahrungen aber genau über Regeln zu definieren, fällt oft sehr schwer.<sup>17</sup>

Für eine Prüfung der Voraussetzungen ist zu berücksichtigen, wieviel Vorwissen und vorhandene Fertigkeiten benötigt werden. Menschen besitzen ein hervorragendes visuelles System zur Erkennung von Objekten, ausgezeichnete manuelle Fertigkeiten und ein umfangreiches Allgemeinwissen über die Welt und ihre Zusammenhänge.

▶ Wenn es sich um eine Optimierungsaufgabe handelt, ist es dann möglich, dass die Fachexpert/innen die Optimierungskriterien definieren können? In manchen Fällen ist das sehr einfach, z.B. wenn die Verspätungen in der Produktion minimiert werden sollen. In manchen Fällen, insbesondere wenn es um den Geschmack von Menschen geht, ist eine allgemeine Spezifikation sehr schwierig. Wenn z.B. ein Computer ein möglichst ähnliches Porträt im Stil eines Künstlers (z.B. Egon Schiele) generieren soll, dann fällt eine allgemeine Spezifikation der Ähnlichkeit sehr schwer. Kunstexpert/innen können eine Einschätzung der Ähnlichkeit geben, wenn sie die generierten Porträts sehen und vergleichen können.

Eine weitere wichtige Voraussetzung für die Anwendung von MO&L ist die praktische Realisierbarkeit. Dies wird hauptsächlich durch die geforderten Eigenschaften der Realisierung einer Funktion bestimmt:

▶ Muss für jeden Input immer ein korrekter Output berechnet werden?  
Welche Fehler können toleriert werden?

▶ Muss immer eine optimale Lösung gefunden werden oder reicht eine zufriedenstellende Lösung?

▶ Ist die Erfüllung von Echtzeitanforderungen notwendig?

<sup>17</sup> Dies gilt interessanterweise auch für formale Wissenschaften wie Mathematik und theoretische Physik. Sehr berühmte Wissenschaftler vertreten die Auffassung, dass man die Qualität bzw. die Eleganz von Theorien „sieht“ aber dies nicht spezifizieren kann.

Die geforderten Eigenschaften der Funktion müssen eine technische Realisierbarkeit zulassen. Diese kann mit aller Vorsicht aufgrund von bereits ähnlichen Anwendungen abgeschätzt werden. Der Teufel steckt aber manchmal im Detail. Scheinbar kleine Probleme können sich als sehr schwierig entpuppen. Als Daumenregel kann man annehmen, je umfangreicher die Beschreibung eines Problems ist, und je schärfer die Forderungen nach Korrektheit, Vollständigkeit, Optimalität und Echtzeitverhalten sind, desto schwieriger ist eine technische Realisierung.

## 6.2 Stärken

Falls die Voraussetzungen erfüllt sind, ist die wesentliche Stärke des Ansatzes, dass die gewünschten Eigenschaften garantiert werden können. Das bedeutet, dass eine mögliche Forderung nach Korrektheit, Vollständigkeit, Echtzeit oder Optimalität garantiert werden kann, wobei diese Garantien von der Qualität der Beschreibungen und der technischen Realisierung abhängen.

Eine weitere Stärke dieses Ansatzes ist die Erklärbarkeit der Lösungen (der Outputs). Die Beschreibungen der Funktionen werden in der Regel durch Menschen erstellt. Daher können die Berechnungen der Lösungen durch Menschen interpretiert werden. Die verwendeten Bezeichnungen und Symbole in der Realisierung einer Funktion entsprechen den Konzepten und Modellen, wie sie von Menschen verwendet werden. Wenn z.B. eine Menge von Regelanwendungen eine Person als kreditwürdig klassifiziert, dann können Fachexpert/innen die Plausibilität oder die ethische Zulässigkeit der Regeln beurteilen sowie die Korrektheit dieser Regelanwendungen validieren, weil die Regeln auf Basis von Symbolen formuliert wurde, die Menschen in ihrem Modell über die Welt verwenden.

Werden in den Beschreibungen mögliche Änderungen berücksichtigt, dann ergibt sich eine hohe Anpassungsfähigkeit der zu realisierenden Funktion. Wird z.B. zum Zweck der Produktionsplanung einerseits ein Produktionssystem durch Maschinen und deren mögliche Fertigungsoperationen beschrieben und andererseits für jedes Produkt die notwendigen Fertigungsoperationen spezifiziert, dann kann eine automatisierte Produktionsplanung sehr einfach an neue Maschinen und Produkte angepasst werden, indem die Beschreibung des Maschinenparks und der Produkte adaptiert wird.

## 6.3 Schwächen

Die Erfüllung der oben genannten Voraussetzungen ist gleichzeitig die „Achillesferse“ dieser Methode. Es kann den Fachexpert/innen in Zusammenarbeit mit den KI-Expert/innen schwerfallen, die Beschreibungen in der notwendigen Qualität zu erstellen. Weiters können die Anforderungen an die Eigenschaften der zu realisierenden Funktion dazu führen, dass die Funktion praktisch nicht durch eine Maschine berechnet werden kann. Dies ist nicht notwendigerweise von den Fähigkeiten der KI-Expert/innen und dem aktuellen Stand der verfügbaren Computertechnik abhängig. Es gibt theoretische Limits hinsichtlich der (praktischen) Lösbarkeit von Aufgaben aufgrund von Laufzeit und Speicherverbrauch.

## 6.4 Risikodämpfung

Das Risiko der Erstellung einer Beschreibung mit hinreichender Qualität kann durch die Eingrenzung des Aufgabenbereiches reduziert werden. Wenn sich für diesen eingegrenzten Aufgabenbereich für alle Inputs beschreiben lässt, ob ein beobachteter Output zulässig ist, dann ist dies ein positiver Indikator für eine hinreichend gute Beschreibbarkeit der Aufgabe für die Anwendung von MO&L.

Das Risiko einer praktischen Erfüllbarkeit der gewünschten Eigenschaften einer Funktion bzgl. Laufzeit und Qualität des Outputs kann ebenfalls durch Anpassung des Aufgabenbereiches und der Anforderungen reduziert werden. Wenn Beschreibungen in hinreichender Qualität möglich sind und Aufgaben verbessert werden sollen, die bereits im Unternehmen abgearbeitet werden, dann ist dies ein positiver Indikator für die praktische Berechenbarkeit von Lösungen.

Können ähnliche und erfolgreich gelöste Aufgabenstellungen in anderen Unternehmen identifiziert werden, so ist dies ebenfalls ein positiver Indikator für die Realisierbarkeit der gewünschten Funktion. Möglicherweise existieren schon konkrete kommerziell verfügbare Softwarelösungen für gewünschte Aufgabenstellungen, die angepasst werden können.

Die Klassifikation der Realisierung einer Funktion als geringe technische Herausforderung auf Basis von ähnlichen, gelösten Aufgabenstellungen muss mit Vorsicht erfolgen. Kleine Unterschiede in der Aufgabenstellung können große Auswirkungen auf die technische Machbarkeit zeitigen. Machbarkeitsstudien, die experimentell die technisch schwierigen Teile einer Aufgabe lösen, geben eine sehr zuverlässige Abschätzung über die technische Realisierbarkeit und dienen so der Risikodämpfung.

## 6.5 Kostentreibende bzw. -senkende Faktoren

### Personalkosten in der Entwicklung:

Die Entwicklungskosten gestalten sich, je nachdem wie schwierig die Beschreibungen zu erstellen sind: je enger das Aufgabenfeld, desto weniger Kosten werden für die Beschreibung anfallen. Forderungen nach Korrektheit, Vollständigkeit, Echtzeitfähigkeit oder Qualitätsgarantien können erhebliche Kosten für die Entwicklung bedeuten. In vielen Fällen spielt der Umfang der Problembeschreibung und der Inputs eine große Rolle. Produktionsplanungsaufgaben mit ein paar tausend Operationen können in der Regel gut beherrscht werden. Bei Aufgaben mit mehr als einer Million Operationen muss man aber mit erheblichen Entwicklungskosten rechnen.

### Personalkosten in der Wartung:

Wenn typische Änderungen vorhersehbar sind, wie Veränderungen im Maschinenpark oder im Produktportfolio, dann können diese Anpassungen sehr kostengünstig in die Beschreibungen eingepflegt werden. Bei sehr großen Aufgaben, die oft spezielle Strategien bei der Lösungssuche erfordern, könnte ein Redesign dieser speziellen Strategie notwendig werden, was zu nennenswerten Kosten führen kann.

### Berechnungskosten für Entwicklung und Wartung:

Üblicherweise werden Stresstests nur dann durchgeführt, wenn die Beschreibungen und die Entwicklung der Funktion abgeschlossen sind. Daher werden die Berechnungskosten im Vergleich zum produktiven Betrieb geringer ausfallen.

### Berechnungskosten im produktiven Betrieb:

Je nach Größe der Aufgabe bzw. der Eigenschaften der zu realisierenden Funktion, können nennenswerte Kosten im produktiven Betrieb anfallen. Die Forderung nach einer beweisbar optimalen Lösung führt üblicherweise zu einer signifikanten Erhöhung der Berechnungskosten. Reichen Lösungen, die den aktuellen Status quo verbessern, aber möglicherweise nicht optimal sind, dann können in der Regel erhebliche Einsparungen bei den Berechnungskosten erzielt werden.

Entwicklungskosten können möglicherweise durch Zukauf von Systemen und Dienstleistungen reduziert werden. Das ist abhängig von der Individualität der Fragestellung und muss für konkrete Aufgabenstel-

lungen geprüft werden. Für klassische Aufgabengebiete wie z.B. Produktkonfiguration oder Produktionsplanung sind Systeme verfügbar, die auf die Bedürfnisse von Unternehmen angepasst werden. Jedenfalls muss aber mit Personalkosten für die Beschreibung des gewünschten Input-Output-Verhaltens gerechnet werden. Auch beim Zukauf von Systemen sind die dargestellten Faktoren ein Indikator für die Kosten des Zukaufs.

## 6.6 Hausaufgaben des Unternehmens zur Vorbereitung der technischen Analyse

Zur Beurteilung der technischen Herausforderung einer möglichen Anwendung von MO&L sollten folgende Vorbereitungen getroffen werden:

- Es sollte eine hinreichend genaue (verbale) Beschreibung der zu lösenden Aufgabe verschriftlicht werden. Wenn die Aufgabe so beschrieben werden kann, dass fachfremde Personen für alle zulässigen Inputs beurteilen können, ob ein Output eine Lösung darstellt, dann wurde bereits ein wesentlicher Schritt für einen erfolgreichen Einsatz von MO&L gesetzt.
- Wenn die zu realisierende Funktion eine Optimierungsaufgabe lösen soll, dann muss das Unternehmen möglichst exakt beschreiben können, was das Optimierungskriterium ist. Eine mathematische Formulierung ist wünschenswert. Eine allfällige verbale Beschreibung sollte fachfremden Personen ermöglichen, die Qualität von Lösungen zu vergleichen. Es gibt Anwendungsbereiche, in denen Fachexpert/innen nur einen Qualitätsvergleich von Lösungen durchführen können, wenn sie die Lösungen „sehen“. Dieser Umstand ist ein starkes Indiz dafür, dass das Optimierungskriterium nicht hinreichend beschreibbar ist.
- Anforderungen und Eigenschaften sollten klar definiert und mit Prioritäten versehen werden. Wenn möglich, sollten Indikatoren spezifiziert werden, welche die Qualität der realisierten Funktion beurteilen. Wie können wir messen, wann eine realisierte Funktion zufriedenstellend arbeitet?

Liegen solche Beschreibungen vor, dann sind wichtige und notwendige Vorarbeiten zur Analyse eines möglichen Einsatzes von MO&L erledigt.



# 7

## Anwendung von KI-Methoden auf Basis des Maschinellen Lernens

Was Sie aus dem Kapitel mitnehmen:

- Voraussetzungen für die Anwendung des ML-Ansatzes
- Wesentliche Kriterien, die den Grad der technischen Herausforderung für die Anwendung dieses Ansatzes bestimmen
- Vorbereitungen zur Anwendung dieses Ansatzes

## 7.1 Voraussetzungen für eine Anwendung

Die wichtigste Voraussetzung für eine Anwendung von Methoden aus dem Bereich Maschinelles Lernen (ML) ist, relevante Daten in ausreichender Quantität und Qualität verwenden zu können. Aus diesen Daten erzeugt ML selbstständig eine Funktion. D.h. für Inputwerte, die noch nie beobachtet wurden und die daher nicht in den Daten vorhanden sind, generiert ein ML-Verfahren einen Output. Die Prognose der Qualität der erzeugten Funktion und deren Tauglichkeit im produktiven Einsatz sind daher von zentraler Bedeutung.

Um zu beurteilen, ob relevante Daten vorhanden sind, muss wie bei MO&L die Aufgabe möglichst klar definiert werden. Es sollten möglichst präzise Vorstellungen über die Outputs existieren. Wenn Problemlösungen beispielhaft vorliegen, dann ist es in der Regel einfach, die Aufgabe zumindest annähernd zu beschreiben. Wenn aber Daten auf Muster, Häufungen und Zusammenhänge untersucht werden sollen, dann ist der gewünschte Output eine Beschreibung dieser Zusammenhänge, wobei sich dieser Output erst durch die Anwendung von unüberwachtem Lernen herauskristallisiert. In diesem Fall ist eine Beschreibung des gewünschten I/O-Verhaltens schwieriger als im Fall des Lernens durch Beispiele (überwachtes Lernen).

Die Identifikation der relevanten Inputs wird im ML als *Feature Engineering* bezeichnet. Die Menge der Features (Inputs) darf einerseits nicht zu klein gewählt werden, da sonst keine akzeptable Funktion gelernt werden kann. Andererseits darf diese Menge auch nicht zu umfangreich sein, da sonst sowohl die Qualität der gelernten Funktion möglicherweise unbefriedigend ist als auch das Erzeugen der Funktion unnötig viele Berechnungsressourcen verbraucht. Im schlimmsten Fall wird durch eine große Menge an Input-Features ein Lernen der Funktion verhindert. Die manuelle Vorauswahl von Input-Features ist nach wie vor ein wesentlicher Faktor für den erfolgreichen Einsatz von ML.

### Indikatoren und Fragen zur Prüfung der Relevanz von Daten:

- Kann klar beschrieben werden, was der gewünschte Output der Funktion ist? Um diese Frage zu beantworten, ist es hilfreich, zu überlegen, wie eine Teststrategie der gelernten Funktion realisiert werden kann. Angenommen, das Ziel ist, Produktempfehlungen für Kunden zu lernen, dann sollte festgestellt werden können, wann eine konkrete Produktempfehlung erfolgreich war.
- Können jene nützlichen Input-Features identifiziert werden, von denen wir annehmen, dass diese den Output beeinflussen? Können wir beispielsweise davon ausgehen, dass die Vorlieben von Kunden bei getätigten Einkäufen von Wein auch die Auswahl bei zukünftigen Weinkäufen bestimmen werden?

### Indikatoren und Fragen zur Prüfung der ausreichenden Quantität von Daten:

- Sind Datensätze für die identifizierten Input-Features vorhanden und dürfen diese verwendet werden? Existieren Beispiele für das gewünschte I/O-Verhalten? Lernen auf Basis von Beispielen benötigt sowohl Werte für die Input-Features als auch für den gewünschten Output.
- Falls diese Datensätze nicht vorhanden sind, können diese Datensätze erzeugt und aktuell gehalten werden? Was sind die rechtlichen Rahmenbedingungen? Wie teuer wird eine allfällige Erzeugung der Datensätze?
- Falls Datensätze vorhanden sind, ist deren Umfang ausreichend? Für die Beantwortung dieser Frage gibt es aktuell nur Daumenregeln. Beispielsweise mindestens 100 bis 1.000 Datensätze pro Outputwert; mehr als  $K \times d \times \log d$  Datensätze, wobei  $K$  eine hinreichend große Konstante ist, z.B. 10, und  $d$  die Anzahl an Input-Features, etc.

Die Anzahl der notwendigen Datensätze hängt vom verwendeten ML-Verfahren, von der Auswahl der Daten und deren Qualität ab. Die erstaunlichen Erfolge von ML in den letzten Jahrzehnten beruhen zum Großteil auf der Verfügbarkeit von großen Datenmengen. Die aktuellen Lernverfahren sind datenhungrig. Je mehr Datensätze vorhanden sind, desto größer ist die Erfolgswahrscheinlichkeit. Aber viele Daten sind noch keine Erfolgsgarantie.

## Indikatoren und Fragen zur Prüfung der ausreichenden Qualität von Daten:

- Wie wurden die Datensätze gewonnen? Erfolgte die Eingabe manuell oder automatisiert? Erfahrungsgemäß sind manuell erfasste Daten fehleranfällig. Gibt es Verfahren, die die Qualität der Daten überprüfen bzw. sicherstellen oder Datenfehler korrigieren?
- Sind die Datensätze vollständig oder fehlen Werte?
- Sind die Prozeduren zur Datengewinnung stabil?
- Sind die Beobachtungen, die Daten liefern, klar definiert? Ist die Definition stabil oder hat es Änderungen geben?
- Decken die Daten alle möglichen Fälle in einem ausreichenden Maß ab? Beispielsweise wird man bei der Erkennung von betrügerischen Verwendungen von Kreditkarten wesentlich mehr Transaktionen beobachten können, in denen die Kreditkarte korrekt verwendet wurde, als in jenen, in denen eine Betrugsabsicht vorlag.
- Sind die möglichen Werte der Input-Features wohl definiert und in Symbolen oder Zahlen abgespeichert? Fallweise sind Werte nur in (natürlichsprachlichen) Texten enthalten. Das Erkennen von Werten für Input-Features aus Texten kann zu zusätzlichen Fehlern in den Datensätzen führen.

## Indikatoren und Fragen zur Prüfung der ausreichenden Qualität der gelernten Funktion:

- Ist es möglich, ein Monitoring des gelernten Systems durchzuführen, um die Qualität der Outputs zu erkennen? Kann auf Basis dieser Beobachtungen erkannt werden, dass die gelernte Funktion aktualisiert werden muss? Wenn z.B. ein ML-basiertes KI-System entwickelt wird, um Spam-E-Mails zu filtern, wie kann man die Qualität dieses Filters beurteilen? Wie erkennt man, dass der Filter nicht mehr aktuell ist?
- Ist dieses Monitoring technisch und rechtlich möglich? Muss bei der Beurteilung eines Spam-Filters das Benutzerverhalten beobachtet werden, so müssen die rechtlichen Voraussetzungen geklärt werden.
- Können allfällige Fehler des ML-Systems toleriert oder durch geeignete Maßnahmen neutralisiert werden? Diese Frage muss für unterschiedliche Fehlerklassen geprüft werden. Ist es z.B. tolerierbar, dass eine lesenswerte E-Mail als Spam gekennzeichnet wird? Umgekehrt, ist es tolerierbar, dass eine Spam-Mail als lesenswert klassifiziert wird? Maßnahmen zur Fehlerneutralisierung können z.B. dadurch ergriffen werden, dass Systeme nur assistieren und der Mensch eine endgültige Entscheidung trifft. Ist dieses Vorgehen im praktischen Betrieb realistisch und zu verantworten?

## 7.2 Stärken

Die herausragende Stärke des ML-Ansatzes ist die automatische Erzeugung der zu realisierenden Funktion auf Basis von Datensätzen. Anders als beim MO&L muss hier der/die Entwickler/in des Systems keine Beschreibung liefern, die darauf abzielt, alle gewünschten I/O-Kombinationen zu definieren. Im Idealfall kann automatisch die gewünschte Funktion auf Basis des beobachteten I/O-Verhaltens generiert werden. Typischerweise werden ML-Methoden in jenen Bereichen verwendet, in denen eine Lösung der Aufgabe mit MO&L *nicht möglich* ist.

Wurde eine Funktion erzeugt, dann kann die Auswertung dieser Funktion in Abhängigkeit der angewendeten Lernmethode sehr effizient und mit einer garantierten Antwortzeit erfolgen. Wird z.B. ein Künstliches Neuronales Netz (KNN) erlernt, um die gewünschte Funktion zu realisieren, dann kann die Laufzeit für KNNs mit azyklischen Neuronenverbindungen sehr gut prognostiziert werden. Die Anzahl der Neuronen ist fix, die Daten fließen ohne Schleifen von den Inputs zum Output und die Verarbeitung kann parallelisiert werden.

## 7.3 Schwächen

Die Stärke der automatischen Erzeugung der zu realisierenden Funktion ist gleichzeitig ihre größte Schwäche. Da die Funktion selbstständig erzeugt wird, kann die Qualität des I/O-Verhaltens für Inputs, die noch nie beobachtet wurden, nur auf Basis der vorhandenen Datensätze abgeschätzt werden. Dadurch können keine Qualitätsgarantien hinsichtlich Vollständigkeit, Korrektheit oder Optimalität der Aufgabenlösung gegeben werden.

Zum aktuellen Stand der Forschung kann nicht vorhergesagt werden, welche ML-Methode eine befriedigende Erzeugung einer Funktion zulässt. Welche von diesen sich für eine konkrete Anwendung besonders gut eignet und welche Parameter dieser Methode für einen konkreten Anwendungsfall optimal sind, kann aktuell nur explorativ bestimmt werden. Zwar kann eine Funktion durch eine ML-Methode automatisch erzeugt werden, aber für die Anwendung und für das Tuning müssen in den meisten Fällen Vorbereitungsarbeiten von geschulten Expert/innen durchgeführt werden. So muss etwa bei der Anwendung von KNNs der Aufbau des Netzwerkes festgelegt werden. Darüber hinaus hängt der Erfolg eines ML-Ansatzes signifikant von Quantität und Qualität der Daten und der Auswahl der Input-Features ab.

Für die Erzeugung der Funktion sind in Abhängigkeit von der verwendeten ML-Methode erhebliche Rechenressourcen notwendig. So müssen für alle Trainingsbeispiele je nach Aufbau eines KNNs tausende numerische Parameter angepasst werden. Für jede Adaption des KNNs oder der zu lernenden Funktion muss dieser Lernvorgang wiederholt werden.

In Abhängigkeit des verwendeten ML-Ansatzes können keine Erklärungen zur Generierung eines Outputs gegeben werden. Zum Beispiel kodieren KNNs das Wissen über den I/O-Zusammenhang in eine Vernetzung der Neuronen und in numerische Gewichte. Vom Menschen interpretierbare Symbole sind in KNNs meistens nicht vorhanden. Aber es gibt auch ML-Ansätze, wie z.B. die Generierung von Entscheidungsbäumen, die eine Erklärung eines Outputs auf Basis von Symbolen zulassen, die der Mensch zur Beschreibung von Sachverhalten verwendet.

Die Integration von Schlussfolgerungen und Berechnungen in ML-Methoden ist aktuell schwierig und Gegenstand von intensiven Forschungsaktivitäten.

## 7.4 Risikodämpfung

Ein wesentlicher Faktor zur Minderung des Risikos ist eine stabile, definierte und möglichst automatische Erzeugung der Datensätze, die für die Generierung der Funktion verwendet werden. Die Verwendung von Datenbanken mit klar spezifizierten Relationen und Werten unter Einhaltung der üblichen Normalformen ist eine sehr gute Grundlage für eine erfolgreiche Anwendung von ML. Datenmodelle ändern sich über die Zeit. Folglich ist eine Dokumentation der Änderungen sowie eine genau spezifizierte Anpassung von Datenbankrelationen ein wichtiger Faktor, um Daten für ML verwenden zu können.

Ebenso wirkt eine klare und gut abgegrenzte Aufgabe risikodämpfend. Aufgaben in ähnlicher Form, die schon erfolgreich gelöst wurden, sind Hinweise auf ein geringes Risiko. Können Aufgaben von Expert/innen aufgrund von wohldefinierten Messungen und Beobachtungen sowie Erfahrungen ohne umfangreiches Allgemein- und Fachwissen gelöst werden, so ist dies ein Indikator für einen erfolgreichen Einsatz von ML.

Die Identifikation der nützlichen Features ist ein Schlüssel für den erfolgreichen Einsatz von ML. Existiert im Unternehmen schon Wissen, welche Faktoren den Output einer zu realisierenden Funktion bestimmen und welche Faktoren dominant oder eher nebensächlich sind, so wirkt sich dies ebenfalls risikodämpfend aus.

## 7.5 Kostentreibende bzw. -senkende Faktoren

### Personalkosten in der Entwicklung:

Der Reifegrad eines Unternehmens bzgl. einer qualitativ hochwertigen Erfassung von Datensätzen ist ein bestimmender Kostenfaktor. Hinsichtlich der Qualität von Daten wird eine defensive Einschätzung empfohlen. Die Qualitätskontrolle und die Aufbereitung von Datensätzen können erhebliche Personalkosten verursachen. Wenn allerdings umfangreiche, wohldefinierte und qualitätsgesicherte Datenbestände vorliegen, die gewünschte I/Os beispielhaft beschreiben, dann hat dies eine hohe kostendämpfende Wirkung auf die Anwendung von ML-Methoden.

Wird durch die zu lösenden Aufgaben Neuland in der Anwendung von ML betreten, so könnte eine experimentelle Phase notwendig werden, in der die zu verwendende ML-Methode bestimmt wird. Erhöhte Personalkosten sind die Folge.

### Personalkosten in der Wartung:

Werden die Veränderungen einer Aufgabe in den Daten widerspiegelt, dann ergibt sich eine Anpassung durch die automatische Generierung einer neuen Funktion. Ist z.B. die zu realisierende Funktion eine Prognose des Kundenverhaltens, und wird das Kundenverhalten durch aktualisierte getätigte Einkäufe umfangreich beschrieben, so kann ein geändertes Kaufverhalten durch das Lernen einer adaptierten Funktion berücksichtigt werden. Die Personalkosten in der Wartung sind in diesem Fall als gering einzustufen.

Werden die Veränderungen einer Aufgabe von den Datensätzen nicht abgedeckt, so muss unter Umständen eine Neuentwicklung der ML-Anwendung durchgeführt werden. Wurde etwa ein Diagnosesystem für eine Maschine auf Basis von ML entwickelt, und die Maschine wird im Zuge einer Modernisierung umgebaut, so müssen für diese adaptierte Maschine neue Datensätze beobachtet und eine neue Diagnosefunktion erzeugt werden.

### Berechnungskosten für Entwicklung und Wartung:

Die Berechnungskosten für die Erzeugung einer Funktion können in Abhängigkeit der verwendeten ML-Methode erheblich sein. Dies ist bei der Identifikation von ähnlichen Aufgabenstellungen zwecks Einschätzung der Machbarkeit zu berücksichtigen. Aufgaben, die für ein Unternehmen mit umfangreichen Ressourcen an Rechnerleistung lösbar sind, können für ein mittelständisches Unternehmen aufgrund der hohen Kosten praktisch unlösbar sein.

### Berechnungskosten im produktiven Betrieb:

Wenn Lernen durch Beispiele verwendet wird, dann sind üblicherweise die Kosten der Anwendung der gelernten Funktion im Vergleich zum Erzeugen der Funktion gering.

Bei unüberwachtem Lernen kommt es auf die Verwendung der Lernergebnisse an. Ist das gelernte Muster das produktive Ergebnis, so sind die Berechnungskosten im produktiven Betrieb ähnlich den Berechnungskosten bei der Entwicklung, z.B. regelmäßiges Lernen von Kundentypen. Dient unüberwachtes Lernen zur Erzeugung von Regeln, die produktiv angewendet werden, dann ist die Anwendung dieser Regeln im Vergleich zur Erzeugung der Regeln wesentlich kostengünstiger.

Für die Entwicklung von ML-Anwendungen existieren zahlreiche Software-Bibliotheken, die oft frei verfügbar sind. Auch wenn bereits ähnliche Aufgaben in anderen Bereichen oder Unternehmen gelöst wurden, so ist in den meisten Fällen eine Anpassung der entwickelten ML-Anwendung an die aktuelle Situation der Datenhaltung eines Unternehmens erforderlich.

## 7.6 Hausaufgaben des Unternehmens zur Vorbereitung der technischen Analyse

Zur Beurteilung der technischen Herausforderung einer möglichen Anwendung von ML sollten folgende Vorbereitungen getroffen werden:

- Möglichst präzise Definition der Daten, die verwendet werden können: Wenn Datenbanken vorhanden sind, dann sollte eine genaue Beschreibung des Datenbankschemas vorliegen sowie die Bedeutung der Werte.
- Bewertung der Qualität der Daten: Sind die Datensätze vollständig bzw. ist mit Fehlern zu rechnen? Wie wurden die Daten gewonnen? Erfolgt eine Qualitätssicherung der Daten?
- Quantität der Daten: Wie groß ist der Umfang an vorhandenen Daten hinsichtlich Menge und Historie? Wie wird sich die Datenerfassung in der Zukunft gestalten?
- Konkretisierung der Aufgaben und der Erwartungshaltung: Welche Outputs erwartet man sich von der zu lernenden Funktion? Welche Erwartungen gibt es bzgl. des produktiven Einsatzes der gelernten Funktion und existieren Indikatoren, um den Erfolg zu messen? Welche Qualität soll der Output aufweisen? Welche Fehler der gelernten Funktion könnten toleriert werden und welche Fehler können nicht toleriert werden? Gibt es Daten, die beispielhaft den gewünschten Output beschreiben?
- Identifikation der Input-Features: Gibt es Wissen über den Zusammenhang zwischen den vorhandenen Daten oder möglichen neuen Datenquellen und den gewünschten Outputs der zu lernenden Funktion?

Diese Beschreibungen sind notwendige Vorarbeiten, die selbstständig im Unternehmen durchgeführt werden können und die letztlich für die Prüfung eines möglichen Einsatzes von ML notwendig sind.

# 8

## Managementaufgaben für eine erfolgreiche Einführung von KI-Methoden

Was Sie aus dem Kapitel mitnehmen:

- Organisatorische Rahmenbedingungen für eine erfolgreiche Einführung von KI-Methoden
- Weitere Vorbereitungsschritte für den Start einer Umsetzung

## 8.1 Organisatorische Rahmenbedingungen

Die Anwendung von KI-Methoden in der betrieblichen Praxis ist wie die meisten Innovationsprojekte gut zu meistern, wenn die notwendigen Voraussetzungen geschaffen werden und eine sorgfältige Planung unter Berücksichtigung der Risikofaktoren und Unsicherheiten durchgeführt wird. Je unbekannter das Terrain ist, je unsicherer die Umgebungsbedingungen einer Expedition sind, umso genauer muss die Planung durchgeführt werden, um den Erfolg sicherzustellen.

Die Einführung von KI-Methoden betreffen in der Regel weite Teile eines Unternehmens. Wir wissen aus der Innovationstheorie, gestützt auf Daten der betrieblichen Praxis, dass es unterschiedliche Promotoren benötigt. Innovationen sind dann besonders erfolgreich, wenn die Geschäftsleitung dem Innovationsprojekt unmissverständlich und sichtbar hohe Priorität und die notwendigen Ressourcen gibt. KI-Projekte brauchen aber auch das Know-how der Fachexpert/innen eines Unternehmens, die bestens über Verfahren und Prozesse des Unternehmens informiert sind. Letztlich müssen die Ergebnisse eines KI-Projektes in ein Unternehmen integriert werden. Dazu benötigt man Menschen, welche die formellen und informellen Strukturen eines Unternehmens kennen und gut vernetzt sind.

Sollten KI-Experten von außen in das Unternehmen geholt werden, muss eine offene und wertschätzende Kommunikation auf Augenhöhe gegeben sein. Die Unternehmensleitung muss überzeugend kommunizieren, dass ein KI-Projekt keine Bedrohung, sondern eine wichtige Chance für das Unternehmen und seine Mitarbeiter/innen darstellt. Daten und Know-how werden in einem umfangreichen Maß benötigt und müssen zur Verfügung gestellt werden.

Die Einführung von KI-Methoden wird begünstigt, wenn bereits ein hoher Digitalisierungsgrad erreicht ist. Bildlich gesprochen wird die Umsetzung eines KI-Projekts erleichtert, wenn das Unternehmen bereits viele digitale „Ohren und Augen“ besitzt, um den Zustand des Unternehmens zu erfassen, und wenn viele digitale „Hände“ existieren, um Aufgaben zu erledigen. Die Einführung von KI-Methoden kann Hand in Hand gehen mit der Einführung von automatischer Datenerfassung durch Sensoren und der Automatisierung der Prozesse durch Roboter. Ein umfassender strategischer Masterplan hilft, die Innovationsprojekte abzustimmen.

## 8.2 Weitere Schritte

Betrachten wir den Gesamtprozess zur Einführung von KI-Methoden, so können typischerweise die in Abbildung 17 dargestellten Schritte durchlaufen werden. Die Erstellung eines Projektportfolios liefert als Ergebnis eine Menge von möglichen Umsetzungs- oder Forschungsprojekten. Diese möglichen Projekte sind jeweils auf Kosten und Nutzen zu evaluieren, um auf dieser Basis eine Durchführungsentscheidung zu treffen. Das Ergebnis von Forschungsprojekten ist in der Regel ein Wissenszuwachs, der eine Neubewertung des Projektes ermöglicht. Idealerweise kann das Projekt nach der Forschungsarbeit als Umsetzungsprojekt klassifiziert und einer detaillierten Kosten- und Nutzenanalyse unterzogen werden.

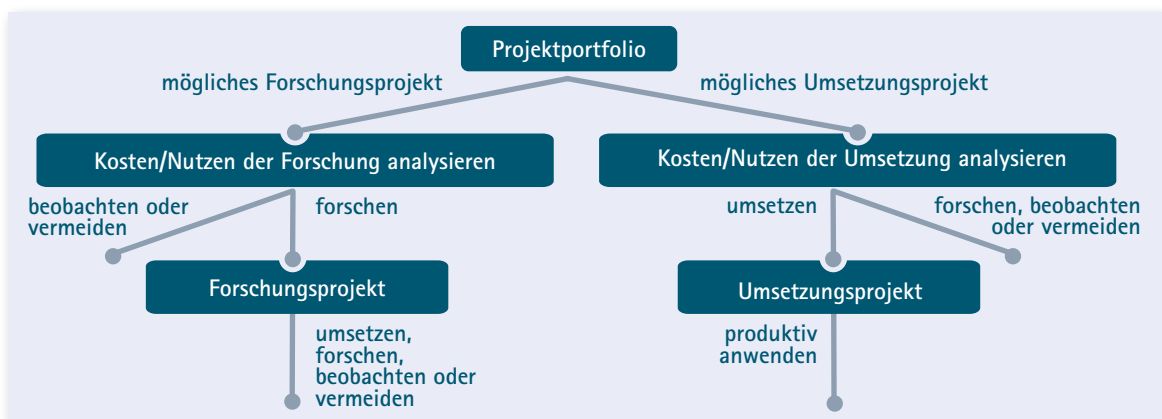


Abbildung 17: Analyse des Projektportfolios



Für alle diese Aktivitäten zur Einführung von KI-Methoden ist fachspezifisches Know-how notwendig. Insbesondere ist zu berücksichtigen, dass erfolgreiche Umsetzungsprojekte zu einem langfristigen Know-how-Bedarf hinsichtlich der Anpassung und Weiterentwicklung führen.

Wie üblich stehen die Unternehmen vor der Entscheidung, dieses notwendige Know-how von anderen Organisationen einzukaufen oder selbst im Haus aufzubauen. Je nach Anwendung können auch Netzwerke gebildet werden, die gemeinsame Forschung und Umsetzung kooperativ organisieren.

Entscheidet man sich, Know-how im Haus aufzubauen, so sind Forschungsk Kooperationen mit Universitäten, Hochschulen oder Forschungsorganisationen ein sehr effektives Werkzeug. Der beste Weg, um Know-how zu transferieren, ist der Transfer von Mitarbeiter/innen. Forschungsprojekte mit Universitäten, Hochschulen oder Forschungsorganisationen ermöglichen die Gewinnung von Personen, die sowohl unternehmensspezifisches Know-how als auch Wissen über KI besitzen. Mit einem Wechsel von Personen aus den kooperativen Forschungsprojekten in ein Unternehmen kann ein Know-how-Aufbau realisiert werden, der zielgerichtet das Wissen über die benötigten KI-Methoden und deren fachspezifische Anwendung in das Unternehmen transferiert. Unternehmen arbeiten schon seit Jahrzehnten sehr erfolgreich mit dieser Methode, um frisches KI-Know-how in die operativen Bereiche eines Unternehmens zu transferieren.

Zur Finanzierung von innovativen Projekten stehen auf Ebene der Europäischen Union, der Nationalstaaten und der Provinzen Fördermittel zur Verfügung. Es gilt die Daumenregel, dass je forschungsintensiver das Vorhaben ist, desto höher der Förderanteil ausfällt. Förderung ist aber nicht notwendigerweise an Forschung gebunden. Risikoreiche, experimentelle Entwicklung hat ebenfalls Chancen, gefördert zu werden.

# 9

## Resümee

KI wird bereits sehr breit eingesetzt, um die Produktivität zu erhöhen, die Qualität zu verbessern und die Prozesse zu beschleunigen sowie die Flexibilität zu steigern. Darüber hinaus erlaubt KI, neue Produkte und Dienstleistungen zu entwickeln. Für viele Unternehmen ist es daher nur noch eine Frage der Zeit, bis KI angewendet werden muss.

Dieser Leitfaden erklärt die Grundprinzipien der zurzeit erfolgreichsten KI-Methoden, um ein grundlegendes Verständnis aufzubauen. Durch dieses Verständnis können Entscheidungsträger/innen zwei wichtige Fragen beantworten und Einschätzungen treffen: (1) Wo kann KI sinnvollerweise im Unternehmen eingesetzt werden und (2) welche technischen Herausforderungen sind zu erwarten?

Zur Unterstützung der Beantwortung der Frage nach den Anwendungsmöglichkeiten haben wir einerseits beispielhaft typische Einsatzgebiete von KI in den Wertschöpfungsbereichen skizziert. Andererseits erlaubt ein allgemeines Grundverständnis der KI eine kreative Suche nach Anwendungsmöglichkeiten mit hohem Potential.

Zur Beantwortung der Frage nach den technischen Herausforderungen haben wir für die wichtigsten KI-Methoden die Anwendungsvoraussetzungen, Stärken und Schwächen sowie Risiko- und Kostenfaktoren ausführlich diskutiert. Auf Basis dieser Einschätzungen kann ein Projektportfolio entwickelt werden, das zur Identifikation der erfolgversprechenden KI-Projekte dient. Für die Umsetzung von KI-Projekten haben wir die weiteren Schritte dargestellt sowie die hausinternen Aufgaben formuliert, die zur Vorbereitung einer Umsetzung von KI-Projekten notwendig sind.

Die Einführung von KI-Methoden in Unternehmen sind Innovationsprojekte, die mit sorgfältiger Planung erfolgreich durchgeführt werden können. Dieser Leitfaden gibt den Einstieg für diese Planungsarbeit und liefert daher einen Beitrag für die Weiterentwicklung von Unternehmen durch KI.

Die historische Entwicklung der KI, insbesondere die öffentliche Wahrnehmung der KI, verlief immer in Zyklen, und wir haben allen Grund zur Annahme, dass diese Dynamik auch die zukünftige Entwicklung der KI charakterisieren wird. Zur Erreichung einer *Generellen KI*, d.h. die vollständige Automatisierung der kognitiven Fähigkeiten des Menschen, sind noch viele wissenschaftliche Durchbrüche notwendig. Folglich ist aus praktischer Sicht die KI als wissenschaftliche Disziplin zu sehen, die voraussichtlich kontinuierlich Werkzeuge mit signifikanten Auswirkungen auf die Gesellschaft und die Unternehmen liefern wird. Eine stetige Beobachtung der Entwicklung der KI ist daher für innovative Unternehmen erforderlich.



Handelskammer Bozen  
PID - Digitales Unternehmen  
Südtiroler Straße 60  
I - 39100 Bozen  
Tel. +39 0471 945 691  
[digital@handelskammer.bz.it](mailto:digital@handelskammer.bz.it)  
[www.handelskammer.bz.it](http://www.handelskammer.bz.it)

© 2022 Handels-, Industrie-, Handwerks-,  
Tourismus- und Landwirtschaftskammer Bozen