

Ulrich Engelke | Barbara Engelke

ChatGPT & Co. in der **Schule**

Modern unterrichten mit KI

Effizient vorbereiten,
lehren, prüfen und
korrigieren



Inhaltsverzeichnis

Einleitung	11
Was Sie in diesem Buch erwartet	12
Über die Autoren	13
1 KI, Machine Learning & ChatGPT	15
1.1 Wie funktionieren KI-Chatbots?	15
1.1.1 Überblick über KI und maschinelles Lernen	15
1.1.2 Die Dartmouth-Konferenz und führende Köpfe der KI	16
1.1.3 Kurzer Abriss der KI-Entwicklung bis heute	18
1.1.4 Machine Learning und Deep Learning	20
1.1.5 Sam Altman, OpenAI und ChatGPT	24
1.1.6 Und wie funktionieren KI-Chatbots nun wirklich?	26
1.2 Datenschutz, Urheberrecht und Einschränkungen	32
1.2.1 Datenschutz und KI-Bots	32
1.2.2 Urheberrecht und LLMs	34
1.2.3 Einschränkungen von KI-Chatbots	38
1.2.4 Halluzinieren von KI-Sprachmodellen	45
1.2.5 Sind KI-Suchmaschinen die Zukunft?	48
1.3 Erste Schritte mit ChatGPT	51
1.3.1 Als neuer Nutzer registrieren	51
1.3.2 Erste Schritte des Promptings	52
1.3.3 Kostenlose oder kostenpflichtige Nutzung?	55
2 Richtig prompten – Ein Prozess	57
2.1 Simple-Prompts und einfache Erweiterungen	57
2.2 Die wichtigsten zehn Prompting-Parameter	59
2.2.1 Aufgabe, Limitierung und Ausgabeform	60
2.2.2 Das Ziel	61
2.2.3 Der Tonfall	62
2.2.4 Die Rolle	63
2.2.5 Das Publikum	64
2.2.6 Die Terminologie	65
2.2.7 Schlüsselwörter	67
2.2.8 Die Sprache	69
2.2.9 Top 10 der Prompting-Parameter im Überblick	73

2.3	Weitere Prompting-Parameter	73
2.3.1	Kontext	73
2.3.2	Statistik	75
2.3.3	Standpunkte	75
2.3.4	Begründungen	76
2.3.5	Gegenargumente	78
2.3.6	Analogien	79
2.3.7	Expertenurteile	80
2.3.8	Zitate	83
2.3.9	Beispieltexte und Prompt-Rückschluss-Technik	85
2.3.10	Sensible Inhalte	88
2.4	Allgemeine Regeln für bessere Prompts	89
2.5	Was sind Power-Prompts?	92
2.6	Basis-Prompts setzen Rahmen für folgende Anfragen	94
2.7	Rollenspiele mit der KI: »Du bist jetzt mein ...«	95
2.8	Temperatur der Ausgabe steuern	98
2.9	Iteratives Prompting, Feedback-Schleifen und Optimierungen	101
2.10	Prompts von ChatGPT verbessern lassen	103
3	ChatGPT als Assistent des Lehrenden	111
3.1	Unterrichtsvorbereitung	111
3.1.1	Jahresplanung und Strukturierung	111
3.1.2	Fächerübergreifende Projekte	113
3.1.3	Binnendifferenzierung	115
3.1.4	Vereinfachen komplizierter Regeln	119
3.1.5	Vereinfachen von Texten – Hilfen für förderungsbedürftige Schüler oder bei schwierigen Inhalten (inklusive Ansatz) .	121
3.1.6	Eilige Unterrichtsvorbereitung	123
3.1.7	Größere Methodenvielfalt	125
3.2	Herausforderungen außerhalb des Unterrichts	128
3.2.1	Artikel für den Jahresbericht der Schule	128
3.2.2	Zwischenmenschliche Probleme	129
3.2.3	Tipps für Disziplinprobleme und Elterngespräche	131
3.2.4	Vorbereitung von Studienfahrten (inkl. Elterninformation)	135
3.3	ChatGPT im Unterricht	139
3.3.1	Kognitive Schulung: Erörtern und Debattieren	141
3.3.2	Die Arbeit mit Bildern	142
3.3.3	Einführung in ChatGPT	143
3.4	Prüfungsvorbereitung	145
3.4.1	Allgemeine Prüfungsvorbereitung	145
3.4.2	Prüfungsvorbereitung mit Custom GPTs	147

3.5	Korrigieren mit KI	149
3.5.1	PEER	150
3.5.2	DeepL-Write-Schreibassistent	151
3.5.3	ChatGPT 4o	152
3.6	Weitere digitale Tools für Lehrkräfte	154
4	Einsatz von KI für verschiedene Schularten und Fächer	157
4.1	Grundschule	158
4.1.1	Unterrichtsvorbereitung	158
4.1.2	Unterstützung im Unterricht	162
4.1.3	Nachbereitung (Korrekturen und Prüfungen)	165
4.1.4	Pädagogische Arbeit an den Grundschulen	173
4.2	Mittelschule (ehemals Hauptschule)	179
4.2.1	Unterrichtsvorbereitung	180
4.2.2	Unterstützung im Unterricht	182
4.2.3	Nachbereitung, Korrekturen und Prüfungen	185
4.2.4	Nebenfächer an der Mittelschule	187
4.2.5	Pädagogische Arbeit an den Mittelschulen	192
4.3	Realschulen und Gymnasien	193
4.3.1	Unterrichtsvorbereitung	194
4.3.2	Unterstützung im Unterricht	199
4.3.3	Nachbereitung, Korrekturen und Prüfungen	202
4.3.4	Weitere Fächer an Realschulen und Gymnasien	206
4.4	Pädagogische Arbeit an weiterführenden Schulen	225
4.4.1	Ethnische Heterogenität und Rassismus	227
4.4.2	Bildungsferne Stammfamilien	228
4.5	Verfassungsviertelstunde in Bayern	230
4.5.1	Grundschule	230
4.5.2	Mittelschule	231
4.5.3	Realschule	231
4.5.4	Gymnasium	232
5	Unterrichtsziel: KI-Kompetenz	233
5.1	Wie Jugendliche die Relevanz von KI für sich und die Schule einschätzen	233
5.2	Warum der Umgang mit ChatGPT und anderen KI-Technologien entscheidend ist	234
5.2.1	Die Zukunft (und Gegenwart) des Arbeitsmarkts	234
5.2.2	Fähigkeit zum kritischen Urteil	235
5.2.3	Verbesserung der Lernprozesse	237
5.2.4	Lebenslanges Lernen	237

5.3	Die 4 Ks der Bildung im 21. Jahrhundert	238
5.4	Reformpädagogik und KI – das geht	246
5.4.1	Erfahrungsorientiertes Lernen	246
5.4.2	Neue Rolle der Lehrkraft	247
5.4.3	Kooperatives Lernen	247
5.4.4	Offene Unterrichtsformen	248
6	Datenschutzkonform unterrichten	255
6.1	Die Unsicherheit der Lehrkräfte im Umgang mit KI	255
6.2	Grundprinzipien des Datenschutzes und die DSGVO	256
6.2.1	Was sind personenbezogene Daten?	256
6.2.2	Lehrkräfte und Datenschutz	257
6.2.3	Die sechs Grundprinzipien der DSGVO	257
6.3	Warum Datenschutz im Unterricht mit KI meist gar kein Problem ist	259
6.4	KI-Tools und Plattformen für Lehrkräfte mit Datenschutzversprechen im Faktencheck	259
6.4.1	KI-Tools für Lehrkräfte im Überblick	260
6.4.2	Datenschutzkonformität von KI-Tools für Lehrkräfte	263
6.4.3	ChatGPT und Datenschutz – Welche Version für Lehrkräfte?	264
6.5	Vorschlag für einen DSGVO-konformen KI-Einsatz in Schulen ...	265
6.5.1	Vermeidung der Eingabe personenbezogener Daten	265
6.5.2	Team-, Enterprise oder Edu-Version von ChatGPT mit korrekter Einstellung	266
6.5.3	Nutzung einer lokalen KI ohne Internetverbindung	266
6.6	Konkrete Handreichung mit Checkliste für Schulen	267
6.7	Quelle: datenschutz-schule.info	269
6.8	Regeln für künstliche Intelligenz – der EU AI Act und die KI-Verordnung	270
7	Herausforderungen für den Bildungssektor	273
7.1	Betrug durch KI?	273
7.1.1	Selbstverständlicher Umgang mit KI-Modellen im Schulalltag	274
7.1.2	Prüfungsleistungen aus dem häuslichen Umfeld	275
7.1.3	Wie zitiert man die Ergebnisse von KI-Textgeneratoren? ..	275
7.2	Generative KI im W-Seminar	276
7.2.1	Assistenz der Lehrkräfte	276
7.2.2	ChatGPT als Schülerwerkzeug für die W-Seminararbeit ...	278

7.3	Prüfen mit Sprachgeneratoren – ein Blick in die Zukunft	284
7.3.1	Zukunftsformat 1: Text im Team	284
7.3.2	Zukunftsformat 2: Gamifiziertes Prüfen	286
	Sei nett zu deiner KI	289
	Stichwortverzeichnis	293

KI, Machine Learning & ChatGPT

Das nächste große Ding ist da und es passt in jede Hosentasche: Künstliche Intelligenz ist dabei, den Alltag zu erobern und klopft nun auch an den Türen der Klassenzimmer an. Zwischen Schulbüchern, Tafel, Heften und Stundenplänen ist ein neues Thema aufgetaucht, das nicht mehr verschwinden wird. Wie verändert KI im Allgemeinen und ChatGPT im Besonderen die Schule und unseren Unterricht?

Wir zeigen Ihnen, wie diese intelligenten Technologien funktionieren und wie sie nicht nur unseren Alltag, sondern auch das Lernen und Lehren revolutionieren. Zunächst werfen wir mit diesem einführenden Kapitel einen Blick hinter die Kulissen der digitalen Revolution im Bildungsbereich. Statt trockener Theorie erwartet Sie eine anschauliche Reise von den Anfängen der KI bis zu aktuellen Entwicklungen wie ChatGPT, die weit mehr können, als nur einfache Antworten auf simple Fragen zu geben.

1.1 Wie funktionieren KI-Chatbots?

Ein Chatbot alias *Large Language Model* (LLM) ist ein KI-Modell, das auf einer riesigen Menge an Textdaten trainiert wurde, um natürliche Sprache zu verstehen und zu generieren. Es kann Texte verfassen, Fragen beantworten und viele sprachbasierte Aufgaben unterstützen. KI und maschinelles Lernen haben eine Revolution eingeläutet, von der erst spätere Generationen wissen werden, welche tiefgreifenden Veränderungen sie ausgelöst hat. Klar ist aber längst, dass die Veränderungen bahnbrechend sind und dass die Auswirkungen auf unser Leben ebenso vielfältig wie unabsehbar sind.

1.1.1 Überblick über KI und maschinelles Lernen

KI als Thema wirft uns notgedrungen immer wieder auf die Frage zurück, was *Intelligenz* eigentlich ist. Das ist gar nicht so einfach zu beantworten. Auf jeden Fall ist die Frage nach der Intelligenz eine, an der sich unterschiedliche Fächer und Forschungsrichtungen seit vielen Jahren abarbeiten und noch zu keiner gemeinsamen und allgemeingültigen Definition gefunden haben. Intelligenz kann man als ein komplexes und vielschichtiges Konzept beschreiben, das sich auf die Fähigkeit von Individuen bezieht, Informationen zu verarbeiten und darauf basierend zu handeln. Wir können also **lernen** und das Gelernte **sinnvoll anwenden** und immer **weiterentwickeln**, bis wir Dinge tun, die wir so niemals gelernt haben. Das wäre

eine zumindest vorläufige und grundlegende Definition von natürlicher, menschlicher Intelligenz.

Das eigentlich Faszinierende daran ist der *Transfer*, also unsere Fähigkeit, Probleme zu lösen, die teilweise weit über das Gelernte hinausgehen. Dass wir unser Wissen ganz offensichtlich an immer neue Situationen anpassen und dort erfolgreich anwenden, ist ein ganz wichtiger Teil unserer Intelligenz. Um zu verstehen, wie das möglich ist, müssen wir uns die ganze Palette unserer kognitiven Fähigkeiten möglichst detailliert ansehen, einschließlich des **logischen Denkens**, der kreativen **Problemlösungskompetenz**, der gezielten **Wahrnehmungsfähigkeit**, des **Verständnisses von Zusammenhängen**, der Fähigkeit zur **Kommunikation** und des **Lernens aus Erfahrungen**. Aus diesen und anderen Grundfertigkeiten entstehen neue und zunehmend komplexere Fertigkeiten: die Fähigkeit, aus der Interaktion mit der Umwelt zu lernen, anspruchsvolle Konzepte zu erfassen, effektiv zu planen und zu handeln sowie kreativ und innovativ auf immer neue Herausforderungen zu reagieren.

Die Urväter der KI waren von der natürlichen, menschlichen Intelligenz auf jeden Fall so fasziniert, dass sie diese unsere Fähigkeiten auf Maschinen übertragen und Computern das selbstständige Lernen und Denken beibringen wollten. Die Ursprünge der Künstlichen Intelligenz sind stark mit dem Streben verbunden, maschinelle Systeme zu schaffen, die ähnliche kognitive Fähigkeiten wie der Mensch aufweisen. Die Urväter der KI, darunter Wissenschaftler wie Alan Turing, John McCarthy, Marvin Minsky, Allen Newell und Herbert A. Simon, waren von der Komplexität und Vielseitigkeit der menschlichen Intelligenz tief beeindruckt und inspiriert. Sie wollten verstehen, wie Intelligenz funktioniert, und diese Erkenntnisse nutzen, um Maschinen zu entwickeln, die ähnliche Aufgaben ausführen können. Heute ist Künstliche Intelligenz – oder im englischen Original Artificial Intelligence (AI) – der Überbegriff für durch Maschinen erbrachte, menschenähnliche Intelligenzleistungen.

1.1.2 Die Dartmouth-Konferenz und führende Köpfe der KI

Wie immer ist die Entwicklung neuer Technologien eng mit der Leistung ihrer Pioniere und bestimmten Ereignissen verbunden. **Alan Turing** gehört zu den ersten Visionären, der die Frage stellte, ob Maschinen denken können. Der berühmte **Turing-Test** war damals (1950) eher eine Idee als ein Test, der mit den vorhandenen Programmen schon hätte durchgeführt werden können: Wenn eine Maschine in der Lage ist, in einem Gespräch nicht von einem Menschen unterscheidbar zu sein, könnte sie als *intelligent* betrachtet werden und hätte damit den Turing-Test bestanden.

Die **Dartmouth-Konferenz** von 1956 gilt als die Geburtsstunde der KI als eigenständiges Forschungsfeld der Informatik, hier wurde die Grundlage für die zukünftige

Forschung in diesem Bereich gelegt. Eine Vielzahl führender Köpfe kam auf dieser Konferenz zusammen.

John McCarthy ist eine Schlüsselfigur in der Geschichte der Künstlichen Intelligenz, er gilt vielen sogar als der eigentliche Vater der KI. Zumindest hat er schon während der Vorbereitung der Dartmouth Konferenz den Begriff *Künstliche Intelligenz (KI)* geprägt. Außerdem entwickelte er 1958 die Programmiersprache *LISP*, die zur bevorzugten Sprache in der KI-Forschung wurde und es in einigen Bereichen bis heute ist. McCarthy hat bedeutende Beiträge in mehreren Kernbereichen der KI verfasst, war ein Vorreiter bei der Entwicklung von Theorien und Modellen, die es Computern ermöglichen sollen, Alltagswissen zu nutzen, das für Menschen selbstverständlich ist. Er arbeitete sogar bereits an der Konzeptualisierung von autonomen Systemen, einschließlich autonomer Fahrzeuge, und entwickelte Technologien, wie sie heute in selbstfahrenden Autos zum Einsatz kommen.

Marvin Minsky war ein weiterer Pionier und gilt als der einflussreichste Theoretiker im Forschungsfeld. Er gründete zusammen mit John McCarthy das *MIT Artificial Intelligence Laboratory*, das zu einem der weltweit führenden Zentren für KI-Forschung wurde. Dieses Labor zog viele talentierte Forscher an und war der Geburtsort zahlreicher bahnbrechender Ideen und Technologien im Bereich der KI. Minsky entwickelte die sogenannte *Frametheorie*, die ein Konzept zur Wissensrepräsentation in KI-Systemen darstellt. Minskys Buch *Society of Mind* ist ein bahnbrechendes Werk, das eine Theorie der menschlichen Intelligenz und des Bewusstseins als Netzwerk aus vielen kleinen und einfachen Prozessen bzw. Agenten entwirft. Diese Idee hat die Forschung in den Bereichen kognitive Wissenschaften und KI beeinflusst, insbesondere im Hinblick auf das Verständnis davon, wie komplexe geistige Prozesse aus simpleren Interaktionen entstehen können. Minsky hat Generationen von Studenten beeinflusst, die später zu führenden Wissenschaftlern und Technikern in der KI und verwandten Feldern wurden.

Nathaniel Rochester arbeitete bei IBM und war einer der Architekten des *IBM 701*, des ersten wissenschaftlichen Computers des Unternehmens. Seine Arbeit trug wesentlich dazu bei, die technische Basis für spätere Entwicklungen in der KI zu ermöglichen. Rochester war auch an der Entwicklung eines der ersten Programme beteiligt, das als KI-Experiment angesehen werden kann. Das Programm wurde auf dem *IBM 704*-Computer implementiert und zielte darauf ab, einfache algebraische Probleme zu lösen.

Claude Shannon revolutionierte das Verständnis von Datenübertragung, -verarbeitung und -speicherung. Seine Grundprinzipien der Informationstheorie sind für viele Aspekte der KI, wie Datenkompression und Fehlerkorrektur in maschinellen Lernsystemen, von großer Bedeutung. Shannon war einer der Ersten, der die Möglichkeiten von Computern zum Spielen von Schach und anderen Spielen erforschte. Seine Arbeiten in den 1950er-Jahren, insbesondere seine Strategien zur Schach-

programmierung, gelten als Pionierleistungen und beeinflussten die Entwicklung von KI-Algorithmen im Bereich der *Spiele* und *Entscheidungstheorien*.

Die führenden Köpfe der Dartmouth-Konferenz und ihre unterschiedlichen Schwerpunkte machen uns begreiflich, wie viele unterschiedliche Forschungsansätze nötig waren und an einem Ort zusammenkommen mussten, damit wir heute die Früchte ihrer visionären Gedanken und ambitionierten Bemühungen ernten können.

1.1.3 Kurzer Abriss der KI-Entwicklung bis heute

Nach der Dartmouth-Konferenz als Geburtsstunde der Künstlichen Intelligenz entwickelte sich die Forschung in mehreren Phasen weiter. Hier sind die wichtigsten Etappen und eine kurze Beschreibung der wesentlichen Entwicklungen von 1956 bis heute:

Frühphase (1956 bis 1970er-Jahre)

Die ersten Jahrzehnte der KI-Forschung konzentrierten sich stark auf symbolische Methoden und Expertensysteme. Diese Systeme basierten auf Logik und regelbasierten Entscheidungsprozessen, die menschliches Wissen speichern und versuchen, komplexe Problemlösungsfähigkeiten zu imitieren. Zu Beginn herrschte großer Optimismus über die Möglichkeiten der KI und die Forscher gingen davon aus, dass bedeutende Fortschritte schnell erreicht werden könnten. Allerdings stießen sie bald auf erhebliche technische und konzeptionelle Herausforderungen, die das Fortschrittstempo verlangsamten.

KI-Winter (1970er- bis 1980er-Jahre)

Der (erste) KI-Winter ist geprägt von allgemeiner Ernüchterung und unerwarteten Finanzierungsproblemen. Aufgrund der enttäuschten Erwartungen und der begrenzten Fortschritte kam es in den 1970er- und 1980er-Jahren zu einem Rückgang des Interesses für die KI-Forschung und einer zunehmend unsicheren Finanzierung. Trotz der allgemeinen Stagnation gab es in einigen spezifischen Bereichen Fortschritte, wie z.B. in der Entwicklung von Algorithmen für das maschinelle Lernen und in der Robotik.

Aufstieg der Maschinen und neuronalen Netze (1980er- bis 2000er-Jahre)

In den 1980er-Jahren erlebte die KI einen erneuten Aufschwung durch den Einsatz von **Expertensystemen** in der Industrie. Expertensysteme zielten darauf ab, das Wissen und die Entscheidungsfähigkeiten menschlicher Experten in einem spezifischen, eng abgegrenzten Bereich nachzuahmen. Diese Systeme zogen deduktive Schlussfolgerungen und trafen Entscheidungen auf Basis einer komplexen Wissensbasis aus Fakten und Regeln. An der Stanford University entstanden mehrere Programme in den Bereichen der medizinischen Diagnostik und chemischen Analyse: **MYCIN** wurde entwickelt, um bakterielle Infektionen zu diagnostizieren

und geeignete Antibiotika-Behandlungen vorzuschlagen. **DENDRAL** half Chemikern bei der Interpretation von Massenspektren, um die Struktur organischer Moleküle zu bestimmen. Damit waren KI-Programme erstmals in der Lage, komplexe wissenschaftliche Probleme zu lösen.

In diese Zeit fällt auch die Wiederentdeckung und Weiterentwicklung **neuronaler Netze**, die für den eigentlichen Durchbruch im maschinellen Lernen verantwortlich sind und zu bedeutsamen praktischen Fortschritten führten. Künstliche neuronale Netze sind Computer-Modelle, die von der Struktur und Funktionsweise des menschlichen Gehirns inspiriert sind. Ein neuronales Netz besteht aus mehreren Schichten von Knoten (Neuronen), die miteinander verbunden sind. Hinzu kamen neue Lernalgorithmen wie das *Backpropagation-Verfahren*, mit denen die Gewichte in einem neuronalen Netz angepasst werden konnten. Diese Gewichte sind die Werte, die die Stärke der Verbindung zwischen einzelnen Neuronen bestimmen. Sie beeinflussen, wie stark ein Eingangssignal weitergeleitet wird und sind entscheidend für das Lernen des Netzes. Das alles ermöglichte jetzt das Training tiefer neuronaler Netzwerke, die komplexe Muster in sehr großen Datensätzen erkennen konnten.

Datengetriebene KI und Deep Learning (2000er-Jahre bis heute)

Die 2000er-Jahre markieren zwei wichtige Entwicklungen, die zu den eigentlichen Katalysatoren der Künstlichen Intelligenz wurden: Mit der rasanten Verbreitung des Internets und dem immer schneller wachsenden World Wide Web bekamen Forscher einfachen Zugang zu riesigen Datenmengen – insbesondere Texten und Bildern. Hinzu kam eine geradezu explosionsartige **Entwicklung der Rechenleistung** von Computern: Große Fortschritte in der Halbleitertechnik, die Entwicklung von Mehrkernprozessoren, immer größere Speicherkapazitäten mit schnelleren Zugriffsgeschwindigkeiten, leistungsstarke Grafikkarten (GPUs) und die skalierbare Rechenleistung des Cloud Computings haben der datengetriebenen KI den entscheidenden Schub versetzt. Komplexe Algorithmen konnten nun auf riesigen Datensätzen mit gigantischer Rechenpower trainiert werden, was zu beeindruckenden Ergebnissen in verschiedenen Anwendungsbereichen führte. Die Nutzung tiefer neuronaler Netze (Deep Learning) hat zu bahnbrechenden Fortschritten in Bereichen wie Bilderkennung, Sprachverarbeitung und Spielen wie AlphaGo geführt.

Gerade in den letzten Jahren hat sich das Tempo nochmals vervielfacht, KI flutet unser Leben wie ein mächtiger Tsunami: Apple, Microsoft, Google und Amazon haben jeweils eigene **Sprachassistenten** entwickelt und über **mobile Endgeräte** in unseren Alltag eingeschleust. Andere KI-Technologien sind mittlerweile in vielen Bereichen des täglichen Lebens präsent, neben Sprachassistenten sind selbstfahrende Autos Realität geworden, medizinische Diagnosen nutzen KI und personalisierte Empfehlungen auf Facebook, YouTube und Spotify sind für uns ganz selbstverständlich geworden.

1.1.4 Machine Learning und Deep Learning

Aber wie wurde das alles, noch dazu in so kurzer Zeit, möglich? Was unterscheidet die KI so grundlegend von anderen Zweigen der Informatik? Welche Methoden und Prinzipien machen den entscheidenden Unterschied? Um das herauszufinden, müssen wir uns mit dem Bereich Machine Learning (ML) befassen. Machine Learning ist ganz allgemein gesprochen ein Teilbereich der Künstlichen Intelligenz, der sich mit der Entwicklung von Algorithmen und statistischen Modellen beschäftigt, die Computersysteme in die Lage versetzen, aus Daten zu lernen und Muster zu erkennen, ohne explizit für genau diese Muster programmiert zu sein.

Machine Learning (oder künstliches Lernen ganz allgemein) wird üblicherweise in drei grundlegende Konzepte bzw. Methoden unterteilt: überwachtes Lernen (Supervised Learning), unüberwachtes Lernen (Unsupervised Learning) und bestärkendes Lernen (Reinforcement Learning).

Überwachtes Lernen (Supervised Learning)

Überwachtes Lernen liegt immer dann vor, wenn ein Algorithmus aus einem vorbereiteten Trainingsdatensatz lernt, der neben den Eingabedaten auch schon die entsprechenden Ausgabewerte enthält. Der einfachste und am häufigsten zitierte Fall zur Erklärung des überwachten Lernens ist ein Algorithmus, der Bilder von Hunden und Katzen unterscheiden kann. Wir nehmen dazu einen Datensatz mit 100 Bildern, 50 Hundebilder und 50 Bilder von Katzen. Typischerweise würde man jetzt 70 Bilder für das Training verwenden und dem Algorithmus zu jedem Bild die Information geben, um welches der beiden Tiere es sich auf dem gezeigten Bild handelt. Ist das Training abgeschlossen, prüft man mit den restlichen 30 Bildern, wie gut die Unterscheidung in der Praxis schon funktioniert. Ist das Ergebnis noch nicht zufriedenstellend und die Fehlerrate zu hoch, kann der Algorithmus durch zusätzliches Training verbessert werden. Weitere Bilder müssen bereitgestellt und klassifiziert (gelabelt) werden, solche *gelabelten Daten* sind die Voraussetzung für überwachtes Lernen. In unserem Fall müssten mindestens weitere 100 Bilder von Hunden und Katzen einer der beiden Arten zugeordnet werden. Der Aufwand dafür ist zwar überschaubar, aber die Fähigkeiten des so entstandenen Programms sind natürlich auch sehr begrenzt.

Reale Anwendungsbeispiele des überwachten Lernens bringen aber schon ziemlich komplexe Programme mit hohem praktischen Nutzen hervor. Der *Bayes-Filter* ist eine weit verbreitete Methode zur **Klassifikation von E-Mails als Spam oder Nicht-Spam**. Statt Tierbildern legt man dem Algorithmus reale Mails aus dem eigenen Postfach vor und kennzeichnet alle, die wir als Spam einstufen und eigentlich nicht lesen wollen. Daraus lernt der Algorithmus eine individuelle und recht zuverlässige Klassifikation von E-Mails als Spam oder Nicht-Spam. Eine andere KI-Anwendung kann den **Kaufpreis eines Hauses**, basierend auf typischen Merkmalen wie Baujahr, Quadratmeterzahl, Anzahl der Schlafzimmer usw., vor-

hersagen. Überwachtes Lernen ist die Grundlage von **Algorithmen zur Gesichtserkennung** oder um vorherzusagen, ob ein Kunde ein Produkt kauft – basierend auf dem Verhalten anderer, ähnlicher Kunden. Auf der Basis medizinischer Daten kann damit die Wahrscheinlichkeit eines Herzinfarkts für einen gegebenen Patienten berechnet und vorausgesagt werden. Die viel zitierte **Kreditrisikobewertung** für eine Bank ist ebenfalls eine auf überwachtem Lernen basierte Anwendung, um die Wahrscheinlichkeit vorherzusagen, mit der ein Kreditnehmer seine Schulden zurückzahlen wird oder ob die Forderung ausfällt.

Unüberwachtes Lernen (Unsupervised Learning)

Nicht alle Daten können vor dem Training aufbereitet und gelabelt werden: Erstens, weil der Aufwand zu hoch ist und die Datenmenge dadurch immer begrenzt bleibt, und zweitens, weil oft gar noch nicht bekannt ist, welche Merkmale für eine Kennzeichnung überhaupt relevant sind. Unüberwachtes Lernen ist eine Methode des maschinellen Lernens, bei der der Algorithmus auf einen Datensatz ohne vorherige Kennzeichnung der Daten trainiert wird. Statt explizit zu wissen, welche Daten zu welchen (noch unbekannt) Kategorien gehören, versucht der Algorithmus, *Muster und Strukturen in den Daten selbst zu erkennen*. Ein klassisches Beispiel für unüberwachtes Lernen ist das *Clustering*, bei dem ähnliche Datenpunkte in Gruppen oder Clustern zusammengefasst werden.

Stellen Sie sich vor, Sie haben einen Datensatz mit 1.000 Bildern von Tieren, darunter Hunde, Katzen, Vögel und Fische, aber ohne zu wissen, welche Bilder zu welchen Tieren gehören. Ein Clustering-Algorithmus wie *K-Means* könnte verwendet werden, um diese Bilder in Gruppen zu unterteilen, basierend auf ihren Ähnlichkeiten. Der Algorithmus könnte beispielsweise feststellen, dass es vier Hauptgruppen gibt und diese entsprechend kennzeichnen. Wir wissen jedoch nicht im Voraus, dass eine Gruppe *Hunde* und eine andere *Katzen* enthält; das muss durch Interpretation der resultierenden Cluster erfolgen.

Ein weiteres Beispiel für unüberwachtes Lernen ist das Vereinfachen von großen Datensätzen für die Analyse von Kunden in einem Supermarkt, über die sehr viele unterschiedliche Daten gesammelt wurden:

- Alter
- Geschlecht
- Wohnort
- Einkommen
- Einkaufsgewohnheiten (z.B. Häufigkeit der Einkäufe, bevorzugte Wochentage)
- Gekaufte Produkte (z.B. Obst, Gemüse, Fleisch, Milchprodukte)
- Durchschnittlicher Einkaufswert
- Zahlungsmethode (z.B. bar, Kreditkarte)

Das sind sehr viele Informationen und es ist schwierig, einen Überblick zu behalten. Mit Techniken wie der Hauptkomponentenanalyse (*PCA*) oder *t-SNE* kann man diese vielen Daten auf einige wenige wichtige Merkmale reduzieren, die trotzdem die wichtigsten Unterschiede zwischen den Kunden zeigen. Zum Beispiel könnte man die Daten auf die drei Merkmale *Einkaufsgewohnheiten*, *Alter* und *geografische Lage* reduzieren. Das macht es einfacher, Muster zu erkennen, wie z.B., dass Kunden aus bestimmten Wohngebieten häufiger einkaufen oder dass junge Kunden andere Produkte bevorzugen als ältere Kunden. So kann der Supermarkt seine Marketingstrategien besser anpassen und gezielt auf die Bedürfnisse verschiedener Kundengruppen eingehen.

Die Vorteile des unüberwachten Lernens

Weil Daten vorher nicht mehr manuell aufbereitet werden müssen, können wir beim unüberwachten Lernen auf wesentlich größere (und theoretisch unbegrenzte) Datenmengen zurückgreifen. Unüberwachtes Lernen kann dazu beitragen, neue und unentdeckte Muster oder Gruppen innerhalb der Daten zu identifizieren, um Daten zu bereinigen, zu gruppieren oder zu reduzieren, was die Effizienz und Genauigkeit von Modellen des überwachten Lernens verbessern kann.

Typische Anwendungen des unüberwachten Lernens:

- **Kundensegmentierung:** Einteilung von Kunden in Gruppen für gezieltes Marketing
- **Anomalieerkennung:** Erkennung von Betrug oder Fehlern in Finanztransaktionen oder Netzwerksicherheit
- **Marktforschung:** Entdeckung von Mustern und Trends in großen Datensätzen zur Unterstützung der Produktentwicklung
- **Dokumenten- oder Textklassifikation:** Gruppierung von Dokumenten, basierend auf ihrem Inhalt in Themen oder Kategorien, beispielsweise in Bibliotheken
- **Datenvisualisierung:** Visualisierung komplexer Datensätze in vereinfachter Form, um bessere Geschäftsentscheidungen zu treffen
- **Bildanalyse und Gesichtserkennung:** Erkennung von Mustern in Bilddaten
- **Empfehlungssysteme:** Erstellung personalisierter Empfehlungen für Videobeiträge, Filme und Produkte wie bei YouTube, Netflix und Amazon

Bestärkendes Lernen (Reinforcement Learning)

Bestärkendes Lernen ist die dritte grundlegende Methode des maschinellen Lernens, die durch kontinuierliches Feedback immer genauere Anpassungen und Op-

timierungen ermöglicht. Algorithmen und Maschinen lernen, optimale Entscheidungen zu treffen, um komplexe Aufgaben zu bewältigen. Hierzu lernt ein Agent durch Interaktion mit seiner Umgebung, wie er bestimmte Aufgaben ausführen kann, um eine **Belohnung zu maximieren**. Anders als beim überwachten Lernen, wo der Algorithmus anhand von gelabelten Daten trainiert wird, oder beim unüberwachten Lernen, wo der Algorithmus Muster in unstrukturierten Daten erkennt, basiert das bestärkende Lernen auf dem **Prinzip von Versuch und Irrtum**. Der Agent erhält Feedback in Form von Belohnungen, ausbleibenden Belohnungen oder gar Strafen und passt sein Verhalten entsprechend an. Ein einfaches Beispiel für bestärkendes Lernen ist das Training eines Saugroboters, der lernen soll, wie man durch ein Wohnzimmer navigiert. Der Roboter erhält eine Belohnung, wenn er das Ziel erreicht, und keine Belohnung, wenn er gegen eine Wand stößt. Anfangs wird der Roboter zufällige Bewegungen ausführen, aber mit der Zeit lernt er, welche Aktionen ihn näher zum Ziel der Belohnung bringen und welche nicht.

Roboter mögen keine Schokolade

Wenn Sie sich auch schon Gedanken darüber gemacht haben, womit man einen Staubsauger mit KI-Unterstützung belohnen kann: mit numerischen Belohnungspunkten! Der Roboter erhält Punkte oder einen numerischen Wert als Belohnung, wenn er erfolgreich ein Ziel erreicht, wie z.B. einen bestimmten Bereich vollständig zu reinigen oder effizient von einem Punkt zum anderen zu navigieren, ohne irgendwelche Hindernisse zu berühren. Roboter belohnt man eben anders als Menschen!

Ein anderes Beispiel sind Computerprogramme, die lernen, Spiele wie Schach oder Go zu spielen. Hier wird der Agent (das Programm) durch die Rückmeldungen (Gewinn oder Niederlage) trainiert. Der Algorithmus analysiert verschiedene Spielzüge und deren Ergebnisse, um Strategien zu entwickeln, die seine Gewinnchancen erhöhen.

Weitere typische Anwendungen des bestärkenden Lernens sind sehr vielfältig, viele finden sich in der Robotik. Sie ermöglicht es Robotern in dynamischen und komplexen Umgebungen wie in der Produktion oder bei Rettungseinsätzen, ihre Aufgaben immer effektiver und sicherer ausführen. Sie lernen, sich an neue Situationen anzupassen und Aufgaben effizient zu erledigen. Bestärkendes Lernen hilft bei der Optimierung beliebiger Prozesse und kann z.B. auch die Steuerung von Verkehrsflüssen erheblich verbessern: Der Agent lernt, wie er Ampelschaltungen optimieren kann, um den Verkehrsfluss zu maximieren und Staus zu minimieren.

In der Finanzwelt wird bestärkendes Lernen zur Entwicklung von Handelsalgorithmen eingesetzt werden, die optimale Entscheidungen treffen, um Gewinne zu maximieren und Verluste zu minimieren. Der Algorithmus lernt aus historischen