

1 Grundlagen der Künstlichen Intelligenz

In diesem Kapitel werden die Grundlagen der Künstlichen Intelligenz (KI) behandelt. International spricht man von »Artificial Intelligence« (AI). Das Ziel ist es, ein Verständnis für die Funktionsweise, Terminologie und Technologie von KI zu schaffen. Weniger im technischen Sinne, sondern eher für Sie als Entscheider aufbereitet. Es soll erreicht werden, dass Sie die aktuellen und kurzfristigen erwarteten Möglichkeiten so einordnen können, dass Sie gute Entscheidungen für Ihr Geschäftsmodell treffen können. Dies bildet die Grundlage für das tiefere Verständnis, wie KI im B2B-Vertrieb sinnvoll genutzt werden kann.

Was ist KI?

Künstliche Intelligenz, kurz KI, ist in aller Munde. Von selbstfahrenden Autos bis hin zu smarten Assistenten, die uns den Alltag erleichtern – KI scheint überall zu sein. Doch was genau verbirgt sich hinter diesem Begriff, der so vielversprechend und zugleich schwer fassbar klingt?

Eine Definition, die Licht ins Dunkel bringt

Wenn wir über KI sprechen, meinen wir im Wesentlichen Maschinen oder Systeme, die Aufgaben übernehmen können, die normalerweise menschliche Intelligenz erfordern. Diese Aufgaben umfassen das Verstehen von Sprache, das Treffen von Entscheidungen auf Basis unstrukturierter Information, das Erkennen von Mustern und sogar das Lernen aus Erfahrungen.

Künstliche Intelligenz bedeutet also, Maschinen so zu programmieren, dass sie in gewissem Maße »denken« und »handeln« können – zumindest in den Grenzen, die ihnen von ihren Entwicklern gesetzt werden.

Ein besonders alltagsnahes Beispiel für Künstliche Intelligenz, das wir fast alle nutzen, ist das Navigationssystem in unseren Autos oder auf unseren Smartphones. Diese Systeme verwenden KI, um Routen in Echtzeit zu berechnen, basierend auf einer Vielzahl von Daten wie Verkehrsinformationen, Straßensperrungen und gemessenen Reisezeiten.

Dabei lernen sie kontinuierlich aus neuen Informationen, um die besten Strecken vorzuschlagen. So wird die Fahrt nicht nur schneller und effizienter, sondern das System kann sich auch an individuelle Vorlieben anpassen, wie etwa die Vermeidung von Autobahnen oder Mautstraßen. Dies zeigt, dass KI in vielen Bereichen unseres Lebens eine stille, aber effektive Rolle spielt – oft, ohne dass wir es überhaupt bewusst wahrnehmen.

Von den Anfängen bis heute: Ein Blick zurück

Die Idee, Maschinen zu bauen, die denken können, ist nicht neu. Bereits in den 1950er Jahren legten Vordenker wie Alan Turing und John McCarthy die theoretischen Grundlagen der KI. Turing entwickelte den nach ihm benannten Turing-Test, der prüfen sollte, ob eine Maschine menschliche Intelligenz nachahmen kann, ohne dass der Mensch den Unterschied bemerkt.

McCarthy prägte den Begriff »Künstliche Intelligenz« und veranstaltete 1956 die berühmte Dartmouth-Konferenz, die als offizieller Startpunkt der KI-Forschung gilt. Seitdem hat sich die Technologie rasant weiterentwickelt.

Obwohl die Science-Fiction-Literatur schon in den 1960er Jahren visionäre Ideen von denkenden Maschinen und selbstlernenden Robotern hervorbrachte, verlief die tatsächliche Entwicklung der Künstlichen Intelligenz zunächst enttäuschend langsam. Werke wie Isaac Asimovs *Robotergesetze* oder Filme wie *2001: Odyssee im Weltraum* zeigten Welten, in denen KI tief in den Alltag integriert war und menschliche Aufgaben übernahm.

Die Realität hinkte diesen Visionen jedoch lange hinterher. In den ersten Jahrzehnten der KI-Forschung waren die Fortschritte bescheiden, und die hochgesteckten Erwartungen der frühen Forscher konnten oft nicht erfüllt werden. Es fehlte an Rechenleistung, Daten und ausgefeilten Algorithmen, um diese Ideen Wirklichkeit werden zu lassen.

Doch was damals nach einem ernüchternden Stillstand aussah, hat sich heute grundlegend verändert: Viele der Konzepte aus der Science-Fiction – von Sprachassistenten bis zu selbstfahrenden Autos – sind inzwischen Teil unseres Alltags geworden, angetrieben durch Fortschritte in der Rechentechnik und dem exponentiellen Wachstum von Daten.

Insbesondere die Verfügbarkeit großer Datenmengen, die für automatisierte Lernprozesse der KI-Systeme genutzt werden können, hat die Geschwindigkeit der Entwicklung enorm beschleunigt.

Schwache und starke KI

Wenn wir von KI sprechen, müssen wir zwischen zwei grundlegenden Typen unterscheiden: der schwachen und der starken KI.

- Schwache KI, auch »narrow AI« genannt, ist auf die Erfüllung spezifischer Aufgaben beschränkt. Beispiele dafür sind Sprachassistenten wie Siri oder Alexa, die in festgelegten Bereichen, wie der Spracherkennung und Befehlsausführung, brillieren. Diese Systeme können jedoch nicht über ihre programmierten Aufgaben hinausdenken oder handeln.
- Starke KI, oder »general AI«, wäre in der Lage, in einer Vielzahl von Bereichen so zu agieren wie ein Mensch – flexibel, lernfähig und anpassungsfähig. Bisher ist dies jedoch eher ein theoretisches Konzept und in der Praxis noch nicht verwirklicht. Wissenschaftler und Ingenieure arbeiten weltweit daran, diesen nächsten Schritt zu erreichen, aber es bleibt eine Herausforderung, die möglicherweise noch Jahrzehnte entfernt ist.

Abgrenzung der Begriffe in der Künstlichen Intelligenz

In der Diskussion rund um Künstliche Intelligenz (KI) begegnen uns häufig verschiedene Begriffe und Konzepte, die auf den ersten Blick verwirrend erscheinen können. Die Abbildung 1.1 visualisiert die Hierarchie und Abgrenzung einiger dieser zentralen Begriffe und hilft, die verschiedenen Bereiche der KI besser zu verstehen. Lassen Sie uns die einzelnen Schichten und Modelle näher betrachten, um eine fundierte Basis für strategische Entscheidungen im Geschäftsmodell zu schaffen.

Künstliche Intelligenz (KI)

Ganz oben, und zugleich der größte Rahmen, steht die Künstliche Intelligenz (KI) als übergeordneter Begriff. Sie umfasst alle Technologien, die darauf abzielen, menschenähnliche Intelligenz nachzuahmen – sei es durch maschinelles Lernen, das Verstehen und Generieren von Sprache oder das Erkennen von Bildern. Im Grunde genommen handelt es sich bei KI um die Fähigkeit von Maschinen, Aufgaben zu übernehmen, die traditionell menschliches Denken erfordern. Dabei geht es um Mustererkennung, Vorhersagen und die Automatisierung von Entscheidungen.

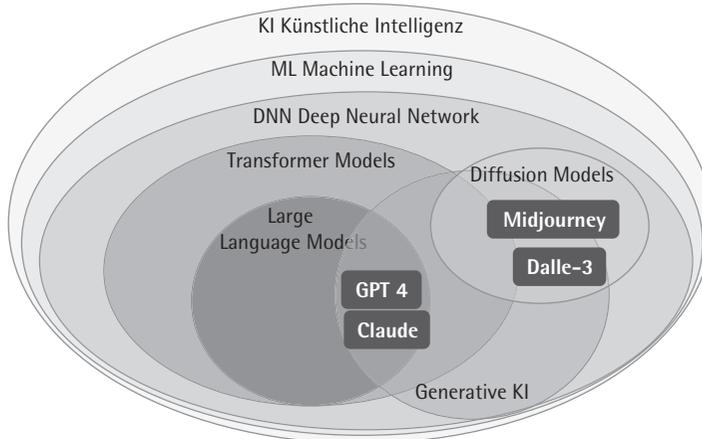


Abbildung 1.1: Zentrale Begriffe der KI

Maschinelles Lernen (ML)

Innerhalb der KI ist das Maschinelle Lernen (ML) ein besonders wichtiger Bereich. Hierbei geht es darum, dass Systeme aus Daten lernen, ohne explizit dafür programmiert zu werden. Während klassische Algorithmen auf festen Regeln basieren, können maschinelle Lernmodelle durch das Erkennen von Mustern in großen Datenmengen selbst lernen. Unternehmen können ML nutzen, um beispielsweise Prognosen zu erstellen, wie sich Märkte entwickeln, oder um Kaufverhalten vorherzusagen. Maschinelles Lernen bildet somit die Grundlage für viele der leistungsstarken KI-Systeme, die wir heute sehen.

Deep Neural Networks (DNN)

Ein spezieller Teil des maschinellen Lernens sind Deep Neural Networks (DNN). Diese tiefen neuronalen Netze sind inspiriert von der Struktur des menschlichen Gehirns und bestehen aus vielen Schichten von Neuronen, die komplexe Datenmuster erkennen können. Sie sind besonders effektiv bei der Verarbeitung unstrukturierter Daten, wie Bilder, Texte oder Audiodateien. Dies macht sie zu einem unverzichtbaren Werkzeug für Anwendungen, bei denen es um die Analyse großer, komplexer Datensätze geht. Im Vertrieb können Deep Neural Networks helfen, Kundensegmente zu identifizieren oder komplexe Kundeninteraktionen zu analysieren.

Transformer-Modelle

Ein großer Durchbruch in der Entwicklung von KI sind die sogenannten Transformer-Modelle. Diese Modelle sind besonders effektiv in der Verarbeitung von Sequenzen, wie Texte oder gesprochene Sprache, und haben die Entwicklung von leistungsfähigen Sprachmodellen erst möglich gemacht. Ein bekannter Vertreter dieser Modelle ist GPT-4o von OpenAI, ein Large Language Model, das in der Lage ist, menschliche Sprache zu verstehen und selbst zu generieren. Ebenso gehört Claude von Anthropic zu dieser Kategorie. Diese Modelle finden beispielsweise

im Vertrieb Anwendung, indem sie personalisierte Texte für Kundenkommunikation erzeugen oder automatisch Antworten auf Kundenanfragen formulieren.

Diese Architektur wurde 2017 in dem Papier *Attention is All You Need*¹ eingeführt. Der Schlüsselmechanismus ist die Selbstaufmerksamkeit (self-attention), die es dem Modell ermöglicht, den Kontext jedes Wortes in einem Satz zu verstehen, unabhängig von seiner Position.

Transformer-Modelle bestehen aus zwei Hauptteilen: dem Encoder und dem Decoder. Der Encoder verarbeitet die Eingabesequenz, und der Decoder erzeugt die Ausgabesequenz.

Transformermodelle sind besonders gut für NLP-Aufgaben geeignet, wie maschinelle Übersetzung, Textgenerierung, Sprachmodellierung und Fragebeantwortung.

Neuere Modelle wie Vision Transformers (ViTs) wenden die Transformer-Architektur auf Bilderkennung an.

Transformermodelle sind sehr gut darin, den Kontext von Wörtern in langen Texten zu verstehen. Sie lassen sich gut auf große Datenmengen und komplexe Aufgaben skalieren.

Large Language Models (LLM)

Large Language Models (LLMs), wie eben erwähnt, sind eine spezielle Form der Transformer-Modelle. Sie sind darauf trainiert,

¹ "Attention Is All You Need" ist ein bahnbrechendes Forschungspapier aus dem Jahr 2017 im Bereich des maschinellen Lernens, das von acht Wissenschaftlern bei Google verfasst wurde. Es führte eine neue Deep-Learning-Architektur ein, den Transformer, der auf dem 2014 von Bahdanau et al. vorgeschlagenen Aufmerksamkeitsmechanismus basiert. Dieses Papier gilt als grundlegend für die moderne Künstliche Intelligenz, da der Transformer-Ansatz zur Hauptarchitektur von großen Sprachmodellen, wie z.B. den auf GPT basierenden Modellen, geworden ist. Ursprünglich lag der Fokus der Forschung auf der Verbesserung von Techniken für maschinelle Übersetzungen, doch die Autoren sahen das Potenzial dieser Methode auch für andere Aufgaben wie die Beantwortung von Fragen und die heutige multimodale generative KI voraus. https://en.wikipedia.org/wiki/Attention_Is_All_You_Need

große Mengen an Text zu verarbeiten und menschenähnliche Sprache zu erzeugen. Diese Modelle werden durch gewaltige Datenmengen und enorme Rechenkapazitäten trainiert, was sie zu sehr leistungsfähigen Werkzeugen macht.

LLMs sind besonders nützlich für Anwendungen, bei denen Textanalyse und -generierung eine Rolle spielen, wie zum Beispiel in der automatisierten Kundenansprache oder bei der Analyse von Kundenfeedback. Bekannte Vertreter sind GPT-4o und Claude.

Generative KI

Im Zusammenhang mit LLMs und Deep Learning steht auch der Begriff Generative KI. Hierbei handelt es sich um Technologien, die in der Lage sind, neue Inhalte zu generieren, seien es Text, Bilder oder sogar Musik. Dies eröffnet völlig neue Möglichkeiten im Vertrieb. Mit generativer KI können zum Beispiel individualisierte Marketingmaterialien erstellt oder Produktvisualisierungen generiert werden. Die beiden prominentesten Unterbereiche innerhalb der generativen KI sind Large Language Models und Diffusion Models.

Diffusion Models

Eine weitere faszinierende Entwicklung in der KI-Forschung sind die Diffusion Models. Diese Modelle sind darauf spezialisiert, neue Bilder oder andere visuelle Inhalte zu erstellen. Bekannte Beispiele für solche Modelle sind Midjourney und DALL-E 3. Sie funktionieren, indem sie bestehende Bilder stückweise »verwischen« und aus diesen Verzerrungen dann neue Bilder erzeugen. Für Unternehmen bieten sie das Potenzial, Produktvisualisierungen oder Designs in kurzer Zeit zu generieren, was im Marketing oder bei der Produktentwicklung erhebliche Vorteile bietet.

Diese Modelle basieren auf einem stochastischen Prozess, bei dem Daten schrittweise mit Rauschen überlagert und dann wieder rekonstruiert werden. Sie modellieren den Prozess der schrittweisen Hinzufügung von Rauschen zu Daten und deren schrittweisen Wiederherstellung.

Der Diffusionsprozess wird durch eine Folge von Wahrscheinlichkeitsverteilungen beschrieben. Diffusionsmodelle sind besonders gut für die Generierung von hochauflösenden Bildern geeignet.

Sie werden auch zur Erzeugung von Audiodaten und Videos verwendet, da sie in der Lage sind, feine Details und Texturen gut zu modellieren.

Diffusionsmodelle sind bekannt für ihre Fähigkeit, sehr realistische und detaillierte Bilder zu erzeugen. Sie können mit verschiedenen Arten von Daten arbeiten und sind robust gegenüber kleinen Veränderungen im Datenraum.

Ein praxisnahes Fazit für Unternehmen

Die unterschiedlichen Begriffe und Technologien innerhalb der KI mögen auf den ersten Blick verwirrend wirken.

Ein tieferes Verständnis ist entscheidend, um die richtigen strategischen Entscheidungen für Ihr Unternehmen zu treffen. Durch die Kombination dieser Technologien kann KI im Vertrieb maßgeschneiderte Lösungen liefern – von der automatisierten Erstellung von Texten (in beliebigen Sprachen) über die Analyse von Kundendaten bis hin zur Visualisierung von Produkten und anderen Darstellungen.

Unternehmen, die die Potenziale dieser verschiedenen KI-Technologien erkennen und nutzen, können nicht nur ihre Effizienz steigern, sondern auch personalisierte Erlebnisse für ihre Geschäftskunden schaffen, die zu langfristigen Wettbewerbsvorteilen führen.

Maschinelles Lernen und Deep Learning

Wenn Sie sich mit Künstlicher Intelligenz beschäftigen, werden Sie schnell feststellen, dass zwei Begriffe immer wieder auftauchen: Maschinelles Lernen (ML) und Deep Learning (DL). Diese

Technologien sind die Motoren hinter vielen modernen KI-Anwendungen und bieten enorme Potenziale für Unternehmen im B2B-Vertrieb. Lassen Sie uns die beiden Konzepte etwas genauer beleuchten und verstehen, wie sie Ihre Vertriebsprozesse optimieren können.

Was ist Maschinelles Lernen (ML)?

Der Begriff »Maschinelles Lernen« ist der Sammelbegriff für Methoden, bei der Maschinen durch die Analyse großer Datenmengen lernen, ohne explizit dafür programmiert zu werden. Das bedeutet: Anstatt feste Regeln für die Maschine zu definieren, erkennt die Maschine selbstständig Muster und Zusammenhänge in den Daten. Stellen Sie sich das so vor, als würde eine Maschine aus Erfahrung lernen – ähnlich wie wir Menschen.

Ein einfaches Beispiel im Vertrieb: Sie haben eine große Datenmenge an Kundeninteraktionen. Ein ML-Modell kann in diesen Daten erkennen, welche Kunden mit hoher Wahrscheinlichkeit bald kaufen werden und welche möglicherweise abspringen. Diese Erkenntnisse könnten Sie dann nutzen, um Ihre Vertriebsmaßnahmen gezielt und effektiv zu steuern.

Es gibt drei Hauptarten des Maschinellen Lernens:

- **Überwachtes Lernen:** Hierbei wird das System mit gelabelten Daten gefüttert. Das bedeutet, dass der Maschine bereits bekannte Eingaben und die dazugehörigen Ausgaben gezeigt werden, damit sie lernt, diese Zusammenhänge auf neue Daten anzuwenden. Zum Beispiel könnten Sie historische Verkaufsdaten nutzen, um vorherzusagen, welche Kunden in den nächsten Monaten am ehesten einen Kauf tätigen werden.
- **Unüberwachtes Lernen:** In diesem Fall arbeitet die Maschine mit unmarkierten Daten. Sie sucht nach Mustern und Strukturen in den Daten, ohne vorherige Informationen darüber, was diese Muster darstellen. Das ist besonders hilfreich, wenn Sie zum Beispiel neue Kundensegmente entdecken möchten, die Sie zuvor vielleicht übersehen haben.

- **Bestärkendes Lernen:** Dieser Ansatz ähnelt dem Lernen durch Belohnung und Bestrafung. Das System trifft Entscheidungen, bekommt Feedback zu diesen Entscheidungen und passt sein Verhalten entsprechend an. Dies könnte zum Beispiel in der automatisierten Preisgestaltung angewendet werden, bei der das System lernt, den optimalen Preis zu finden, der die Kaufwahrscheinlichkeit maximiert.

Deep Learning: Ein tieferes Verständnis von Daten

Während Maschinelles Lernen in vielen Bereichen bereits beeindruckende Ergebnisse liefert, geht Deep Learning einen Schritt weiter. Deep Learning ist ein spezielles Teilgebiet des maschinellen Lernens, das auf künstlichen neuronalen Netzen basiert. Diese Netze sind inspiriert von der Funktionsweise des menschlichen Gehirns und bestehen aus mehreren Schichten von »Neuronen«, die es ermöglichen, auch sehr komplexe und unstrukturierte Daten zu analysieren.

Ein Vorteil von Deep Learning ist, dass es besonders gut mit großen Datenmengen und komplexen Strukturen umgehen kann. Dies ist besonders relevant für Anwendungen wie die Verarbeitung von Bildern, die Analyse von Texten oder die Erkennung von Sprache. Unternehmen, die große Mengen an unstrukturierter Daten – wie Kundengespräche, E-Mails oder Support-Tickets – haben, können durch den Einsatz von Deep Learning enorme Vorteile erzielen.

Nehmen wir zum Beispiel die automatische Verarbeitung von Kundenanfragen. Durch den Einsatz von Deep Learning könnten Sie ein System entwickeln, das in der Lage ist, eingehende E-Mails zu analysieren, deren Inhalt zu verstehen und sie automatisch an den richtigen Ansprechpartner weiterzuleiten. Es gibt sogar Ansätze, die E-Mails direkt zu beantworten.

Hier könnten zweistufige Systeme eingesetzt werden. In der ersten Stufe wird zunächst die eingehende E-Mail analysiert und dann ein Antwortvorschlag erarbeitet. Danach wird die eingehende E-Mail und die dazu generierte Antwort einem Menschen

zugeführt. Dieser muss nun nicht mehr alle Fragen selbst beantworten. Vielmehr beurteilt er die Qualität der Antwort mit einer Punkteskala von 1 bis 10. Die beste Qualität wird ohne weitere Eingriffe als Antwort versendet.

Geringere Qualitäten werden vom Menschen überarbeitet und dann versendet. So entstehen zusätzliche Lerndaten. Eine zweite KI-Instanz könnte nun anhand der korrigierten Antworten gemäß der Interaktion des Menschen weiter lernen. Im nächsten Schritt kann die KI dann immer besser entscheiden, welchen Qualitätswert der KI-Entwurf bekommt. Jetzt wird der Mensch bereits entlastet, weil die hohen Qualitäten ohne menschliches Zutun versendet werden.

Aus der Korrektur der schlechteren Qualitäten lernt die KI, wie die Entwürfe verbessert werden können. Sie kann somit gleich einen Verbesserungsvorschlag mitliefern. Der Mensch muss also in diesem Prozess immer seltener eingreifen. Sobald in diesem Lernprozess eine Erfolgsquote erreicht ist, die der des Menschen entspricht, kann die KI in der Mehrzahl der Fälle völlig autonom antworten. Nur noch die wenigen Fälle, die die KI alleine nicht »versteht«, landen dann auf dem Tisch eines Sachbearbeiters.

Anpassung auf eigene Bedürfnisse

Wenn Sie bereits Erfahrungen mit Angeboten wie ChatGPT gemacht haben, haben Sie vielleicht bemerkt, dass die Antworten dieser öffentlichen KI-Systeme nicht immer genau das treffen, was Sie erwartet haben. Das liegt daran, dass ChatGPT auf Basis öffentlich zugänglicher Informationen trainiert wurde und kontinuierlich mit neuen Daten »weitergebildet« wird. Für sehr spezifische Anwendungsfälle – beispielsweise im Kontext Ihrer eigenen Produkte oder Dienstleistungen – stößt dieses allgemeine Training jedoch an seine Grenzen.

Angenommen, Sie möchten Kundenanfragen zu einem bestimmten Produkt Ihres Unternehmens weitgehend automatisieren. In solchen Fällen ist es unwahrscheinlich, dass ein System wie

ChatGPT von Haus aus genügend detaillierte Daten besitzt, um diese Aufgabe zu Ihrer vollsten Zufriedenheit zu erfüllen. Hier kommt eine Technik namens **Fine-Tuning** ins Spiel.

Beim Fine-Tuning sammeln Sie spezifische Fragen und die dazugehörigen Antworten, idealerweise aus Ihrem eigenen Kundenservice oder von realen Interaktionen der letzten Jahre. Diese Frage-Antwort-Paare werden in ein spezielles Format gebracht und dann dem KI-System zum Training bereitgestellt. Wenn die Daten konsistent und klar strukturiert sind, kann die KI nach diesem Feinschliff gezielt auf die Fragen zu Ihren Produkten reagieren und präzise, relevante Antworten geben.

Mit dieser Vorgehensweise machen Sie die KI nicht nur smarter, sondern auch gezielt einsetzbar für Ihre individuellen Anforderungen – und das führt letztlich zu besseren Ergebnissen in der Kundenkommunikation.

Die Bedeutung für den B2B-Vertrieb

Nun fragen Sie sich vielleicht: »Wie kann das konkret in meinem Vertriebsprozess aussehen?« Die Antwort lautet: vielfältig.

Stellen Sie sich vor, Sie haben ein ML-System, das auf historischen Daten basiert, um vorherzusagen, welche Kunden am ehesten einen Kauf abschließen. Dieses System könnte in Ihrem CRM-System verankert sein. Es vergleicht offene Verkaufschancen mit bereits abgeschlossenen Chancen. Auf Basis dieser Analyse errechnet die KI die statistische Erfolgs-Wahrscheinlichkeit.

Sicherlich kann Statistik sich irren. Aber in der langfristigen Betrachtung behält sie zumeist recht. Wie würden Sie das beurteilen: Eine Verkaufsorganisation konzentriert sich konsequent als Erstes auf die besseren Chancen gemäß der errechneten Wahrscheinlichkeit. Die im Wettbewerb dazu stehende Organisation behandelt die Chancen nach anderen Kriterien oder behandelt alle Chancen gleich. Welche der beiden Verkaufsorganisationen wird auf lange Sicht erfolgreicher sein?

Ebenso könnten Sie Deep Learning verwenden, um komplexe unstrukturierte Daten – wie Kundenfeedback oder Gesprächsnotizen – zu analysieren und daraus wertvolle Erkenntnisse zu gewinnen. Diese Erkenntnisse könnten Ihnen helfen, Ihre Verkaufsstrategie anzupassen und den Kunden genau das Angebot zu machen, das zu ihren Bedürfnissen passt.

Ein weiteres Beispiel: Mit Deep Learning könnten Sie Sentiment-Analysen² von Kundenfeedback durchführen und herausfinden, wie Ihre Kunden über Ihre Produkte oder Dienstleistungen denken. Diese Informationen können dann genutzt werden, um proaktive Maßnahmen zu ergreifen – sei es in der Anpassung Ihrer Produktstrategie oder in der Optimierung Ihrer Verkaufsprozesse.

Ein Werkzeugkasten für den modernen Vertrieb

Maschinelles Lernen und Deep Learning sind keine Zukunftstechnologien mehr – sie sind heute bereits im Einsatz und bieten enormes Potenzial, insbesondere im B2B-Vertrieb. Sie ermöglichen es Unternehmen, aus den Daten, die sie ohnehin täglich sammeln, wertvolle Einblicke zu gewinnen, Prozesse zu optimieren und letztlich die Verkaufszahlen zu steigern. Der Schlüssel liegt darin, die richtige Anwendung für Ihr Geschäftsmodell zu finden und KI gezielt einzusetzen, um Wettbewerbsvorteile zu erzielen.

KI-Algorithmen und ihre Funktionsweise

Wenn wir von Künstlicher Intelligenz sprechen, dann sind Algorithmen die unsichtbaren Motoren, die die gesamte Maschine antreiben. Ohne sie wären die beeindruckenden Fortschritte, die

² Sentiment Analysis ist ein Prozess zur Ermittlung der Meinung, des Urteils oder der Emotion, die hinter einer Aussage steht. Sie bietet eine effektive Möglichkeit, geschriebene oder gesprochene Sprache zu bewerten, um festzustellen, in welchem Ausmaß der Ausdruck positiv, negativ oder neutral ist.

wir heute sehen, nicht möglich. Doch was genau ist ein Algorithmus, und wie funktioniert er in der Praxis? In diesem Kapitel werfen wir einen Blick auf die wichtigsten KI-Algorithmen und ihre Funktionsweise, damit Sie verstehen, welche Ansätze für Ihr Geschäft von Bedeutung sein könnten.

Was ist ein KI-Algorithmus?

Ein Algorithmus ist im Grunde genommen eine Reihe von Regeln oder Anweisungen, die eine Maschine befolgt, um ein bestimmtes Problem zu lösen. In der Künstlichen Intelligenz wird der Algorithmus verwendet, um Daten zu analysieren, Muster zu erkennen und Vorhersagen zu treffen. Der große Unterschied zu herkömmlichen Algorithmen besteht darin, dass KI-Algorithmen oft auf der Fähigkeit basieren, selbstständig zu lernen und sich an neue Informationen anzupassen – und das ist der wahre Durchbruch.

Stellen Sie sich vor, Sie hätten ein Team von Vertriebsmitarbeitern, das aus Tausenden von Kundengesprächen lernt und immer besser darin wird, die Kaufwahrscheinlichkeit eines Kunden vorherzusagen. Genau das tun KI-Algorithmen: Sie lernen aus Daten, um zukünftige Entscheidungen immer besser und präziser zu treffen.

Wichtige KI-Algorithmen und ihre Einsatzmöglichkeiten

Im Folgenden möchten wir einige der wichtigsten Algorithmen vorstellen, die in der Praxis Anwendung finden – und wie Sie diese für Ihren Vertrieb sinnvoll einsetzen können.

Regressionsmodelle

Regressionsmodelle gehören zu den einfachsten, aber dennoch sehr effektiven Algorithmen in der KI. Sie werden verwendet, um Vorhersagen über kontinuierliche Werte zu treffen. Ein klassisches Beispiel im Vertrieb wäre die Umsatzprognose. Hier analysiert das Modell vergangene Verkaufszahlen und externe Faktoren wie

saisonale Schwankungen, um eine Vorhersage für die kommenden Monate zu treffen.

Im B2B-Vertrieb können Regressionsmodelle auch genutzt werden, um das Verhalten von Geschäftskunden vorherzusagen. Zum Beispiel: Wie wahrscheinlich ist es, dass ein bestimmter Kunde in den nächsten sechs Monaten seinen Vertrag verlängert oder kündigt?

Entscheidungsbäume

Ein Entscheidungsbaum funktioniert nach dem Prinzip, Daten basierend auf bestimmten Kriterien immer weiter aufzuteilen. Stellen Sie sich einen Baum vor, bei dem jeder Knoten eine Frage darstellt, die mit »Ja« oder »Nein« beantwortet werden kann. Diese Struktur hilft dem Modell, Entscheidungen zu treffen.

Im Vertrieb könnten Entscheidungsbäume verwendet werden, um zu entscheiden, welche Kunden mit der höchsten Wahrscheinlichkeit zu einem Kauf bereit sind. Anhand von Kriterien wie Kaufhistorie, Interaktionen mit dem Vertriebsteam und Unternehmensgröße könnte der Baum Kunden in »heiße«, »warme« und »kalte« Leads aufteilen, sodass sich Ihre Vertriebsmitarbeiter auf die besten Chancen konzentrieren können.

Künstliche neuronale Netze (ANNs)

Künstliche neuronale Netze (Artificial Neural Networks, ANNs) sind die Grundlage des Deep Learning und arbeiten ähnlich wie das menschliche Gehirn. Diese Algorithmen bestehen aus mehreren Schichten von »Neuronen«, die miteinander verbunden sind und Informationen verarbeiten. Je komplexer das Netz, desto besser kann es versteckte Muster in großen Datenmengen erkennen.

Für den B2B-Vertrieb sind ANNs besonders nützlich, wenn es darum geht, große Mengen an unstrukturierten Daten zu analysieren, wie zum Beispiel E-Mails oder Kundengespräche. Ein neuronales Netz könnte aus diesen Daten lernen, um zum

Beispiel die Stimmung von Kunden zu bewerten und zu entscheiden, ob ein Kunde kurz vor dem Absprung steht.

K-Means-Clustering

K-Means-Clustering ist ein unüberwachter Lernalgorithmus, der Datenpunkte in verschiedene Gruppen (Cluster) einteilt. Im B2B-Vertrieb kann dies nützlich sein, um Kundensegmente zu identifizieren. Stellen Sie sich vor, Sie haben eine große Liste von Kunden, aber keine klare Vorstellung davon, welche Gemeinsamkeiten sie haben. K-Means-Clustering kann helfen, Muster zu entdecken und Kunden in Gruppen mit ähnlichem Verhalten oder Bedürfnissen zu kategorisieren.

Diese Cluster können dann verwendet werden, um gezielte Marketingkampagnen zu entwickeln oder maßgeschneiderte Angebote für unterschiedliche Kundensegmente zu erstellen. So erhöhen Sie die Wahrscheinlichkeit, dass Ihre Kunden auf Ihre Angebote positiv reagieren.

Funktionsweise von KI-Algorithmen: Vom Training bis zur Anwendung

Der Erfolg eines KI-Algorithmus hängt stark von der Qualität der Daten ab, mit denen er trainiert wird. Die Funktionsweise lässt sich grob in drei Schritte unterteilen:

1. Datenaufnahme und Vorbereitung: Der erste Schritt besteht darin, die relevanten Daten zu sammeln und vorzubereiten. Im Vertrieb könnten dies CRM-Daten, Verkaufszahlen oder Kundenfeedback sein. Die Daten müssen gereinigt, strukturiert und in ein Format gebracht werden, das für die Analyse geeignet ist.
2. Training des Algorithmus: Im zweiten Schritt wird der Algorithmus auf den Daten trainiert. Dabei »lernt« das Modell, Zusammenhänge und Muster in den Daten zu erkennen. Beim

überwachten Lernen werden dem Modell bereits bekannte Eingaben und die dazugehörigen Ausgaben gezeigt, damit es lernt, diese Beziehungen zu verallgemeinern. Beim unüberwachten Lernen entdeckt der Algorithmus von selbst Muster in den Daten.

3. Anwendung und Optimierung: Sobald der Algorithmus trainiert ist, kann er in der Praxis angewendet werden. Er analysiert neue Daten und trifft Vorhersagen oder Entscheidungen basierend auf dem, was er gelernt hat. Um den Algorithmus zu verbessern, wird er kontinuierlich mit neuen Daten gefüttert und entsprechend angepasst.

Die Bedeutung für den Vertrieb

Für den modernen Vertrieb eröffnen diese Algorithmen völlig neue Möglichkeiten. Sie können nicht nur helfen, die richtigen Kunden zur richtigen Zeit anzusprechen, sondern auch Ihre Effizienz im Vertrieb erheblich steigern. Automatisierte Algorithmen können Entscheidungen schneller und präziser treffen, als es ein Mensch je könnte, und so den gesamten Vertriebsprozess optimieren.

Ob Sie Regressionsmodelle zur Prognose von Umsätzen nutzen, Entscheidungsbäume für die Priorisierung von Leads einsetzen oder neuronale Netze zur Analyse von Kundendaten verwenden – die richtige Auswahl und Implementierung von KI-Algorithmen kann einen entscheidenden Wettbewerbsvorteil schaffen.

Die Ur-ur-ur-ur-Enkel der Maschinenstürmer

Das Phänomen der Maschinenstürmer, auch bekannt als die **Luddisten-Bewegung**, trat erstmals zu Beginn des 19. Jahrhunderts in England auf. In einer Zeit des massiven industriellen Wandels zerstörten aufgebrachte Arbeiter Textilmaschinen, die sie als Bedrohung für ihre Arbeitsplätze und Lebensgrundlagen

betrachteten. Angeführt von der mythischen Figur **Ned Ludd**, richteten sich die Aufstände vor allem gegen mechanische Webstühle und Spinnmaschinen, die es den Fabrikbesitzern ermöglichten, die Arbeitskraft vieler Fachkräfte durch Maschinen zu ersetzen.

Die Proteste fanden in den Jahren 1811 bis 1816 statt und wurden von der britischen Regierung brutal niedergeschlagen. Die Maschinenstürmer waren keine Gegner des technologischen Fortschritts per se, sondern sahen in den Maschinen ein Symbol für die wachsende Ungleichheit und die Entwertung ihrer Fähigkeiten. Der Luddismus wurde damit zu einem historischen Beispiel für den Widerstand gegen technische Innovationen, die Arbeitsprozesse verändern und menschliche Arbeit bedrohen.

Künstliche Intelligenz – Kollege oder Konkurrent

Dieser Widerstand spiegelt eine tief verwurzelte Angst wider, die sich auch heute noch im Umgang mit Automatisierung und Künstlicher Intelligenz zeigt: die Sorge, durch Maschinen ersetzt zu werden, und der damit verbundene Verlust von Kontrolle über den eigenen Arbeitsplatz und die eigene wirtschaftliche Existenz.

Der Spruch »Wer wäre schon gerne Kran« ist die vielleicht etwas flapsige Antwort auf die geäußerte Angst vieler Menschen, dass Maschinen zunehmend Arbeiten übernehmen, die bisher als menschliche Domäne galten. Ein Kran ist ein Symbol für mechanische Effizienz, aber auch für eine Maschine, die ihre Arbeit präzise und unermüdlich ausführt, ohne kreative oder emotionale Beteiligung. Der Kran ist eine Maschine, die schwere Arbeiten, wie das Schleppen von Baumaterial übernimmt. Eine Arbeit, die sicherlich von den allerwenigsten Menschen als attraktiv oder bereichernd angesehen wird.

Die omnipräsente Sorge ist, dass, wenn Maschinen bestimmte Aufgaben übernehmen, der Mensch nicht mehr gebraucht wird.

Diese Angst vor einem Jobverlust oder dem Wegfall von Aufgaben, die dem Menschen Sinn, Identität, wenigstens Einkommen geben, ist tief verwurzelt. Dabei geht es nicht nur um den wirtschaftlichen Aspekt, sondern auch um das Gefühl, ersetzt und damit überflüssig zu werden. Viele Menschen fürchten, dass Maschinen nicht nur die Effizienz steigern, sondern den menschlichen Wert in Arbeitsprozessen herabsetzen könnten. Das verdeutlicht, wie emotional aufgeladen diese Diskussion ist, weil sie nicht nur um Technologie und Effizienz geht, sondern um die Veränderung der Rolle des Menschen in einer zunehmend automatisierten Welt.

Vor allem in der westlichen Welt wird der Wert von Arbeit mit der Entlohnung ausgedrückt. Je wertvoller die Arbeit, je besser wird sie entlohnt. Arbeiten, die Maschinen günstiger verrichten können, entwerten gewissermaßen den Menschen.

Der menschliche Widerstand gegen die Einsicht, dass Künstliche Intelligenz (KI) einige Arbeitsschritte besser, schneller und günstiger erledigen kann, wurzelt oft in emotionalen und psychologischen Faktoren. Viele Menschen identifizieren sich stark mit ihren beruflichen Fähigkeiten und haben das Gefühl, dass sie durch KI ersetzt oder abgewertet werden könnten. Diese Angst vor dem Verlust der eigenen Relevanz und Autonomie führt oft zu Ablehnung, selbst wenn die Effizienzvorteile offensichtlich sind.

Hinzu kommt die Sorge, dass durch die Automatisierung von Routineaufgaben der zwischenmenschliche Aspekt im Arbeitsalltag verloren geht. Zudem fehlt manchmal das Vertrauen in die Technologie, sei es aus mangelndem Verständnis oder aus der Angst vor Fehlern, die man selbst besser kontrollieren könnte. All diese Faktoren tragen dazu bei, dass der Übergang zu einer KI-gestützten Arbeitsweise emotional und kulturell herausfordernd ist, auch wenn die objektiven Vorteile auf der Hand liegen.

In den 1970er und 1980er Jahren gab es unter Mathematiklehrern weltweit Bedenken und teils heftigen Widerstand gegen den

zunehmenden Einsatz von Taschenrechnern im Unterricht. Viele Lehrer befürchteten, dass Taschenrechner die grundlegenden mathematischen Fähigkeiten der Schüler untergraben könnten, insbesondere im Bereich des Kopfrechnens, der Bruchrechnung und der Fähigkeit, komplexe Probleme manuell zu lösen. Diese Proteste ähnelten in gewisser Weise den Maschinenstürmern des 19. Jahrhunderts, die neue Technologien als Bedrohung für ihre Fähigkeiten und Arbeitsplätze sahen.

Die Hauptsorge der Mathematiklehrer war, dass Schüler sich zu sehr auf die Technologie verlassen könnten, anstatt ein tiefes Verständnis für mathematische Konzepte zu entwickeln. Einige Lehrer argumentierten, dass das Erlernen von Rechenverfahren wie das schriftliche Multiplizieren und Dividieren ein wichtiger Bestandteil des kognitiven Lernprozesses sei, der durch den Taschenrechner umgangen werde.

Dieser Widerstand führte in vielen Ländern zu hitzigen Debatten darüber, wann und wie Taschenrechner im Unterricht eingesetzt werden sollten. Während einige Bildungseinrichtungen Taschenrechner vollständig verboten, erlaubten andere den Einsatz ab einer bestimmten Klassenstufe oder für bestimmte Aufgaben, insbesondere in fortgeschrittenen Bereichen wie Algebra oder Trigonometrie.

Über die Jahre hinweg lockerte sich der Widerstand jedoch allmählich, da Studien zeigten, dass Taschenrechner, wenn sie sinnvoll eingesetzt werden, das mathematische Verständnis unterstützen können, indem sie Schülern helfen, sich auf die Lösung komplexerer Probleme zu konzentrieren, anstatt sich in langwierigen Berechnungen zu verlieren. Heute sind Taschenrechner im Mathematikunterricht weit verbreitet, und der Fokus hat sich mehr auf die richtige Balance zwischen technischem Einsatz und grundlegender Mathematikkompetenz verschoben.

Die Proteste der Mathematiklehrer gegen Taschenrechner spiegeln eine allgemeine Skepsis gegenüber neuer Technologie wider, die oft auftritt, wenn traditionelle Lehrmethoden durch moderne Hilfsmittel herausgefordert werden.

In seiner Kolumne³ auf Spiegel Online argumentiert Sascha Lobo deutlich gegen die Auffassung des deutschen Ethikrats⁴, der betont, dass Künstliche Intelligenz keine menschliche Verantwortung übernehmen könne. Lobo sieht diesen Ansatz als zu konservativ und nicht ausreichend, um der Realität gerecht zu werden, in der KI zunehmend in entscheidende Bereiche vordringt. Er hinterfragt, ob es realistisch ist, die Verantwortung immer vollständig beim Menschen zu belassen, wenn KI-Systeme immer komplexer und autonomer handeln.

Lobo fordert, dass wir dringend neue Formen der Verantwortungsverteilung entwickeln müssen, die die Rolle der KI berücksichtigen. Denn in einer Welt, in der Algorithmen in Bereichen wie Verkehr, Medizin oder Justiz mitentscheiden, ist eine simple Zuordnung der Verantwortung an den Menschen möglicherweise nicht mehr praktikabel.

Fehler durch »Noise« und die Überlegenheit einfacher Algorithmen

Diese Einschätzung, dass KI tatsächlich in einigen Aufgabenstellungen besser ist als der Mensch, passt zu den Forschungsergebnissen des inzwischen verstorbenen Nobelpreisträgers Daniel Kahneman.

In ihrem Buch *Noise: Was unsere Entscheidungen verzerrt – und wie wir sie verbessern können*⁵ beleuchten Daniel Kahneman, Olivier

3 Die Kolumne ist am 13.9.2024 hier abgerufen worden: <https://www.spiegel.de/netzwelt/netzpolitik/kuenstliche-intelligenz-kolumne-von-sascha-lobo-a-9fbc4869-4ab6-41ad-9959-d60fc5eda4c8>

4 Der deutsche Ethikrat hat 2023 eine ca. 300-seitige Stellungnahme herausgegeben. »Mensch und Maschine – Herausforderungen durch Künstliche Intelligenz« Abgerufen am 13.9.2024

<https://www.ethikrat.org/fileadmin/Publikationen/Stellungnahmen/deutsch/stellungnahme-mensch-und-maschine.pdf>

5 Kahneman, D., Sibony, O. & Sunstein, C. R. (2021). *Noise: Was unsere Entscheidungen verzerrt – und wie wir sie verbessern können*. Siedler Verlag.

Sibony und Cass R. Sunstein ein oft übersehenes Phänomen: **Noise**, das in Entscheidungsprozessen auftritt und systematisch zu Fehlern führt. Anders als **Bias**, das sich auf eine systematische Verzerrung in eine bestimmte Richtung bezieht, beschreibt **Noise** zufällige Schwankungen und Inkonsistenzen in den Urteilen von Menschen. Selbst Experten unterliegen diesen Schwankungen, was zu unerwarteten und schwer vorhersehbaren Abweichungen führt. Kahneman und seine Koautoren zeigen eindrucksvoll, wie selbst in standardisierten Umgebungen wie Gerichten, Krankenhäusern und Unternehmen die gleiche Aufgabe von verschiedenen Personen oder sogar derselben Person zu unterschiedlichen Zeiten unterschiedlich gelöst wird – und das oft ohne erkennbare Gründe.

Noise: Unsichtbare Kosten durch Fehlentscheidungen

Die Autoren betonen, dass **Noise** besonders in Bereichen auftritt, in denen menschliche Urteile eine zentrale Rolle spielen, wie zum Beispiel in der Medizin, im Recht, bei der Bewertung von Finanzrisiken oder auch bei der Einschätzung von Erfolgsaussichten von Unternehmen. Diese zufälligen Unterschiede können erhebliche Konsequenzen haben, sei es bei der Diagnose von Krankheiten, der Entscheidung über die Höhe einer Strafe oder der Kreditvergabe. Eine zentrale Erkenntnis des Buches ist, dass diese Form der Ungenauigkeit oft nicht erkannt wird, weil wir dazu neigen, uns auf systematische Verzerrungen wie Vorurteile (**Bias**) zu konzentrieren.

Beispielsweise kann ein Arzt in einer bestimmten Situation eine andere Diagnose stellen, wenn er an einem Montag arbeitet, als wenn er dieselbe Entscheidung am Freitag treffen würde. Diese zufälligen Schwankungen sind nicht systematisch vorhersehbar, sondern variieren zufällig – und genau das ist der Kern des Problems. Noise führt zu unnötigen Inkonsistenzen, die die Qualität der Entscheidungen beeinträchtigen und in vielen Fällen zu schwerwiegenden Fehlurteilen führen.

Die Überlegenheit einfacher Algorithmen

Eine der überraschendsten Erkenntnisse, die in *Noise* beschrieben werden, ist, dass **einfache Algorithmen oft zu besseren Ergebnissen führen als menschliche Experten** – selbst dann, wenn diese Experten die Grundlagen für die Algorithmen selbst geschaffen haben. Kahneman und seine Koautoren stützen sich auf eine Vielzahl von Studien, die zeigen, dass algorithmische Ansätze, bei denen klare, standardisierte Regeln angewendet werden, weniger anfällig für Noise und Bias sind als menschliche Urteile.

Eine der bekanntesten Studien, die diesen Punkt unterstreicht, wurde in den 1950er Jahren von dem Psychologen Paul Meehl durchgeführt. Meehl zeigte in seiner Forschung, dass einfache statistische Modelle – oft nur basierend auf wenigen Faktoren – im Durchschnitt bessere Vorhersagen trafen als erfahrene Psychologen und Psychiater. In einem klinischen Kontext, in dem es um die Prognose ging, wie sich psychisch kranke Patienten entwickeln würden, lagen die von Experten getroffenen Entscheidungen häufiger falsch als die durch Algorithmen generierten Vorhersagen. Diese Ergebnisse waren schockierend, weil sie suggerierten, dass menschliche Expertise nicht nur fehlerhaft, sondern systematisch unterlegen sein kann.

Moderne Forschung bestätigt diesen Effekt. Zum Beispiel ergab eine 2019 veröffentlichte Studie, dass einfache Algorithmen in der Lage sind, Kreditrisiken besser zu bewerten als Bankmitarbeiter, die jahrelange Erfahrung in der Kreditvergabe haben. In der Medizin zeigen Studien, dass maschinelles Lernen und Algorithmen bei der Diagnose bestimmter Krankheiten, etwa in der Dermatologie oder Radiologie, deutlich präziser arbeiten als menschliche Ärzte. Dies bedeutet nicht, dass Algorithmen frei von Fehlern sind, sondern dass sie weniger anfällig für Noise und inkonsistente Urteile sind als Menschen.

Warum schneiden Algorithmen besser ab?

Kahneman, Sibony und Sunstein erklären, dass Algorithmen im Wesentlichen frei von zwei zentralen Problemen sind, die menschliche Entscheidungen verzerren: **Bias** und **Noise**. Algorithmen sind in der Lage, klare, standardisierte Regeln anzuwenden, die unabhängig von Zeit, Ort oder der Stimmung der Person, die sie anwendet, konsistente Ergebnisse liefern. Menschen hingegen neigen dazu, von irrelevanten Faktoren beeinflusst zu werden – sei es Müdigkeit, die Tageszeit oder sogar das Wetter.

Ein weiterer entscheidender Vorteil von Algorithmen ist ihre Fähigkeit, große Datenmengen zu analysieren und Muster zu erkennen, die für Menschen unsichtbar bleiben. Dies ist besonders relevant in der Medizin und im Finanzwesen, wo kleine Abweichungen oder Anomalien oft übersehen werden können, aber dennoch große Auswirkungen haben. Algorithmen bieten eine Möglichkeit, solche Informationen zuverlässig und schnell zu verarbeiten und konsistente Entscheidungen zu treffen.

Die Rolle von Experten

Eine häufige Kritik an der Verwendung von Algorithmen ist, dass sie menschliches Urteilsvermögen ersetzen. Kahneman und seine Koautoren sehen das jedoch differenzierter: Algorithmen sollen menschliche Experten nicht überflüssig machen, sondern sie unterstützen. Experten sind entscheidend für die Entwicklung und Feinabstimmung der Algorithmen, aber in vielen Fällen ist es effizienter, den Entscheidungsprozess einem Algorithmus zu überlassen. Dies gilt besonders in Bereichen, in denen Konsistenz und Präzision entscheidend sind.

Was allerdings oft übersehen wird, ist, dass Experten dazu neigen, den Wert von Algorithmen zu unterschätzen – auch wenn sie die Modelle selbst entwickeln. Kahneman und seine Koautoren erklären dies mit dem sogenannten **Overconfidence Bias**: Experten überschätzen häufig ihre eigene Fähigkeit, komplexe

Probleme besser als ein Algorithmus zu lösen. Die Realität zeigt jedoch, dass in vielen Fällen selbst einfache, regelbasierte Systeme konsistentere und präzisere Entscheidungen treffen können.

In *Noise* zeigen Kahneman, Sibony und Sunstein auf eindrückliche Weise, wie menschliche Entscheidungen durch zufällige Schwankungen beeinflusst werden und dass Noise oft unbemerkt bleibt, während Bias deutlich erkennbar ist.

Menschen neigen dazu zu glauben, dass sich die Fehler bei Noise im Durchschnitt aufheben, weil sie annehmen, dass zufällige Schwankungen in verschiedene Richtungen (positiv und negativ) sich gegenseitig ausgleichen. Das ist jedoch ein Irrtum, denn Noise führt nicht zu einer gleichmäßigen Verteilung von Fehlern, sondern zu systematischer Inkonsistenz in individuellen Urteilen. Diese zufälligen Abweichungen führen dazu, dass sich nicht nur die Ergebnisse unterscheiden, sondern auch die Entscheidungsqualität insgesamt verschlechtert, da die Schwankungen unvorhersehbar und nicht korrigierbar sind.

Ein Beispiel für die Auswirkungen von Noise in der Preiskalkulation: Angenommen, ein Vertriebsteam setzt Preise für ein Produkt fest. Durch Noise kann es vorkommen, dass ein Teammitglied aufgrund von unterschiedlichen Faktoren wie Tageszeit, Stimmung oder externem Druck einen Preis zu hoch oder zu niedrig ansetzt. Ein zu hoher Preis könnte potenzielle Kunden abschrecken, während ein zu niedriger Preis den Gewinn schmälert.

Der Fehler gleicht sich nicht aus

Entgegen der typischen Einschätzung bei zufälligen Schwankungen, heben sich diese zufälligen Schwankungen im Schnitt nicht auf. Vielmehr führen sie zu inkonsistenten und oft suboptimalen Ergebnissen. Die Fehler heben sich also im Durchschnitt nicht auf. Ein zu hoher Preis verhindert Erfolg. Ebenso verhindert ein zu niedriger Preis Erfolg. Beide Fehler sind demnach für sich

schädlich und werden nicht dadurch ausgeglichen, dass der Preis in der statistischen Mittelung wieder passen würde.

Die Lösung für dieses Problem liegt in der Nutzung von Algorithmen, die klare Regeln und Verfahren anwenden, um konsistente Ergebnisse zu liefern. Diese Algorithmen haben in zahlreichen Studien bewiesen, dass sie menschlichen Urteilen überlegen sein können – selbst in Situationen, in denen Experten die Modelle entwickelt haben. Während Algorithmen nicht perfekt sind, bieten sie eine vielversprechende Möglichkeit, die Qualität und Konsistenz von Entscheidungen zu verbessern, indem sie sowohl Bias als auch Noise minimieren.

Künstliche Intelligenz (KI) kann eine entscheidende Rolle dabei spielen, Algorithmen konsequent und fehlerfrei zu nutzen, um menschliche Schwankungen in Entscheidungsprozessen zu minimieren. Durch die Fähigkeit, Daten in großem Umfang zu analysieren und wiederkehrende Muster präzise zu erkennen, gewährleistet KI, dass Algorithmen unabhängig von externen Faktoren immer gleich angewendet werden. Dies führt zu konsistenteren Ergebnissen und eliminiert sowohl Noise als auch Bias, was in Bereichen wie Preisgestaltung, Kreditvergabe oder medizinischen Diagnosen zu besseren und zuverlässigeren Entscheidungen führt.

KI macht Entscheidungen qualitativ besser

Die Grundlagen der KI bieten eine solide Basis für das Verständnis der Technologien, die im modernen Geschäftskundenvertrieb Anwendung finden. KI, maschinelles Lernen und Algorithmen sind mächtige Werkzeuge, um Vertriebseffizienz zu steigern, Kundenerlebnisse zu verbessern und letztlich den Umsatz zu maximieren.

Kritiker verweisen zu Recht auf die Gefahr, dass KI aufgrund von systematisch verfälschten Trainingsdaten verzerrte Urteile fällt.

Das stimmt ohne Zweifel. Allerdings ist es einfach, die Fehler in den Trainingsdaten zu finden und zu beseitigen. Wesentlich einfacher, als Noise oder Bias von menschlichen Experten zu korrigieren.

KI mag auf den ersten Blick wie eine futuristische Technologie erscheinen, aber sie ist bereits ein fester Bestandteil unserer Gegenwart – und auch des B2B-Vertriebs. Es ist nicht die Frage, ob Unternehmen KI nutzen sollten, sondern vielmehr, wie sie dies am besten tun können, um bessere Entscheidungen zu treffen und ihre Geschäftsziele zu erreichen.

Zusammenfassung

- **Verständnis für Künstliche Intelligenz (KI):** Entwickeln Sie ein klares Verständnis der Funktionalität, Terminologie und Technologie von KI, um fundierte Entscheidungen für Geschäftsmodelle treffen zu können.
- **Unterscheidung von KI-Typen:** Differenzieren Sie zwischen schwacher KI (z. B. Sprachassistenten) und starker KI, die theoretisch menschenähnlich agieren könnte, aber noch nicht existiert.
- **Technologien im Fokus:** Nutzen Sie Schlüsseltechnologien wie Maschinelles Lernen (ML), Deep Neural Networks (DNNs) und Transformer-Modelle, um Datenanalysen und Entscheidungsprozesse zu optimieren.
- **Einsatz von Algorithmen:** Reduzieren Sie menschliche Fehlentscheidungen durch den Einsatz präziser Algorithmen, die unabhängig von Noise und Bias konsistente Ergebnisse liefern.
- **Strategischer Nutzen im Vertrieb:** Verwenden Sie KI und generative Modelle wie Large Language Models (LLMs), um Kundenbedarfe zu analysieren, Texte zu generieren und personalisierte Kundenansprachen zu ermöglichen.

