



# ARTIFICIAL INTELLIGENCE

**Zusammenspiel des Maschinellen Lernens  
mit Künstlicher Intelligenz**

**E-Book**

#### Herausgeber

SIGS DATACOM GmbH  
Lindlaustraße 2c  
53842 Troisdorf

[info@sigs-datacom.de](mailto:info@sigs-datacom.de)  
[www.sigs-datacom.de](http://www.sigs-datacom.de)

Copyright © 2018 SIGS DATACOM GmbH  
Lindlaustr. 2c  
53842 Troisdorf

Die vorliegende Publikation ist urheberrechtlich geschützt. Alle Rechte vorbehalten. Die Verwendung der Texte und Abbildungen, auch auszugsweise, ist ohne die schriftliche Zustimmung des Herausgebers urheberrechtswidrig und daher strafbar. Dies gilt insbesondere für die Vervielfältigung, Übersetzung oder die Verwendung in elektronischen Systemen.

Es wird darauf hingewiesen, dass die in der Broschüre verwendeten Soft- und Hardware-Bezeichnungen sowie Markennamen und Produktbezeichnungen der jeweiligen Firmen im Allgemeinen warenzeichen-, marken- oder patentrechtlichem Schutz unterliegen. Alle Angaben und Programme in dieser Broschüre wurden mit größter Sorgfalt kontrolliert. Weder Autor noch Herausgeber können jedoch für Schäden haftbar gemacht werden, die im Zusammenhang mit der Verwendung dieser Broschüre stehen.

Wo nicht anders angegeben, wurde auf die im Text verlinkten Quellen zurückgegriffen.

<b>Vorwort</b>	<b>4</b>
<b>1 Einleitung</b>	<b>5</b>
<b>2 Maschinelles Lernen in der Künstlichen Intelligenz</b>	<b>6</b>
<b>3 Beispiele Ansätze Künstlicher Intelligenz</b>	<b>9</b>
3.1 Das Multilayer Perceptron für Klassifikationsaufgaben	9
3.2 Überwachtes Lernen im Deep Learning	12
3.2.1 Reinforcement Learning	12
3.2.2 Künstliche Neuronale Netze + Reinforcement Learning = Deep Learning	13
3.3 Entwicklung des Deep Learning hin zu Convolutional Neural Networks	13
3.4 Kognitive Systeme	14
3.4.1 Kognitive Grundvorstellungen	14
3.4.2 Entwicklung von Sachkenntnis und Problemlösung	16
<b>4 Anwendungsbeispiele</b>	<b>17</b>
4.1 Einsatzgebiete der Künstlichen Intelligenz	18
4.1.1 Mensch-Maschine-Kommunikation	18
4.1.2 Maschine-Maschine-Kommunikation	19
4.1.3 Automatisierung	19
<b>5 Fazit</b>	<b>21</b>
<b>Literatur</b>	<b>22</b>
<b>Über unseren Sponsoren</b>	<b>23</b>

## Vorwort

Die rasende technologische Entwicklung der letzten Dekade hat zu fundamentalen Änderungen in nahezu allen Bereichen unseres Lebens geführt und damit auch betriebliche Entwicklungen in allen Organisationen motiviert. Im privaten Leben unterstützen uns Verfahren der Künstlichen Intelligenz durch Sprachassistenten oder erweiterte Suchverfahren auf unseren mobilen Endgeräten. In Unternehmen entstanden Produktionsumgebungen, die Künstliche Intelligenz einsetzen, physische Komponenten mittels Internettechnologien vernetzen und diese Strukturen noch um nicht-physische Bausteine zu sogenannten Cyber-Physical-Systems erweitern. Ein solches Internet of Things ermöglicht durch die eingesetzte Intelligenz eine weitgehende Prozessautomation in allen Bereichen eines Unternehmens und eine weitgehende Entscheidungsunterstützung. Damit werden Echtzeitsysteme und dabei eine Echtzeit-Analytics relevant, die mittels Verfahren der Künstlichen Intelligenz umgesetzt werden. Diese Verfahren gibt es in der Diskussion des Maschinellen Lernens schon seit vielen Jahrzehnten, nur werden diese heutzutage durch die technischen Entwicklungen nutzbar. Um sie jedoch angemessen einsetzen und nutzen zu können, ist ein Verständnis über die Entwicklungen und Arbeitsweisen des Maschinellen Lernens und der Künstlichen Intelligenz notwendig, dem sich das hier vorliegende E-Book widmet. Dabei werden auch Einsatzbeispiele vorgestellt, um das Potenzial der Künstlichen Intelligenz einschätzen und eigene Nutzungsszenarios gestalten zu können.

## 1 Einleitung

Künstliche Intelligenz gewinnt in Unternehmen, Verwaltungen und unserem täglichen Leben an Bedeutung. In vielen Situationen erfahren wir bereits heute Unterstützung durch Methoden der Künstlichen Intelligenz. Grundlage dessen sind Innovationen, die in der Prozessor- und Speichertechnologie, im Cloud-Computing, der Sensorik, dem Internet der Dinge und der Robotik stattfanden, von denen die Nutzung der Künstlichen Intelligenz profitiert. Zwar stehen wir beim Einsatz von KI-Systemen trotz aller Fortschritte noch ganz am Anfang. „Dank Big Data und algorithmischen Fortschritten wie Deep Learning hat sich das Feld des Maschinellen Lernens in den letzten Jahren rasant weiterentwickelt. Während in der Vergangenheit Maschinelles Lernen häufig offline nach kritischem Review durch Experten und in unkritischen Anwendungen – etwa der Werbeplatzierung im Internet – genutzt wurde, wird es heutzutage mehr und mehr in operativen und sicherheitskritischen Systemen auf 24/7 Basis eingesetzt. Selbstfahrende Autos, medizinische Entscheidungsunterstützung und das Monitoring technischer Infrastruktur sind Beispiele. Diese Fortschritte sind von den Trends Big Data und Digitalisierung getrieben, die sowohl mehr Daten für die automatische Analyse bereitstellen als auch schnellere und komplexere Entscheidungen in kontinuierlichen Datenanalyseprozessen verlangen.“ [BITKOM 2017]

Die Entwicklungen der vergangenen Jahre haben, wie bereits erwähnt, nicht nur die verfügbaren Rechenkapazitäten an den Arbeitsplätzen erhöht, sondern auch die Datenverfügbarkeit und damit die Grundlage datengetriebener Entscheidungsfindung. Darüber hinaus sind Machine-Learning-Algorithmen in den letzten Jahren leistungsfähiger geworden. Insbesondere der Ansatz des Deep Learning, also dem Maschinellen Lernen mit großen neuronalen Netzen, ist aktuell ein oftmals benannter Analyseansatz und damit die Referenz zur Auswertung großer, verauschter Datenmengen und steckt hinter aktuellen Fortschritten etwa in der Text-, Bild- und Spracherkennung. Es hat sich in prominenten Beispielen bereits gezeigt, dass Deep Learning selbst menschliche Experten schlagen kann. Dies ist ein Effekt der hohen Anpassungsfähigkeit dieser tiefen neuronalen Netze, gepaart mit der Möglichkeit, diese Netze auch auf großen Datenmengen effizient zu trainieren.

Im Folgenden werden nun zunächst die Begriffe Künstliche Intelligenz und Maschinelles Lernen zueinander eingeordnet, sodass daran anschließend im dritten Kapitel Verfahren der Künstlichen Intelligenz methodisch eingeführt werden. Kapitel 4 skizziert Anwendungsbeispiele, sodass Einsatzpotenziale ersichtlich sind.

## 2 Maschinelles Lernen in der Künstlichen Intelligenz

Maschinelles Lernen (ML) bezeichnet Verfahren, bei denen Computer-Algorithmen aus Daten lernen, beispielsweise Muster zu erkennen oder gewünschte Verhaltensweisen zu zeigen, ohne dass jeder Einzelfall explizit programmiert wurde. So lernen Algorithmen im Online-Buchhandel, dass es bestimmte Klassen von Büchern gibt, die von bestimmten Klassen von Kunden gekauft werden, ohne, dass irgendwo im Vorfeld definiert würde, was Liebesromane sind oder was ein junger Familienvater ist. Autonome Fahrzeuge können schlicht dadurch lernen, dass Menschen sie eine Zeitlang steuern. Mit diesem Verfahren wird auch das automatische Labeln von Bildern trainiert. Menschen ergänzen hierbei Bilder z. B. mit der Information, ob ein Gesicht fröhlich oder traurig erscheint, und nach mehreren Tausenden oder Zehntausenden Beispielen kann dann ein Algorithmus lernen, neue Bilder selbst zu klassifizieren. Oft wird Maschinelles Lernen mit künstlicher Intelligenz gleichgesetzt. Während in der Künstlichen Intelligenz häufig ML eingesetzt wird, ist ML eine Methode und damit ein Werkzeug unter vielen der Künstlichen Intelligenz. [generell hierzu Felden 2017]

Künstliche Intelligenz beschreibt Informatik-Anwendungen, deren Ziel es ist, intelligentes Verhalten zu zeigen. Dazu sind in unterschiedlichen Anteilen bestimmte Kernfähigkeiten notwendig: Wahrnehmen, Verstehen,

Handeln und Lernen. Diese vier Kernfähigkeiten stellen die größtmögliche Vereinfachung eines Modells zur modernen Künstlichen Intelligenz dar: Wahrnehmen - Verstehen - Handeln erweitern das Grundprinzip aller EDV-Systeme: Eingabe – Verarbeitung - Ausgabe. Das wirklich Neue ist das Lernen und Verstehen. Heutigen Künstlichen-Intelligenz-Systemen ist gemein, dass sie in der Verarbeitungskomponente auch trainiert werden und damit lernen können und so bessere Ergebnisse erzielen als mit herkömmlichen Verfahren, die auf klar definierten und fest programmierten Regelwerken basieren. Heute sprechen wir von der schwachen Künstlichen Intelligenz, bei der es darum geht, den Menschen intelligent beim Erreichen seiner Ziele zu unterstützen, also um smarte Mensch-Maschine-Interaktion und Zusammenarbeit zwischen Mensch und Maschine. Die starke Künstliche Intelligenz ist eher philosophisch relevant. Sie zielt auf eine Imitation des Menschen ab. Die vier Entwicklungsphasen der Künstlichen-Intelligenz-Forschung spiegeln sich auch im Einsatz der Künstlichen Intelligenz in industriellen und privaten Anwendungsfeldern wider. Letztlich ist das Ziel von Künstlichen-Intelligenz-Systemen, den Menschen beim Erreichen seiner Ziele intelligent zu unterstützen und dabei unmenschliche oder unangenehme Arbeit deutlich zu vermindern, aber nicht den Menschen überflüssig zu machen [generell hierzu und im Folgenden Cavanillas et al. 2016]

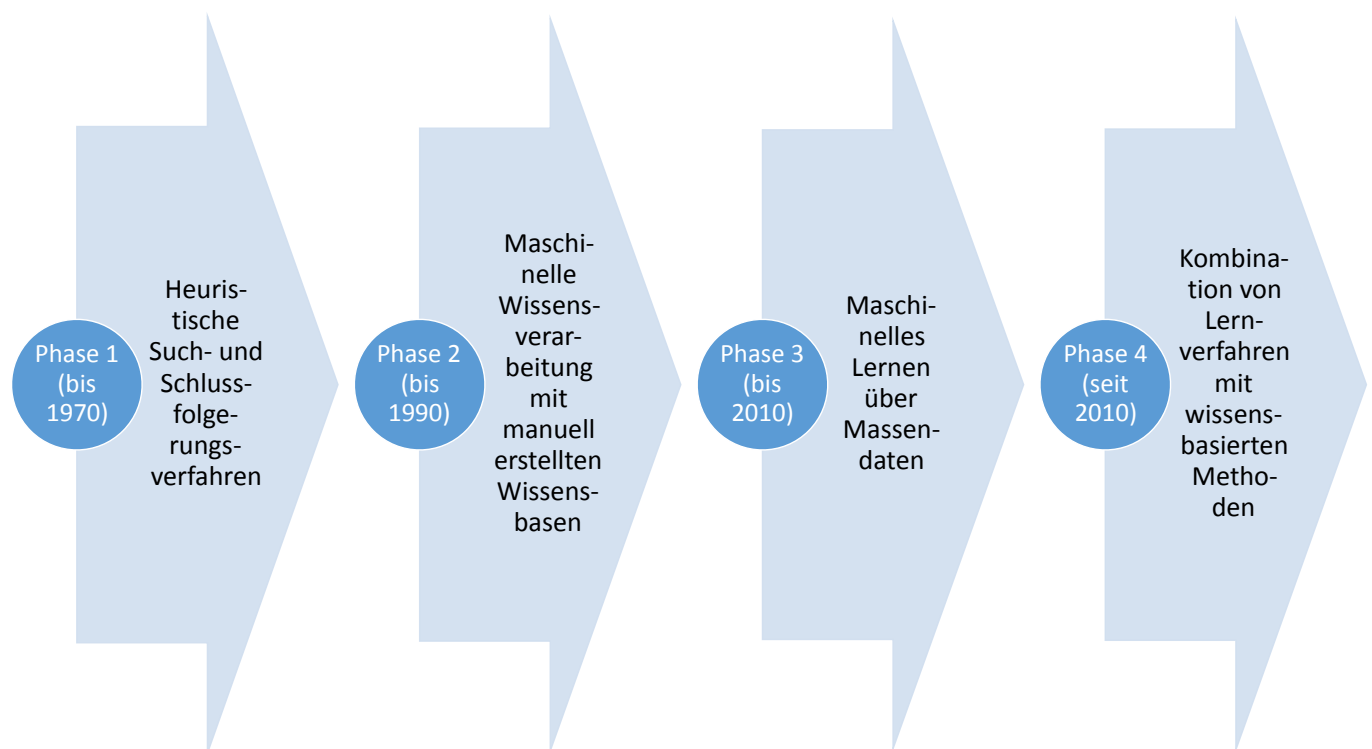


Abb. 1: Entwicklungsphasen der Künstlichen Intelligenz [entnommen und modifiziert aus Cavanillas et al. 2016]

## 2 Maschinelles Lernen in der Künstlichen Intelligenz

In der ersten und zweiten Phase wurde sehr viel an Wissen manuell und direkt in die Maschine einprogrammiert. Ein Beispiel hierfür wäre ein Taschenrechner. Dieser zeigt zwar intelligentes Verhalten, indem er rechnet, aber seine Funktionsweise ist nicht intelligent. Mit den Ansätzen der zweiten Phase hatte man zwar sehr gute Kontrolle über das Verhalten der Maschinen, aber deren Handlungsumfang war extrem begrenzt. Beispielhaft seien hier Empfehlungssysteme aus dem Buchhandel genannt, die auf früheren Einkäufen basieren.

In der dritten Phase der Künstlichen Intelligenz kam der Durchbruch über das Maschinelle Lernen aus Massendaten. Um beim Beispiel Buchhandel zu bleiben, ist es heute so, dass die Kunden und die Waren automatisch in Gruppen (Cluster) einsortiert werden und die Empfehlungen vom System selbst gelernt und ständig verbessert werden. Ein Nachteil an diesem Ansatz des vollautomatischen maschinellen Lernens wurde bereits angedeutet: Es ist nur schwer nachvollziehbar, warum ein System einen bestimmten Vorschlag macht, und noch schwerer ist es, diesen zu korrigieren bzw. zukünftig zu unterbinden.

Die vierte Phase von Künstlichen-Intelligenz-Systemen versucht, Lernverfahren mit Expertenwissen zu verbinden, um das Beste aus beiden Welten zu nutzen: Kontrolle und explizites Wissen mit der Kraft von Lernalgorithmen, die dann auch bei unsicherer Faktenlage ähnlich gut wie ein Mensch handeln kann. In der Geschichte der Künstlichen-Intelligenz-Forschung und -Entwicklung gab es immer wieder disruptive Ereignisse. In letzter Zeit sind IBM Watson, Alpha Go und die autonomen Fahrzeuge von Google aus den Medien bekannt.

Lernen und Verstehen sind die zentralen Kernfähigkeiten, die sich in den Prozess: Sense, Comprehend, Act and Learn einbetten (vgl. Abbildung 2). Diese Vier stellen die größtmögliche Vereinfachung eines Modells zur modernen Künstlichen Intelligenz dar und erweitern das Grundprinzip aller EDV-Systeme: Input – Operating – Output oder Eingabe – Verarbeitung – Ausgabe. Das wirklich Neue ist das Lernen und davon ausgehend auch das Verstehen. Heutigen Künstlichen-Intelligenz-Systemen ist gemein, dass sie in der Verarbeitungskomponente trainiert werden und so immer bessere Ergebnisse erzielen können und zwar

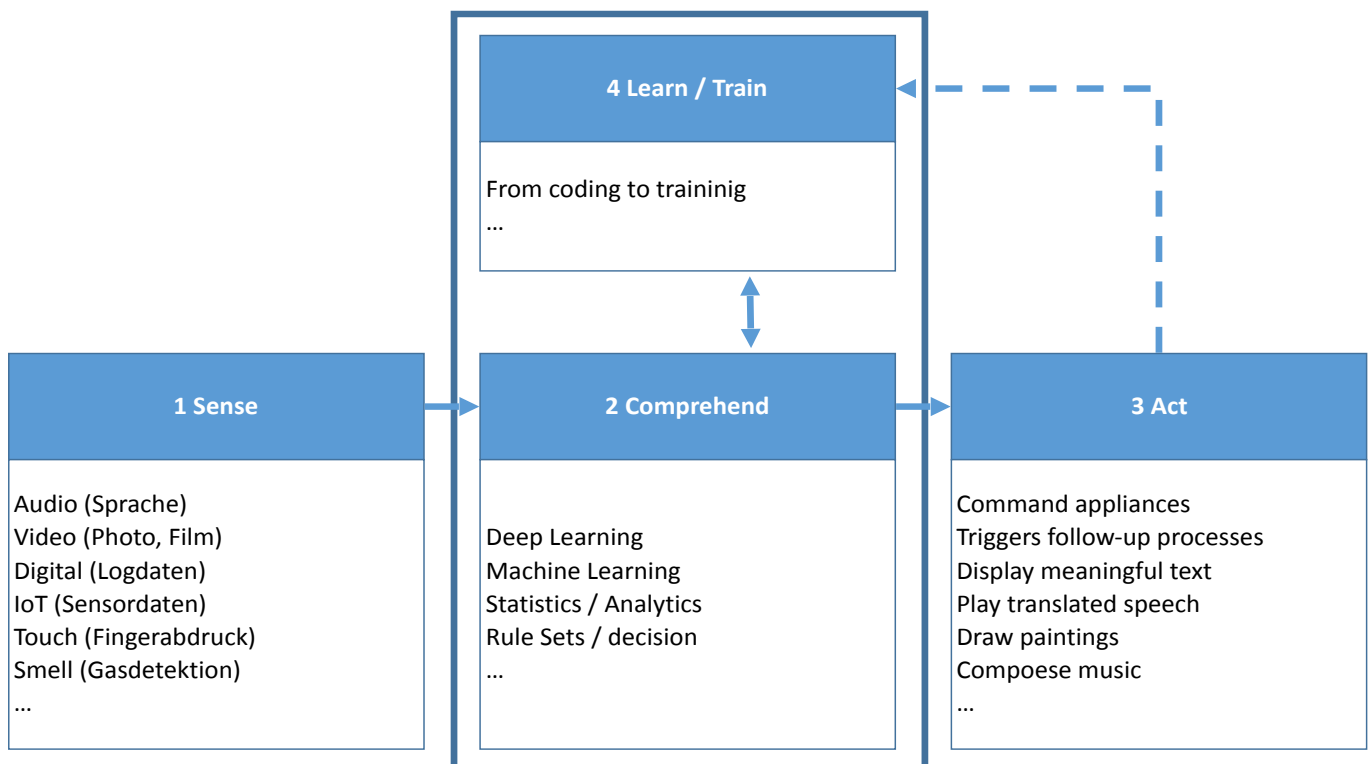


Abb. 2: Komponenten einer Künstlichen Intelligenz [Purdy/Daugherty 2016]

## 2 Maschinelles Lernen in der Künstlichen Intelligenz

häufig besser, als mit herkömmlichen Verfahren, die im Wesentlichen auf klar definierten und fest programmierten Regelwerken basieren.

Betrachtet man die vier Kern-Komponenten detaillierter, so wird deutlich, welch enormes Potenzial in den Anwendungen besteht. Dies liegt an der Vielfalt der verarbeiteten Datenarten und Datenmengen (1 - Sense), die kaum noch Limitationen unterliegen. Die verarbeitende Komponente (2 - Comprehend) wird um Künstlichen-Intelligenz-Methoden, meist Sprachverstehen und Deep bzw. Machine Learning erweitert. Damit ist gemeint, dass die Experten-Software um eine trainierbare, lernende Komponente erweitert wird, dass aber auch weiterhin eine eindeutige Systemsteuerung zum Einsatz kommt, wenn Fallentscheidungen eindeutig definiert werden können. Wenn zum Beispiel ein Dokument als vollständiges Formular erkannt wird, dann wird der entsprechende Weiterverarbeitungs-Prozess angestoßen. Im

Gegensatz hierzu ist eine unstrukturierte Kunden-E-Mail zu sehen, wo eine Künstliche Intelligenz erst verstehen muss, was der Kunde eigentlich will - und dies können trainierte Systeme mittlerweile leisten. Die Ausgabekomponente (3 - Act) beinhaltet wiederum alle Steuerungsmöglichkeiten moderner IT-Systeme. In den Medien erscheinen immer wieder die beachtenswerten Ergebnisse aus der Künstlichen-Intelligenz-Forschung, wie Systeme, die Bilder malen wie van Gogh, Musikstücke komponieren wie Bach, Lastenroboter, die auf vier Beinen wie ein Tier durch unwegsames Gelände laufen, etc. In der Praxis sind aber eher Dinge wie intelligente Prozess- oder Gerätesteuerung relevant.

Das Besondere an aktuellen Künstlichen-Intelligenz-Systemen ist nun, dass sie während der Trainingsphase (4), aber auch im laufenden Betrieb aus ihren Fehlern bzw. anhand eines Feedbacks lernen können.



### 3 Beispiele Ansätze Künstlicher Intelligenz

Im Folgenden werden nun mit dem Multilayer Perceptron, dem Deep Learning, den Convolutional Neural Networks und der Cognitive Intelligence drei Ansätze herausgegriffen und pragmatisch als Bei-

spiele eingeführt, um zum einen die Vorgehensweise dieser Ansätze nachvollziehen zu können und andererseits auch die damit einhergehenden Unterschiede aufzuzeigen.

#### 3.1 Das Multilayer Perceptron für Klassifikationsaufgaben

Durch ein Künstliches Neuronales Netz [McCulloch/Pitts 1943] kann eine Klassifikation durchgeführt werden. Ein Neuronales Netz besteht aus Verarbeitungseinheiten (Neuronen), die in Schichten angeordnet sind. Dabei wird die Input-, die Hidden- und die Outputschicht unterschieden. „Das Grundmodell eines Neurons stützt sich im Wesentlichen auf Vereinfachungen von McCulloch und Pitts ..., die Neuronen als eine Art Addierer mit Schwellenwert betrachten.“ [Brause 1991, S. 6] In einem Neuron  $j$  kommen Signale von der Eingabeschicht zur versteckten Schicht mit Eingangswerten  $x_{ij}$  mit einem

Gewicht  $w_{ij}$  an, werden verarbeitet und es erfolgt ein Output  $x_{2j}$ . Dieser Output ist entweder Input für ein nachfolgendes Neuron oder aber die Netzausgabe. Die Eingabewerte sind im Rahmen dieser Arbeit die ermittelten Deskriptoren und deren Erweiterungen sowie Qualitätscharakteristika. Diese Eingabewerte müssen für das Neuronale Netz entsprechend kodiert werden, damit die Regeln angewendet werden können. Ausgabe ist die Klassifikation, die angibt, ob eine relevante Internetseite interessant oder uninteressant ist. Die Abbildung 3 zeigt den Aufbau des Neurons.

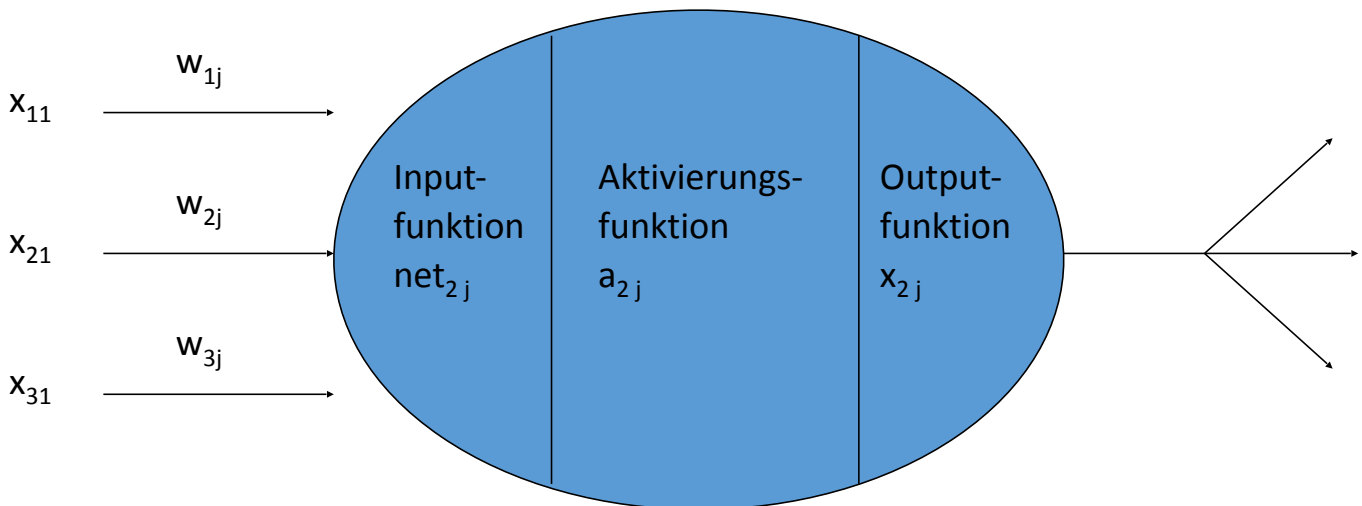


Abb. 3: Aufbau eines Neurons [entnommen und modifiziert aus: Düsing 1997, S. 62]

### 3 Beispiele Ansätze Künstlicher Intelligenz

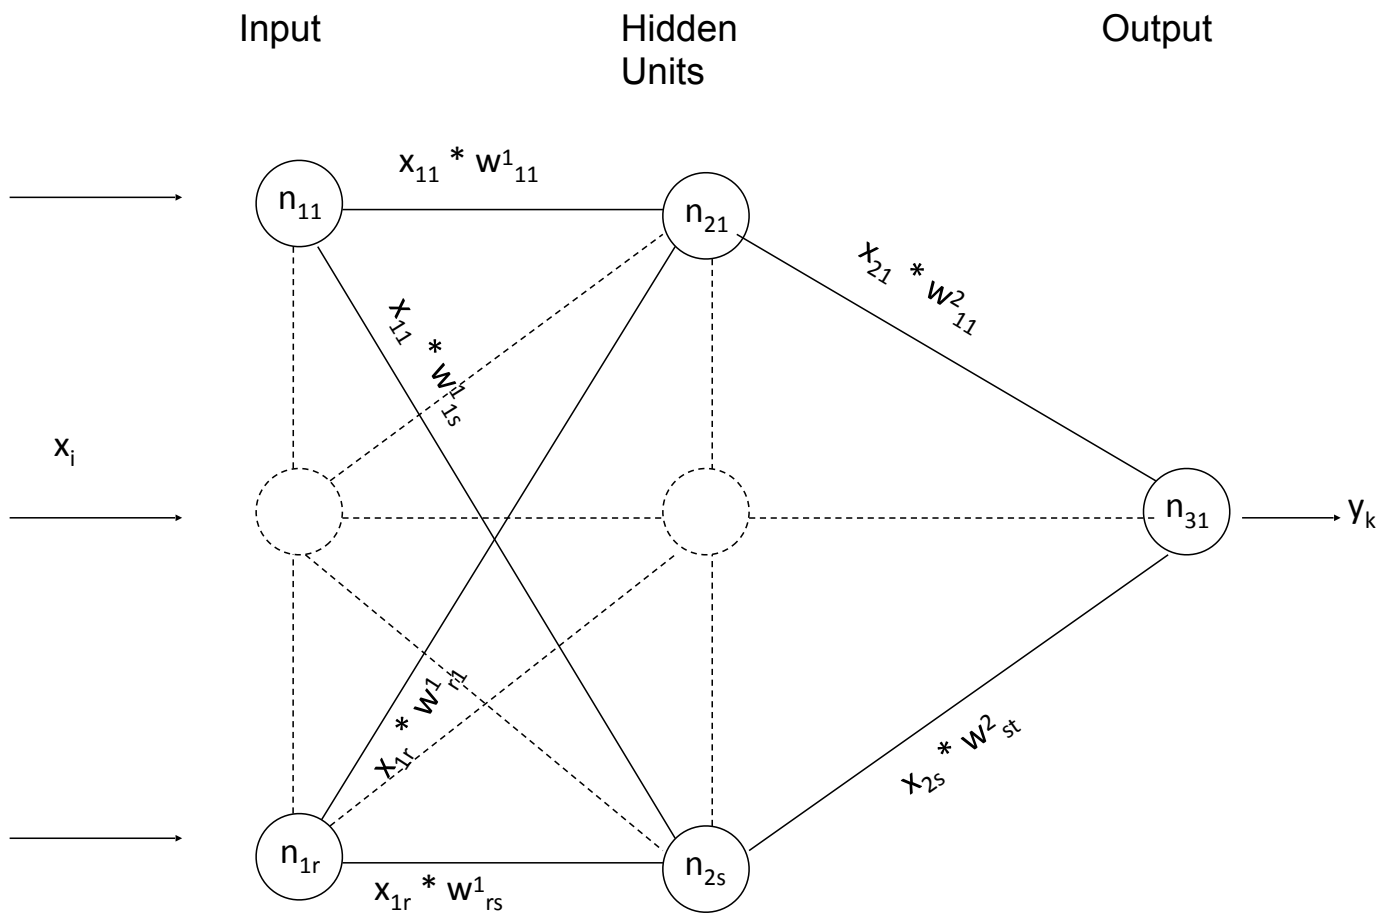


Abb. 4: Multilayer Perceptron [Bishop 1995, S. 117]

Als Neuronales Netzwerk kann ein Multilayer Perceptron (MLP) eingesetzt werden. Perceptrons sind „... simplified networks, designed to permit the study of lawful relationships between the organization of a nerve net, the organization of its environment, and the ‘psychological’ performances of which it is capable.“ [Khanna 1990, S. 50] Ein MLP besteht aus einer Eingabe- (Input), mindestens einer versteckten Ebene (hidden units) und einer Ausgabebene (Output). Ein Perceptron übernimmt als Input zum einen die ursprüngliche Eingabe, zum anderen stammen die Werte aus einer vorgelagerten Ebene. [Khanna 1990, S. 70] Obige Abbildung 4 zeigt exemplarisch ein MLP-Netzwerk.

Das dargestellte Netzwerk der Abbildung 4 führt zu einer Transformation der Werte durch zwei nachgelagerte Ebenen.

Die Abbildung enthält  $r$  Inputneuronen ( $n_{11}, \dots, n_{1r}$ ),  $s$  Hidden Units ( $n_{21}, \dots, n_{2s}$ ) und  $t$  Outputneuronen ( $n_{31}, \dots, n_{3t}$ ), mit denen der Neuronenwert  $x_i$  verbunden ist. [Bishop 1995, S. 116 ff.] Eine mögliche analytische Funktion zu der Neuroneneingabe von der Inputschicht zur versteckten Schicht ist:

$$net_{2j} = \sum_{i=1}^r w_{ij}^1 * x_i \quad j=1, \dots, s .$$

### 3 Beispiele Ansätze Künstlicher Intelligenz

Dabei ist  $w_{ij}^l$  die Gewichtung von  $x_i$  ( $x_{j_i}=x_i \forall i$ ) in der Eingabeebene für den Übergang zum versteckten Neuron  $j$ . Zur Aktivierung des versteckten Neurons erfolgt eine Transformation der linearen Summe mit der Aktivierungsfunktion  $a_{2j}(\cdot)$ . Die Aktivierungsfunktion lässt sich wie folgt darstellen, wobei diese nicht an eine bestimmte Funktionsform gebunden ist:

$$a_{2j}(net_{2j}) .$$

Als Aktivierungsfunktion soll im Folgenden eine sigmoide (s-förmige) Funktion angewendet werden. Hierbei handelt es sich um die Fermifunktion (auch logistische Funktion genannt). Sie ist definiert durch:

$$a_{2j}(net_{2j}) = s(net_{2j}) = \frac{1}{1 + e^{-c \cdot net_{2j}}}$$

Durch einen geschickt gewählten Wert  $c$  wird die Steigung der Funktion so steil, dass diese ähnlich einfach wie eine Schrittfunktion anzuwenden ist. Eine vergleichbare Steigung kann z. B. durch eine Squashing-Funktion nicht erreicht werden. Die Netzeingabe für das Outputneuron erfolgt durch eine lineare Kombination der Ausgaben der versteckten Ebene in der Form:

$$net_{3j} = \sum_{j=1}^s w_{jk}^2 * x_{2j} \quad k=1, \dots, t.$$

Die Aktivierung erfolgt über die nicht-lineare Funktion, für die auch die sigmoide Funktion angewendet werden kann:

$$\tilde{a}_{3j}(net_{3j}).$$

Die Notation a-Schlange gibt an, dass es sich nicht um die gleiche Aktivierungsfunktion wie zuvor handeln muss. Die Zusammenfassung der dargestellten Funktionen ergibt den formalen Ausdruck für den in Abbildung 4 vorgestellten Sachverhalt:

$$y_k = \tilde{a} \left( \sum_{j=1}^s w_{jk}^2 * a \left( \sum_{i=1}^r w_{ij}^1 * x_i \right) \right).$$

Bezogen auf die Problemstellung sind die Eingangswerte die zuvor beschriebenen Deskriptoren des Indexes, die Qualitätsanforderungen sowie die Erweiterungen der Deskriptoren.

Somit erhält der Filter  $F_i$  die folgenden Kriterien:

$$F_i = D \wedge Q \wedge E \\ = (d_1, \dots, d_k; q_1, \dots, q_l; e_1, \dots, e_m)$$

Unter Beachtung der jeweiligen Gewichtungen im Neuronalen Netz ergibt sich:

$$\tilde{F}_i = \{(d_1, \dots, d_k); (q_1, \dots, q_l); (e_1, \dots, e_m)\}.$$

## 3 Beispiele Ansätze Künstlicher Intelligenz

### 3.2 Überwachtes Lernen im Deep Learning

Deep Learning beschreibt die Verwendung von Neuronalen Netzen im Rahmen des sogenannten Reinforcement Learning (bestärkendes Lernen). Im Folgenden werden zunächst Künstliche Neuronen anhand sogenannter Perceptrons pragmatisch eingeführt. Perceptrons wurden in den 1950er und 1960er Jahren von Frank Rosenblatt entwickelt, inspiriert durch frühere Arbeiten von Warren McCulloch und Walter Pitts. Heute ist es üblicher, andere Modelle künstlicher Neuronen zu benutzen (aktuell hat das Sigmoid Neuron die dominierende Rolle). Ein Perceptron an sich nimmt mehrere Binäreingänge,  $x_1, x_2, \dots$  auf und erzeugt eine einzelne Binärausgabe. Im Allgemeinen könnte es mehr oder weniger Eingaben haben. Rosenblatt schlug eine einfache Regel vor, um die Ausgabe zu berechnen. Er führte Gewichte,  $w_1, w_2, \dots$  (reelle Zahlen) ein, welche die Bedeutung der jeweiligen Eingänge zum Ausgang ausdrücken. Die Ausgabe des Neurons, 0 oder 1, wird bestimmt, wenn die gewichtete Summe  $\sum_j w_j x_j$  kleiner oder größer als ein Schwellwert ist. Genau wie die Gewichte ist

die Schwelle eine reelle Zahl, die ein Parameter des Neurons ist.

Wie bereits erwähnt, finden heutzutage Sigmoidfunktionen als Aktivierungsfunktion Anwendung, da der Einsatz von differenzierbaren Funktionen die Verwendung von Lernmechanismen, wie zum Beispiel dem Backpropagation-Algorithmus, ermöglicht. Als Aktivierungsfunktion eines künstlichen Neurons wird die Sigmoidfunktion auf der Summe der gewichteten Eingabewerte angewendet, um die Ausgabe des Neurons zu erhalten. [Nielsen 2017] Dazu wird beispielsweise in sogenannten Feed Forward Netzwerken, wie dem Multilayer Perceptron, der Forward Pass durchgeführt (Aktivierung einer jeden Einheit), also der normale Durchlauf des Netzes. Basierend auf den dann ermittelten Fehlern (ermitteltes Ergebnis versus tatsächliches Ergebnis) erfolgt ein Backward Pass, um Modifikationen im Netz durchzuführen (partiell Derivat), sodass ein neuer Forward Pass mit einem neuen und hoffentlich besseren Ergebnis initiiert werden kann.

#### 3.2.1 Reinforcement Learning

Neben dem Supervised Learning (überwachtes Lernen, für das ein entsprechender Trainingsdatenbestand mit bekannten Daten zu erzeugen ist) und dem Unsupervised Learning (unüberwachtes Lernen, bei dem eine direkte Algorithmusanwendung auf dem jeweiligen Datenbestand stattfindet) bildet das Reinforcement Learning (bestärkendes Lernen) die dritte Gruppe der Lernverfahren. Es ist ein rechenintensiver Ansatz zum Lernen durch Interaktion. Dem Algorithmus, also dem Lerner, wird vorab nicht mitgeteilt, welche Maßnahmen zu ergreifen sind, wie in vielen Formen des maschinellen Lernens, sondern stattdessen muss der Algorithmus durch Ausprobieren entdecken, welche Handlungen zielführend sind. Dies wird dem Lerner durch eine dann entsprechende positive (Bonus), aber auch negative (Malus) Belohnung mitgeteilt. Dabei handelt es sich um sogenannte closed loops Probleme, da sowohl durch eine Aktion des Lerners als auch die jeweilige Belohnung alle nachfolgenden Handlungen beeinflusst werden. Um

nun eine Menge Bonus zu erhalten, muss ein Lerner Handlungen bevorzugen, die bereits in der Vergangenheit genutzt wurden und bei denen die Aussicht darauf besteht, dass diese wieder zu einem Bonus führen. Aber um solche Aktionen zu entdecken, muss der Algorithmus Aktionen ausprobieren (exploit), die er vorher nicht ausführte. Das bedeutet nun aber, dass der Algorithmus von seiner Wissensbasis abhängig ist und ausnutzen muss, was er bereits kennt, um Belohnung zu erhalten. Darüber hinaus muss er auch erforschen (explore), was noch möglich ist, um in Zukunft eine bessere Handlungsauswahl zu betreiben. Das Dilemma ist, dass weder Exploration noch Exploitation losgelöst von der Ausführung der Aufgabenstellung verfolgt werden können, das heißt, dass es keine Lern- und Anwendungsphasen gibt, sondern sich der Algorithmus durch das Ausprobieren einer Vielzahl von Aktionen und Auswahl der zu dem jeweiligen Zeitpunkt am besten geeigneten schrittweise der Lösung der Aufgabenstellung nähert. Ein in die-

## 3 Beispiele Ansätze Künstlicher Intelligenz

sem Zusammenhang wichtiges Merkmal des Verstärkungslernens ist es, dass es ausdrücklich die gesamte Problemstellung betrachtet, die sich im Spannungsfeld einer unsicheren Umgebung bewegt. Alle Algorithmen, die dieses Lernparadigma nutzen, haben jedoch explizit formulierte Ziele, können Aspekte ihrer Umgebungen aufnehmen und wählen Aktionen, um das Ziel zu erreichen. Es ist in der Regel von Anfang

an davon auszugehen, dass der Agenten trotz der signifikanten Ungewissheit über die Umwelt, mit der er konfrontiert ist, zu agieren hat. Wenn das Reinforcement Learning mit der Planung einhergeht, muss es das Zusammenspiel von Planungs- und Echtzeitaktionsauswahl sowie die Frage, wie Umweltmodelle erworben und verbessert werden, adressieren. [Sutton/Barto 2017]

### 3.2.2 Künstliche Neuronale Netze + Reinforcement Learning = Deep Learning

Ein Deep Learning funktioniert nicht angemessen im Rahmen des zuvor beschriebenen Backpropagation-Algorithmus. Dieser gehört zu den überwachten Lernverfahren, liefert aber nur gute Ergebnisse bei ein oder zwei verdeckten Schichten. Mehr Schichten verschlechtern die Performance des Lernens. Auf Grund der hohen Anzahl von Gewichten in einem typischen Deep-Learning-Netz besteht insbesondere das Problem des sogenannten Overfitting (das Netz schafft keine Verallgemeinerung für die Fälle, auf denen es nicht trainiert wurde), was es eigentlich zu vermeiden gilt. Zusätzlich funktioniert Backpropagation nicht gut im Rahmen des Deep Learning, da die partiellen Ableitungen, die durch ihre Rückwärtsbewegungen berechnet werden, entweder schnell zur Eingangssei-

te des Netzwerks zerfallen, das Lernen durch tiefe Schichten extrem langsam machen oder die partiellen Ableitungen schnell zur Eingangsseite des Netzes wandern und somit das Lernen instabil machen.

Im Rahmen des bestärkenden Lernens ist die Gefahr des Overfitting reduziert (nicht eliminiert), da nicht auf einem limitierten Trainingsdatenbestand gearbeitet wird. Darüber hinaus ist eine Abstraktion über mehrere Schichten umsetzbar, da das Lernen nach dem zuvor eingeführten Prinzip funktioniert und sich somit wesentlich performanter verhält und auch eine höhere Generalisierungsfähigkeit erhält und das aufgeführte Ziel eher erreicht: Do not listen to what I say – listen to what I mean!

### 3.3 Entwicklung des Deep Learning hin zu Convolutional Neural Networks

Ein Convolutional Neural Network (CNN) wurde zwar schon in den 1990er Jahren eingeführt, ist aber ein aktueller Trend, der den Gedankengang des Deep Learning weiter fortführt. Ein solches Netz besteht aus einer oder mehreren Faltungsschichten (oft mit einem Unterabtastungsschritt) und dann gefolgt von einer oder mehreren vollständig verbundenen Schichten wie in einem Multilayer Perceptron. Die Architektur eines CNN wird genutzt, um die zweidimensionale Struktur eines Eingangsbildes (oder eines anderen zweidimensionalen Eingangssignals, wie beispielsweise eines Sprachsignals) zu nutzen. Dies wird mit lokalen Verbindungen und gebunde-

nen Gewichten erreicht, gefolgt von einer Art von Pooling, was zu Invarianzen führt. Ein Vorteil eines solchen Netzwerks ist es, dass sie einfacher zu trainieren sind und viel weniger Parameter haben als vollständig verbundene Netzwerke mit der gleichen Anzahl versteckter Schichten. Convolutional Neural Networks sind somit eine Kategorie neuronaler Netzwerke, die sich in Bereichen wie Bilderkennung und Klassifikation als effektiv erwiesen haben. Sie beherrschen die Identifizierung von Gesichtern, Objekten und Verkehrszeichen und unterstützen somit das Sehen in Robotern und selbstfahrenden Autos. [Karn 2018]

## 3 Beispiele Ansätze Künstlicher Intelligenz

### 3.4 Kognitive Systeme

Kognitive Systeme, als Spezialfall der sogenannten Adaptiven Systeme, sind in ihre Umwelt eingebettet, um mit ihr über Sensoren und Aktuatoren in Austausch zu treten. Basierend auf einer Reizaufnahme werden Signale verarbeitet und auf Grund einer hinterlegten Wissensbasis gehandelt. Das bedeutet, dass kognitive Funktionen wie Wahrnehmung und Mustererkennung, Handlungssteuerung und Kontrolle, Wissensrepräsentation und Schlussfolgern, Lernen aus Erfahrung, Problemlösen, Entscheiden und die Verarbeitung natürlicher Sprache ausführbar sind. Das beste Beispiel für ein kognitives System ist

der Mensch, wobei allerdings im Folgenden darunter die Schnittmenge zwischen Künstlicher Intelligenz, also der Algorithmen zur Lösung von Problemen, und kognitiver Psychologie verstanden wird, da kognitive Funktionen derart zu realisieren sind, dass sie auf zum Menschen ähnlichen Strukturen und Prozessen agieren. Erkenntniswissenschaftlich betrachtet ist eine formale Modellierung notwendig, um die kognitiven Prozesse und Strukturen beschreiben zu können, um intelligente Systeme im Sinne einer menschengerechten Interaktion und Präsentation realisieren zu können.

#### 3.4.1 Kognitive Grundvorstellungen

Kognitive Grundvorstellungen adressieren den Bereich der zuvor bereits genannten psychischen Grundfunktionen. Dabei ist für das System jedoch eine Abstraktion individueller Unterschiede erforderlich, was als Elastizität (Reaktion auf Schwankungen der Umwelteinwirkungen) und Plastizität (Berücksichtigung von Zusammenhängen zwischen System und Umwelt) bezeichnet wird. Darüber hinaus ist die Entwicklung der Funktionen im Lauf der Lebensspanne durch innere und äußere Einflüsse und das Erleben und Verhalten im gegebenen Kontext zu beachten. Dies bedeutet, dass ein Zustandsraum zu definieren ist, der alle möglichen Konfigurationen der dargestellten Objekte erfasst. Bezogen auf definierte Anfangs- und Endzustände erfordert dies eine Regelmenge, um das System von einem Zustand in den nächsten Zustand zu überführen. Dabei sind relationale Repräsentationen mentaler Modelle entscheidend, um analoges Schließen zu ermöglichen.

Die Ansätze zur Modellierung mentaler Repräsentationen im menschlichen Gehirn lassen sich grob in die Kategorien symbolische, konnektionistische und hybride Ansätze einordnen. Die am weitesten verbreiteten symbolischen Modelle verwenden dabei die sogenannte Symbol-Argument-Argument(=SAA)-Notation. Relationen und deren Argumente werden

explizit in Form von Symbolen ausgedrückt. Die relationalen Rollen, welche die Argumente dabei einnehmen, werden implizit durch deren Position ausgedrückt. Die SAA typische Fähigkeit zu Generalisierungen hängt dabei nicht von den Eigenschaften der einzelnen Argumente ab, sondern von den Rollen, die diese Argumente spielen. Die entscheidende Voraussetzung zum Generalisieren und zum Aufbau abstrakter Schemata besteht in der Fähigkeit, relationale Rollen und Objekte, die diese Rollen einnehmen können, unabhängig voneinander abzubilden. Der große Nachteil symbolischer Modelle ist deren Unfähigkeit im Umgang mit semantischem Inhalt von Argumenten und deren relationaler Rollen. Traditionelle symbolische Modelle versuchten diesen Nachteil durch den Einsatz händisch angelegter Lookup-Tabellen, welche die semantische Ähnlichkeit von jeweils zwei Symbolen enthalten, auszugleichen.

Konnektionistische Modelle stellen Wissen nicht mithilfe von Symbolen, sondern über Aktivierungsmuster verteilter Einheiten dar. Die Einheiten nehmen dabei die Rolle der Neuronen im menschlichen Gehirn ein und ein einzelnes Konzept wird als Aktivierung bestimmter verteilter Einheiten gebildet. Ähnliche Konzepte werden durch ähnliche Aktivierungsmuster modelliert. Durch die Einheiten ist es

### 3 Beispiele Ansätze Künstlicher Intelligenz

konnektionistischen Modellen möglich, explizit den semantischen Inhalt von Konzepten zu modellieren. Traditionelle konnektionistische Modelle haben aber einen entscheidenden Nachteil gegenüber symbolischen Modellen: Durch die einfache Aktivierung der (semantischen) Einheiten lassen sich relationale Rollen nicht unabhängig von ihren Argumenten repräsentieren. Es ist daher nicht möglich, relationale Rollen und deren Argumente getrennt voneinander zu behandeln.

Die beiden vorherigen Ansätze haben gezeigt, dass sowohl symbolische als auch traditionelle konnektionistische Modelle große Teile menschlicher Kognition nicht ausreichend abbilden. Im Rahmen hybrider Ansätze versucht man, symbolische Repräsentationen und konnektionistische Systeme miteinander zu verbinden. Beispielsweise finden Kreuzprodukte (oder Vektorprodukte) zur Verzahnung symbolischer und konnektionistischer Modelle Verwendung.

Mit der Modellerzeugung sind die Grundlagen zur Verarbeitung der Eingangssignale geschaffen. Diese Verarbeitung lässt sich als neuronales Korrelat verstehend – das Suchen nach Strukturen und Prozessen in den gegebenen Speicherstrukturen. Computer funktionieren zwar in Interaktion mit ihrer Umwelt, doch ist der Dialog zwischen Mensch und Maschine gewöhnlich auf genau definierte Symbole beschränkt. Auch bei solchen Systemen, die über Sensoren nichtsymbolische Informationen aufnehmen, werden diese letztlich in dieselbe interne Symbolik umgewandelt. Anders als bei den natürlichen kognitiven Systemen entspricht diese interne Symbolik aber keiner bedeutungsevaluierten Re-

präsentation des sensorischen Geschehens, sondern einem maschinenintern festgelegten Zeichensatz. Die Symbole selbst lassen sich nach bestimmten vorgegebenen Regeln in einem zentralen Prozessor oder auch dezentral verarbeiten, um eine durch einen Algorithmus evaluierte Antwort des Systems erzielen zu können.

Die auf den erstellten Modellen stattfindende topologisch-basierte Informationsverarbeitung lässt sich im Sinne einer atomistischen oder modularen Struktur ausführen. Das atomistische oder auch stückhafte Vorgehen ist das Bemühen, eine Aufgabenstellung zu verstehen, indem die einzelnen Elemente nachvollzogen werden. Aus der Zusammenstellung der gewonnenen Bedeutungen ist abschließend ein Gesamtverständnis zu erzielen. Im Rahmen der modularen Struktur hingegen erfolgt die Konstruktion neuen Wissens durch die Modifikation des alten Wissens. Das setzt allerdings voraus, dass die Module des alten Wissens im Rahmen der Systemkonstruktion derart miteinander verbunden sind, dass vorhandenes Wissen verbindend ausgewertet werden kann.

Letztlich ist es eine offene und aufgabenbezogene Gestaltungsfrage, ob die Intelligenz des Systems durch den jeweiligen Entwickler in einem komplexen Modell vorzugeben ist, oder ein dezentraler Ansatz verfolgt wird, der atomistisch oder modular basierend auf generischen Regeln oder Knoten ein Gesamtverhalten als Reaktion auf die Eingangssignale zeigt. Während der erste Ansatz initial schnelle Ergebnisse ermöglicht, bietet die letztgenannte Umsetzungsphilosophie mehr Entwicklungsflexibilität bezüglich einer Systemweiterentwicklung.

## 3 Beispiele Ansätze Künstlicher Intelligenz

### 3.4.2 Entwicklung von Sachkenntnis und Problemlösung

„Unter Problemlösen versteht man das Bestreben, einen gegebenen Zustand (Ausgangs- oder Ist-Zustand) in einen anderen, gewünschten Zustand (Ziel- oder Soll-Zustand) zu überführen, wobei es gilt, eine Barriere zu überwinden, die sich zwischen Ausgangs- und Zielzustand befindet.“ [Hussy 1983, S. 114] Diese Überführung kann mittels Brute-Force-Methoden, also dem Ausprobieren unterschiedlicher Wege, oder heuristischer Ansätze, also dem Metawissen über mögliche Lösungsschritte, erfolgen. Problemlösen auf Basis von Sachkenntnis ist die grundlegende Idee der Expertensysteme, in denen die Wissensrepräsentation eine wichtige Funktion einnimmt. Dabei gilt zunächst die Annahme, dass das abgebildete Wissen in der Wissensbasis unabhängig von der späteren Anwendung ist. [hier und im Folgenden Mandorf 2008]

Um die Sachkenntnis und Problemlösung nachzubilden, muss das relevante Wissen explizit formuliert werden. Eine zunächst einfache Abbildungsform bilden einfache kontrollierte Vokabularien wie Kataloge oder Glossare. Eine Erweiterung der Glossare sind Thesauri, die eine begrenzte Anzahl an Relationen, jedoch ohne Vererbungshierarchie, zulassen. Regeln sind eine weiterhin einfache Form der Wissensabbildung und bestehen lediglich aus einer Vorbedingung und einer Implikation. Es wird also lediglich festgelegt, was beim Eintritt einer Bedingung getan wird. Dies wird mittels einer Vorwärtsverkettung (Lösung basierend auf der vorhandenen Wissensbasis) oder Rückwärtsverkettung (Lösungsidentifikation basierend auf dem formulierten Ziel) realisiert.

Regeln beziehen sich auf Objekte in Datenbanken. Diese eigentlich unstrukturierte Sammlung von Fakten lässt sich als Bündelung aller Fakten zu einem Objekt zusammenfassen. Erfolgt hier eine Erweiterung durch eine Vererbungshierarchie und eine Zuordnung von sowohl Prozeduren als auch Methoden etc., so spricht man von Frames.

Ein weiterer und oftmals genutzter Ansatz ist die Prädikatenlogik erster Ordnung. Die Prädikatenlogik

basiert auf der Aussagenlogik, die wiederum auf vorgegebenen Aussagen (Axiomen, Fakten, Annahmen) beruht. Abgeleitete Aussagen heißen Schlussfolgerungen. Als Verknüpfung benutzt man „und“. Mit der Aussagenlogik lassen sich keine Allgemein-Aussagen formulieren. Deshalb wurde sie zur Prädikatenlogik erweitert. Diese verwendet anstatt einfacher Aussagen Prädikate, denen sie Objekte zuordnet. Existenz- und Allaussagen über Individuen werden durch sogenannte Quantoren „es gibt“ beschrieben.

Alle Formalismen zur Wissensrepräsentation kann man als Axiome bzw. Kalküle auffassen. Ein Kalkül beschreibt über Aussagen Objekte oder Zustände der realen Welt. Über Ableitungsregeln werden neue Aussagen hergeleitet. Die Ausdrucksstärke resultiert aus der Abbildung von Aussagen über den Problem-bereich. Es ist korrekt, wenn alle syntaktisch abzuleitenden Schlussfolgerungen auch semantisch in der tatsächlichen Welt erfolgen. Für Expertensysteme ist in diesem Zusammenhang entscheidend, wie realistisch ein Problembereich beschrieben werden kann (Adäquanz) und wie effizient sich Problemlösungen herleiten lassen.

In der Prädikatenlogik erster Ordnung sind Strukturierungsmittel, wie Hierarchien oder Kontexte, nicht vorhanden. Daher ist sie nicht zur Repräsentation großer Wissensbasen, wie bei Expertensystemen, geeignet. Dieses Defizit wird allerdings durch Semantische Netze, einem formalen Modell von Begriffen und ihren Beziehungen, beseitigt. Weitergehender sind Taxonomien, also hierarchische Darstellung einfacher kontrollierter Vokabularien bzw. Ontologien, also eine Darstellung formal geordneter Begrifflichkeiten.

Für all diese Ansätze gilt jedoch, dass sicherzustellen ist, dass die Syntax und Semantik korrekt und eindeutig abgebildet sind, um zutreffende und zeitperformante Schlussfolgerungen zu ermöglichen, die auch für den menschlichen Anwender direkt nachvollziehbare Ergebnisse darstellen.



## 4 Anwendungsbeispiele

Bereits anhand des einfachen Vier-Komponentenmodells wird deutlich, wie vielfältig die Themengebiete von Systemen der Künstlichen Intelligenz sind. Beschleunigt wird die gesamte Entwicklung durch den ständigen Fortschritt von Digitalisierung, IoT und Big Data, die immer neue Daten und Prozesse für derartige Systeme zugänglich machen und in Wechselwirkung Digitalisierung, IoT und Big Data auch weiter etablieren. Gerade die ungezählten Kombinationsmöglichkeiten der Komponenten ermöglichen immer neue Anwendungsfelder und machen jeden Klassifizierungsversuch letztlich zu einer Momentaufnahme.

Der Bitkom-Arbeitskreis für Big Data unterteilt die heutigen Geschäftsmodelle und Business Cases in der Datenwirtschaft ebenfalls in vier Kategorien. Dafür sind die Dimensionen Geschäftsmodellbezug (Business) und Datenquelle gewählt worden. Diese wiederum stellen auch eine Basis für die Einsatzgebiete der Künstlichen Intelligenz dar.

Der Geschäftsmodellbezug wird dabei in neues Business und vorhandenes Business unterteilt. Die Dimension Datenquelle bezieht sich in dieser Kategorisierung auf vorhandene Daten und neue Daten. Die Anwendungsfälle werden in diesem Modell über die vier Klassen in Optimierung, Aufwertung, Monetarisierung und Durchbruch kategorisiert (vgl. Abbildung 5).

Die Klasse Optimierung beschreibt Anwendungsfälle der Künstlichen Intelligenz, die einen großen Mehrwert durch Optimierung bestehender Geschäftsprozesse mithilfe der Auswertung bereits existierender Datenbestände erzeugt. Diese Klasse wird deshalb als Einstiegsklasse betrachtet, da hier eine Nutzung der bereits bestehenden Infrastruktur stattfindet. Die Analyse von existierenden und unternehmenseigenen Datenbeständen kann bereits durch die Optimierung von Prozessen einen Mehrwert generieren [BITKOM 2013, S. 17]. In den Bereich der Monetarisierung lassen sich Anwendungsfälle einordnen, die durch die Nutzung vorhandener Datensätze neue Geschäftsmodelle bzw. Produkte erzeugen. Hierbei ist jedoch der Datenschutz zu beachten und es ist fraglich, ob die Nutzung der Daten zu diesem Zweck rechtlich zulässig ist. Es ist zum Beispiel möglich, anonymisierte Standortdaten von Telefonnutzern für ortsbezogene Werbung zu verwenden [BITKOM 2013, S. 17]. Die Aufwertung soll all jene Fälle kategorisieren, die bestehende Geschäftsmodelle und Dienstleistungen durch das Erschließen neuer Daten optimieren. Hier sind beispielsweise Reiseunternehmen zu finden, die detaillierte Wetterprognosen für Marketingaktivitäten und bessere Auslastung der Reiseziele integrieren [BITKOM 2013, S. 18]. Die vierte Klasse, Durchbruch, bezeichnet die Entwicklung neuer Geschäftsmodelle

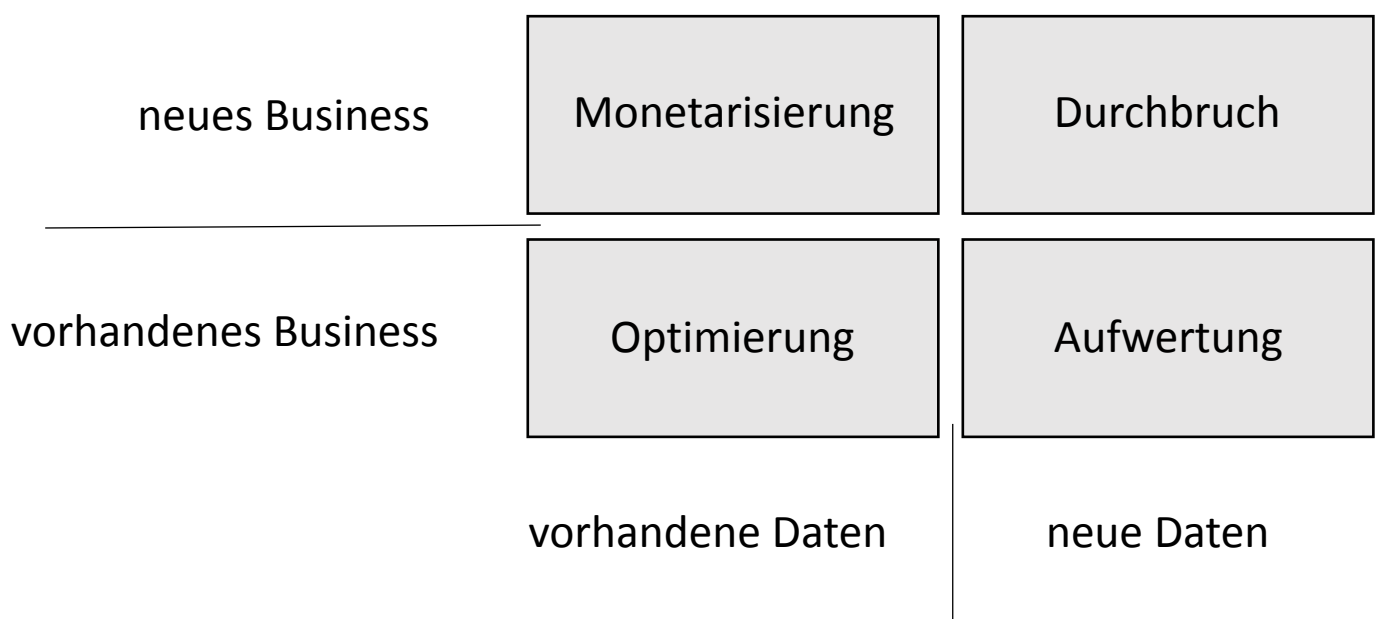


Abb. 5: Kategorisierung [BITKOM 2015]

## 4 Anwendungsbeispiele

delle für die Datenwirtschaft. Neue Produkte und Dienstleistungen lassen sich auf der Basis der Sammlung und Digitalisierung neuer Datenbestände erschaffen. Als Beispiel ist hier die Kartierung von Google durch den Service Streetview zu nennen [BITKOM 2013, S. 18].

### 4.1 Einsatzgebiete der Künstlichen Intelligenz

Wie nun ersichtlich ist, erzeugt Künstliche Intelligenz für ein Unternehmen Wirkung auf und durch das jeweilige Geschäftsmodell. Dabei können die Facetten dieser Wirkung in unterschiedlichen Einsatzszenarios

Während die Betrachtung des Geschäftsmodells redundant ist, erscheint der Einbezug der Datenherkunft als eine weitere relevante Beschreibungsdimension von Anwendungsfällen der Künstlichen Intelligenz, da durch die Ergänzung das Ziel der Entscheidungsunterstützung bedient wird.

erzeugt werden. Diese sind sowohl Dialogprozesse, Mensch-Maschine-Prozesse als auch Automatisierungsansätze, die im Folgenden in Anlehnung an [BITKOM 2017] skizziert werden.

#### 4.1.1 Mensch-Maschine-Kommunikation

Eine der großen Errungenschaften der Künstlichen Intelligenz ist zweifelsohne die Möglichkeit, menschengerechte Dialogprozesse zu ermöglichen und zwar durch Dialoge, die in natürlicher Sprache geführt werden, sei es in Schriftform oder als gesprochenes Wort. Virtuelle Agenten, die Menschen unterstützen, komplexe Vorgänge zu erledigen wie „Ein-Antragsformular-Ausfüllen“, Haushaltsgeräte per Sprache zu steuern, sich in der Telefonhotline nicht mehr durch Zahlenmenüs zu navigieren, sondern sein Anliegen sprachlich zu artikulieren, oder einfach zum Beispiel diesen Text zu diktieren. Dies führt zu einer Transformation, dass nicht mehr der Mensch umständliche oder komplexe Bildschirm-/Tastatordialoge erlernen muss, die sich stets an den technischen Limitationen orientiert haben. Vielmehr stellt sich die Maschine auf den Menschen ein, der endlich mit ihr so kommunizieren kann, wie er es gewohnt ist – in natürlicher Sprache, wenn notwendig Übersetzung inklusive. Dies bedeutet im Einzelnen die Umsetzung eines sogenannten Language Understanding Intelligent Service (LUIS), was bedeutet, die Befehle von Nutzern zu verstehen und konkrete Handlungen durchzuführen. Vertraut sind wir schon mit Rechtschreibungs-API, die eine automatisierte Verbesserung der Rechtschreibung ermöglichen sol-

len und dabei auch Verbundwahrscheinlichkeiten und bedingte Wahrscheinlichkeiten bestimmen, um so eine Vervollständigung von Wörtern zur schnelleren Dokumentation und Vereinfachung der Eingabe zu ermöglichen. Einen Schritt weiter geht die linguistische Analyse und damit das Verstehen der Textstruktur zum Beispiel zur automatisierten Erstellung von Meeting Minutes anhand von Sprachaufzeichnungen und auch die Sentimentanalyse zur Klassifizierung von Kommentaren oder Gesprächsaufzeichnungen. Damit einhergehend rücken Textübersetzungs-API mit Deep-Learning-Algorithmen zur Übersetzung von Datensätzen oder aufgerufenen Websites in die Betrachtung, um das alltägliche Arbeiten in internationalen Umgebungen zu unterstützen. Dies wird ergänzt um Live-Übersetzung inklusive Textausgabe für jegliche Kommunikation beziehungsweise auch Text-zu-Sprache und umgekehrt zur schnellen Protokollierung. Im Sinne von Zugriffsberechtigungsprüfungen kann hier auch eine Stimmenerkennung zur Identifikation von Personen und Anpassung anhand trainierter Modelle erfolgen. Diese Prüfung lässt sich zwischenzeitlich auch mittels Bildanalyse durch Gesichtserkennung zur Personenidentifikation ausführen, wie es beispielsweise bei UBER bereits im Einsatz ist.

## 4 Anwendungsbeispiele

### 4.1.2 Maschine-Maschine-Kommunikation

Das Internet of Things ermöglicht viele neue Anwendungen, die sowohl in der Industrie als auch im privaten Bereich Einzug halten. Internet of Things (IoT) ermöglicht, Geräte miteinander beziehungsweise mit einer zentralen Logik zu vernetzen. Im Heimbereich lassen sich immer mehr Geräte über Sprache und über eine App steuern. Eine intelligente Logik erlernt das Verhalten der Benutzer und kann Vorschläge machen, wann zum Beispiel Geräte gereinigt oder gewartet werden müssen. Ähnliche Anwendungen können in der Gebäudesteuerung zum Einsatz kommen, um beispielsweise Wartungsarbeiten bei Klimaanlage rechtzeitig durchzuführen. Man spricht hierbei auch von Predictive Maintenance, also der Vorhersage von Wartungsarbeiten mittels Sensorik und Machine Learning. Dieses Verfahren kann prinzipiell auf alle mit Verschleiß verbundenen Maschinen, Geräte und Fahrzeuge übertragen werden; es erhöht die Betriebssicherheit und senkt die Kosten. In der Industrie finden solche Ansät-

ze schon unterschiedliche Anwendungsszenarios, da bereits oftmals in einzelnen Bauteilen Datenaufnahmen und Weitergaben stattfinden, die zum Beispiel erst den Service einer Predictive Maintenance ermöglichen. Darüber hinaus ist die automatisierte Bildverarbeitung insbesondere in der Qualitätskontrolle zunehmend relevant, sodass hier Ansätze zum automatischen Tagging und der Optical Character Recognition (OCR) zur verbesserten Ablage und Durchsuchbarkeit von Bildern und Videos eingesetzt werden. Mittels Bildern lässt sich eine Fehlererkennung durch Trainieren eigener API realisieren, um beispielsweise Materialrisse in Glas oder Unebenheiten auf Flächen in Echtzeit identifizieren zu können. Zunehmend erleben wir auch eine automatisierte Emotionserkennung durch den Einsatz der Kamera am Endgerät zum Testen der Wirkung der jeweils angezeigten Inhalte und damit zur Anpassung der Produkte in deren Präsentation beziehungsweise einer Anpassung des Hintergrundlichts.

### 4.1.3 Automatisierung

Die sinnhafte Vollautomation ist seit jeher das Postulat der Wirtschaftsinformatik. Insbesondere Künstliche Intelligenz bietet hier das Potenzial, eine tiefgreifendere Automatisierung zu erzielen und somit Aufgaben ausführen zu lassen, für die es keinen menschlichen Anwender benötigt, beziehungsweise ergänzende Tätigkeiten zu automatisieren, die somit eine Unterstützung für den menschlichen Aufgabenträger darstellen. Beispielsweise lassen sich E-Mails im Posteingang nach Aufgabengebiet und Sachbearbeiter automatisch klassifizieren und weiterleiten. Dabei können die Daten aus der E-Mail bereits in Online-Formularen erfasst werden, sodass der menschliche Aufgabenträger nur noch die finalen Schritte selber ausführen muss. Genauso können auch Bewerbungen durch Personalsysteme automatisiert erfasst und deren Inhalte in entsprechende Formulare übertragen werden, sodass diese Tätigkeiten nicht mehr manuell auszuführen sind.

Automatisierung im Sinne einer Prozessunterstützung geschieht auch durch die Unterstützung bei Recherche- beziehungsweise Suchaufgaben. Hier ist das Konzept der Assistenzsysteme relevant, die einzelne Aufgaben der Entscheidungsträger übernehmen oder Zuarbeiten in die jeweiligen Prozesse der Entscheidungsträger ausführen. Grundsätzlich führen Suchvorschläge basierend auf antrainierten Verhalten zu einer schnelleren Suche im Internet. Ergänzend dazu lässt sich eine automatisierte Bildersuche beziehungsweise eine Filterung von Bildinformationen beispielsweise zur Identifikation von Produkttrends realisieren, um Entscheidungsträger in Unternehmen bei ihrer Arbeit über Marktentwicklungen zu informieren. Dabei können diese Informationen auch inhaltlich zusammengefasst, mit einem Suchindex versehen und mit einem entsprechenden Ranking, je nach Wichtigkeit, versehen werden.

## 4 Anwendungsbeispiele

Darüber hinaus haben wir schon alle Empfehlungsvorhersagen im Sinne von Cross-Selling-Systemen, einer personalisierten Empfehlung oder der Auffindbarkeit von Produkten aus eigener Erfahrung kennengelernt. Derartiges setzt zunehmend voraus, dass eine interaktive Suche möglich ist, die parallel eine automatisierte Auswertung der natürlichen Sprache mit sich bringt, um Anfragen zu vervollständigen und ergänzende Empfehlungen basierend auf den Erkenntnissen geben zu können.

Insgesamt stellen wir fest, dass die Innovationsdiffusion der Künstlichen Intelligenz in unterschiedlichen

Komponenten im täglichen Leben bereits jetzt eine enorme Geschwindigkeit erreicht hat. Es entstehen durch die grundsätzlich zunehmenden technischen Realisierungsmöglichkeiten und das wachsende Verständnis über die Anwendung immer neue Kombinationen dieser Komponenten weitere Anwendungsfelder, die sich, sobald in ihrem Entstehungsbereich bewährt, schnell auf andere Bereiche und Industrien übertragen lassen. War die Sprachsteuerung noch auf Smartphones beschränkt, sind es heute schon digitale Assistenten im Heimbereich und am Arbeitsplatz, die uns die täglichen Entscheidungen bei unseren Arbeiten erleichtern und qualitativ verbessern.

## Fazit

Die wieder einmal in den Vordergrund gerückte Künstliche Intelligenz, als jedoch schon seit den 1960er Jahren existierendes Thema, umfasst aktuell viel Forschung, die nach allgemeinen Grundsätzen des Lernens, der Suche und der Entscheidungsfindung sucht und versucht, riesige Mengen an Domänenwissen zu integrieren.

„Mit den rapiden Fortschritten in der Erfassung von Daten aus der realen Welt, mit der Möglichkeit zur aktiven Interaktion und mit virtuellen Agenten sind wesentliche Voraussetzungen für einen tiefgreifenden Wandel in Wirtschaft und Gesellschaft gegeben. Kognitive Systeme setzen auf Big Data und KI auf und können bereits vielfältige Aufgaben übernehmen, die von der Beschaffung und Verdichtung von Informationen über die Verrichtung gefährlicher, schmutziger, körperlich anstrengender Arbeiten bis hin zur Unterstützung von Management-Entscheidungen reichen. In den nächsten Jahren werden kognitive Systeme ihr Leistungsspektrum deutlich ausweiten. Daraus ergibt sich das Erfordernis, die wirtschaftlichen und gesell-

schaftlichen Konsequenzen des eingeleiteten kognitiven Zeitalters zu verstehen und in einen Diskurs einzutreten – insbesondere im Kontext der globalen politischen und wirtschaftlichen Herausforderungen.“ [BITKOM 2017]

Dabei steht aktuell insbesondere das Deep Learning im Zentrum der Diskussion und fokussiert derzeit Ordnungsrahmen, die Optimierung des Deep Learning selbst sowie deren Grenzen im praktischen Einsatz. Die Optimierung hinsichtlich Funktionsumfang und Bedienbarkeit von Deep-Learning-Ansätzen ist ein wesentlicher Hebel, um Data-Scientist-Teams den Einstieg in das Deep Learning zu erleichtern. Zugleich werden aber auch immer stärker die Grenzen der reinen Mustererkennung im Vergleich zu einer dualen Verwendung von Mustererkennung mit generischen Lernansätzen diskutiert. Aber auch der hohe Komplexitätsgrad von Neuronalen Netzen gegenüber dem Einsatz von einfacheren Methoden bei ähnlich guten Ergebnissen wird zum Gegenstand einer lebhaften Diskussion.

## Literatur

- [Bishop 1995] Bishop, Ch.: Neural Networks for Pattern Recognition. Oxford: Clarendon Presse 1995. [http://cs.du.edu/~mitchell/mario\\_books/Neural\\_Networks\\_for\\_Pattern\\_Recognition\\_-\\_Christopher\\_Bishop.pdf](http://cs.du.edu/~mitchell/mario_books/Neural_Networks_for_Pattern_Recognition_-_Christopher_Bishop.pdf)
- [BITKOM 2017] o.V.: Entscheidungsunterstützung mit Künstlicher Intelligenz - Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung. [https://www.bitkom.org/noindex/Publikationen/2017/Positionspapiere/FirstSpirit-1496912702488Bitkom-DFKÜNSTLICHE\\_INTELLIGENZ-Positionspapier-Digital-Gipfel-AI-und-Entscheidungen-13062017-2.pdf](https://www.bitkom.org/noindex/Publikationen/2017/Positionspapiere/FirstSpirit-1496912702488Bitkom-DFKÜNSTLICHE_INTELLIGENZ-Positionspapier-Digital-Gipfel-AI-und-Entscheidungen-13062017-2.pdf), abgerufen am 2018-02-21.
- [BITKOM 2015] Bitkom-Bundesverband Informationswirtschaft, Telekommunikation und neue Medien e.V. (Hrsg.): Leitlinien für den Big Data Einsatz. Chancen und Verantwortung. 2015.
- [BITKOM 2013] Bitkom-Arbeitskreis Big Data: Management von Big-Data-Projekten. Bitkom 2013.
- [Brause 1991] Brause, R.: Neuronale Netze: eine Einführung in die Neuroinformatik, in: Brause, R.; Appelrath, H.-J.; Claus, V.; [u. a.] (Hrsg.): Leitfäden und Monographien der Informatik, Stuttgart, 1991.
- [Cavanillas et al. 2016] Cavanillas, J. M.; Curry, E.; Wahlster, W. (Eds.): New Horizons for a Data-Driven Economy. A Roadmap for Usage and Exploitation of Big Data in Europe. Springer 2016.
- [Düsing 1997] Düsing, R.: Betriebswirtschaftliche Anwendungsbereiche konnektionistischer Systeme, in: Düsing, R.; Barth, K.; Bodenstein, G.; [u. a.] (Hrsg.): Duisburger betriebswirtschaftliche Schriften, Band 14, Hamburg, 1997.
- [Felden 2017] Felden, C.: Die Bedeutung von Big Data und Advanced Analytics für die Mittelstandsfinanzierung, in: Corporate Finance, 11-12, November/ Dezember 2017, S.333-338.
- [Hussy 1983] Hussy, W.: Denken und Problemlösen, Stuttgart; Berlin; Köln: Kohlhammer 1993.
- [Karn 2018] Karn, U.: An Intuitive Explanation of Convolutional Neural Networks. <https://ujjwalkarn.me/2016/08/11/intuitive-explanation-convnets/> Abruf am 2018-02-22.
- [Khanna 1990] Khanna, T.: Foundations of Neural Networks, Reading, Massachusetts [u. a.], 1990.
- [Mandorf 2008] Mandorf, S.: Einführung in Expertensysteme – Beitrag zu Grundlagen des Knowledge Engineering. <https://www.grin.com/document/115039>. Abruf am 2018-02-22.
- [McCulloch/Pitts 1943] McCulloch, W. S.; Pitts, W.: A logical calculus of the ideas immanent in nervous activity, in: Bulletin of mathematical biophysics, Vol. 5, 1943, S. 115-133.
- [Nielsen 2017] Nielsen, M.: Neural Networks and Deep Learning. <http://neuralnetworksanddeeplearning.com/index.html>. Abruf am 2017-07-10.
- [Purdy/Daugherty 2016] Purdy, M.; Daugherty, P.: Why Artificial Intelligence is the Future of Growth. [https://www.accenture.com/lv-en/\\_acnmedia/PDF-33/Accenture-Why-AI-is-the-Future-of-Growth.pdf](https://www.accenture.com/lv-en/_acnmedia/PDF-33/Accenture-Why-AI-is-the-Future-of-Growth.pdf). Abruf am 2018-02-21.
- [Sutton/Barto 2017] Sutton, R. S.; Barto, A. G.: Reinforcement Learning: An Introduction. Second Edition. The MIT Press, Cambridge (Massachusetts), London (England), 2017. <http://incompleteideas.net/book/bookdraft2017nov5.pdf>. Abruf am 2017-07-10.

## Über unsere Sponsoren

# EVACO

## Intelligent Business Solutions

### Kontakt

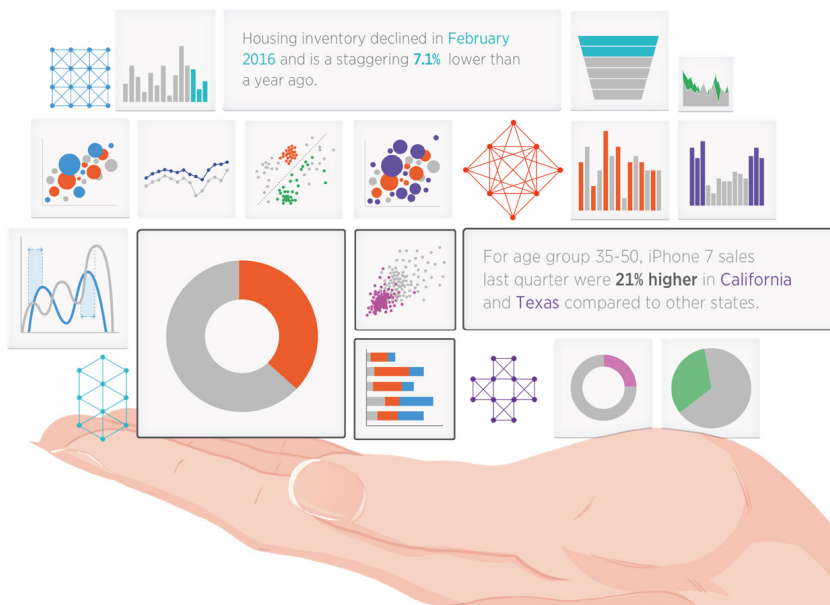
EVACO GmbH  
Philosophenweg 31-33  
47051 Duisburg

Tel: +49 203 709002-0  
Fax: +49 203 709002-11  
E-Mail [info@evaco.de](mailto:info@evaco.de)  
URL [www.evaco.de](http://www.evaco.de)

In DACH ist EVACO führender Anbieter für anwendergesteuerte Business Analytics-Lösungen, insbesondere für die Qlik Visual Analytics Platform, Qlik Sense & QlikView und hat sich auf die Beratung und Implementierung moderner Analysesysteme spezialisiert. Unternehmensziel ist es, aus komplexen Daten Wissen zu machen – Wissen, das Kunden die Grundlage bietet, einfacher und schneller zu entscheiden. Mehr als fünfzehn Jahre branchenübergreifende Expertise sowie die Zusammenarbeit mit ausgewählten internationalen Partnern ermöglichen BI-Anwendern den entscheidenden Vorteil bei der Optimierung ihrer Analysen.

Durch die Partnerschaft mit ThoughtSpot ist EVACO in der Lage, hier in Deutschland eine zukunftsweisende Analyse-Plattform, bei der Business Intelligence auf Basis von Enterprise Search und künstliche Intelligenz umgesetzt wird, in Unternehmen zu realisieren. Der bisher einzigartige Ansatz, eine Google-ähnliche Suche mit künstlicher Intelligenz zu kombinieren, ermöglicht Anwendern von ThoughtSpot Abfragen über Milliarden von Datensätzen in Sekundenschnelle mit einem einzigen Klick. Mit SpotIQ von ThoughtSpot legt EVACO die Leistungsfähigkeit von tausend Analysten direkt in die Hände der Anwender.

Für weitere Informationen kontaktieren Sie uns! Wir sind neben dem Hauptsitz Duisburg, auch in Hamburg, Leipzig und München vertreten.



Als hätten Sie  
die Leistung  
von tausend  
Analysten  
direkt in  
Ihrer Hand.



**E-Book**