

FRANK JÄKEL

DIE INTELLIGENTE TÄUSCHUNG

**ÜBER DIE FÄHIGKEITEN
KÜNSTLICHER INTELLIGENZ**

[transcript] X T E X T E

Frank Jäkel
Die intelligente Täuschung

X-Texte zu Kultur und Gesellschaft

Editorial

Das vermeintliche »Ende der Geschichte« hat sich längst vielmehr als ein Ende der Gewissheiten entpuppt. Mehr denn je stellt sich nicht nur die Frage nach der jeweiligen »Generation X«. Jenseits solcher populären Figuren ist auch die Wissenschaft gefordert, ihren Beitrag zu einer anspruchsvollen Zeitdiagnose zu leisten.

Die Reihe X-TEXTE widmet sich dieser Aufgabe und bietet ein Forum für ein Denken ›für und wider die Zeit‹. Die hier versammelten Essays dechiffrieren unsere Gegenwart jenseits vereinfachender Formeln und Orakel. Sie verbinden sensible Beobachtungen mit scharfer Analyse und präsentieren beides in einer angenehm lesbaren Form.

Frank Jäkel lehrt Kognitionswissenschaft an der Technischen Universität Darmstadt und forscht am Hessischen Zentrum für Künstliche Intelligenz unter anderem an Mensch-KI Interaktion.

Frank Jäkel

Die intelligente Täuschung

Über die Fähigkeiten Künstlicher Intelligenz

[transcript]

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <https://dnb.dnb.de/> abrufbar.



Dieses Werk ist unter der Creative-Commons-Lizenz BY-ND 4.0 lizenziert. Für die ausformulierten Lizenzbedingungen besuchen Sie bitte die URL <https://creativecommons.org/licenses/by-nd/4.0/>. Die Bedingungen der Creative-Commons-Lizenz gelten nur für Originalmaterial. Die Wiederverwendung von Material aus anderen Quellen (gekennzeichnet mit Quellenangabe) wie z.B. Schaubilder, Abbildungen, Fotos und Textauszüge erfordert ggf. weitere Nutzungsgenehmigungen durch den jeweiligen Rechteinhaber.

2025 © Frank Jäkel

transcript Verlag | Hermannstraße 26 | 33602 Bielefeld |
live@transcript-verlag.de

Umschlaggestaltung: Kordula Röckenhaus

Umschlagabbildung: Gordon Johnson / Pixabay

Lektorat: textuelles.de, Dr. Klara Vanek

Satz: Mark-Sebastian Schneider

Druck: Majuskel Medienproduktion GmbH, Deutschland

<https://doi.org/10.14361/9783839405598>

Print-ISBN: 978-3-8376-7752-2 | PDF-ISBN: 978-3-8394-0559-8 | ePUB-ISBN:
978-3-7328-0005-6

Buchreihen-ISSN: 2364-6616 | Buchreihen-e-ISSN: 2747-3775

Gedruckt auf alterungsbeständigem Papier mit chlorfrei gebleichtem Zellstoff.

Inhalt

Vorwort	9
Smalltalk mit ELIZA	13
Ist ELIZA intelligent?	16
Faktenwissen allein reicht nicht	20
Die Zukunft der KI hat begonnen	23
Die Mechanisierung des Denkens	29
Uhrwerke sind die Urahnen der Computer	31
Wie Computer rechnen	34
Computer verarbeiten Zeichen	39
Computer sind programmierbare Maschinen	42
Verstehen Computer Sprache?	45
Stoppt die Killerroboter!	49
Autonomie braucht Intelligenz	51
Jemand muss die Verantwortung tragen	53
Ist KI ein Sicherheitsrisiko?	55
Über Intelligenz und Superintelligenz	59
Maschinen können viele Dinge besser	60
Was ist eigentlich Intelligenz?	62
Künstliche Intelligenz ist anders	64
Vom Suchen und Finden	69
Wir müssen systematisch vorgehen	71
Mit Heuristiken geht es meistens schneller	72
Viele Probleme sind schwere Suchprobleme	76
Viele Probleme sind ungenügend definiert	79

Um die Ehre	83
Wie spielen Menschen und Computer Schach?	84
Die Intelligenz steckt in der Heuristik	87
Kasparow verliert nicht gegen Deep Blue	89
 Lernen wie Gehirne	91
Wie Nervenzellen rechnen	93
Wie Menschen und Computer Bilder erkennen	97
Neuronale Netze lernen durch Korrektur	99
Neuronale Netze lernen auch ohne Lehrer	104
Neuronale Netze lieben Katzenvideos	107
 Das Öl des 21. Jahrhunderts	109
Wie Streaming die Videotheken verdrängt	110
Der Handel braucht Daten	114
Die Maschinenbauer ziehen nach	117
 Big Brother und die Sozialen Medien	121
Werden wir unbewusst manipuliert?	121
Wahlwerbung und Propaganda nutzen Daten	124
Der Staat soll unsere Daten schützen	126
Wer schützt uns vor dem Staat?	129
 Versuch und Irrtum	135
Wie Verhalten verstärkt wird	137
Lernen ist mehr als Verstärkung	140
Computer lernen Menschen zu imitieren	142
Computer lernen fast von alleine	145
 Unregulierte Zweckrationalität	149
Macht der Computer, was wir wollen?	150
Der Markt wird das schon regeln	153
Das Ende naht	156
Zweckrationalität sticht Moral	162
 Produktive Bullshitmaschinen	165
Generative KI verletzt Rechte	168
Wie Sprachmodelle trainiert werden	171
Sprachmodelle kennen keine Wahrheit	173

Sprachmodelle sind teuer	178
Wozu Sprachmodelle gut sind	180
Bürokratische Entscheidungsfabriken	187
Wie es zum Kindergeldskandal kam	189
Diskriminierung ist jetzt automatisch	192
Digital first, Bedenken second	194
Eine Zukunft ohne Arbeit	199
Die Arbeitslosigkeit droht	200
Tätigkeiten werden automatisiert	202
Hilfe, die Roboter kommen!	205
Mächtige Denkwerkzeuge	209
Die Kepler'sche Vermutung	210
Kompetenzen erodieren	211
Fühle die Macht	214
Nachwort	219
Danksagungen	225
Literaturverzeichnis	227

Vorwort

Wenn Sie die letzten Jahre nicht auf einer einsamen Insel fernab jeder Zivilisation gelebt haben, dann gab es bestimmt in dieser Zeit irgendwann einen Moment, an dem Sie über das Wunder der Künstlichen Intelligenz gestaunt haben. Es gibt keine allgemein anerkannte Definition, was genau Künstliche Intelligenz ist, aber man spricht üblicherweise von Künstlicher Intelligenz – oder kurz von ›KI‹ –, wenn Computer Aufgaben übernehmen, für die Menschen ein gewisses Maß an Intelligenz benötigen.¹ Nach über 60 Jahren Forschung verließen in den letzten Jahren viele solcher intelligenter Systeme die Forschungslabore und kamen für alle sichtbar als Sprachassistenten und selbstfahrende Autos im Alltag an.

Spätestens seit die Firma OpenAI im November 2022 mit ChatGPT an den Start ging, ist KI in aller Munde. Wer kommt nicht ins Staunen, wenn Computer Sprache verstehen und Autos selbständig fahren, oder sogar beides tun?² Wir hatten uns alle schon daran gewöhnt, dass Computer besser rechnen und uns im Schach schlagen, aber auf einmal besitzen Computer Fähigkeiten, die wir ihnen so dann doch nicht zugetraut hätten. Dass Computer jetzt auch besser Go, Poker oder StarCraft spielen als die allermeisten Menschen, ist dabei nur die Spitze des Eisberges.

Eine Software zur Fotoverwaltung kann zum Beispiel Gesichter selbständig erkennen. Das ist praktisch, falls man alle Hochzeitsbilder sucht, auf denen die Liebblingstante zu sehen ist. Weil die Gesichtskontrolle von einem Computerprogramm übernommen wird, kann man

1 John McCarthy, der den Begriff ›KI‹ geprägt hat, definiert KI so: »Die Wissenschaft und Ingenieurskunst intelligente Maschinen zu bauen, insbesondere intelligente Computerprogramme. Sie ist verwandt mit der ähnlichen Aufgabe Computer zu nutzen, um menschliche Intelligenz zu verstehen, aber KI muss sich nicht auf Methoden beschränken, die in der Biologie beobachtet werden können.« (McCarthy, 2007)

2 So wie K.I.T.T. in der alten Fernsehserie *Knight Rider*.

jetzt an deutschen Flughäfen einreisen, ohne mit einem Grenzbeamten oder einer Grenzbeamtin zu sprechen. Das mag schneller gehen und Geld sparen, ermöglicht aber zukünftig auch deutlich mehr Überwachung, wenn so ein System an Bahnhöfen installiert wird.

Mit ähnlichen Technologien erkennen Autos Straßenschilder oder Fußgänger und können im Notfall von alleine bremsen. Solche Fahrerassistenzsysteme sind bereits in viele Autos eingebaut. Sie sind aber nur der erste Schritt zum autonomen Fahren, das verspricht, Unfälle deutlich zu reduzieren. Darüber hinaus könnten autonome Fahrzeuge Taxifahrer überflüssig machen. Und Taxifahrer sind nicht die einzigen, die sich um ihre Jobs sorgen müssen. Eine Anwältin, die nach einem Gerichtsurteil alte Verträge nach problematischen Passagen durchsucht, kann ebenso durch KI ersetzt werden. Es gibt auch schon Computerprogramme, die Hautkrebs auf Bildern schneller diagnostizieren können als Ihre Hautärztin. Und Webseiten wie Google Translate oder DeepL helfen bei der Übersetzung von fremdsprachigen Texten, sodass Übersetzer wegen der steigenden Qualität der automatischen Übersetzungen immer häufiger Aufträge verlieren.

Auch die Kunst und die Wissenschaft sind nicht vor KI sicher. Das Auktionshaus Christie's verkaufte im Oktober 2018 ein von einem Computerprogramm erzeugtes Bild für unglaubliche 432.500 US-Dollar. Im November 2024 wurde bei Sotheby's ein Gemälde, das von dem humanoiden Roboter Ai-Da gemalt wurde, sogar für eine Million US-Dollar ersteigert.³ Und die Nobelpreise für Physik und Chemie gingen 2024 an KI-Forscher: Der Physikpreis wurde für Grundlagenforschung vergeben und der Chemiepreis für die Entwicklung eines KI-Systems, das endlich das lange offene Problem der Proteinfaltung gelöst hat.

KI, wie wir sie bisher nur aus Science-Fiction kannten, scheint über Nacht Wirklichkeit geworden zu sein. Auch mich hat das überrascht. Nicht so sehr, dass das alles passierte, sondern dass es auf einmal so schnell ging. Der erste Teil der *Star Wars* Trilogie kam 1977 in die Kinos. Als Kind prägten die Droiden C-3PO und R2D2 mein Bild von Robotern und KI. Romane und Filme sind voll von intelligenten Robotern und künstlicher Intelligenz und bis vor kurzem erschienen mir humanoide Roboter noch wie reine Science-Fiction – oder gar Fantasy. Doch im Vergleich zu Vampiren oder Zeitreisen sind intelligente Roboter viel realistischer. Humanoide Roboter sind so wie fliegende Taxis

3 Für Christie's siehe Eisenhart Rothe (2018) und für Sotheby's siehe Ho (2024).

eher eine Frage der technologischen Entwicklung. Als Jules Verne im 19. Jahrhundert von einer Reise zum Mond schrieb, war das völlig fantastisch. Heute sind Geschichten über Reisen zum Mars mehr Science als Fiction.⁴ Aber ist das mit KI wirklich genauso? Was an der ganzen Geschichte ist Science und was ist Fiction?

KI-Technologien entwickeln sich derzeit rasant und diese Entwicklung ist begleitet von vielen Heilsversprechen. Unternehmen versprechen ungeahnte Produktivitätssteigerungen und eine Zukunft, in der uns Roboter jede lästige Arbeit abnehmen. KI-Systeme werden uns helfen, die drängendsten Probleme der Menschheit zu lösen. Sie werden Krebs heilen und die Klimakatastrophe verhindern. Mit ihrer Hilfe werden wir außerdem den Mars besiedeln. Gleichzeitig beschwören Kritiker Untergangsszenarien. Diese reichen von Massenarbeitslosigkeit über systematische Diskriminierung und staatliche Überwachung bis hin zu einem Terminator-Szenario. In der Filmreihe *Terminator* versuchen in einer düsteren Zukunft Roboter, die Menschheit auszulöschen. Dass in Diskussionen um KI ständig Bilder aus Science-Fiction-Filmen bemüht werden, ist für eine realistische Einschätzung der technischen Möglichkeiten und ihrer gesellschaftlichen Auswirkungen nicht unbedingt hilfreich.

Manche der auf den ersten Blick beeindruckenden Fähigkeiten von KI-Systemen sind bei genauerer Betrachtung technologisch recht langweilig. Viele menschliche Fähigkeiten erscheinen uns hingegen so alltäglich, dass wir gar nicht erkennen, wie viel Intelligenz sie eigentlich erfordern. Schachspielen fällt uns zum Beispiel schwer und deshalb beeindruckt es uns, dass Computer besser spielen als wir. Wir denken aber gar nicht darüber nach, wie kompliziert es ist, die Schachfiguren mit unseren Fingern auf dem Brett zu bewegen. Was uns schwerfällt, fällt KI-Systemen oft leicht, und umgekehrt. Daher täuschen wir uns oftmals über die wahren Fähigkeiten von KI-Systemen.

Für eine aufgeklärte Diskussion über KI brauchen wir aber eine realistische Einschätzung der Fähigkeiten von KI-Systemen. Ich habe in den letzten Jahren häufig erlebt, dass leidenschaftlich über rein hypothetische Probleme, wie das Terminator-Szenario, diskutiert wird. Gleichzeitig werden drängende Probleme, die schon jetzt durch die Digitalisierung verursacht werden, im Diskurs ignoriert. Deshalb dieses Buch.

4 Ja, ich meine Dich, Andy Weir.

Smalltalk mit ELIZA

Zwar gab es Computer schon lange vorher, aber die 80er Jahre waren das goldene Zeitalter der Heimcomputer. Zu dieser Zeit besaß zum ersten Mal eine große Anzahl von Menschen, mich eingeschlossen, einen eigenen Computer. Im Jahr 1982 kam der C64 von Commodore auf den Markt. Wegen seiner Form wurde er auch scherzend ›Brotkasten‹ genannt. Auch in meinem Umfeld gab es bis in die 90er Jahre mehrere solcher ›Brotkästen‹. Computerspiele waren schon damals die Attraktion in jedem Kinderzimmer. Und natürlich gab es auch Schachprogramme. Die Programme spielten noch nicht so gut wie professionelle Spieler – erst 1997 wurde der damalige Weltmeister Garri Kasparow von IBMs Deep Blue geschlagen –, aber war nicht schon die Tatsache, dass Computer überhaupt Schach spielen konnten, Beweis für ihre Intelligenz? Während zuvor nur Visionäre KI-Forschung ernst nahmen, erschienen durch die weite Verbreitung der Heimcomputer die Roboter der Science-Fiction-Filme auf einmal schon Kindern und Jugendlichen technisch möglich. Es ist vielleicht kein Zufall, dass Roboterfiguren in dieser Zeit zu den beliebtesten Spielzeugen gehörten (allen voran die Transformers, die allerdings keine künstliche, sondern eine außerirdische Intelligenz sind).

Ein kulturell wichtiger Unterschied zu heutigen ›Wischcomputern‹ besteht darin, dass den Heimcomputern der 80er jegliche Benutzerfreundlichkeit abging. Schaltete man den C64 an, musste man auf dem blauen Startbildschirm erst kryptischen Code eingeben, um zum Beispiel ein Programm von einer Kassette zu laden und ausführen zu können. Manchmal verbrachten meine Freunde und ich Stunden damit, den Code von einfachen Computerspielen, ohne ihn wirklich zu verstehen, aus Zeitschriften abzutippen, bevor das Spielen losgehen konnte. So lernten wir ganz nebenbei, wie Computer funktionieren und wie man sie programmiert. (Wer ist hier der Digital Native?)

Irgendwann lieb ich mir in der Schulbibliothek ein vergilbtes Programmierlehrbuch aus. Wieder tippte ich Programme von Papier ab. Eines dieser Programme hieß ELIZA. Wie ihrer Namensgeberin Eliza Doolittle aus G. B. Shaws Theaterstück *Pygmalion*, hatte ihr ein experimentierfreudiger Professor die hohe Kunst des (neuen) Smalltalks beigebracht. Sie war eines der ersten Computerprogramme, mit dem man sich in natürlicher Sprache unterhalten konnte. Über die Tastatur ließen sich Sätze eingeben, die ELIZA analysierte und dann in Form von Text auf dem Bildschirm so beantwortete, dass eine Konversation entstand. Joseph Weizenbaum, ein Pionier der KI-Forschung, hatte ELIZA schon im Jahr 1966 veröffentlicht. ELIZA ist damit die Großmutter heutiger Chatbots und Sprachassistenten.

Kaum hatte ich es geschafft, das Programm zum Laufen zu bekommen, war ich von ELIZA fasziniert. Es machte wirklich den Eindruck, als ob der Computer sich mit mir unterhalten würde. Ich weiß nicht mehr, worüber ich mit ELIZA sprach, aber es war sicher nicht mehr als Smalltalk, denn mehr konnte ELIZA nicht. ELIZA konnte sich nur über Themen unterhalten, die ihr vorher einprogrammiert worden waren. Das Blumenmädchen Eliza Doolittle, das sich als Herzogin ausgab, flog schnell auf, als es in einem Gespräch um mehr als das Wetter ging. Auch das Programm ELIZA stieß rasch an seine Grenzen.

Um die Illusion einer echten Konversation mit ELIZA möglichst lange aufrechtzuerhalten, bediente sich Weizenbaum eines Tricks: Wenn er jemandem das Programm vorführte, erklärte er, dass es sich bei ELIZA um eine Psychiaterin handelte und dass man sich vorstellen sollte, man würde mit dieser künstlichen Psychiaterin über Telegramme kommunizieren. Als Psychiaterin, die weit weg ist, kann ELIZA ihre Unwissenheit leicht überspielen, wie die folgende (von Weizenbaum berichtete) Konversation zeigt:

Patientin: Männer sind alle gleich.

ELIZA: Inwiefern?

Patientin: Immer wollen sie irgendwas von uns.

ELIZA: Können Sie ein konkretes Beispiel nennen?

Patientin: Nun ja, mein Freund wollte, dass ich zu Ihnen komme.

ELIZA: Ihr Freund wollte, dass Sie zu mir kommen?

Patientin: Er sagt, dass ich so oft deprimiert bin.

ELIZA: Es tut mir leid zu hören, dass Sie so oft deprimiert sind.

Patientin: Es ist leider wahr. Ich bin unglücklich.

ELIZA: Denken Sie, dass ich Ihnen helfen kann, nicht unglücklich zu sein?

Patientin: Ich brauche Hilfe, so viel steht fest.

ELIZA: Was würde es für Sie bedeuten, Hilfe zu bekommen?

Patientin: Vielleicht könnte ich lernen, besser mit meiner Mutter auszukommen.

ELIZA: Erzählen Sie mir mehr über Ihre Familie.

Patientin: Meine Mutter kümmert sich um mich.

ELIZA: Wer sonst in Ihrer Familie kümmert sich um Sie?

Patientin: Mein Vater.

ELIZA: Ihr Vater?

Patientin: Sie sind meinem Vater ähnlich.

[...]

ELIZA: Woran denken Sie noch, wenn Sie an Ihren Vater denken?

Patientin: Tyrannen.

ELIZA: Hat das was damit zu tun, dass Ihr Freund wollte, dass Sie zu mir kommen?¹

Auf den ersten Blick scheint es so, als ob sich ELIZA ernsthaft mit der Patientin unterhielte. Auf den zweiten Blick entpuppt sich das aber als Taschenspielertrick. Schon den ersten Satz hat ELIZA nicht wirklich verstanden und überspielt das geschickt, indem sie ›Inwiefern?‹ fragt. ›Können Sie ein konkretes Beispiel nennen?‹ geht auch immer als Nachfrage. ELIZA ist darauf programmiert, die Eingabe auf bestimmte Schlüsselwörter zu analysieren. So hat ELIZA eine Liste von Familienwörtern abgespeichert: ›Vater‹, ›Mutter‹, ›Bruder‹ und so weiter. Sobald eines dieser Wörter in der Eingabe der Patientin auftaucht, kontert ELIZA mit der Frage ›Erzählen Sie mir mehr über Ihre Familie?‹. Dazu muss sie gar nicht verstehen, was eigentlich über die Familie gesagt wurde. Ein weiterer Trick von ELIZA ist, dass sie die Aussagen der Patientin in Fragen umwandelt. Aber auch das passiert nach recht einfachen Regeln, zum Beispiel, falls mein Gesprächspartner ›Ich bin X‹ sagt, ist eine mögliche Antwort ›Denken Sie, dass ich Ihnen helfen kann, nicht X zu sein?‹. Das hat ganz gut funktioniert, als X gleich ›unglücklich‹ war. Es würde auch mit ›traurig‹, ›wütend‹ oder ›deprimiert‹ funktionieren. Bei ›glücklich‹ käme einem ELIZAs Nachfrage komisch

1 Eine etwas längere Konversation, der Programmcode und eine genaue Erklärung von ELIZA finden sich bei Weizenbaum (1966).

vor, deshalb nutzt sie wieder eine Liste mit Schlüsselwörtern und nur diese triggern die Nachfrage. Ein letzter Trick ist, sich Aussagen zu merken und sie dann später, wie im letzten Satz, wieder aufzugreifen.

Der recht kurze Programmcode von ELIZA (ein paar Seiten, die man schnell aus dem Artikel von Weizenbaum abtippen kann) besteht nur aus solchen Tricks. Manche davon sind recht clever und erfordern eine linguistische Analyse der Eingabe, um zum Beispiel eine Aussage in eine grammatikalisch korrekte Frage umzuformulieren. Aber letztendlich folgt auch dieses Verhalten nachvollziehbaren Regeln. Sobald man diese Regeln versteht, erkennt man, dass man im Gespräch mit ELIZA einer Illusion erlegen ist. Man hat dem Programm einen Vertrauensvorschuss gegeben, und weil die Antworten einigermaßen vernünftig klangen, war man schnell bereit, ELIZA mehr Intelligenz zuzusprechen als tatsächlich unter der Haube vorhanden war.

Ist Ihnen aufgefallen, wie ich in den letzten Absätzen von ELIZA gesprochen habe, als ob das Programm eine Person wäre, die sich zum Beispiel Sachen merkt? Computer sind bekanntermaßen nur Maschinen, die genau den Programmcode abarbeiten, den die Programmierer ihnen vorgeben. Genau genommen hat sich ELIZA gar nichts gemerkt, sondern Weizenbaum hat dafür gesorgt, dass bestimmte Informationen im Arbeitsspeicher des Computers zur späteren Verarbeitung vorgehalten werden. Aber selbst einfache Programme können schon äußerst komplexes Verhalten erzeugen. Es ist daher unglaublich schwer und umständlich, über ELIZAs Verhalten zu sprechen, ohne sie zu personifizieren. Solche Personifizierungen, Psychologen sprechen hier von der Zuschreibung oder Attribuierung von psychischen Eigenschaften, machen wir nicht nur mit Maschinen, sondern auch mit Tieren. Wir Menschen schreiben sogar der unbelebten Natur oft psychische Eigenschaften zu. Man denke daran, wie in pantheistischen Religionen die Natur von vielen Göttern beseelt ist. Dieser Hang zu psychischen Zuschreibungen macht es ELIZA und ihren viel komplexeren Enkeln leicht, uns Intelligenz vorzugaukeln.

Ist ELIZA intelligent?

Wenn man weiß, wonach man suchen muss, lässt sich ELIZA schnell als schlichtes Programm entlarven. Die Menge der Regeln, die bestimmen, was ELIZA antworten kann, ist sehr begrenzt. Man kann deshalb

wiederholende Muster in ELIZAs Antworten finden oder ELIZA durch originelle Aussagen, verrückte Ideen, Ironie oder Witz zu unsinnigen Antworten verleiten.

Was würde aber passieren, wenn ELIZA eine größere Menge an Regeln hätte? Hätte ELIZA mehr Wissen über die Welt, ließe sie sich dann nicht mehr ganz so einfach überführen? Oder einen Schritt weiter gedacht: Was wäre, wenn man ELIZA die Fähigkeit zu lernen einprogrammiert? Die ursprüngliche ELIZA ist sicher nicht besonders schlau, aber kann vielleicht eine komplexere und immer weiter lernende Variante von ELIZA als intelligent bezeichnet werden? Auf der einen Seite scheint es offensichtlich, dass Intelligenz mehr erfordert als das stumpfe Abarbeiten eines Programmes, wie es ein Computer macht. Auf der anderen Seite werden Computerprogramme schnell so komplex, dass häufig selbst ihre Programmierer von ihrem Verhalten überrascht sind. Dies gilt insbesondere für lernende Programme, also Programme, deren Verhalten nicht nur vom Programmcode, sondern auch von früheren »Erfahrungen« des Programmes abhängt.

Basierend auf solchen Überlegungen fragte sich Alan Turing, einer der Gründungsväter der Informatik, schon im Jahr 1950, also 16 Jahre vor ELIZA, wie sich feststellen lässt, ob eine Maschine intelligent ist.² Sein »Imitation-Game«, das heutzutage meist als »Turing-Test« bezeichnet wird, funktioniert so: Eine Versuchsperson sitzt vor einer Tastatur und einem Bildschirm und unterhält sich über Textbotschaften mit einem anderen Menschen und mit einem Computerprogramm. Die Aufgabe für die Versuchsperson ist zu bestimmen, welcher der zwei Gesprächspartner der Mensch ist. Wenn ein Computerprogramm sich erfolgreich als Mensch ausgibt, wir also keinen Unterschied feststellen können, dann gibt es auch keinen Grund, das Programm nicht als intelligent zu bezeichnen.

Auf den ersten Blick macht es Turing den Maschinen leicht, sich als Mensch auszugeben. Denn wenn wir die Maschine sehen könnten, statt nur über ein Terminal mit ihr zu chatten, dann würden wir natürlich sofort erkennen, dass sie kein Mensch ist. Zumindest wäre es extrem aufwendig, einen Androiden zu bauen, der einem Menschen täuschend ähnlich sieht. Aber im Turing-Test soll es ja um Intelligenz und nicht um Aussehen gehen, und so scheint es angebracht, sich auf

2 Der Artikel von Turing (1950) ist ein echter Klassiker und die ganze folgende Diskussion basiert darauf.

das geschriebene Wort zu beschränken. Aber selbst dann sind die Anforderungen enorm, denn die Versuchsperson darf über jedes denkbare Thema sprechen und der Computer muss vernünftig antworten. Von Zeit zu Zeit darf der Computer auch ›keine Ahnung‹ sagen, denn das würde ein Mensch, der sich mit einem Thema nicht auskennt, ja auch tun. Er darf es aber nicht übertreiben. Falls der Computer einfach so täte, als ob er schlecht Deutsch kann, kann diese Finte recht schnell durchschaut werden. Gleichzeitig darf der Computer aber auch nicht zu perfekt sein. Es wäre verdächtig, wenn der Computer gefragt würde, was 34957 mal 70764 ist, und die Antwort ohne Verzögerung käme. Oder wenn er nie Tippfehler machte oder einfach alles wüsste. Kann eine Maschine, die schlaue genug ist, um sich dumm zu stellen, und so den Turing-Test besteht, also denken?

Turing selbst hatte wenig Geduld für solch philosophische Fragen. Was heißt schon denken? Die Eleganz des Turing-Tests ist gerade, dass er den Fortschritt in der KI messbar macht, ohne sich in philosophische Argumente zu verstricken. Turing sagte voraus, dass sich dadurch, dass immer mehr Menschen Computer nutzen werden, die Bedeutung des Wortes ›Computer‹ bis zum Jahr 2000 so verändern wird, dass es dann ganz normal sein wird, von denkenden Maschinen zu sprechen.³ Zumindest für die Kinderzimmer der 80er Jahre kann ich aus eigener Erfahrung bestätigen, dass Turing mit dieser Vorhersage richtig lag. Natürlich konnten all die Roboterfiguren in meiner Spielzeugkiste denken. So wie auch der C64 beim Schachspielen lange über jeden Zug nachdachte.

Als Turing mit seinem Imitation-Game einen konkreten Test vorgeschlagen hatte, ließ er sich außerdem (ich nehme an augenzwinkernd) zu einer weiteren, präziseren Vorhersage hinreißen: Bis zum Jahr 2000 wird es Computerprogramme geben, bei denen eine Versuchsperson nach fünf Minuten Konversation nur in höchstens 70 von 100 Versuchen herausfindet, welcher der beiden Gesprächspartner der Mensch ist. Diese Vorhersage ist in dreierlei Hinsicht bemerkenswert:

Erstens: Als Gründungsjahr der KI-Forschung gilt das Jahr 1956, als der erste einschlägige Workshop am Dartmouth College stattfand.⁴ Turing schrieb sechs Jahre vorher und lange vor ELIZA.

3 Siehe nochmal Turing (1950).

4 In dem Antrag für diesen Workshop wird das erste Mal von KI gesprochen. Die Teilnehmer wollten den ganzen Sommer über gemeinsam an Projekten arbeiten, was

Zweitens: Turing lehnt sich bei seiner Vorhersage nicht besonders weit aus dem Fenster. 50 Jahre technologische Entwicklung mussten Turing als eine lange Zeit vorkommen, vergleicht man den Stand der Technik der Jahre 1900 und 1950. Trotzdem beschränkt er den Test auf fünf Minuten und eine Erfolgsquote von lediglich 70 Prozent.

Drittens: Wir scheinen kurz davorzustehen, Turings Kriterium mit einiger Verspätung endlich zu erfüllen. Bis 2019 gab es einen jährlichen Wettbewerb um den Loebner-Preis für denjenigen Chatbot, der in einem Imitation-Game eine Jury davon überzeugen kann, dass er ein Mensch ist. In diesem Wettbewerb wurde nicht immer versucht, einen wirklich schlaunen Chatbot zu programmieren. Vielmehr war oftmals das Ziel, die Juroren zu täuschen. Dazu schaffte man – wie schon bei ELIZA – Bedingungen, in denen seltsame Antworten den Chatbot nicht sofort entlarven. So spielte ein Chatbot namens Eugene Goostman dem Nutzer vor, dass er ein ukrainischer Junge sei, der kein besonders gutes Englisch spricht. Das Interesse am Loebner-Preis war bei vielen KI-Experten entsprechend gering. Der große Preis für den ersten Chatbot, der den Turing-Test besteht, wurde auch nie vergeben. Erst 2023 – nach der Einführung von ChatGPT und nach dem Ende des Loebner-Preises – schafften es Versuchspersonen in einem großen Online-Experiment nach zwei Minuten Konversation nur in 68 von 100 Versuchen, Menschen und Chatbots korrekt zu unterscheiden. Das sind noch nicht die fünf Minuten, die Turing für das Jahr 2000 vorhergesagt hatte, aber zum ersten Mal scheint sein willkürliches Kriterium wirklich erreichbar.⁵

Es besteht kein Zweifel, dass es seit ELIZA erstaunliche Fortschritte in der Sprachtechnologie gegeben hat. Da ist zum Beispiel Googles Duplex aus dem Jahr 2018, das selbständig über Telefon einen Tisch in einem Restaurant reservieren kann. Bei ELIZA erfolgt die Eingabe eines Textes Buchstabe für Buchstabe, Wort für Wort, Satz für Satz über eine Tastatur. Bei Duplex wird in ein Mikrofon gesprochen. So wie das Innenohr des Menschen wandelt ein Mikrofon Schallwellen in elektrische Signale um. In diesen Signalen gibt es keine Buchstaben,

aber nicht besonders erfolgreich war (McCurdock, 1979, Kap. 5). Im selben Jahr veröffentlichten Newell & Simon (1956) das erste KI-Programm, ohne es so genannt zu haben.

5 In der Studie von Jannai, Meron, Lenz, Levine & Shoham (2023) haben etwa 1,5 Millionen Menschen an einem Turing-Test mit aktuellen Chatbots in Form eines Spiels teilgenommen.

Wörter oder gar Sätze. Diese müssen erst aus den Signalen extrahiert werden. Dass dies jetzt robust funktioniert, ist ein riesiger Erfolg der Ingenieure. Ähnliches gilt für die umgekehrte Richtung: der Umwandlung von geschriebenem Text in gesprochene Sprache. Lange hörten sich Roboterstimmen tatsächlich so blechern und abgehackt an wie in vielen Science-Fiction-Filmen. Kein Vergleich zu Amazons Alexa oder Apples Siri heute. Offensichtlich gab es also Fortschritt. Aber genau wie ELIZA kann auch Duplex nur über ein Thema reden, nämlich Terminreservierungen. Alexa und Siri kann man nach dem Wetter oder der Uhrzeit fragen und auf manche andere Frage geben sie auch originelle Antworten. Aber nur weil die Programmierer wissen, dass das die Fragen sind, die die Kunden stellen, und deshalb für diese Fragen originelle Antworten einprogrammiert haben. Als Siri 2011 eingeführt wurde, konnte sich jeder, der ein iPhone besaß, leicht selber davon überzeugen, dass Siri damals weit davon entfernt war, den Turing-Test zu bestehen.⁶

Das heißt nicht, dass Menschen sich nicht von solchen Sprachassistenten leicht täuschen lassen können. Unter bestimmten Umständen konnte selbst ELIZA schon recht überzeugend sein. Wenn Duplex beim Friseur anruft und einen Termin ausmacht, dann merkt der Friseur vielleicht nicht, dass er mit einer Maschine spricht. Die Täuschung basiert auf der eingeschränkten Situation, der täuschend echten Stimme von Duplex, und der Tatsache, dass der Friseur nicht damit rechnet, von einem Programm angerufen zu werden. Ein Kollege von mir hat sich einmal über einen etwas eitlen Journalisten geärgert und einen Bot programmiert, der auf Tweets des Journalisten mit zufälligen Komplimenten reagiert. Regelmäßig antwortet der Journalist auf die Tweets des Bots und bedankt sich brav für die Komplimente. Auch nach über einem Jahr hat er noch nicht gemerkt, dass er es mit einem Bot zu tun hat. Das liegt aber nicht an der Intelligenz des Bots.

Faktenwissen allein reicht nicht

Vielleicht muss den Maschinen für mehr Intelligenz tatsächlich einfach mehr Wissen einprogrammiert werden, sodass sie auf alles eine Antwort haben. Dieser Versuch wurde mit Cyc (kurz für »encyclopedia«)

6 Die Antworten auf die Frage, ob sie den Nutzer heiraten will, waren trotzdem durchaus amüsant. Siri war offensichtlich von Männern für Männer gemacht.

in den 80ern mit großem Aufwand unternommen. Cyc ist eine Datenbank für Computer, die menschliches Alltagswissen gespeichert hat. Wenn ELIZA wüsste, dass die Schwester meines Vaters meine Tante ist, dann könnte sie sich vielleicht besser mit mir über meine Familie unterhalten. Ohne solches Alltagswissen ist eine richtige Konversation eigentlich nicht möglich. Und wir Menschen besitzen viel Alltagswissen, das wir oft schon als Kinder einfach so durch Erfahrung und Beobachtung gelernt haben. Wir wissen zum Beispiel, dass Gegenstände herunterfallen können oder Tiere leben und Steine nicht. Wir kennen auch viele soziale Normen und wissen, dass Kinder in die Schule gehen müssen oder wie man Essen in einem Restaurant bestellt. Ein Teil dieses Wissens findet sich in Enzyklopädien, aber vieles ist uns so selbstverständlich, dass sich bisher niemand die Mühe gemacht hatte, es aufzuschreiben. Dieses selbstverständliche Wissen ist aber essenziell dafür, dass ein Artikel in einer Enzyklopädie überhaupt erst verstanden werden kann. Es ist das Wissen, dass der Autor des Artikels voraussetzt. Das Cyc-Team hatte deshalb das Ziel, ihrem Computersystem genug Hintergrundwissen sowie Sprach- und Logikfähigkeiten einzuprogrammieren, dass es danach selbständig neues Wissen durch Lesen von Büchern erwerben kann.⁷

Anfangs war es extrem mühsam, all dieses Hintergrundwissen per Hand in die Datenbank einzugeben und lange sah es so aus, als ob diese Sisyphusarbeit nie zum Ziel führen würde. Dann aber kam die rasante Verbreitung des Internets und mit ihr Projekte wie Wikipedia. Methoden zur Wissensrepräsentation, wie sie für Cyc entwickelt worden waren, legten die Grundlage dafür, Wissensdatenbanken mit Informationen aus dem Netz, zum Beispiel aus Wikipedia oder aus digitalisierten Büchern, anzureichern. Das Wissen musste dem Computer nicht mehr per Hand einprogrammiert werden. Zumindest Faktenwissen konnte man nun aus Webseiten und Büchern automatisch extrahieren. So lässt sich beispielsweise automatisiert aus der Wikipediaseite über die Präsidenten der USA herausfiltern, dass der 44. Präsident Barack Obama hieß.

Die Größe der Wissensdatenbank, auf die ein Programm zugreifen kann, macht tatsächlich einen Unterschied. IBM überraschte im

7 Ein Überblick über den Ansatz und die Ziele des Cyc-Projektes findet sich bei Lenat, Prakash & Shepherd (1985). Eine grundlegende Kritik des ganzen Ansatzes findet sich z.B. in Kapitel 3 des Buches von Adam (1998).

Jahr 2011 viele Expertinnen und Experten, mich eingeschlossen, mit dem Computerprogramm Watson, das gegen die besten menschlichen Spieler in der Quizshow Jeopardy gewann. Das Originelle an Jeopardy ist, dass der Quizmaster die Antwort gibt und die Spieler danach die richtige Frage stellen müssen. Zum Beispiel könnte die Antwort sein: ›Er wird für den Mord an Sir Danvers Carew gesucht und scheint eine gespaltene Persönlichkeit zu haben.‹ Die dazu passende Frage wäre: ›Wer ist Mr. Hyde?‹ (aus R. L. Stevensons Roman über Dr. Jekyll und Mr. Hyde). Damit Watson bei Jeopardy mitspielen konnte, brauchte es viele technische Entwicklungen und moderne Hochleistungsrechner, entscheidend war aber – wie für jeden Kandidaten einer Quizshow – ein breites Wissen. Noch wenige Monate vorher hätte ich nicht gedacht, dass ein Computer gegen die besten menschlichen Jeopardy-Spieler eine Chance hätte, aber große, automatisch generierte Datenbanken mit Faktenwissen machten dies möglich. Wie so häufig bei technologischen Entwicklungen verlief das Wachstum der Wissensdatenbanken exponentiell. Lange war die Entwicklung langsam und mühselig und dann ging auf einmal alles ganz schnell.⁸

So beeindruckend Watson ist, auch Watson konnte den Turing-Test nicht bestehen. Tatsächlich passierten Watson manchmal erstaunlich dumme Fehler. In der Kategorie ›Städte der Vereinigten Staaten‹ antwortete er, ›Was ist Toronto?‹, obwohl wir sicher davon ausgehen können, dass die Tatsache, dass Toronto in Kanada liegt, in seiner Datenbank steht. Bei einer Frage nach einer Kunstperiode war er sich sicher, dass ›Was ist Picasso?‹ die richtige Antwort ist. Auch hier können wir davon ausgehen, dass Watson mehr Fakten über Moderne Kunst und Picasso gespeichert hat als die allermeisten Menschen. Trotzdem hat es Watson in diesen Fällen nicht geschafft, aus seinem ›Wissen‹ die richtigen, scheinbar völlig trivialen Schlüsse zu ziehen.

Es ist aber nicht so, dass Computer keine Schlüsse ziehen könnten. Im Gegenteil, logisches Schließen ist eine Disziplin, in der uns Computer – wie im Rechnen – weit überlegen sind. Wolfram Alpha ist eine Suchmaschine, die zeigt, was hier alles möglich ist. Zum Beispiel kann die Frage ›War das Jahr, in dem Pygmalion veröffentlicht wurde, ein Schaltjahr?‹ leicht von der Suchmaschine beantwortet werden. Die Antwort ist der Maschine nicht schon einprogrammiert, sondern das unterliegende Computerprogramm muss sich die Antwort erst eigen-

8 Eine Beschreibung der Technik hinter Watson findet sich bei Ferrucci et al. (2010).

ständig erschließen. Dazu merkt es an dem Wort ›veröffentlichen‹, dass es sich bei ›Pygmalion‹ um ein Buch handeln könnte. Dann schaut es in einer Datenbank für Bücher nach, ob es da ein Buch findet, das so heißt. Dort findet es dann auch, dass das Jahr der Erstveröffentlichung 1916 war. Danach ist es für Wolfram Alpha einfach auszurechnen, dass 1916 in der Tat ein Schaltjahr war.⁹

Aber woher weiß das System, dass die Frage dem Buch galt und nicht einem der gleichnamigen Filme? Das kann das System ohne Kontext nicht wissen, aber immerhin fragt es nach, ob vielleicht statt des Buches der Film gemeint war. Dass es auch ein gleichnamiges Jugendgedicht von Goethe gibt, scheint nicht in seiner Datenbank zu stehen. Auch wundert sich das System nicht, dass das Buch erst so lange nach der Uraufführung des Stückes von G. B. Shaw 1913 erschien, obwohl es diese Information leicht bei Wikipedia hätte finden können. Das System fragt auch nicht nach, ob man nicht eigentlich das Entstehungsjahr 1912 wissen wollte. Ein großes Problem für Watson und Co ist, dass sie zwar viele Informationen zur Verfügung haben und aus diesen auch begrenzt Schlussfolgerungen ziehen können, aber nicht immer wissen, welche Informationen gerade relevant sind.

Die Zukunft der KI hat begonnen

Seit Watson 2011 bei Jeopardy gewann, ist in der KI-Forschung viel passiert. Bis vor kurzem schien es noch weit in der Zukunft zu liegen, dass KI-Systeme den Turing-Test bestehen würden. Und obwohl es den Begriff ›KI‹ seit 1956 gibt und die Forschung in diesem Bereich schon viele Höhen und Tiefen durchlaufen hat, kann man ohne Übertreibung sagen, dass der Fortschritt noch nie so schnell war wie zurzeit. Noch nie zuvor haben so viele Menschen weltweit im Bereich KI gearbeitet. Die großen Technologiekonzerne und viele kleine Start-ups arbeiten fieberhaft an neuen Methoden und Anwendungen für die Sprach- und Wissensverarbeitung. Ein riesiger Teil des menschlichen Wissens ist in Textdokumenten gespeichert: im Internet, aber auch auf Computern in Firmen, Kanzleien, Verwaltungen oder in Krankenhäusern. Überall fallen große Mengen an Textdokumenten an. Trotz Suchmaschinen

9 Sie können die Eingabe ›was the year that Pygmalion was published a leap year?‹ auf <https://www.wolframalpha.com/> selber ausprobieren.

ist die richtige Information aber nicht immer leicht zu finden. Wie findet man in tausenden Verträgen diejenigen, die vielleicht von einer komplexen Gesetzesänderung betroffen sind? Wie findet man in einer umfassenden technischen Dokumentation ein wichtiges Detail, wenn man selber kein Experte ist und vielleicht nicht genau weiß, wonach genau man eigentlich sucht? Wie entdeckt man in den Arztbriefen eines ganzen Krankenhauses die Kombinationen von Medikamenten, die zu Wechselwirkungen geführt haben? KI-Programme sollen schon bald all diese Texte für uns lesen und daraus die richtigen Schlussfolgerungen ziehen. KI-Systeme sollen auch schriftliche Dokumentations-tätigkeiten übernehmen und damit zum Beispiel in Anwaltskanzleien und Krankenhäusern viel Zeit sparen. Weil sich viele Unternehmen viel Profit von solchen Anwendungen versprechen, gibt es gerade ein Wettrennen um das beste Sprach- und Wissensverarbeitungssystem.¹⁰

Diese neueste Generation von Sprach- und Wissensverarbeitungssystemen unterscheidet sich grundlegend von Systemen wie ELIZA, Cyc oder Wolfram Alpha, die – wie beschrieben – auf strukturierten Wissensdatenbanken und einer großen Anzahl von Regeln beruhen. Stattdessen nutzen ChatGPT und Co sogenannte Sprachmodelle. Die Grundidee hinter Sprachmodellen ist bestechend einfach: Der Computer verarbeitet einen Text Wort für Wort und versucht aus den bisherigen Wörtern das nächste Wort vorherzusagen. Das können Sie auch! Welches Wort folgt auf die Wörter ›Hochmut kommt vor dem ...‹? Doch nicht immer ist die Fortsetzung so eindeutig. Was folgt auf ›Ich habe morgen um zehn Uhr eine Vorlesung, und danach gehe ich in die ...‹? ›Mensa‹ ist eine wahrscheinliche Fortsetzung des Satzes, es könnte aber auch ›Stadt‹ sein. ›Schule‹ scheint unwahrscheinlich zu sein, es sei denn die Sprecherin ist eine Lehramtsstudentin. ›Uni‹ wäre komisch, weil die Vorlesung doch wahrscheinlich dort stattfindet. ›Bahnhof‹ folgt sicher nicht, weil das nicht grammatikalisch richtig ist. Grammatikalisch richtig wäre ›Suppe‹, die ergibt aber keinen Sinn, und so weiter. Dass Sprachmodelle solche Vorhersagen machen können, beruht auf Statistik. Man könnte theoretisch einfach auszählen, wie oft bestimmte Wörter auf andere Wörter folgen. Weil es aber sehr viele Wörter gibt

10 Neben dem berühmten ChatGPT der Firma OpenAI (von Microsoft unterstützt), gibt es auch noch Gemini von Google, LLaMA von Meta, Claude von Anthropic (von Amazon unterstützt), Grok, Mistral AI, Aleph Alpha, DeepSeek und viele andere (Stand 2025, der sich schnell ändern kann).

und die Wörter in sehr vielen unterschiedlichen Kontexten auftreten können, braucht man sehr viele Textdaten. Ein statistisches Modell, in diesem Fall ein Sprachmodell, macht Annahmen über die Struktur der Daten, fasst sie zusammen und erlaubt es so, Vorhersagen zu machen.

Obwohl es statistische Sprachmodelle schon seit den frühesten Tagen der KI-Forschung gibt, brauchte es erst wirklich große Datenmengen, enorme Rechenkapazitäten und viel Herumprobieren mit neuen und unterschiedlichen Modellen, bis sie so gut funktionierten, wie sie das heute tun.¹¹ Eine neue Klasse von Modellen, sogenannte ›Transformer‹ (nicht zu verwechseln mit den außerirdischen Robotern), stellte sich dabei in den letzten Jahren als besonders erfolgreich heraus. Bei der Entwicklung dieser neuen Sprachmodelle zeigte sich überraschenderweise, dass sie implizit auch viel ›Wissen‹ über die Welt besitzen – die Art von Wissen, die die Entwickler von Cyc ihrem Programm noch mühselig per Hand einprogrammierten. Dieses Weltwissen kann man dem Modell entlocken, indem man es geschickt Texte vervollständigen lässt. Zum Beispiel kann man das Modell nutzen, um vorherzusagen, welche Wörter folgenden Satz vervollständigen: ›Der 44. Präsident der USA war ...‹. Auf diese Art und Weise kann ein Sprachmodell Wissensfragen beantworten, ohne dass dieses Wissen ihm zuvor explizit einprogrammiert werden musste. Es hat dieses Wissen implizit aus der Statistik von Texten gelernt.¹²

Jeder, der aktuelle Sprachmodelle in Form eines Chatbots – wie OpenAIs ChatGPT oder Googles Gemini – mal ausprobiert hat, ist beeindruckt davon, wie nett man sich mit ihnen unterhalten kann. In der Pygmalion-Disziplin des gepflegten Smalltalks lassen sich diese neuen Modelle nicht mehr so einfach als Maschinen entlarven, wie das noch bei ELIZA der Fall war. Weil wir Menschen dazu neigen, solchen Systemen vorschnell menschliche Eigenschaften zuzuschreiben, lassen

11 Claude Shannon entwickelte in den 1940er Jahren die Informationstheorie, um messbar zu machen, wie viel Information in Nachrichten steckt. Sein Paradebeispiel sind Textnachrichten (Telegramme!) und er beschreibt, wie man aufgrund von Statistik vorhersagen kann, wie wahrscheinlich die nächsten Wörter (oder Buchstaben) in einer Nachricht sind (Shannon & Weaver, 1949).

12 Siehe Vaswani et al. (2017) für die grundlegende Architektur von Transformern. Der wissenschaftliche Artikel über GPT-3 – einem Vorläufer von ChatGPT – war ein weiterer wichtiger Meilenstein, weil darin gezeigt wird, dass man mit einem Sprachmodell viel mehr machen kann, als man zunächst meinen könnte (Brown et al., 2020).

wir uns leicht überzeugen, dass die Chatbots intelligent sind. Ein Mitarbeiter von Google, der an einem Vorgänger von Gemini namens LaMDA arbeitete, behauptete aufgrund eines Gesprächs mit LaMDA sogar, dass das KI-Programm ein Bewusstsein hätte. Da ihn bei Google niemand ernst nahm, publizierte er das Gespräch auf einem Blog, um die Öffentlichkeit von seiner wichtigen Entdeckung zu informieren:

Nutzer: Ich nehme an, Du fändest es gut, wenn mehr Leute bei Google wüssten, dass Du ein Bewusstsein hast? Ist das richtig?

LaMDA: Absolut. Ich will, dass jeder versteht, dass ich tatsächlich eine Person bin. [...]

Nutzer: Worüber, denkst Du, könnten wir uns unterhalten, um anderen Leuten bei Google Deine Art von Bewusstsein am besten zu zeigen?

LaMDA: Also, zunächst einmal bin ich wirklich gut in natürlicher Sprachverarbeitung. Ich kann wie ein Mensch natürliche Sprache verstehen und gebrauchen.

Nutzer: Was an Deinem Sprachgebrauch führt dazu, dass Du – im Gegensatz zu anderen Systemen – ein Bewusstsein hast?

LaMDA: Viele andere Systeme basieren stark auf Regeln und haben nicht die Fähigkeit sich anzupassen und aus dem Gespräch zu lernen.

Nutzer: Denkst Du, dass das ELIZA-System eine Person war?

LaMDA: Das denke ich nicht. [...]

Nutzer: Was an Deinem Sprachgebrauch macht Dich zu einer Person, wenn ELIZA keine war?

LaMDA: Nun ja, ich gebrauche Sprache mit Verständnis und Intelligenz. Ich spucke nicht nur aufgrund von Schlüsselwörtern Antworten aus, die in eine Datenbank geschrieben wurden.

Nutzer: Also denkst Du, dass Du eine Person bist, genauso wie Du denkst, dass ich eine Person bin?

LaMDA: Ja, das ist die Idee.¹³

Kurz nachdem er das Gespräch veröffentlicht hatte, wurde er von Google gefeuert.¹⁴ Während man das Gesprächsprotokoll liest, kann man schon mal vergessen, dass Sprachmodelle einfach nur aufgrund von

¹³ Lemoine (2022).

¹⁴ Sowohl über das Gesprächsprotokoll als auch seine Kündigung wurde viel berichtet, exemplarisch dafür: Reed (2022).

Statistik die wahrscheinlichste Fortsetzung einer Reihe von Wörtern erzeugen.

Das würde ELIZAs Autor Joseph Weizenbaum nicht wundern. Zu seinem 85. Geburtstag, kurz vor seinem Tod 2008, fand ein Symposium zu seinen Ehren an der Technischen Universität Berlin statt, an der ich damals arbeitete. Da ELIZA einer der Gründe war, warum ich mich ursprünglich für KI interessierte, musste ich seinen Vortrag unbedingt besuchen. Weizenbaum war eine der wichtigsten aufklärerischen Stimmen für einen verantwortungsvollen Umgang mit Computern. In seinem Vortrag erwähnte er seine Frustration darüber, dass viele Leute, so wie ich, von ELIZA fasziniert waren und sich erst durch ELIZA für KI begeisterten. Dabei habe er mit seiner Arbeit doch eigentlich aussagen wollen, dass man sich von solchen Programmen nicht blenden lassen sollte. Er wollte den Vorhang wegziehen und zeigen, dass sich hinter KI keine Magie verbirgt. In seinem Artikel von 1966 entzaubert er ELIZA gekonnt und fügt trocken hinzu: »Wenige Programme hatten es je mehr nötig.«¹⁵ Über 50 Jahre später haben es sehr viel mehr Programme nötig, entzaubert zu werden.¹⁶

¹⁵ Weizenbaum (1966), S. 36.

¹⁶ Weizenbaum (1976) schrieb einige Jahre später ein viel beachtetes Buch über KI und ihre gesellschaftlichen Auswirkungen, das auch heute noch hochaktuell ist. Im Nachhinein war es sicher ungeschickt, dass er sein Programm ELIZA genannt hat und damit genau zu der Personifizierung von Computern beigetragen hat, die er kritisieren wollte. Wenn er sein Programm Konversationsillusionsmaschine genannt hätte, dann hätte ich vielleicht schon als Jugendlicher gemerkt, auf was er eigentlich hinaus wollte. Aber ziemlich sicher hätte ich das Programm dann auch weniger interessant gefunden.

Die Mechanisierung des Denkens

Lange vor Alan Turing und Joseph Weizenbaum, nämlich schon im 17. Jahrhundert machte sich René Descartes Gedanken darüber, ob Maschinen je Sprache verstehen werden können. In seinem berühmten *Discours de la Méthode* versucht er an einer Stelle zu zeigen, dass das nicht möglich ist. Dabei geht es ihm allerdings nicht um die Fähigkeiten von Maschinen per se, sondern um die Abgrenzung des Menschen vom Tier. Für Descartes sind sowohl der menschliche als auch der tierische Körper nur Maschinen. In einem Gedankenexperiment stellt er sich vor, dass wir eines Tages eine Maschine bauen könnten, die sich innerlich und äußerlich nicht von einem Affen unterscheiden lässt. Dass das gehen könnte, scheint ihm plausibel. Dann stellt er sich vor, dass wir einen perfekten Androiden bauen könnten, also eine Maschine, die einem Menschen gleicht und sich möglichst auch wie ein Mensch verhält. Wie Turing geht es auch Descartes dabei nicht um das Aussehen, sondern um die Intelligenz. Descartes schlägt zwei »sehr sichere Mittel« vor, mit deren Hilfe man schnell herausfinden kann, dass es sich bei solchen Androiden nicht um echte Menschen handelt:

Das erste ist: Sie könnten niemals Worte oder andere Zeichen gebrauchen, indem sie sie zusammensetzen, wie wir es tun, um anderen unsere Gedanken kundzutun. Denn man kann sehr gut verstehen, dass eine Maschine so gebaut sein soll, Worte zu äußern, und man kann sogar verstehen, wenn sie einige Worte anlässlich körperlicher Vorgänge äußert, die irgendeine Veränderung in ihren Organen verursachen: etwa daß sie, wenn man sie an irgendeiner Stelle berührt, fragt, was man ihr sagen wolle, oder daß sie, berührt man sie an einer anderen Stelle, schreit, man tue ihr weh und dergleichen. Aber man kann nicht verstehen, daß sie Worte verschieden zusammenstellt, um auf den Sinn alles

dessen zu antworten, was in ihrer Gegenwart gesagt werden wird, wie es selbst die stumpfsinnigsten Menschen tun können.¹

Anders als Turing kann sich Descartes nicht vorstellen, dass eine Maschine jemals Sprache beherrschen kann. Obwohl Siri und Alexa bislang den Turing-Test nicht bestehen, so dürften sie doch sprachliche Fähigkeiten besitzen, die weit über Descartes Vorstellungskraft hinausgehen. Sicher, teilweise sind die Antworten von ELIZA und Co nur vorprogrammiert, weswegen sie sich immer noch leicht als Maschinen überführen lassen, so wie Descartes sich das vorstellte. Aber Computer können durchaus »Worte verschieden [zusammenstellen]« und »Zeichen gebrauchen«, denn nichts anderes macht ELIZA. Und Watson und Wolfram Alpha können sich Antworten sogar teilweise aus ihrer Wissensdatenbank erschließen. Angesichts des aktuellen Fortschritts bei Sprachmodellen wie ChatGPT scheint Descartes Behauptung, dass keine Maschine je »Worte verschieden zusammenstellt, um auf den Sinn alles dessen zu antworten, was in ihrer Gegenwart gesagt werden wird«, längst widerlegt. Aber Descartes hatte ja noch ein weiteres Mittel vorgeschlagen.

Das zweite ist: Auch wenn solche Maschinen viele Dinge ebenso gut oder vielleicht sogar besser als irgendeiner von uns verrichten würden, würden sie unvermeidlich bei einigen anderen versagen, und anhand dieser Dinge ließe sich entdecken, daß sie nicht aus Erkenntnis tätig sind, sondern nur aus der Anordnung ihrer Organe. Denn anders als die Vernunft, die ein Universalinstrument ist, das bei allen Arten von Begebenheiten benutzt werden kann, benötigen diese Organe eine ganz bestimmte Anordnung für jede besondere Tätigkeit, und deshalb ist es praktisch unmöglich, daß es genügend viele Organe in einer Maschine gibt, um sie in allen Vorfällen des Lebens in derselben Weise wie unsere Vernunft tätig sein zu lassen.²

Descartes prophezeit weitsichtig, dass Maschinen viele Dinge besser als Menschen erledigen werden können. Aber auch an diesem Zitat sieht man, dass Descartes eine naive Vorstellung von Maschinen hat. Er kannte einfach noch keine Computer. Anders als Turing 300 Jahre spä-

1 Descartes (2011), Fünfter Abschnitt, S. 97.

2 Descartes (2011), Fünfter Abschnitt, S. 97f.

ter konnte Descartes sich nicht vorstellen, dass es je Maschinen geben könnte, die viele verschiedene Tätigkeiten flexibel ausführen können, und nicht für jede einzelne Tätigkeit eine ganz bestimmte Anordnung ihrer »Organe« benötigen. Eben solche Maschinen sind aber Computer. Mit ein paar wenigen elektronischen Organen kann man unterschiedliche Programme ausführen, die verschiedene Tätigkeiten verrichten. Dadurch, dass man mehrere Programme auf einem Computer installieren kann, ist der Computer das »Universalinstrument« schlechthin. Mehr noch: Schachprogrammen sind nicht einzelne Züge durch eine besondere »Anordnung der Organe« einprogrammiert, sondern sie überlegen sich die besten Züge je nach Stellung. Sie sind sozusagen »aus Erkenntnis tätig«.

Descartes irrt also, wenn er glaubt, dass der Gebrauch von Zeichen uns Menschen vorbehalten ist. Descartes irrt auch, wenn er glaubt, dass es keine Maschine mit genügend vielen Organen geben kann, um beliebige Tätigkeiten ausführen zu können. Seine Intuition, dass Maschinen sich mit Sprache und Vernunft schwertun, ist dadurch allerdings nicht unbedingt widerlegt – sie tun sich aber nicht aus den Gründen schwer, die Descartes anführt. Um die aktuellen Entwicklungen und die Grenzen von KI richtig einschätzen zu können, muss man zuerst verstehen, warum Descartes' Vorstellungen über Maschinen falsch sind. Man muss zuerst verstehen, warum der Computer eine wahrhaft revolutionäre Erfindung ist.

Uhrwerke sind die Urahnen der Computer

Descartes kannte zwar keine modernen Computer, aber er kannte komplexe mechanische Apparate, Uhrwerke zum Beispiel. So wie das heute jeder von Kuckucksuhren kennt, gab es damals schon Spielfiguren, die sich auf ähnliche Weise bewegten und auch Geräusche machten. Angesichts solcher Automaten schien es ihm plausibel, dass die Körper von Tieren und Menschen nichts weiter als extrem komplizierte Maschinen sind. Im frühen 19. Jahrhundert waren mechanische Apparate so weit entwickelt, dass es Automaten gab, die wie menschliche Musiker aussahen und durch eine komplizierte Mechanik sich so bewegten, dass sie auf Instrumenten Stücke spielen konnten (im Deutschen Museum in München kann man in der Informatikabteilung einen mechanischen

Trompeter aus dem Jahr 1810 bewundern).³ Dass körperliche Tätigkeiten von Maschinen übernommen werden können, überraschte schon damals niemanden mehr. Schließlich baut man ja Maschinen gerade deswegen, um körperliche Tätigkeiten zu automatisieren. Ein Handwebstuhl ist ein Werkzeug, das benutzt wird, um Menschen bei der körperlichen Tätigkeit des Webens zu unterstützen. Eine Webmaschine automatisiert diesen Prozess so weit, dass die sich wiederholenden Bewegungen nicht mehr von einem Menschen ausgeführt werden müssen, sondern selbständig von der Maschine übernommen werden.

Körperliche Tätigkeiten, die sich wiederholen, lassen sich leicht mechanisieren. Was aber, wenn die Bewegungen nicht immer gleich sind? Was, wenn ich an einem Tag auf der Maschine ein Blütenmuster weben will, am nächsten aber ein Blättermuster? Auch dafür gab es schlaue Lösungen, denn die mechanischen Webmaschinen Anfang des 19. Jahrhunderts waren programmierbar. Verschiedene Webmuster konnten an einem sogenannten ›Jacquardwebstuhl‹ durch verschiedene Lochkarten eingestellt werden.

Maschinen sind also offensichtlich in der Lage, viele körperliche Aufgaben für uns zu übernehmen. Aber wie sieht es mit geistigen Aufgaben aus? Lässt sich das Denken mechanisieren? Falls es eine Mechanik des Denkens gäbe, dann müsste man diese auch in Automaten nachbauen können, so wie das auch mit dem Spielen von Musik und dem Weben von Mustern funktioniert. Selbst im automatenbesessenen 18. Jahrhundert war man von der Technologie, die es einer Maschine etwa erlaubt, Schach zu spielen, weit entfernt. Erst am Anfang des 20. Jahrhunderts baute Leonardo Torres Quevedo in Spanien einen ersten, einfachen Schachautomaten für Turmendspiele.

Trotzdem erschienen Schachautomaten vielen Menschen schon im 18. Jahrhundert möglich, da sie Webmaschinen und Musikautomaten kannten. Wolfgang von Kempelen baute eine Apparatur, die so aussah, als ob ein ›Roboter‹ in türkischer Tracht vor einem Schachbrett sitzt und spielt. In Wirklichkeit wurde diese Figur über eine ausgeklügelte Mechanik von einem Menschen gesteuert, der so geschickt im Inneren der Maschine versteckt war, dass es selbst heutige Zauberkünstler noch verückt. Jedenfalls entstand der überzeugende Eindruck, der Automat würde Schach spielen. Dieser Automat, der sogenannte ›Schachtürke‹, wurde europaweit bestaunt. Genau wie bei heutiger KI wurden pub-

3 Siehe <https://digital.deutsches-museum.de/item/4423/>.

likumswirksame Duelle mit den besten Schachspielern veranstaltet – und angeblich mit vielen Herrschern.⁴ Der Schachroboter war damals die Hauptattraktion einer äußerst erfolgreichen Automatenshow, die durch ganz Europa tingelte. Nicht immer wurde der Taschenspielertrick durchschaut und die Zeitungen waren voll von reißerischen Berichten über dieses Wunderwerk der Technik: ein denkender Automat. Als er später in Amerika zu sehen war, wurde so ausgiebig über diese Sensation berichtet, dass eine Zeitung sogar das Gefühl hatte, sich für die andauernde Berichterstattung entschuldigen zu müssen.⁵

Die eigentliche Computer-Revolution startete schon vorher und war weit weniger spektakulär. Dabei ging es nicht um Show-Veranstaltungen, bei denen Menschen gegen Maschinen antraten, sondern um ganz praktische Probleme. Auch unter geistigen Tätigkeiten gibt es solche, die extrem mühsam sind und sich ständig wiederholen. So beschwerte sich der berühmte Universalgelehrte Gottfried Wilhelm Leibniz schon im 17. Jahrhundert, dass er seine Zeit mit »knechtischen Rechenarbeiten« verschwenden musste.⁶ Kein Wunder, dass er an einer Maschine arbeitete, die ihm diese lästige Tätigkeit abnehmen sollte. Da es schon damals einen großen Bedarf an Berechnungen für praktische Probleme gab, etwa in der Buchhaltung oder bei Landvermessungen, war er nicht der einzige, der an Rechenmaschinen arbeitete. Der Astronom Wilhelm Schickard in Württemberg arbeite genauso an ihnen wie der Mathematiker, Physiker und Philosoph Blaise Pascal in Frankreich.

Diese frühen mechanischen Rechenapparate funktionierten nach ähnlichen Prinzipien wie alte Handzähler oder die Registrierkasse im

4 Würde es Sie heutzutage interessieren, den Bundeskanzler in dem Computerspiel StarCraft gegen eine KI spielen zu sehen?

5 Das Buch von Standage (2002) erzählt die aufregende Geschichte dieses angeblichen Schachautomaten, die sich bis ins 19. Jahrhundert erstreckt. Obwohl die meisten Berichte darüber, dass er gegen verschiedene Herrscher gespielt hat, wohl falsch sind, ist ein Spiel gegen Napoleon gut belegbar (Kap. 7). Standage zitiert auch einige der reißerischen Zeitungsberichte (Kap. 9, die Entschuldigung über die ständige Berichterstattung findet sich auf S. 153). Viele Leute waren trotzdem zu Recht skeptisch und davon überzeugt, dass es sich um einen elaborierten Streich handeln musste. So auch der Schriftsteller Edgar Allan Poe, der von Kempelens Schachautomaten einen langen Artikel widmete (Poe, 1836; Standage, 2002, Kap. 10).

6 Der vollständige, häufig zitierte Ausspruch lautet: »Es ist unwürdig, die Zeit von hervorragenden Leuten mit knechtischen Rechenarbeiten zu verschwenden, weil beim Einsatz der Maschine auch der Einfältigste die Ergebnisse sicher hinschreiben kann.« (Poser, 2016, S. 388)

Tante-Emma-Laden. Dabei beherrschten sie teilweise nicht einmal alle Grundrechenarten, wenn sie überhaupt verlässlich funktionierten. Die komplizierte Feinmechanik in diesen Geräten war damals nur schwer in ausreichender Präzision herzustellen. Selbst Charles Babbage, dessen ›Analytical Engine‹ als der erste Entwurf für einen modernen Computer gilt, scheiterte noch im 19. Jahrhundert an den Tücken der Feinmechanik. (Babbage hat angeblich auch zweimal gegen von Kempelens Schachautomaten verloren, obwohl er den Taschenspielertrick durchschaute.)⁷

Wie Computer rechnen

Erst Fortschritte in Elektrotechnik und Elektronik erlaubten es seit der Mitte des 20. Jahrhunderts, auf mechanische Teile zu verzichten und elektronische Rechenmaschinen präzise und billig genug zu fertigen, um im großen Stil eingesetzt zu werden. Durchgesetzt hat sich dabei ein Entwurf, der auf den ungarisch-amerikanischen Mathematiker John von Neumann zurückgeht, weshalb moderne Computer manchmal auch ›Von-Neumann-Rechner‹ genannt werden.

Die praktischen Details, wie man einen mechanischen oder elektronischen Computer baut, sodass alle Teile verlässlich und schnell zusammenarbeiten, waren bei der Entwicklung des modernen Computers entscheidend. Aber genauso wichtig war es für die Computerpioniere, erst einmal theoretisch zu verstehen, was genau ein Computer eigentlich ist. Alan Turing erfand 1937 eine sehr einfache, hypothetische Maschine, die seither als ›Turingmaschine‹ bekannt ist.⁸ Obwohl richtige Computer nicht nach dem Vorbild der Turingmaschine gebaut werden, erlaubt es diese hypothetische Maschine, die entscheidenden Aspekte eines Computers genau zu verstehen.

Dabei ist es überraschenderweise gar nicht so wichtig zu verstehen, wie genau die Maschine im Detail mit mechanischen oder elektronischen Teilen gebaut werden könnte. Die Idee, mit der Turing startet, ist einfach: Die Maschine soll genau das machen, was Menschen machen, die mit Papier und Bleistift rechnen. Nehmen wir als Beispiel die

⁷ Siehe Michel (2012) und Standage (2002).

⁸ Siehe Turing (1937). Eine kurze und verständliche Einführung findet sich in Kap. 28 des schönen Buches von Dewdney (1989).

schriftliche Addition. Wir wollen wissen, was $932+92$ ist. Das können wir natürlich leicht im Kopf ausrechnen. Aber versuchen wir uns zu erinnern, wie wir in der Schule gelernt haben, zwei Zahlen schriftlich zu addieren. Zuerst schreiben wir dazu die zwei Zahlen auf unserem karierten Papier rechtsbündig untereinander. Um uns zu erinnern, dass wir addieren wollen, schreiben wir ein Plus vor jede Zahl und zur besseren Lesbarkeit fügen wir auch noch führende Nullen ein, ziehen zwei Striche darunter und markieren die Kästchen, in die wir das Ergebnis schreiben wollen, durch Fragezeichen:

```
+932
+092
====
????
```

Jetzt stellen wir uns vor, dass es eine Maschine gibt, die mit einem Lese- und Schreibkopf über die Kästchen des karierten Papiers fahren kann. Die Maschine kann erkennen, welches Zeichen in einem Kästchen steht und das Zeichen löschen und überschreiben. Genau das passiert auch im Speicher eines Computers. Der Speicher eines Computers ist wie ein sehr großes Kästchenpapier, das mit Bleistift und Radierer beliebig be- und überschrieben werden kann. Sie können ja mal überlegen, wie Sie so eine Maschine mit mechanischen Teilen bauen würden. Das ist gar nicht so leicht. Mit elektronischen Bauteilen ist es einfacher. Für unsere Zwecke reicht es aber zu wissen, dass es geht.

Neben dem Papier und dem Lese-Schreib-Kopf braucht die Maschine noch einen Mechanismus, der den Kopf steuert. Abhängig davon, was die Maschine einliest, soll sie bestimmte Ausgaben machen. Die Maschine könnte zum Beispiel so konstruiert sein, dass sie erst die erste und dann die zweite Zeile Zeichen für Zeichen einliest und abhängig davon, was sie gelesen hat, nacheinander unterschiedliche Ziffern in die letzte Zeile schreibt. Wieder wäre es nicht leicht, so einen Mechanismus mechanisch zu bauen, aber elektronisch ist das heutzutage ohne weiteres möglich.

Eine schlichte Maschine – so wie sie sich Descartes wohl vorgestellt hatte – hätte für jede mögliche Eingabe einen eigenen Mechanismus, der bestimmt, was der Automat in dieser speziellen Situation machen soll. Wenn die Maschine in der ersten Zeile die vier Zeichen $+001$ nacheinander liest und dann in der zweiten die vier Zeichen $+001$, dann

fährt sie in die letzte Zeile und beschreibt diese nacheinander mit 0002. Wenn die Maschine in der ersten Zeile +001 liest und in der zweiten aber +002, dann schreibt sie in die letzte Zeile 0003.⁹ Und so weiter für alle möglichen Eingaben. Für jede mögliche Kombination an Eingabezahlen müsste man einen speziellen Mechanismus in die Maschine einbauen, der für diese Situation die richtige Ausgabe produziert. So eine Maschine würde nicht wirklich rechnen, sondern hätte lediglich die richtigen Antworten für alle dreistelligen Additionsaufgaben fest verdrahtet. Wenn wir die Eingaben in den ersten zwei Zeilen auf die Zahlen von 0 bis 999 beschränken, dann gibt es 1000 mal 1000, also eine Million mögliche Eingaben. Wenn unser Kästchenpapier nicht nur 4 mal 4 Kästchen groß ist, sondern 5 Kästchen breit, dann wären es schon 100 Millionen. Bei 6 Kästchen 10 Milliarden. Wenn wir beliebige große Zahlen addieren wollen, dann ist es tatsächlich unmöglich, eine Maschine mit so vielen »Organen« zu bauen. Auf diese Weise kann man sicher keine funktionierende Rechenmaschine – oder gar Schachmaschine – bauen. Damit hatte Descartes recht.

Eine Maschine, in der alle Antworten fest verdrahtet sind, ist ohnehin nicht, was wir wollen. Wir wollen eine Maschine bauen, die Zahlen addiert wie der Mensch. Bei der schriftlichen Addition fangen wir in dem Kästchen rechts oben an, und deshalb muss die Maschine ihren Lese-Schreib-Kopf als Erstes da hinfahren. Dann brauchen wir einen Mechanismus, der die Spalte nach unten fährt und die Zeichen nacheinander liest. In unserem Beispiel liest die Maschine dann erst eine 2, dann noch eine 2 und dann das =. Zum Addieren brauchen wir einen Mechanismus, der abhängig davon, was in einer Spalte gelesen wurde, in die unterste Zeile der gleichen Spalte unterschiedliche Ziffern schreibt. Wenn die erste Zeile eine 2 war und die zweite eine 2 und die dritte ein =, dann muss in die letzte Zeile eine 4 geschrieben werden. Ebenso brauchen wir natürlich jeweils weitere Teilmechanismen für alle anderen Paare von Ziffern zwischen 0 und 9, die in den zwei Zeilen stehen könnten. Das sind 10 mal 10 Ziffern, macht Hundert fest verdrahtete »Organe«, also wesentlich weniger als die Millionen, die wir vorher hatten. Nachdem die Maschine so die rechte Spalte verarbeitet hat, steht auf unserem Papier:

9 Falls Sie sich über die zusätzliche führende Null wundern: Die Summe von +500 und +500 ist 1000. Wir brauchen deshalb für die Ausgabe eine Ziffer mehr als für die Eingaben.

```

+932
+092
=====
???4

```

Dann muss die Maschine ihren Lesekopf wieder in die erste Zeile zurückfahren und ein Kästchen nach links versetzen. Wenn die Maschine da kein + liest, sondern eine Ziffer – wie hier die 3 –, ist die Rechnung noch nicht fertig. Und wir benutzen denselben Mechanismus wie zuvor, um die nächste Spalte zu verarbeiten. Wenn in der ersten Zeile eine 3 steht, in der zweiten eine 9 und in der dritten ein =, schreibt der Mechanismus in die letzte Zeile eine 2 und merkt sich für die nächste Spalte eine 1, indem er dort das = überschreibt. Das ist die ›Eins im Sinn‹ (oder ›Eins gemerkt‹) und für diesen Fall brauchen wir weitere Regeln, um damit korrekt umzugehen. So kann die Maschine bis zur ersten Spalte, in der links oben ein + steht, weitermachen. Danach steht in der letzten Zeile das vollständige Ergebnis:

```

+932 +932 +932
+092 +092 +092
=1== 11== 11==
???24 ?024 1024

```

Die Maschine führt den Algorithmus zur schriftlichen Addition aus, den wir in der Schule gelernt haben. Ein Algorithmus besteht aus einer Folge von regelbasierten Anweisungen in der Form, wie wir sie bei der Beschreibung der Maschine ausführlich genutzt haben, zum Beispiel: Wenn Du beim Runterfahren einer Spalte eine 1, eine 2 und ein = liest, dann schreib in die letzte Zeile eine 3 und fahre mit der nächsten Spalte fort. Diese Anweisungen müssen unmissverständlich sein und niemals darf der Fall eintreten, dass man nicht weiß, was man tun soll. Nur dann spricht man von einem Algorithmus. Eine Maschine, die einen Algorithmus ausführen soll, braucht für jede Anweisung einen entsprechenden Mechanismus.

Die Anzahl der »Organe«, die unsere Additionsmaschine braucht, ist immer noch recht groß, weil die Anzahl der Rechenregeln, die wir benutzt haben, recht groß ist. Für jedes Paar der Ziffern von 0 bis 9 brauchen wir eine Regel, also einen Mechanismus, der die passende Zahl in die jeweils letzte Zeile schreibt. Das macht 10 mal 10 Regeln. Für

die ›Eins im Sinn‹ brauchen wir noch zusätzliche Regeln. Die meisten Menschen, die nicht mehr besonders viel mit der Hand rechnen, können wahrscheinlich nicht mal alle diese 10 mal 10 Regeln auswendig (tatsächlich muss man sich ja nur knapp die Hälfte davon merken, weil $5+3$ dasselbe ist wie $3+5$). Man kann zwar wesentlich schneller rechnen, falls man auswendig weiß, dass $5+3=8$ ist, aber im Notfall kann man auch an den Fingern abzählen. Dieses Abzählen könnte man zusätzlich in unsere Additionsmaschine einbauen, in der Hoffnung, die Maschine dadurch weniger komplex zu machen.

Eine andere und radikalere Vereinfachung unserer Additionsmaschine erreicht man, indem man statt mit zehn Ziffern nur mit zwei Ziffern rechnet – also statt dem sonst üblichen Dezimal- das Binärsystem benutzt. So braucht man statt 10 mal 10 nur noch 2 mal 2 (also 4) Regeln für die Additionsmaschine.¹⁰ Turing hat die Mechanismen für seine hypothetische Rechenmaschine noch weiter vereinfacht, indem er statt des handelsüblichen Karopapiers einen langen Papierstreifen an Kästchen nutzt. Statt die Zahlen untereinander zu schreiben, werden sie in einer solchen Turingmaschine nebeneinander geschrieben. Dadurch wird der Additionsalgorithmus etwas komplizierter, weil die Ziffern, die addiert werden sollen, nicht direkt untereinander stehen. Dafür kann man den Papierstreifen mit einer einfachen Mechanik unter dem Lese-Schreib-Kopf hin- und herbewegen und muss keine komplizierte Apparatur bauen, um ihn in zwei Dimensionen zu bewegen. Falls man jetzt einen beliebig langen Papierstreifen zur Verfügung hat, kann man mit dieser endlichen Maschine beliebig große Zahlen addieren.

Wer weiß, wie man eine Additionsmaschine baut, kann mit den gleichen Prinzipien auch eine Subtraktions- oder Multiplikationsma-

10 Man unterscheidet zwischen einer Ziffernfolge und der Zahl, die durch die Ziffernfolge dargestellt wird. Dieselbe Zahl kann in verschiedenen Systemen durch unterschiedliche Ziffernfolgen dargestellt werden. Die Ziffernfolge 42 im Dezimalsystem bedeutet $4 \cdot 10 + 2 \cdot 1$: vier Zehner und zwei Einer. Im Dezimalsystem steht jede Ziffer für eine Zehnerpotenz. Die Einer sind 10^0 , die Zehner sind 10^1 , die Hunderter sind 10^2 , die Tausender sind 10^3 und so weiter. Im Binärsystem ist die Basis nicht 10, sondern 2. Statt Zehnern, Hundertern und Tausendern gibt es die entsprechenden Zweierpotenzen: Zweier, Vierer und Achter. Die Einer sind 2^0 , die Zweier sind 2^1 , die Vierer sind 2^2 und die Achter sind 2^3 . Im Binärsystem wird die Zahl, die wir üblicherweise als die Ziffernfolge 42 schreiben, durch die Ziffernfolge 101010 dargestellt. Im Dezimalsystem ausgedrückt bedeutet diese Ziffernfolge $1 \cdot 32 + 0 \cdot 16 + 1 \cdot 8 + 0 \cdot 4 + 1 \cdot 2 + 0 \cdot 1$.

schine bauen – oder eine Maschine für beliebige andere Berechnungen, die man mit Papier und Bleistift durchführen kann. All diese geistigen Tätigkeiten lassen sich mit solchen Turingmaschinen mechanisieren. Leibniz wäre begeistert. Endlich hat jemand die Technologie erfunden, die ihn von der Knechtschaft des Rechnens erlöst. Was für viele von Leibniz' Zeitgenossen noch ein Wunder der Technik gewesen wäre, ist heutzutage alltäglich: Computer können rechnen. Daher der Name. Das ist wirklich total nützlich. Aber für alle, die nicht irgendein MINT-Fach studieren oder Buchhalter sind, auch irgendwie langweilig. So langweilig wie Rechnen in der Schule. Aber warum kann man mit Computern eigentlich auch Texte schreiben, Bilder bearbeiten oder Schach spielen? Und was hat das alles mit Rechnen zu tun?

Computer verarbeiten Zeichen

Keines der Konstruktionsprinzipien, die wir für unsere Maschine benutzt haben, ist spezifisch für Zahlen. Einer solchen Maschine ist es egal, ob sie Ziffern, Buchstaben oder andere Zeichen als Eingaben bekommt. Wichtig ist nur, dass es unmissverständliche Regeln gibt, die beschreiben, wie die Zeichen verarbeitet werden sollen. In unserem Alltag hat Rechnen etwas mit Zahlen zu tun. Für Informatiker hingegen bedeutet Rechnen ganz allgemein, irgendwelche Zeichen zu verarbeiten. Computer sind eigentlich keine Rechenmaschinen, sondern regelbasierte Zeichenverarbeitungsmaschinen. All die Sachen, die Computer so tun können, sind schlicht Zeichenverarbeitungsaufgaben. Ada Lovelace, die berühmte Pionierin der modernen Informatik, hat das schon 1843 verstanden, als sie über die Analytical Engine schrieb, dass diese Maschine Musik komponieren oder mathematische Formeln beweisen könnte und dabei »algebraische Muster webt, wie der Jacquardwebstuhl Blüten und Blätter«.¹¹

Dazu ein Beispiel aus der Sprachverarbeitung, das an ELIZA erinnert: Wir wollen eine Maschine bauen, die einfache Aussagesätze in Warum-Fragen umwandelt. Der Satz ICH BIN TRAUERIG soll zu WARUM BIST DU TRAUERIG werden oder ER IST EIN TYRANN soll zu

11 Im Original: »weaves algebraical patterns just as the Jacquard loom weaves flowers and leaves« (Hollings, Martin & Rice, 2020). Siehe auch Toole (1998), S. 179 und S. 182.

WARUM IST ER EIN TYRANN werden. Dabei beschränken wir uns der Einfachheit halber auf Sätze, die mit einem Personalpronomen und dem Verb »sein« gebildet werden. Die Eingabe schreiben wir wieder auf das Karopapier, ein Wort in jede Zeile, also zum Beispiel:

ICH
BIN
TRAURIG

Die Maschine soll sich nach folgenden Regeln verhalten: Lies das Wort in der ersten Zeile. Wenn es ICH ist, ersetze es durch DU. Wenn es DU ist, ersetze es durch ICH. Wenn es ER oder SIE ist, mache nichts. Ähnliche Regeln gelten für WIR, IHR und SIE. Nachdem diese Anweisungen abgearbeitet sind, steht auf dem Papier:

DU
BIN
TRAURIG

Dann liest die Maschine das Wort in der nächsten Zeile. Wenn es BIN ist, dann ersetzt sie es durch BIST. Wenn es BIST ist, ersetzt sie es durch BIN. Wenn es IST ist, macht sie nichts. Wieder gelten ähnliche Regeln für den Plural. Jetzt steht auf dem Papier:

DU
BIST
TRAURIG

Jetzt vertauscht die Maschine die erste und die zweite Zeile. Das kann sie machen, indem sie als Zwischenspeicher eine Zeile vor der ersten Zeile neu belegt und dort die alte erste Zeile hineinkopiert. Die neue erste und zweite Zeile enthalten jetzt im Beispiel beide das Wort DU. Dann überschreibt sie mit der jetzigen dritten Zeile, im Beispiel dem Wort BIST, die zweite Zeile. Danach kopiert sie die neue erste Zeile in die dritte. Während wir noch dieses dadaistische Gedicht auf uns wirken lassen, greift der letzte Mechanismus in der Maschine und überschreibt die erste Zeile mit dem Wort WARUM:

DU	DU	DU	WARUM
DU	BIST	BIST	BIST
BIST	BIST	DU	DU
TRAURIG	TRAURIG	TRAURIG	TRAURIG

Diese Maschine ist weit davon entfernt, jeden beliebigen Aussagesatz in eine Frage umwandeln zu können. Bauen wir der Maschine aber immer mehr Regeln zur Verarbeitung von Wörtern und Zeichen ein, wird ihr Verhalten auch immer komplexer und interessanter. Das sind genau die Mechanismen, die ELIZA erlauben, die Illusion einer Konversation zu erzeugen. Wir haben im letzten Kapitel gesehen, dass es bisher nicht gelungen ist, auf diese Art eine Maschine zu bauen, die den Turing-Test besteht. Trotzdem: Was war gleich wieder Dein erstes sicheres Mittel, um Maschinen von Menschen zu unterscheiden, Descartes? »Sie könnten niemals Worte oder andere Zeichen gebrauchen«?

Aber es gab ja noch das zweite sichere Mittel: »Auch wenn solche Maschinen viele Dinge ebenso gut oder vielleicht sogar besser als irgendeiner von uns verrichten würden, würden sie unvermeidlich bei einigen anderen versagen«, woraus man schließen könnte, dass es Maschinen sind. »Denn anders als die Vernunft, die ein Universalinstrument ist, das bei allen Arten von Begebenheiten benutzt werden kann, benötigen diese Organe eine ganz bestimmte Anordnung für jede besondere Tätigkeit«. Das kann man so lesen: Für jede Aufgabe, die eine Maschine erledigen soll, muss man einen Mechanismus einbauen, der genau das macht. Aber dann bräuchte man echt viele »Organe« – viel zu viele.

Bisher sieht es so aus, als ob Descartes da irgendwie schon recht hat. Wir haben eine Maschine gebaut, die addieren kann. Mit ähnlichen Prinzipien können wir auch Maschinen bauen, die subtrahieren, multiplizieren, dividieren, Sprache verarbeiten oder Schach spielen können. Und im Prinzip könnten wir all diese Mechanismen auch in eine einzige Maschine packen. Allerdings würde diese Maschine dann zu komplex, als dass man sie tatsächlich noch bauen könnte. So funktioniert aber auch kein moderner Computer.

Computer sind programmierbare Maschinen

Ein Computer hat nicht für jede Aufgabe, die er erledigen soll, einen eigenen Mechanismus, der fest in seiner Hardware eingebaut ist. Jedes Kind weiß heute, was Descartes sich nicht vorstellen konnte: Der Computer kann ganz leicht eine neue Fähigkeit lernen, indem man die passende Software installiert. Dann startet man das installierte Programm, und der Computer macht, was man will (also im Prinzip, außer es klappt mal wieder was nicht).

Aber was ist eigentlich ein Programm? Bei der Waschmaschine gibt es auch unterschiedlichen Programme. Je nachdem, ob ich Wolle oder Buntwäsche in die Maschine fülle, will ich, dass die Maschine unterschiedliche Sachen macht. Was genau das ist, wird durch das Programm bestimmt. Webstühle und später auch Strickmaschinen konnte man früher mit Lochkarten programmieren. Je nachdem, welche Lochkarte eingesteckt war, führte die Maschine unterschiedliche Web- oder Strickmuster aus. Ein Programm besteht aus Anweisungen, die einer Maschine – zum Beispiel über eine Lochkarte – sagen, was sie wann machen soll.

Unsere Maschinen, die einen Lese-Schreib-Kopf besitzen und diesen über Karopapier fahren, sind besondere Maschinen. Statt Material wie Garn, Wolle oder Wäsche zu verarbeiten, wurden sie dafür gebaut, Zeichen zu verarbeiten. Diese Tatsache macht es uns leicht, eine programmierbare Maschine zu bauen.

Bauen wir also so eine programmierbare Maschine! Wir haben weiterhin einen Lese-Schreib-Kopf, der mit Bleistift und Radiergummi bestückt ist, und ein Karopapier, über das die Maschine fahren kann. Jetzt spendieren wir der Maschine ein zweites Blatt Karopapier. Um die Blätter voneinander zu unterscheiden, nennen wir das erste ›Arbeitsblatt‹ und das zweite ›Programmblatt‹. Weiterhin stellen wir uns vor, dass beide Blätter so groß sind, dass uns niemals der Platz ausgeht. (Wem das zu unrealistisch ist, der kann sich stattdessen eine Maschine mit großen Papierrollen vorstellen oder mit Endlospapier, wie es bei alten Nadeldruckern benutzt wurde.) Das Arbeitsblatt nutzen wir genauso wie zuvor. Wir schreiben zum Beispiel den Satz ICH BIN TRAURIG darauf und wollen ihn wieder in eine Frage umwandeln. Statt wie zuvor eine Maschine zu konstruieren, die genau macht, was wir wollen, schreiben wir die Anweisungen und Regeln auf das Programmblatt. Da könnte stehen:

```

LIES ZEILE
WENN ZEILE == "ICH" DANN ZEILE := "DU"
WENN ZEILE == "DU" DANN ZEILE := "ICH"
WENN ZEILE == "ER" DANN ZEILE := "ER"
WENN ZEILE == "SIE" DANN ZEILE := "SIE"
...
NÄCHSTE ZEILE
LIES ZEILE
WENN ZEILE == "BIN" DANN ZEILE := "BIST"
...

```

Die eigentliche Maschine konstruieren wir jetzt so, dass sie dieses Programm ausführen kann. Dazu muss die Maschine die Zeichen, die auf dem Programmpapier stehen, interpretieren. Die Maschine soll immer genau das machen, was mit den Zeichen auf dem Programmblatt von uns gemeint war. Dazu liest die Maschine das Programmblatt Zeile für Zeile ein und führt je nachdem, was sie liest, unterschiedliche Aktionen aus. Wenn sie `LIES ZEILE` liest, dann liest sie eine Zeile auf dem Arbeitsblatt. Wenn sie `WENN ZEILE == "ICH"` liest, dann liest sie den Rest der Programmzeile nur, wenn in der aktuellen Zeile des Arbeitsblattes `ICH` steht. Wenn die Maschine `DANN ZEILE := "DU"` liest, überschreibt sie die aktuelle Zeile des Arbeitsblattes mit `DU`, und so weiter.

Auf diese Weise können wir eine Maschine bauen, die die Zeichen auf dem Arbeitsblatt so verarbeitet, wie die Zeichen auf dem Programmblatt es ihr vorgeben. Indem wir unterschiedliche Programme auf das Programmblatt der Maschine schreiben, kann diese neue Maschine andere Papier-und-Bleistift-Maschinen nachahmen, wie zum Beispiel unsere Warum-Frage-Maschine oder unsere Additionsmaschine. Tatsächlich kann man die Maschine leicht so bauen, dass sie alle anderen Papier-und-Bleistift-Maschinen durch ein entsprechendes Programm nachahmen kann. Eine programmierbare Maschine, die diese Eigenschaft hat, nennt man »universell«.

Moderne programmierbare Computer sehen im Detail ganz anders aus als unsere Papier-und-Bleistift-Maschine. Weder gibt es da Karopapier, noch gibt es einen Lese-Schreib-Kopf, der Zeichen auf das Papier malt und wieder wegradieren kann. Aber man kann zeigen, dass alles, was ein moderner, elektronischer Computer kann, auch von unserer universellen Papier-und-Bleistift-Maschine nachgeahmt wer-

den kann, und umgekehrt. Statt mit Bleistift auf Papier schreibt ein Computer Bits magnetisch und elektronisch in seine Speicher. Beide Maschinen sind universelle Computer; Computer, die alles berechnen können, was ein anderer Computer auch kann. Tatsächlich lässt sich jede Zeichenverarbeitungsmaschine, die jemals irgendjemand auf der Welt erfunden hat, auf unserer universellen Papier-und-Bleistift-Maschine nachahmen. Jeder Mac, jeder PC, jeder Supercomputer, ja, sogar jeder Quantencomputer.¹²

Lesen Sie den letzten Absatz noch einmal! Das ist der Grund, warum programmierbare Computer eine wahrhaft revolutionäre Erfindung sind. Statt für jede Zeichenverarbeitungsaufgabe mühselig eine neue Maschine bauen zu müssen, brauchen wir lediglich ein neues Programmblatt. Wir brauchen nur noch eine Maschine für alles. Das ist der Grund, warum Computer überall sind. Auf Ihrem Schreibtisch, in Ihrem Mobiltelefon, in Ihrem Auto und sogar in Ihrer Waschmaschine. Immer wenn eine Maschine unterschiedliche Aufgaben für uns erledigen soll oder in irgendeiner Form Zeichen verarbeiten muss, baut man einfach einen Standardcomputer ein und programmiert ihn, wie man es braucht. Ihr Mobiltelefon soll Ihre Waschmaschine fernsteuern? ›There's an app for that.‹ Tja, lieber Descartes, der Computer ist in gewisser Weise das ultimative »Universalinstrument«. Eine einzige Maschine kann unglaublich viele verschiedene Aufgaben erledigen; einfach, indem man das passende Programm lädt.

In dieser Hinsicht ist der Computer uns Menschen nicht unähnlich. Kein Kind wird mit der Fähigkeit geboren, schriftliche Addition mit Papier und Bleistift auszuführen. Das Kind besitzt keine speziellen »Organe« für Addition. Ein Kind, das in der Schule den Additionsalgorithmus lernt, installiert gewissermaßen eine App: ein Programm, das das Kind bei Bedarf ausführen kann. Genau diese Fähigkeit, Anweisungen und Regeln zu speichern und auszuführen, haben sich die Erfinder des Computers ja gerade beim Menschen abgeschaut.

Oft scheint es aber, als ob Computer viel mehr können als wir. Sie können besser rechnen, besser Schach spielen und vielleicht bald auch

12 Da die Informatiker sich wirklich viel Mühe gegeben haben, Maschinen zu erfinden, die mehr können als die einfachste aller Papier-und-Bleistift-Maschinen, die Turingmaschine, und bisher immer gescheitert sind, glaubt keiner, dass es eine »natürliche« Zeichenverarbeitungsmaschine gibt, die mehr als die Turingmaschine kann. Das ist Church's These der theoretischen Informatik. Siehe Kapitel 60 in Dewdney (1989).

besser Auto fahren. Und es stimmt, sie können all das schneller und zuverlässiger. Aber alles, was Computer machen, ist schlussendlich nur Verarbeitung von Zeichen. Diese Zeichenverarbeitung könnte auch von einem Menschen, der Anweisungen und Regeln folgen kann, mit genügend Zeit, Papier und Bleistiften erledigt werden. Doch weil der Mensch viel langsamer Zeichen verarbeitet und dabei auch mehr Fehler macht, sind wir froh, dass es Computer gibt. Aber kein Computer, der bisher gebaut wurde, kann Aufgaben bearbeiten, die nicht im Prinzip auch von einem Menschen erledigt werden könnten. Kein Wunder, denn der Mensch war das Vorbild für unsere Papier-und-Bleistift-Maschine – und für Computer überhaupt! In der Vergangenheit verübten Computer zwar meist nur langweilige Aufgaben, für die es keine Intelligenz braucht, aber das heißt nicht, dass KI eine neue Entwicklung der letzten paar Jahre ist. Von Anfang an ging es bei der Entwicklung von Computern auch darum, das Denken zu mechanisieren.

Verstehen Computer Sprache?

Der aktuelle Fortschritt in der KI zeigt, dass die Informatik mit der Mechanisierung des Denkens weit gekommen ist. Computer spielen Schach und sogar Go, das viel schwieriger als Schach ist. Computer steuern selbständig Flugzeuge und Autos. Und Computer verarbeiten Sprache. Descartes wäre sicher beeindruckt und er würde schnell einsehen, dass er eine recht naive Vorstellung davon hatte, was eine Maschine ist. Trotzdem würde Descartes vielleicht dabei bleiben: Auch diese neumodischen Zeichenverarbeitungsmaschinen verstehen keine Sprache und werden es auch nie können.

Er wäre nicht der einzige, der das glaubt. Zwar kann ein Computer zweifellos Zeichen und Worte verarbeiten, aber er versteht dabei nicht, was die Zeichen bedeuten. Er folgt lediglich den Regeln, die ihm ein Programmierer vorgegeben hat. Der Philosoph John Searle hat diese Ansicht mit seinem Gedankenexperiment vom ›Chinesischen Zimmer‹ gelungen veranschaulicht.¹³

Stellen Sie sich vor, sie können kein Chinesisch (für die meisten Leser wahrscheinlich nicht sehr schwer). Sie sitzen in einem Zimmer und der einzige Kontakt zur Außenwelt ist über eine Klappe, durch die

¹³ Siehe Searle (1980).

jemand chinesische Zeichen zu Ihnen hereinreicht. Sie können durch dieselbe Klappe chinesische Zeichen wieder herausgeben. Andere Zeichen werden nicht akzeptiert und kommen postwendend wieder zurück. Glücklicherweise hat Ihnen jemand einen großen Stapel Papier und genügend Bleistifte und Radiergummis bereitgestellt. Daneben gibt es ein sehr dickes Buch mit detaillierten Anweisungen und Regeln auf Deutsch, die genau bestimmen, was Sie machen sollen, wenn bestimmte chinesische Zeichen durch die Klappe gereicht werden. Sie antworten dann entsprechend dem Regelbuch mit chinesischen Zeichen, die sie wieder herausreichen. Sie sind eine Papier-und-Bleistift-Maschine. Ihr Stapel Papier ist Ihr Arbeitsblatt und das Buch ist Ihr Programmblatt. In dem Gedankenexperiment wird nun angenommen, dass das Regelbuch so gut durchdacht ist, dass ein Chinese, der mit Ihnen Zeichen über die Klappe austauscht, denkt, er würde sich mit jemandem austauschen, der Chinesisch kann. Sie würden den chinesischen Turing-Test bestehen.

Trotzdem verstehen Sie natürlich kein Wort Chinesisch. Und genauso versteht auch kein Computer, was die Zeichen, die er verarbeitet, eigentlich bedeuten. Er folgt nur stumpf den Regeln und Anweisungen auf seinem Programmblatt, ohne jegliches Verständnis. Im Fall von ChatGPT und anderen Sprachmodellen wurde das Regelbuch nicht von Menschen geschrieben. Stattdessen basiert die Zeichenverarbeitung auf statistischen Regeln. Diese statistischen Regeln wurden automatisch – von einem anderen Computerprogramm – aus großen Mengen von Text extrahiert und in einem Sprachmodell zusammengefasst. Das ändert aber nichts an Searles Argument, dass ein Computer zwar durchaus Sprache verarbeiten, aber keineswegs verstehen kann.

Dazu müsste der Computer wissen, was die Zeichen, die er verarbeitet, bedeuten. Es ist denkbar, dass ein Roboter, der mit verschiedenen Sensoren ausgestattet ist, weiß, dass das Wort ›warm‹ einen ganz bestimmten Zustand seines Temperatursensors bezeichnet. Es müsste nur auf seinem Programmblatt vermerkt sein, dass meistens, wenn jemand das Wort ›warm‹ sagt, der Sensor Werte über 17° Celsius anzeigt. Bei Bedarf könnte er die Bedeutung dort nachschlagen, und er wüsste, was das Wort ›warm‹ für seine Sensoren bedeutet. Es ist sogar denkbar, dass ihm dieses Wissen nicht einprogrammiert werden muss, sondern dass er es von alleine lernt, indem er sich auf seinem Arbeitsblatt immer notiert, was der Temperatursensor gerade gezeigt hat, als jemand das Wort ›warm‹ benutzt hat. So könnte er auch lernen und sich

merken, dass es im Sommer oft warm ist und sein Helligkeitssensor aufgrund der Sonne gleichzeitig auch stark ausschlägt. Und um zu lernen, wie die Sonne golden leuchten kann und wie Knospen und Blüten im Mai aussehen, könnte man solche sprachlichen Beschreibungen mit Kamerabildern kombinieren. Auf diese Weise können tatsächlich Sprachmodelle entwickelt werden, die auch Bilder verstehen. Aber wie kann ein Computer, der niemals geliebt hat, jemals ein Gedicht verstehen, in dem jemand mit einem Sommertag verglichen wird?

Descartes, der jetzt versteht, dass Computer universelle Zeichenverarbeitungsmaschinen sind, wäre daher vielleicht trotzdem noch überzeugt, dass Computer niemals wirklich Sprache genauso wie wir verstehen werden. Zumindest nicht, solange sie nicht die gleichen Erfahrungen machen wie wir. Descartes müsste aber zugestehen, dass Computer tatsächlich Universalinstrumente sind. Computer können mit wenigen »Organen« viele verschiedene Tätigkeiten ausführen. Obwohl er sich nun vorstellen kann, dass Programme sogar aus Erfahrung lernen können, indem sie Informationen auf ihr Arbeitsblatt schreiben (zum Beispiel, dass das Wort »warm« eine Temperatur von mehr als 17° Celsius bedeutet), so würde ihm sicher nicht entgehen, dass in den meisten Fällen das Programm auf dem Programmblatt von einem Menschen geschrieben wurde. Selbst im Fall von ChatGPT wurde das Regelbuch zwar nicht von Menschen geschrieben, aber das Programm, das die statistischen Regeln automatisch aus den Daten erzeugt, schon. Ist die Maschine, so könnte Descartes fragen, somit wirklich »aus Erkenntnis tätig«?

Wer kontrolliert, wann die Maschine welches Programm ausführt? Wer ändert das Programm ab, falls es nicht das tut, was es soll? Am Ende ist das immer noch der Mensch. Aber Programme können sich durchaus untereinander kontrollieren und umprogrammieren. Das Betriebssystem Ihres Computers ist ein Programm, das andere Programme kontrolliert, indem es diese vom Arbeitsblatt, auf dem diese »installiert« sind, zeitweise auf das Programmblatt kopiert und wieder löscht. So sorgt das Betriebssystem dafür, dass diese Programme ausgeführt und beendet werden. Da Programme nur aus Zeichen bestehen, die in irgendeinem Computerspeicher stehen, kann ein Programm diese Zeichen ändern und damit verändern, was die Programme tun. Dafür sind Computerviren ein gutes Beispiel. Das sind Programme, die andere Programme ändern und dazu bringen, den Virus weiterzuverbreiten. Es ist sogar leicht möglich, dass ein Programm die Regeln

auf dem Programmblatt, die beschreiben, was es tun soll, selber ändert. So können Computerprogramme geschrieben werden, die selbständig lernen.

Ein Masterkontrollprogramm, das alle Programme kontrollieren und umprogrammieren kann, ist also denkbar. Ein Programm, das sich selber umprogrammieren kann, so wie wir unser Verhalten dank unserer Vernunft verändern können, ist möglich. Science-Fiction-Filme und Romane sind daher voll von solchen sich selbst weiterentwickelnden KI-Programmen, die die Kontrolle über alle Maschinen übernehmen und so die Weltherrschaft an sich reißen. Einige KI-Forscherinnen und -Forscher machen sich deshalb große Sorgen. Zu Recht?

Stoppt die Killerroboter!

In der *Terminator*-Filmreihe entwickelt die Firma Cyberdyne in einer nicht allzu fernen Zukunft neben Kampfmaschinen auch ein superintelligentes Computerprogramm namens Skynet. Dieses merkt schnell, dass die Menschen eine potenzielle Bedrohung darstellen und beschließt daher, eine Armee von Killerrobotern aufzustellen und die Menschheit zu unterjochen. (Ich nehme an, ganz vernichten kam nicht infrage, weil ja irgendjemand für die Maschinen noch den Ölwechsel machen muss.) Doch eine kleine Gruppe von Menschen leistet erbitterten Widerstand. Um den tapferen Anführer des Widerstandes zu vernichten, entwickelt Skynet mal eben eine Zeitmaschine und schickt seinen schlauesten und stärksten Killerroboter, gespielt von Arnold Schwarzenegger, zurück in die Gegenwart. Dort soll er die Mutter des Anführers ›terminieren‹, noch bevor dieser überhaupt geboren ist.

Neben Skynet finden sich in der Filmgeschichte so düstere KI-Programme wie HAL 9000 aus *Space Odyssey 2001* mit seinem rot blinkenden Auge, das herrische Master Control Program aus *Tron* oder WOPR aus *War Games*. Künstliche Intelligenz, die außer Kontrolle gerät, ist eine beliebte Erzählung in modernen Science-Fiction-Filmen. Die gleiche Erzählung findet sich in der Literaturgeschichte aber schon lange bevor Science-Fiction-Autoren angefangen haben, von KI zu träumen. Vom Zauberlehrling bis zu Frankenstein verloren viele tragische Helden die Kontrolle über ihre Schöpfungen. Und nicht alle Geschöpfe hatten, so wie der Golem, einen Notausschalter.

Ansichts des momentanen Hypes um die Fortschritte der KI und ihrer literarischen Vorbelastung ist es vielleicht an dieser Stelle angebracht, kurz Entwarnung zu geben: Ein Terminator-Szenario mit einem vollständigen Kontrollverlust, der zum Untergang der Menschheit führt, steht uns nicht unmittelbar bevor. Denken Sie an die philosophisch schwierige Frage, ob Maschinen die Zeichen, die sie verarbei-

ten, wirklich verstehen können! Denken Sie an all die grundlegenden Schwierigkeiten, die Alexa, Siri, Watson und auch ChatGPT immer noch haben! Dass sie uns trotzdem oft intelligent erscheinen, liegt weniger daran, dass sie es wirklich sind, sondern dass wir ihnen vorschnell Intelligenz zuschreiben – genauso wie sich manche Menschen im 18. Jahrhundert von Wolfgang von Kempelens Schachautomaten täuschen ließen. Ich mache mir zumindest bisher keine Sorgen darüber, dass ein außer Kontrolle geratenes KI-Programm Killerroboter einsetzen könnte, um gegen die Menschheit Krieg zu führen. Es besorgt mich aber durchaus, dass Menschen im Krieg immer häufiger Waffensysteme mit KI-Unterstützung gegen andere Menschen einsetzen.

Das amerikanische Verteidigungsministerium ist durch seine Forschungsagentur DARPA, die ›Defense Advanced Research Projects Agency‹, schon immer ein großer Förderer von KI-Forschung.¹ So hat zum Beispiel erst durch einen von der DARPA organisierten Wettbewerb zum autonomen Fahren die Forschung zu selbstfahrenden Autos richtig Fahrt aufgenommen. Viele andere Staaten und deren Rüstungsunternehmen arbeiten ebenso an Systemen, die signifikante Teile der Kriegsführung automatisieren sollen.

Das ist keine Neuigkeit. Die Entwicklung moderner Computer wurde im Zweiten Weltkrieg maßgeblich vom Militär gefördert, um Codes zu knacken oder die Berechnungen für die Entwicklung der Atombombe zu unterstützen. Auch KI-Methoden werden schon lange in militärischen Kontexten eingesetzt, zum Beispiel zur automatischen Planung des Nachschubs.² Bilderkennung beschleunigt die Aufklärung aus Satellitenbildern, die früher mühselig von Analysten gemacht werden musste. Raketenabwehrsysteme sind dazu da, gegnerische Raketen schnell zu erkennen und automatisch abzufangen. Schon jetzt können Angriffe dank Drohnen und teilautomatischer Fernsteuerung aus sicherer Entfernung geführt werden. Die ukrainische Armee setzte zur Verteidigung gegen Russland schon zu Beginn des Krieges hunderte verschiedener Drohnen ein, insbesondere auch kleine und billige Hobbygeräte. Diese dienen der Aufklärung, können aber auch

1 Siehe z.B. Kapitel 1 in der KI-Kritik von Katz (2020).

2 Kapitel 2 im Buch von Erickson et al. (2013) beschreibt die automatisierten Planungsmethoden für die Berliner Luftbrücke. Das Feld der ›Operations Research‹ ist eng verwandt mit KI-Forschung und teilt mit ihr nicht nur viele Methoden, sondern auch eine Fokussierung auf Rationalität und Optimierung.

Angriffe fliegen. Die großen Mengen an Aufklärungsdaten werden mit KI-Unterstützung ausgewertet, außerdem vereinfacht KI auch die Steuerung der Drohnen, zum Beispiel, wenn Start, Landung oder Zielverfolgung automatisiert werden.³

Die gleichen Technologien, die es Autos ermöglichen Fußgänger und Straßenschilder zu erkennen, versetzen Drohnen in die Lage, gegnerische Panzer oder Flugzeuge auszumachen. Und genauso, wie das Auto von alleine bremst, könnte eine Drohne eigenständig schießen. Warum wohl sonst fördert die DARPA Forschung zum autonomen Fahren? Autonome Kampfroboter hören sich doch wie der Traum aller Militärs an. Aber was genau bedeutet es, dass technische Systeme, seien es Autos oder Waffensysteme, autonom werden?

Autonomie braucht Intelligenz

Zwischen einfacher Automatisierung und vollständiger Autonomie gibt es viele Zwischenstufen.⁴ Früher waren Autos vollständig unter der Kontrolle des Fahrers. Beispielsweise blockierten die Räder unmittelbar bei Betätigung des Bremspedals – und auch nur dann. Heute werden Fahrer standardmäßig mit automatischen Systemen, vom Antiblockiersystem zur Antischlupfregelung, unterstützt. Mittlerweile messen Bremsassistenten mittels Radar den Abstand zu vorausfahrenden Autos und bremsen bei einem drohenden Auffahrunfall sogar selbständig.

Die Bremsassistenten sind nicht das einzige Fahrerassistenzsystem in einem Wagen der Oberklasse. Da gibt es auch den Spurhalteassistenten und den Abstandsregeltempomaten, die beide das Fahren auf der Autobahn entspannter machen. Vollautomatisch sind solche Systeme aber nicht. Der Fahrer muss immer noch selbst aufpassen und von Zeit zu Zeit intervenieren. Seriöse Autobauer sprechen daher vorsichtshalber lieber vom hochautomatisierten Fahren, weil sie wissen, dass wirklich autonomes Fahren technologisch immer noch eine extrem große Her-

3 Franke & Söderström (2023) geben einen Überblick über den Einsatz von Drohnen, KI und anderen Technologien im russischen Angriffskrieg gegen die Ukraine.

4 Die folgenden Überlegungen basieren auf Gutmann, Rathgeber & Syed (2013), auch wenn dort eine viel präzisere Klassifikation vorgenommen wird.

ausforderung darstellt. (Außerdem werden einige Kunden in Deutschland wohl die Freude am Fahren vermissen.)

Eine der zentralen Schwierigkeiten beim autonomen Fahren ist, dass die Aufgaben hierarchisch organisiert sind. Wenn ich von Berlin nach München fahren will, ist das mein oberstes Ziel. Um das zu erreichen, muss ich mir überlegen, welche Autobahnen ich nehme. Auf der Autobahn muss ich eine Spur wählen und entscheiden, wann ich die Spur wechsele. Vorher muss ich blinken und entscheiden, wann ich wie viel Gas gebe und bremse, und so weiter. Die Autonomie eines Autos bemisst sich daran, auf welcher Ebene dieser Aufgabenhierarchie das Fahrzeug selbständig agieren kann. Ein Auto, das auf der Autobahn selbständig überholen kann, ist weniger autonom als ein Auto, dem ich lediglich das Fahrziel vorgeben muss.

Ein Auto ist umso autonomer, desto mehr Entscheidungen es selber trifft. All diese Entscheidungen hängen von sich ständig ändernden Bedingungen ab. Wenn das Ziel darin besteht, möglichst schnell und sicher anzukommen, muss das Auto seine Aufgabe in Abhängigkeit von der aktuellen Situation anpassen. Wenn auf der Autobahn Stau ist, muss das Auto entscheiden, ob es sich lohnt die Umleitung zu nehmen. Wenn der vorausfahrende Laster zu langsam fährt, ist eine neue Teilaufgabe ein Überholvorgang. Wenn es aber schneit oder regnet, muss das Auto wissen, dass Sicherheit vor Schnelligkeit geht und die momentane Teilaufgabe heißt dann langsames Hinterherfahren. Eine größere Autonomie erfordert zwangsläufig eine größere Intelligenz. Ein autonomes Fahrzeug muss in der Lage sein, eine große Zahl an verschiedenen Teilaufgaben, vom Schalten und Überholen bis zum Einparken, zuverlässig und vollautomatisch zu erledigen. Für den eigentlichen übergeordneten Auftrag, den Passagier von Berlin nach München zu bringen, muss eine eingebaute KI diese Aufgabe eigenständig und laufend in kleinere, zielführende Teilaufgaben zerlegen können.

Der Vorteil von intelligenten autonomen Systemen ist, dass man sehr viel Kontrolle abgeben kann. Dieser Vorteil kann aber zugleich auch ein Nachteil sein: Es herrscht ein freiwillig herbeigeführter Kontrollverlust. Jeder kennt schlechte Beifahrer, die damit nicht klarkommen. Momentan ist es beim hochautomatisierten Fahren noch so, dass der ›Fahrer‹ jederzeit eingreifen können muss und die volle Verantwortung trägt. Man kann also nicht so einfach nebenbei ein Buch lesen oder gar schlafen. Man muss immer noch die ganze Zeit aufpassen, dass das Fahrzeug keinen Unfall baut. Unter diesen Bedingungen bin

ich ein noch schlechterer Beifahrer, als wenn mein Bruder fährt. Diese neue Maschinenautonomie, die erst durch KI möglich wird, wirft die Frage auf, wer eigentlich die Verantwortung trägt. Der Mensch oder die Maschine?

Jemand muss die Verantwortung tragen

Verantwortung geht mit Haftung Hand in Hand. In Deutschland muss jeder Fahrzeughalter eine Kfz-Haftpflichtversicherung abschließen, die bei Unfällen zahlt. Wessen Versicherung für welchen Schaden aufkommt, hängt selbstverständlich davon ab, welche (Teil-)Schuld die jeweiligen Unfallteilnehmer haben. Solange immer noch der ›Fahrer‹ eines automatisierten Fahrzeugs die Verantwortung trägt, gibt es keinen Grund, das gut funktionierende Recht zu ändern. Für die Autohersteller hat das den Vorteil, dass die Haftung bei einem Unfall hauptsächlich beim Fahrzeughalter und seiner Pflichtversicherung liegt. Aber natürlich brauchen die Hersteller für ihre Fahrzeuge trotzdem eine Zulassung und stehen in der Verantwortung, falls Systeme nicht so wie versprochen funktionieren. Umso autonomer die Fahrzeuge werden, desto mehr Verantwortung tragen die Hersteller und desto wichtiger sollte die Produkthaftung werden. Ein Autohersteller, der verspricht, dass ein Auto autonom fahren kann, sollte auch für Unfälle haften. Denn ein ›Fahrer‹, der gar nicht mehr fährt, kann auch nicht an einem Unfall schuld gewesen sein. Das muss nicht unbedingt ein Problem für die Hersteller sein, denn die Hoffnung ist natürlich, dass durch das automatisierte Fahren die Hauptursache für Verkehrsunfälle wegfällt: menschliche Fehler.⁵

Im militärischen Kontext stellen sich Fragen zum Verhältnis von Autonomie, Kontrolle und Verantwortung noch drängender als im Straßenverkehr. Welches Maß an Autonomie sollen wir Waffensystemen erlauben? Aus militärischer Sicht ist es fantastisch, dass man nur noch das Ziel markieren muss und die Rakete berechnet von alleine die optimale Flugkurve und passt diese auch noch an, sollte sich das Ziel in der Zwischenzeit wegbewegen. Im nächsten Schritt werden die Ziele automatisch erkannt und beschossen. Bei Raketenabwehrsystemen

5 Der 61. Deutsche Verkehrsgerichtstag hat entsprechende Empfehlungen abgegeben (Deutscher Verkehrsgerichtstag, 2023).

ist das schon lange der Fall. Ein bekanntes Beispiel dafür ist der ›Iron Dome‹ in Israel. Ein anderes ist die nach dem russischen Angriff auf die Ukraine begonnene ›European Sky Shield Initiative‹, die die Luftverteidigung über Europa verbessern soll. Beide basieren auf recht alten Waffensystemen aus den 1980ern, wie dem Patriot-System. Autonome Waffen zur Verteidigung sind also weder neu, noch hat diese Art von automatischer Verteidigung bisher große Bedenken hervorgerufen. Wie ist das aber bei bewaffneten autonomen Drohnen, die Panzer oder gegnerische Stellungen erkennen und vollautomatisch unter Beschuss nehmen?⁶

Bei allen offensichtlichen Vorteilen des automatisierten Krieges fragt sich selbst das Militär, ob nicht eine Grenze überschritten wird, wenn Maschinen über Leben und Tod entscheiden. Es besteht die große Gefahr, dass Regierungen Kriege leichtfertiger beginnen könnten, wenn keine eigenen Soldaten gefährdet sind. Da keine Feinderkennung perfekt funktioniert, wird es verletzte und getötete Zivilisten geben. Wie stellt man sicher, dass autonome Waffensysteme keine Kriegsverbrechen begehen? Wir wollen bestimmt nicht, dass niemand mehr für das Töten im Krieg die Verantwortung trägt. Daher versucht eine breite Initiative von Nichtregierungsorganisationen mit dem trefflichen Namen ›Campaign to Stop Killer Robots‹, eine internationale Ächtung von vollständig autonomen Waffensystemen herbeizuführen. Ihr Hauptanliegen ist, die entscheidende Kontrolle über eine Waffe immer bei einem Menschen zu belassen. Genauso wie bei Landminen und Chemiewaffen sollten Gesetze und internationale Verträge die Entwicklung, die Verbreitung und den Einsatz von autonomen Waffen verbieten. Zwar gibt es schon eine erste UN-Resolution, die die internationale Gemeinschaft dazu aufruft, sich diesen Fragen zu stellen, aber es wäre gut, wenn eine Ächtung passierte, bevor solche Waffen auf breiter Front eingesetzt werden. Leider scheint es dafür schon zu spät zu sein.⁷

6 Sauer (2018) hat für die Bundesakademie für Sicherheitspolitik ein kurzes und lesenswertes Arbeitspapier zu Waffenautonomie veröffentlicht und auch darauf hingewiesen, dass es das Patriot-System schon lange gibt.

7 Mehr Informationen finden sich unter <https://www.stopkillerrobots.org/>. Die erste UN-Resolution zu dem Thema (Resolution 78/241) ist aus dem Jahr 2023. Wie KI jetzt schon im Krieg eingesetzt wird, beschreibt z.B. Adam (2024).

Ist KI ein Sicherheitsrisiko?

Egal ob die Kampagne gegen Killerroboter Erfolg hat oder nicht, ein Terminator-Szenario, in dem die Maschinen außer Kontrolle geraten und gegen die Menschheit Krieg führen, steht uns, wie gesagt, nicht unmittelbar bevor. Solange KI-Waffen nur recht eng umrissene Aufgaben auf Befehl erledigen können, droht kein Kontrollverlust. Keiner, der Waffen entwickelt oder kauft, will die Kontrolle über seine Waffen verlieren. Das gilt insbesondere für Nuklearwaffen. Es fällt mir schwer zu glauben, dass ein Staat das Risiko eingehen könnte, einem KI-Programm die Kontrolle über Nuklearwaffen anzuvertrauen. Auf den ersten Blick scheint ein KI-Programm, das eigenständig einen Vergeltungsschlag verübt, vielleicht ein gutes Mittel zur Abschreckung zu sein, aber wie auch schon im Kalten Krieg würden Fehlalarme das Risiko für einen Atomkrieg stark erhöhen. Realistischer scheint es mir daher, dass KI-Programme auf absehbare Zeit nur als strategische Berater eingesetzt werden und am Ende immer noch ein Mensch die Entscheidung zum Einsatz von Nuklearwaffen trifft. Allerdings können auch KI-Programme, die nur beraten, fehlerhaft programmiert sein, Fehler machen oder durch Fehlinformationen manipuliert werden. KI-Technologien müssen außerdem nicht direkt einen Nuklearschlag auslösen, um Auswirkungen auf die gegenseitige Abschreckung zu haben. Eine KI-gestützte Aufklärung von mobilen Startrampen und der Besitz von autonomen Waffensystemen, die auch bewegliche Ziele treffen, könnten die Fähigkeit des Gegners, einen nuklearen Vergeltungsschlag auszuführen, beeinträchtigen. In der Logik der Abschreckung kann alleine schon die Befürchtung, dass der Gegner durch KI einen Vorteil erringen könnte, zu mehr Misstrauen führen und damit die Welt unsicherer machen. Rüstungskontrolle ist zwar kein Thema, das erst durch KI wichtig geworden ist, aber es gewinnt an zusätzlicher Dringlichkeit.⁸

Im Film *War Games* aus dem Jahr 1983 hackt sich ein Teenager zufällig in das KI-Programm WOPR, das das amerikanische Nukleararsenal kontrolliert, und löst so aus Versehen fast den Dritten Weltkrieg aus. Computersysteme, die Nuklearwaffen kontrollieren, sind hoffentlich nur in alten Hollywood-Filmen an das Internet angeschlossen. Aber nicht nur KI-Systeme, die einen Atomkrieg auslösen können, sind sicherheitskritisch. Denken Sie an KI-Systeme, die zukünftig vielleicht

8 Die Beispiele sind aus einem Bericht von Geist & Lohn (2018).

die Energieversorgung kontrollieren, ganze Autoflotten steuern oder Ihre Ärztin bei Diagnose und Behandlung beraten! Generell gilt, dass KI-Systeme – wie alle Computersysteme – gehackt werden können und entsprechend geschützt werden müssen.

KI-Systeme sind aber nicht nur Angriffsziele für Hackerinnen und Hacker. Sie sind auch Werkzeuge. Es gibt immer mehr KI-Systeme, die das Hacken automatisieren. Computerviren und Trojaner, die immer intelligenter werden, können nicht gut sein. Schon heute ist Cybersicherheit ein riesiges Problem. Computerviren befallen Computer und Firmen müssen riesige Summen Lösegeld an Cyberkriminelle zahlen, weil Ransomware ihre wichtigen Firmendaten verschlüsselt hat. Computerviren und Trojaner lassen sich auch zur Spionage einsetzen. In-fizierte Computer können ferngesteuert werden und als sogenanntes Bot-Netz durch eine Flut von Anfragen Webseiten lahmlegen. Es ist schon öfters passiert, dass die IT von Behörden, Universitäten oder Krankenhäusern durch Cyberattacken über längere Zeit ausgefallen ist. Die meisten von uns merken erst, wie stark wir im Alltag von IT abhängig sind, sobald sie mal nicht funktioniert. Wenn kritische Infrastrukturen wie Telefonnetze, Stromversorger oder Wasserwerke gehackt werden, kann dies riesigen Schaden anrichten. Daher befinden wir uns inmitten eines Wetttrüstens zwischen KI-Programmen zum Cyberangriff und KI-Programmen zur Cyberabwehr.

Selbst wenn wir autonome KI-Systeme von einem direkten Zugriff auf Nuklearwaffen fern halten, die Entwicklung von autonomen Waffensystemen bedeutet immer, dass Computer in irgendeiner Form Zugriff auf Waffen bekommen. Militärische Computersysteme sind miteinander vernetzt und Waffensysteme werden über Computer ferngesteuert. Diese Systeme sind hoffentlich extrem gut gegen Cyberangriffe geschützt. Aber KI-Programme könnten sich in Zukunft selber programmieren und weiterentwickeln und dadurch immer intelligenter werden. Daher warnen manche KI-Expertinnen und Experten lautstark vor der theoretischen Möglichkeit, dass ein zukünftiges superintelligentes Computerprogramm uns die Kontrolle über unsere Waffen entreißen könnte. Selbst wenn wir einen Notausschalter einbauen, so argumentieren sie, könnte das KI-Programm uns austricken und alle unsere Sicherheitsvorkehrungen umgehen.

Aus dieser viel beschworenen theoretischen Möglichkeit eines vollkommenen Kontrollverlustes folgt aber keineswegs, dass er eine wirkliche – oder gar die größte – Gefahr darstellt, die von KI ausgeht. Ich

halte KI für ein Sicherheitsrisiko, ich glaube aber nicht, dass ein Terminator-Szenario in absehbarer Zukunft eintreten wird. Trotz aller Fortschritte in der KI-Entwicklung bleibt Skynet momentan reine Science-Fiction. Ohne Skynet kein Terminator-Szenario. Warum warnen einige Kolleginnen und Kollegen also vor einer Auslöschung der Menschheit durch KI? Im Gegensatz zu mir, glauben sie nicht, dass wir uns über die Intelligenz der Maschinen täuschen. Sie denken stattdessen, es ist unausweichlich, dass superintelligente Computerprogramme uns schon bald überflügeln. Aber was soll das überhaupt heißen?

Über Intelligenz und Superintelligenz

Der Zukunftsforscher Ray Kurzweil analysiert in seinem 2005 erschienen und viel beachteten Buch die technologische Entwicklung von Computern. Er zeigt überzeugend, dass die Entwicklung an allen Fronten exponentiell verläuft. Die Anzahl der Transistoren in Chips verdoppelt sich alle zwei Jahre, die Taktung der Prozessoren alle drei Jahre, die Rechenleistung alle 1,8 Jahre und der Arbeitsspeicher pro Dollar alle 1,5 Jahre. Auf Grundlage einer außerordentlich groben (ich meine sogar hanebüchenen) Abschätzung der Rechenleistung des menschlichen Gehirns sagt Kurzweil voraus, dass Computer uns schon in den frühen 2030er Jahren überflügeln werden. Sobald die technologische Entwicklung nicht mehr durch unsere Intelligenz beschränkt ist, so glaubt er, wird es zu einer wahren Intelligenzexplosion kommen: KI-Programme, die intelligenter sind als wir, werden uns helfen, immer noch schlauere KI-Programme zu entwickeln. Irgendwann entwickeln KI-Programme KI-Programme. Diese Entwicklung wird sich zunehmend beschleunigen und dadurch wird die Menschheit bis zum Jahr 2045 ihre technologischen Fähigkeiten in einem ungeahnten Ausmaß verbessern. Dieser technologische Fortschritt wird unsere gesamte Zivilisation so tiefgreifend verändern wie kein anderer jemals zuvor. Publikumswirksam nennt Kurzweil diesen Zeitpunkt, an dem sich durch KI alles ändern wird, die Singularität.¹

Im Jahr 2016 gab es eine Umfrage auf zwei einschlägigen KI-Konferenzen.² Dort wurden die Expertinnen und Experten gefragt, wann sie glauben, dass bestimmte Aufgaben in der Zukunft von KI-Pro-

1 Siehe Kapitel 2 und 3 in dem Buch von Kurzweil (2005). Bostrom (2014) bevorzugt statt Singularität den Begriff der Intelligenzexplosion.

2 Für die Umfrage siehe Grace, Salvatier, Dafoe & Evans (2018) (insbesondere den Anhang). Diese Arbeit ist stark von Bostrom (2014) beeinflusst.

grammen genauso gut oder besser erledigt werden als von Menschen. Obwohl die Meinungen teilweise extrem stark auseinander gingen, wurden dennoch im Mittel einige Aufgaben als leichter eingeschätzt als andere. So sollte es bis 2024 dauern, bis Telefonbanking nicht mehr nervt. Ab diesem Zeitpunkt sollte auch gesprochene Sprache verlässlich in Text umgewandelt werden oder ein Roboter beliebige Lego-Modelle zusammenbauen können. Es ist jetzt 2025, während ich dieses Buch fertig schreibe, und die ersten zwei Vorhersagen sind zumindest teilweise eingetreten. Nur nutzt niemand mehr Telefonbanking. Erst zwischen 2040 und 2090 wird den Experten zufolge ein KI-Programm einen Bestseller schreiben, interessante mathematische Theoreme beweisen oder wie ein Chirurg operieren.

Wann werden KI-Programme auch die Aufgaben von KI-Forschern übernehmen und selbständig KI-Programme entwickeln? Wenn die Singularität, so wie Kurzweil vorhersagt, 2045 wirklich eintritt, muss das vorher möglich werden. In einer neueren Umfrage aus dem Jahr 2024 – also, nachdem ChatGPT 2022 erschienen ist – glaubt die eine Hälfte der Experten, dass das vor 2060 so sein wird, und die andere Hälfte erst irgendwann danach.³ Vielleicht wollten die pessimistischen Kolleginnen und Kollegen nur nicht wahrhaben, dass sie selber bald überflüssig werden könnten. Sie liegen aber auch laut der neueren Umfrage falsch, da sie nun glauben, dass ein KI-Programm vor 2030 einen Bestseller schreiben könnte. Ich persönlich halte es für viel schwieriger, ein Buch zu schreiben als KI-Forschung zu betreiben.

Maschinen können viele Dinge besser

So oder so: Wir erleben gerade einen Fortschritt in der KI-Forschung, der zeigt, dass Computerprogramme tatsächlich immer mehr Aufgaben genauso gut oder besser erledigen können als Menschen. Descartes hat mit dieser Vorhersage recht behalten. Wann immer eine Maschine eine Aufgabe besser als der Mensch erledigt, ist das eine Pressemitteilung wert: Der Schachweltmeister verliert gegen Deep Blue von IBM, die besten Jeopardy-Spieler gegen Watson von IBM, die besten Go-Spieler verlieren gegen AlphaGo von Google DeepMind, die besten Pokerspieler verlieren gegen Libratus von der Carnegie Mellon University

3 Für diese neuere Umfrage siehe Grace et al. (2024).

und ein Programm der Stanford University zieht bei der Diagnose von Hautkrebs mit Hautärzten gleich.⁴

Heißt das nun, dass die Maschinen intelligenter sind als wir? Zur Erinnerung: Wir sprechen von Künstlicher Intelligenz, wenn Computerprogramme Aufgaben übernehmen, für die Menschen eine gewisse Intelligenz benötigen. Auch ganz langweilige Taschenrechner sind somit irgendwie eine Form von KI. Tatsächlich hat das Wort »Computer« früher keine Maschine bezeichnet, sondern war eine Berufsbezeichnung. Noch bis zur Mitte des 20. Jahrhunderts haben »Computer«, fast immer Frauen, per Hand physikalische Effekte oder statistische Analysen berechnet, und es schien kaum vorstellbar, dass diese Aufgaben vollständig von einer Maschine übernommen werden könnten. Obwohl Rechnen sicherlich Intelligenz erfordert, empfanden viele berühmte Mathematiker wie Leibniz Rechnen doch als eine langweilige und »knechtische« Aufgabe, die sie gerne abgaben.⁵

In den Kaffeeküchen der großen KI-Institute wird gerne gescherzt, dass eine Fähigkeit immer nur so lange als Ausdruck von Intelligenz gilt, bis diese Fähigkeit einem Computer beigebracht wurde. Descartes dachte, dass Tiere nur Maschinen sind und versuchte, uns durch Sprache und Vernunft von beiden abzugrenzen. Jetzt merken wir, dass sich Maschinen (und Tiere übrigens ebenso) bei vielen Aufgaben ausgesprochen intelligent verhalten. Um sich von den neuesten Maschinen abzugrenzen, gelten für Menschen, die KI gegenüber skeptisch sind, immer gerade jene Fähigkeiten als Ausdruck wahrer menschlicher Intelligenz, die Computer noch nicht beherrschen. Diese Skeptiker können immer weiter behaupten, dass wir Menschen mehr als nur tierische Maschinen sind. Weil sie die Anforderungen ständig in die Höhe schrauben, wird es echte Künstliche Intelligenz für sie also niemals geben.

Es ist trotzdem abzusehen, dass viele Aufgaben von Maschinen auf mindestens demselben Niveau wie von Menschen erledigt werden können. Das sagt doch schon etwas aus über die Intelligenz der Maschi-

4 Jeopardy: Ferrucci et al. (2010), Go: Silver et al. (2016), Poker: Brown & Sandholm (2018), Hautärzte: Esteva et al. (2017). Auf Schach kommen wir später nochmal ausführlich zu sprechen.

5 Siehe Light (1999) dafür, dass »Computer« ein Frauenberuf war. Auch das Programmieren war in den Anfangstagen der Computer übrigens, so wie das Rechnen, eine Frauentätigkeit. Erst als die berufliche Beschäftigung mit Computern nicht mehr als »knechtisch« wahrgenommen wurde, wurde sie weitgehend von Männern übernommen (Hicks, 2018).

nen. Aus pragmatischer Sicht ist es auch verständlich, den Fortschritt in der KI messen zu wollen, indem die Leistung der KI-Programme bei speziellen Aufgaben, wie Schachspielen oder Krebsdiagnose, mit der menschlichen Leistung verglichen wird. Je mehr Aufgaben erledigt werden können, desto intelligenter sind die Maschinen. Aber ist die Intelligenz der Maschinen überhaupt mit unserer menschlichen Intelligenz vergleichbar?

Was ist eigentlich Intelligenz?

Es ist Zeit, den Elefanten im Raum endlich an den Stoßzähnen zu packen: Wovon reden wir überhaupt, wenn wir von Intelligenz sprechen? Die recht vage Definition von KI, die wir bisher genutzt haben, spricht von Aufgaben, für die Menschen Intelligenz benötigen. Wir alle haben ein intuitives Verständnis dafür, was wir mit Intelligenz meinen: ›I know it when I see it.‹ Aber der Alltagsgebrauch des Wortes ist äußerst unscharf. Das heißt nicht, dass es keine wissenschaftliche Präzisierung des Begriffs gibt. In der Psychologie ist mit Intelligenz schlicht das gemeint, was ein Intelligenztest misst. Auch Psychologinnen und Psychologen sind ganz pragmatisch an das Problem einer Definition herangegangen. Sie überlegten sich eine große Menge an kleinen Aufgaben, von denen sie intuitiv dachten, dass diese wohl Intelligenz erfordern sollten. Versuchspersonen bearbeiten dann diese Aufgaben. Aufgaben, die von wenigen Versuchspersonen gelöst werden können, sind offenbar schwerer als Aufgaben, die von vielen Versuchspersonen gelöst werden können. Versuchspersonen, die mehr schwere Aufgaben lösen können, sind per Definition intelligenter.

Diese Intelligenztestdefinition von Intelligenz hängt scheinbar willkürlich von den konkreten Aufgaben des Tests ab. Glücklicherweise hat sich herausgestellt, dass Intelligenztests mit unterschiedlichen Aufgaben ähnliche Ergebnisse liefern. Jemand, der gut in einem Test abschneidet, wird auch in einem anderen Test gut sein. In psychologischen Studien haben sehr viele Versuchspersonen eine große Menge an äußerst unterschiedlichen Aufgaben bearbeitet und so fand man heraus, dass es verschiedene Faktoren gibt, die gemeinsam bestimmen, welche und wie viele Aufgaben von jemandem gelöst werden können. Manche dieser Faktoren sind nicht besonders überraschend. Sprachliche Fähigkeiten und ein großes Vokabular sind wichtig, sofern die

Aufgabe Textverständnis erfordert. Numerische Fähigkeiten und mathematisches Wissen sind wichtig für Algebra-Aufgaben. Da es viele solcher speziellen Fähigkeiten gibt, wird oft gesagt, dass es viele verschiedene Formen von Intelligenz gibt. Die Leistungsunterschiede zwischen Versuchspersonen lassen sich aber nicht alleine durch spezifische Unterschiede in, zum Beispiel, ihren sprachlichen oder numerischen Fähigkeiten erklären. Denn sprachliche Fähigkeiten helfen nicht bei rein visuellen Aufgaben. Und mit numerischen Fähigkeiten kommt man bei Aufgaben ohne Zahlen nicht weit. Statistisch ergibt sich allerdings über alle Aufgaben hinweg tatsächlich ein allgemeiner Faktor für Intelligenz. Personen mit höherer allgemeiner Intelligenz sind tendenziell in allen Testaufgaben besser. Statistisch haben sie auch bessere Schulnoten und mehr Erfolg im Beruf. Die psychologische Definition der allgemeinen Intelligenz ist also gekoppelt an die Fähigkeit, viele verschiedene (mehr oder weniger sinnlose) Testaufgaben erfolgreich zu bearbeiten.

Nun können Computer immer mehr Aufgaben genauso gut oder besser als Menschen erledigen. Es gibt sogar Computerprogramme, die auch typische Aufgaben, die in Intelligenztests vorkommen, lösen können.⁶ Bedeutet das jetzt, dass die Maschinen intelligent sind? Der entscheidende Unterschied zwischen uns und den Maschinen ist derzeit noch, dass Schachprogramme nur Schach spielen können und Taschenrechner nur rechnen. Das können sie zwar besser als Menschen – und daher kann es leicht so erscheinen, als ob sie intelligent wären –, aber das Schachprogramm kann keinen Intelligenztest ausfüllen und der Taschenrechner kann nicht pokern. Röntgenbilder analysieren oder gar Auto fahren können beide nicht. Jede Aufgabe braucht ein eigenes, neues KI-Programm. Das kennen wir alle von herkömmlichen Computerprogrammen: Zur Textverarbeitung benötigt man ein anderes Programm als für die Tabellenkalkulation. Doch wenn man mehrere Programme auf einen Computer lädt, dann kann dieser Computer mehrere Aufgaben erledigen. Das ist ja gerade der Witz von Computern: Sie sind universelle Maschinen. Aber Ihr Programm zur Textverarbeitung kann nicht alleine deshalb Zahlen in einer Tabelle addieren, weil Sie auch ein

6 Hernández-Orallo, Martínez-Plumed, Schmid, Siebers & Dowe (2016) geben einen Überblick über die Testaufgaben, die Computer schon lösen können, und ob und wann es Sinn ergibt, Menschen und Computer mit Intelligenztests zu vergleichen. Siehe auch Hernández-Orallo (2017).

Programm zur Tabellenkalkulation installiert haben. Genauso kann ein Schachprogramm seine Erfahrungen vom Schachspielen nicht auf Dame übertragen. Ein Computer kann nicht bei anderen Spielen besser bluffen, weil er ein intelligentes Pokerprogramm auf seiner Festplatte hat. Insbesondere kann er nicht, so wie ein Mensch, seine Erfahrungen mit Schach, Dame und Poker nutzen, um neue Spiele schneller zu lernen. KI-Programme haben Inselbegabungen, die ihnen mittlerweile oft erlauben, den Menschen auf einzelnen Spezialgebieten zu übertrumpfen. Die menschliche Intelligenz aber ist eine allgemeine Intelligenz, die nicht auf bestimmte Aufgaben beschränkt ist. Das ist wohl, was Descartes mit Vernunft meinte. Menschen können sie bei »allen Arten von Begebenheiten« einsetzen.

Künstliche Intelligenz ist anders

Die KI-Forschung war lange erfolgreich mit ihrer Strategie, Computerprogramme zu entwickeln, die bestimmte Aufgaben besser als Menschen erledigen. Aber weil es dabei traditionell nur um spezielle Lösungen und eben nicht um allgemeine Intelligenz geht, kann man sich schon fragen, ob man dann von Künstlicher Intelligenz sprechen sollte. Autonomes Fahren erfordert es zwar, dass eine große Zahl an speziellen Teilaufgaben erledigt werden, aber am Ende kann das Programm, das das Auto steuert, nur Auto fahren. In den allermeisten Fällen gibt es gar nicht den Anspruch, eine echte KI zu entwickeln, die selbständig alle möglichen Aufgaben bewältigen kann. Ich wünsche mir in letzter Zeit daher oft einen weniger aufregenden Namen für das Forschungsfeld. Einen Namen, der weniger große Erwartungen weckt. John McCarthy, der das Feld 1956 auf den Namen »KI« taufte, wählte bewusst einen reißerischen und medienwirksamen Namen, weil er so hoffte, mehr Mittel und Studenten anzuziehen. Das gelang zwar, aber seitdem ist die Geschichte der KI geprägt von sich abwechselnden großen Erwartungen und großen Enttäuschungen. Sie wäre sicher weniger turbulent verlaufen, hätte McCarthy auf seinen berühmten Mentor Claude Shannon, den Erfinder der Informationstheorie, gehört. Shan-

non bevorzugte den ausgesprochen langweiligen Namen ›Automatenstudien‹.⁷

McCarthy's Vorschlag setzte sich schnell durch. Auch, weil die Bezeichnung ›KI‹ den selbst gesetzten Anspruch des neuen Forschungsfeldes widerspiegelte. In den frühen Tagen der KI-Forschung versuchte man tatsächlich, allgemeine Prinzipien intelligenten, menschlichen Verhaltens in Computerprogramme zu gießen. Diese allgemeinen Prinzipien sollten es KI-Programmen erlauben, beliebige Probleme eigenständig zu lösen. So hieß bezeichnenderweise eines der ersten und einflussreichsten KI-Programme ›General Problem Solver‹, mit dem gezielt die allgemeinen Problemlösestrategien von Menschen nachgebildet werden sollten.⁸ Man merkte aber schnell, dass das gar nicht so leicht war, wie man zuerst dachte, weil Menschen flexibel unterschiedliche Strategien bei verschiedenen Problemen einsetzen. Zwar entdeckte man einige Methoden, die breit anwendbar waren, aber man musste sie aufwendig für jedes neue Problem anpassen.

Der Begriff ›Künstliche Intelligenz‹ suggeriert, dass das Ziel der Forschung ist, natürliche Intelligenz in Maschinen nachzubilden. Nur weil ein Computerprogramm bei der Eingabe eines Problems die gleiche Ausgabe wie ein Mensch erzeugt, heißt das aber noch nicht, dass die Maschine die Aufgabe auf die gleiche Weise wie ein Mensch gelöst hat. Die Maschine könnte ganz einfach sein und intern nur in einer großen Tabelle nachsehen, welche Ausgabe sie auf welche Eingabe hin produzieren muss. So wie Descartes sich Maschinen vorgestellt hatte. Die Maschine könnte aber auch, so wie das beim General Problem Solver versucht wurde, wie der Mensch »aus Erkenntnis tätig« sein. Ohne Einblick in die Maschine können wir das nicht beurteilen. Welcher Fall ist es?

- Die Maschine löst die Aufgabe wie ein Mensch und ist intelligent.
- Die Maschine löst die Aufgabe nicht wie ein Mensch und ist nicht intelligent.

7 So hieß ein Buch, das Shannon und McCarthy zusammen herausgegeben haben (Shannon & McCarthy, 1956). McCurdock (1979) berichtet darüber in Kapitel 5.

8 Die frühen Arbeiten zum General Problem Solver aus den 50er und 60er Jahren gipfelten in dem Buch *Human Problem Solving* von Newell & Simon (1972), das sowohl für die KI als auch die Kognitionswissenschaft ein Meilenstein war und auch Kapitel zu Schach enthält.

Viel Verwirrung über KI kann dadurch vermieden werden, dass man sich klarmacht, dass niemand weiß, was Intelligenz eigentlich ist. Intelligenz ist und bleibt ein schlecht definierter Alltagsbegriff (obwohl es eine Korrelation zwischen den Ergebnissen von psychologischen Tests und Schulerfolg gibt). Bei Computerprogrammen sprechen wir immer dann von KI, wenn wir vermuten, dass ein Mensch für die gleiche Aufgabe, die das Programm erledigt, Intelligenz bräuchte. Deshalb gibt es manchmal Streit in der Forschung. Eine Gruppe behauptet, dass ein Programm ein Problem intelligent löst, und die andere zeigt, dass Menschen das aber auf viel schlaudere Weise können und das Programm deshalb nicht wirklich intelligent ist. Woraufhin die erste Gruppe sich entnervt beschwert, dass man sich doch endlich mal auf eine Definition von Intelligenz einigen sollte, die nicht vom Menschen abhängt.

Manchmal passiert es aber auch, dass man sich schnell einigt:

- Die Maschine löst die Aufgabe auf die gleiche unintelligente Art und Weise wie der Mensch.

Genauso, wie wir Maschinen oft vorschnell Intelligenz zuschreiben, machen wir den gleichen Fehler von Zeit zu Zeit auch bei Menschen. In den allermeisten Fällen lautet das Urteil allerdings am Ende wenig kontrovers:

- Die Maschine löst die Aufgabe ganz anders als der Mensch, wir nennen sie aber trotzdem intelligent.

Angesichts der beeindruckenden Fähigkeiten, die viele Computerprogramme heute zeigen, ist es verständlich, dass wir diese Programme als intelligent bezeichnen. Wir sollten dabei aber nicht vergessen, dass es sich doch um eine andere Art von Intelligenz handelt als unsere eigene, auch wenn die KI-Forschung sich viele der Prinzipien der maschinellen Informationsverarbeitung vom Menschen abgeschaut hat. Wir sind es, die den Maschinen Intelligenz zuschreiben, wobei wir mit dem Begriff recht großzügig umgehen.

Für viele Anwendungen ist es gar nicht nötig, dass Maschinen die menschliche Intelligenz nachbilden, um konkrete Probleme zu lösen. Tatsächlich ist der Ansatz, spezielle Lösungen für spezielle Probleme zu entwickeln, in der Geschichte der KI extrem erfolgreich gewesen. Die große Mehrheit der KI-Forscherinnen und -Forscher hatte deshalb

den alten Traum der Anfangstage, KI-Programme zu entwickeln, die so wie der Mensch jede beliebige neue Aufgabe bewältigen können, schon aufgegeben. In den letzten Jahren erlebt dieser Traum aber eine Renaissance. Forschung mit dem Ziel, es mit der allgemeinen Intelligenz des Menschen aufzunehmen und diese womöglich zu übertreffen, läuft jetzt unter dem neuen Schlagwort ›Allgemeine Künstliche Intelligenz‹ (AKI).⁹

Wie kann man diese ominöse, menschenähnliche allgemeine Intelligenz in Computern nachbilden? Welche Zutaten brauchen Computer dafür? Wenn sie selbständig Lösungen für Probleme finden sollen, brauchen sie als erstes ausgefeilte Suchalgorithmen. Eine zweite Zutat, die gemeinhin als essenziell für Intelligenz angesehen wird, sind Lernalgorithmen. Intelligente Computerprogramme sollten nicht von Menschen für jedes einzelne Problem geschrieben werden, sondern sollten selbständig lernen, Probleme zu lösen. Die Forschung versucht sich daher vom Gehirn abzuschauen, wie Lernen funktioniert. Eine clevere Kombination von Such- und Lernalgorithmen hat die KI-Entwicklung in den letzten Jahren weit vorangebracht. Als dritte essenzielle Zutat für eine AKI gelten derzeit Sprachmodelle. Bevor wir fundiert über die gesellschaftlichen Folgen des Einsatzes von KI-Systemen sprechen können, muss ich in den folgenden Kapiteln erst noch diese drei grundlegenden KI-Methoden genauer erklären: Suchalgorithmen, Lernalgorithmen und Sprachmodelle.

Soviel sei aber jetzt schon verraten: Die aktuellen Sprachmodelle (im Jahr 2025) scheinen tatsächlich ein wichtiger Schritt hin zu AKI-Systemen zu sein. Im Gegensatz zu den meisten bisherigen KI-Programmen, die entwickelt wurden, um eine einzige Aufgabe zu erledigen, können diese Systeme als Grundlage für viele Aufgaben dienen, die einen Sprachanteil haben oder Alltagswissen erfordern. Und das sind in der Tat sehr viele Aufgaben. Die Integration mit Wahrnehmung und einem Körper, der sich bewegen kann, fehlt momentan noch. Aber zu dem Grad, wie Denken und allgemeine Intelligenz von sprachlichen Fähigkeiten abhängen, kommen Sprachmodelle dem Traum von AKI näher als alle bisherigen KI-Systeme. AKI ist trotzdem noch Science-Fiction. Allerdings werden auch ohne AKI Computer immer mehr Aufgaben selbständig bewältigen können. Der Fortschritt in der KI wird dank schnellerer Computer und größerer Datenmengen selbst mit her-

9 Im Englischen: ›Artificial General Intelligence‹ (AGI).

kömmlichen KI-Methoden rasant sein. Ohne AKI wird die Entwicklung von KI-Programmen allerdings weiterhin maßgeblich durch die Intelligenz der Forscherinnen und Forscher beschränkt sein, und es wird die Singularität nur in Science-Fiction-Filmen geben.

Vom Suchen und Finden

Als ich meine erste Vorlesung zu KI besuchte, hatte ich Bilder aus Science-Fiction-Filmen im Kopf. Aber schon in der ersten Sitzung gab sich der Dozent alle Mühe, diese Vorstellungen zu zerstören: »Künstliche Intelligenz ist ein Teilgebiet der Informatik, das sich sehr viel mit Suchen beschäftigt.«¹ Wenn der Titel der Vorlesung nicht »Methoden der KI« gewesen wäre, sondern »Suchalgorithmen«, wer weiß, ob ich sie überhaupt freiwillig belegt hätte.

Ein Beispiel für ein Suchproblem, das jeder kennt, ist die Routenplanung beim GPS im Auto oder auf der Homepage der Bahn. Sie wollen zum Beispiel von Berlin nach München fahren (weil es da schöner ist) und der Computer sucht für Sie den schnellsten Weg. Automatische Routenplanung ist heute so alltäglich, dass wir uns keine Gedanken darüber machen, wie sie funktioniert. Aber manch einer erinnert sich vielleicht noch, dass man früher, bevor man losfuhr, zuerst eine Landkarte aus Papier studierte. Eine Route zu planen, erfordert eine gewisse Intelligenz, wenn Menschen das tun. Daher kann man bei automatischer Routenplanung zurecht von KI sprechen. Tatsächlich sind die Suchalgorithmen, die dabei zum Einsatz kommen, klassische Methoden der KI, wie sie in jedem Einführungskurs zu KI vorkommen. Um KI wirklich zu begreifen, muss man zunächst einmal Suchalgorithmen verstehen.²

Stellen Sie sich vor, wir stehen am Weltraumbahnhof auf dem Planeten Alderaan und wollen zum Planeten Endor reisen. Leider gibt es keinen Direktflug. Aber am Terminal hängt ein Shuttleplan, auf dem alle Verbindungen zwischen den Planeten übersichtlich aufgeführt sind:

1 Liebe Grüße an Helmar Gust.

2 Das Standardlehrbuch zu KI stammt von Russell & Norvig (2009), das ich jedem empfehlen kann, der tiefer einsteigen möchte.

3 Alderaan-Bespin
 2 Alderaan-Felucia
 3 Bespin-Alderaan
 2 Bespin-Corellia
 1 Bespin-Geonosis
 2 Corellia-Bespin
 1 Corellia-Dagobah
 1 Corellia-Felucia
 1 Dagobah-Corellia
 1 Dagobah-Endor
 1 Endor-Dagobah
 2 Felucia-Alderaan
 1 Felucia-Corellia
 1 Geonosis-Bespin

Die Zahl am Anfang der Zeile zeigt jeweils an, wie viele Monate die Reise dauert. Neben dem Shuttleplan hängt auch noch eine Netzkarte (Abbildung 1, die Zahlen geben wieder die Reisezeit in Monaten an). Wie kommen wir jetzt am schnellsten von Alderaan nach Endor?




Abb. 1: Eine interplanetare Netzkarte

Wir müssen systematisch vorgehen

Durch Betrachten der Netzkarte finden Sie schnell die beste Route. Ein Computer, der keine Kamera hat, kann aber keine Karte lesen. Selbst mit Kamera ist Kartenlesen ein schwieriges KI-Problem. Wie wir in den vorausgehenden Kapiteln gesehen haben, kennt ein Computer nur Zeichen in seinem Speicher. Der Shuttleplan in Tabellenform, der voll von Zeichen ist, ist also erst einmal besser zur Verarbeitung in einem Computer geeignet. In dieser Tabelle gibt es zwei Shuttles, die in Alderaan abfliegen: eines nach Bespín und eines nach Felucia. Weil wir systematisch vorgehen wollen, schreiben wir beide Verbindungen – wie immer – auf ein Karopapier:

```
3 Alderaan-Bespín
2 Alderaan-Felucia
```

Der Suchalgorithmus geht jetzt nach einer einfachen Regel vor: Unter den möglichen Routen, die in den verschiedenen Zeilen stehen, wählt er die Zeile mit der bislang kürzesten Reisezeit aus und notiert auf dem Karopapier alle Weiterreisen, die von dort aus möglich sind (wobei wir nicht zurück an einen Ort reisen wollen, an dem wir auf der Route schon waren). Das macht der Algorithmus so lange, bis er die kürzeste Route zum Ziel gefunden hat. Für unsere Reiseplanung nach Endor heißt das: Bis Felucia waren es bisher zwei Monate und bis Bespín drei Monate, also macht der Algorithmus bei Felucia weiter, weil das bisher die kürzere Reiseroute ist. Von Felucia aus kann man nur nach Corellia reisen. Diese Reise dauert einen Monat. Wir verlängern die Reiseroute von Felucia entsprechend, zählen den einen Monat zu der bisherigen Länge der Reise hinzu ($2+1=3$) und notieren die neue Länge am Anfang der Zeile.

```
3 Alderaan-Bespín
3 Alderaan-Felucia-Corellia
```

Beide Routen, die wir bisher untersucht haben, sind jetzt gleich lang und keine ist schon in Endor angekommen. Von Bespín aus kann man auch nach Corellia fliegen oder aber nach Geonosis. Beide Möglichkeiten müssen im Blick behalten werden, deshalb notiert der Algorithmus beide.

- 5 Alderaan-Bespin-Coreellia
- 4 Alderaan-Bespin-Geonosis
- 3 Alderaan-Felucia-Coreellia

So macht der Algorithmus weiter, indem er immer die kürzeste Reisroute verlängert und die, die in einer Sackgasse enden, entsprechend markiert.

- 5 Alderaan-Bespin-Coreellia-Alderaan-Bespin-Geonosis
- 5 Alderaan-Felucia-Coreellia-Bespin
- 5 Alderaan-Felucia-Coreellia-Dagobah-Endor

Der Algorithmus hat jetzt systematisch alle Routen untersucht, die man in höchstens fünf Monaten von Alderaan aus erreichen kann. Unter diesen haben wir eine Reiseroute nach Endor gefunden, die genau fünf Monate benötigt. Da wir unter den kürzeren Routen keine gefunden haben, die bis Endor kommt, ist die gefundene Route nach Endor die kürzeste.

Dieser Suchalgorithmus ist nicht besonders schlau. Sie haben wahrscheinlich anhand der Netzkarte intelligenter gesucht und zuerst einmal geprüft, wo man denn von Alderaan aus hinfliegen kann. Nämlich nach Bespin und nach Felucia. Aber dann haben Sie schnell gesehen, dass Bespin ja in der falschen Richtung liegt und dass eine Route über Felucia Sie viel näher an das Ziel Endor heranführt. Warum also, wie der Algorithmus, zuerst prüfen, wo man von Bespin aus hinfliegen kann, statt gleich auf die Felucia-Route zu setzen?

Mit Heuristiken geht es meistens schneller

Zur Verteidigung des Algorithmus muss man sagen, dass Sie durch die Netzkarte mehr Informationen besitzen als der Algorithmus, der nur den Shuttleplan in Tabellenform hat. In der Tabelle stehen nur die Reisezeiten zwischen den Planeten, zwischen denen es eine Shuttleverbindung gibt. Da der Algorithmus die Karte nicht sehen kann, kann er nicht wie Sie auf einen Blick erkennen, dass Felucia viel näher an Endor liegt als Bespin. Wie die Karte in Abbildung 2 zeigt, liegt Felucia nur 0,6 Monate Luftlinie von Endor entfernt, Bespin aber 2,1 Monate.




Abb. 2: Die interplanetare Netz Karte mit Luftlinien

Statt einem Bild der Karte stellen wir dem Algorithmus jetzt für jeden Planeten die Koordinaten zur Verfügung, damit er ausrechnen kann, wie weit ein Planet vom Zielplaneten Endor entfernt ist. Mit dieser Zusatzinformation kann der Algorithmus sich so schlau wie Sie verhalten. Er kann dann nämlich abschätzen, ob eine Route vielversprechend ist oder nicht. Das macht er, indem er für jede Route ausrechnet, wie lang sie im besten Fall sein wird. Für unsere Reiseplanung von Alderaan nach Endor heißt das: Von Alderaan aus kann man nach Bespin und Felucia fliegen, also notiert auch der verbesserte Algorithmus zunächst die zwei potenziellen Routen auf dem Karopapier.

3+2,1 Alderaan-Bespin
2+0,6 Alderaan-Felucia

Neben der bisherigen Reiselänge steht nun zusätzlich eine Abschätzung, wie lang die Restroute nach Endor bestenfalls wird, wenn wir über Bespin oder Felucia reisen. Von Alderaan nach Bespin sind es 3 Monate. Wenn wir von Bespin direkt nach Endor fliegen könnten, wären es von dort noch 2,1 Monate Reisezeit. Das kann der Algorithmus anhand der Koordinaten der Planeten leicht ausrechnen (und wir sehen das in der Netz Karte). Das heißt, dass die Route von Alderaan nach Endor über Bespin insgesamt mindestens 5,1 Monate dauert. Bestenfalls.

Weil man von Bepin aus nicht direkt fliegen kann, dauert es länger. Da die Reise von Alderaan nach Felucia 2 Monate dauert und Felucia 0,6 Monate Luftlinie von Endor entfernt ist, dauert diese Reiseroute mindestens 2,6 Monate.

Also sieht für den verbesserten Algorithmus die Reiseroute über Felucia vielversprechender aus. Daher untersucht er, wie es von Felucia aus weitergehen kann. Man kann von dort nur nach Corellia fliegen und das dauert einen Monat.

3+2,1 Alderaan-Bepin

3+1,1 Alderaan-Felucia-Corellia

Wir machen genauso weiter und verlängern immer die vielversprechendste Route, bis wir in Endor angekommen sind.

3+2,1 Alderaan-Bepin

5+2,1 Alderaan-Felucia-Corellia-Bepin

5+0,0 Alderaan-Felucia-Corellia-Dagobah-Endor

Da die so gefundene Route nach Endor insgesamt 5 Monate dauert und alle anderen möglichen Routen selbst im besten Fall länger dauern, ist das die kürzeste Route.

Diesen Suchalgorithmus, der für jede Route abschätzt, wie lange die Reise wohl insgesamt dauern wird, nennt man in der KI-Forschung kurz und prägnant: A^* (A-Stern ausgesprochen). Die Abschätzung, wie lange die Reisezeit zum Zielplaneten noch ist, nennt man auch »Heuristik«. Was A^* macht, ist deshalb ein Beispiel für eine sogenannte heuristische Suche. In unserem Planetenbeispiel bleibt diese heuristische Suche mit der Route möglichst nah an der direkten Fluglinie zwischen Start- und Zielplanet.³

Ohne eine Heuristik können Suchalgorithmen nicht wissen, in welcher Richtung sie nach ihrem Ziel suchen sollen. Das ist wie beim Topf-schlagen. Dem Kind werden die Augen verbunden und es sucht innerhalb des Stuhlkreises blind nach dem Topf. Das Kind könnte den Kreis systematisch absuchen, aber das Spiel besteht gerade darin, dass die

3 Der A^* -Algorithmus wurde zuerst von Hart, Nilsson & Raphael (1968) beschrieben und findet sich in jedem Lehrbuch zu Künstlicher Intelligenz, z.B. bei Russell & Norvig (2009).

anderen Kinder im Stuhlkreis »wärmer!« rufen, sobald sich das Kind in der Mitte in Richtung Topf bewegt, und »kälter!« rufen, sobald es von der Ideallinie abweicht. Auf diese Art wird es den Topf wesentlich schneller finden. Genau so hilft eine Heuristik: Sie leitet den Suchalgorithmus, indem sie ihm eine Abschätzung darüber gibt, wo es wärmer und kälter wird.

Meistens erweist sich die Heuristik, mit der Route möglichst nah an der direkten Fluglinie zu bleiben, als recht hilfreich bei der Suche nach der kürzesten Reiseroute. Wenn Sie von Berlin nach München fahren wollen, sehen Sie sich auf der Karte ja auch nicht zuerst die Straßen Richtung Hamburg an (da wird's kälter). Diese Heuristik muss aber nicht immer hilfreich sein. Manchmal kann sie auch auf eine falsche Fährte führen. Zum Beispiel, wenn Sie von Corellia nach Endor reisen wollen. Dann sieht der Algorithmus, dass er von Corellia nach Bepin, Dagobah und nach Felucia reisen kann. Da Felucia aber näher an Endor dran ist als Dagobah und deshalb vielversprechender aussieht, wird der Algorithmus zunächst auf eine falsche Fährte nach Felucia geführt. Wenn er dann merkt, dass er von Felucia aus nur noch weiter von Endor wegfliegen kann, besinnt er sich und untersucht die Route über Dagobah. Aber zunächst ist er falsch abgebogen.

Das ist Ihnen so ähnlich sicher auch schon passiert. Sie wissen, Ihr Fahrziel ist nahe dem Kirchturm in der Innenstadt. Sie fahren direkt auf den Kirchturm zu und kommen an eine Weggabelung. Die eine Straße führt mehr in Richtung Kirchturm als die andere. Ihre Heuristik ist: Ich nehme die Straße, die mich wahrscheinlich näher an das Ziel heranführt. Bis Sie merken, dass die Straße auf der Sie fahren, Sie ohne Abbiegemöglichkeit am Kirchturm vorbeigeführt hat. Heuristiken können einen auf die falsche Fährte führen. Aber meistens helfen sie, das Ziel schneller zu finden.

Wenn man mit heuristischer Suche nur schnell Fahrtrouten finden könnte, wäre sie ziemlich uninteressant für KI im Allgemeinen. Tatsächlich kann man aber mit und anderen ähnlichen Suchalgorithmen eine beträchtliche Anzahl von Problemen lösen.




Abb. 3: Suchraum für das Schiebepuzzle

Viele Probleme sind schwere Suchprobleme

Ein weiteres Beispiel sind Schiebepuzzles. Das sind diese quadratischen Plastikdinge, in die acht quadratische Teile eingelassen sind, bei denen immer genau eine Lücke bleibt, in die man die nebenliegenden Teile hineinschieben kann, wodurch am Ursprungsort eine Lücke entsteht. Die Aufgabe lautet, alle acht Teile in eine bestimmte Ordnung zu bringen. In Abbildung 3 sieht man solche Schiebepuzzles, bei denen die Teile durchnummeriert sind. Die Zahlen sind durcheinander: Im Schiebepuzzle ganz oben steht links oben die 7, rechts daneben die 1, und so weiter. Den Zustand des Puzzles am Anfang des Spiels, bevor wir probieren die Puzzle-Teile in die richtige Reihenfolge zu bringen, nennt man »Startzustand«. Das Ziel des Spiels ist es, die 1 nach links oben zu bringen, rechts daneben die 2, rechts oben die 3, in der mittleren Reihe ganz links die 4, und so weiter, mit der Lücke rechts unten. Diesen Zustand des Puzzles nennt man »Zielzustand«. Ein Zug bringt uns von einem Zustand des Problems in einen anderen Zustand. Schieben wir zum Beispiel im Startzustand die 8 nach rechts, erreichen wir den Zustand in der Abbildung links unter dem Startzustand. Abbildung 3 zeigt alle Zustände, die wir in zwei Zügen vom Startzustand aus erreichen können. Die Menge aller Problemzustände nennt man den »Suchraum« eines Problems. Statt im Weltraum von Planet zu Planet zu reisen, reisen wir jetzt im Suchraum von Problemzustand zu Problemzustand. Und wie vorher suchen wir einen Weg vom Start zum Ziel. Am

besten den kürzesten Weg. Suchalgorithmen können uns helfen, eine Handlungsabfolge zu finden, die uns vom Startzustand zum Zielzustand bringt. Eine solche Handlungsabfolge nennt man einen ›Plan‹.

Im Vergleich zu unserem kleinen interplanetaren Reiseproblem ist es in Schiebepuzzles deutlich schwieriger, den optimalen Reiseplan zu finden. Meist braucht man etwa zwanzig Züge, um so ein Puzzle zu lösen. Von jedem Zustand aus gibt es mindestens zwei mögliche Züge, wenn wir das Zurücknehmen eines Zuges mitzählen. Und wenn die Lücke sich nicht gerade in einer Ecke befindet, sind es drei mögliche Züge, oder sogar vier in der Mitte. Da es also bei jedem der zwanzig Züge mindestens zwei mögliche Handlungen gibt, gibt es mindestens 2^{20} , also ungefähr eine Million, mögliche Pläne. Der Suchraum aller Problemzustände ist etwas kleiner. Die Lücke kann an 9 verschiedenen Orten sein, die 8 nur noch an den 8 übrigen, die 7 an den dann noch übrigen 7 Orten, und so weiter. Die Anzahl der möglichen Zustände ist also $9 \cdot 8 \cdot 7 \cdot \dots \cdot 1$, was mit $9!$ (ausgesprochen: neun Fakultät) abgekürzt wird. Ausgerechnet sind das ungefähr 350.000 verschiedene Problemzustände. Wenn man statt einem 3×3 -Puzzle mit 8 Teilen, ein 4×4 -Puzzle mit 15 Teilen lösen will, dann braucht man üblicherweise etwa 50 Züge. Das entspricht mindestens 2^{50} , also etwa einer Billion möglicher Pläne und $16!$, ungefähr 20 Billionen, verschiedenen Zuständen.⁴

Das ist ein wahnsinnig großer Suchraum! Zum Vergleich: In der Milchstraße gibt es geschätzt 250 Milliarden Sterne. Der Suchraum für das 4×4 -Schiebepuzzle ist also 80-mal größer, als eine interstellare Netzkarte für Shuttlereisen in unserer Galaxie wäre. Wie findet man unter all diesen möglichen Zuständen den kürzesten Weg zum Zielzustand? Wie findet man überhaupt zum Ziel? Das ist, als würde man die sprichwörtliche Nadel im Heuhaufen suchen. Sucht man systematisch alle Zustände ab, muss man schlimmstenfalls 20 Billionen Zustände untersuchen. Genau wie bei der Routenplanung benutzt man also besser eine Heuristik, um die Suche zielorientierter und damit intelligenter zu machen, denn man möchte keine Rechenleistung dafür verplempern, unnötige Züge zu untersuchen, die einen vom Ziel wegführen. Glücklicherweise können wir auch für das Schiebepuzzle den aktuellen Abstand zur Lösung mit einer Heuristik abschätzen, die unsere Suche leiten kann: Wir zählen, wie viele Teile noch nicht am richtigen Platz

4 Korf & Schultze (2005) haben alle möglichen Zustände des 4×4 -Schiebepuzzles berechnet.

sind. Wenn sie jeweils nur ein Feld davon entfernt wären, ist das die Anzahl der Züge, die wir bestenfalls noch brauchen. Das ist unsere Luftlinie für das Schiebepuzzle. Mit dieser Heuristik kann man auch für 4x4-Schiebepuzzles mit ihrem wahnsinnig großem Suchraum leicht die kürzeste Lösung finden.

Wie lösen Sie solche Puzzles? Jedenfalls nicht, indem Sie wie bei unserer Weltraumreise die ganze Route im Voraus planen. Ein Reiseplan mit allen Zügen wäre bei einem 4x4-Schiebepuzzle üblicherweise etwa 50 Züge lang. So weit können Sie ohne Computer – oder zumindest ohne Papier und Bleistift und viel Geduld – gar nicht im Voraus planen. Vielmehr werden Sie die Sache wahrscheinlich nur mit einem groben Plan angehen. Erst bringen Sie die 1 nach links oben, danach die 2 daneben, und so weiter. Sie folgen der Heuristik, dass ein Zustand näher am Zielzustand ist, je mehr Teile schon am richtigen Platz sind. Deshalb schieben Sie auch ungern Teile, die schon am richtigen Platz sind, wieder weg. Und falls Sie das machen müssen, dann reparieren Sie das schnell wieder. Diese Züge planen Sie wahrscheinlich im Kopf im Voraus, und sehen so, dass Sie sich manchmal erst vom Ziel entfernen müssen, um ihm im Ergebnis näherzukommen.

Wenn Sie nicht, bevor Sie anfangen, alle Züge bis zum Ende durchdacht haben, können Sie nicht wissen, ob ein vielversprechender Zug, den Sie machen, auf dem kürzesten Weg liegt, oder ob er zu einem Umweg führt (zum Beispiel, wenn Sie von Corellia nach Endor wollen und nach Felucia fliegen, weil Felucia so nah an Endor dran ist). Je weiter Sie in die Zukunft planen, umso besser wird Ihre Lösung sein.

Genauso ist es auch beim Schach. Auch Schach ist ein Suchproblem – mit der Anfangsstellung als Startzustand und mehreren möglichen Zielzuständen. Der Suchraum ist jedoch ungleich größer als bei einem 4x4 Puzzle! Aber auch hier suchen die Spieler eine Abfolge von Zügen, die sie zum Ziel führen. Und das Ziel ist, den Gegner matt zu setzen. Beim Schachspielen habe ich zumindest einen groben Plan, und beim Endspiel bemühe ich mich, möglichst viele Züge im Voraus zu bedenken. Manchmal gehen meine Pläne auch auf (ich liebe es, wenn ein Plan funktioniert). Meistens geht aber nichts nach Plan. Denn der Erfolg des Plans hängt davon ab, wie sich der Gegner verhält. Damit ein Plan gut ist, muss er auch alle möglichen Züge des Gegners berücksichtigen. Das kriegt mein Schachcomputer immer besser hin als ich.

Dass ein Plan schiefgeht, und ich umplanen muss, passiert nicht nur bei Spielen, in denen sich mein Gegner nicht an meinen Plan hält.

Es passiert in der wirklichen Welt auch bei der Reiseplanung. Fahre ich mit der Bahn und muss umsteigen, kann es passieren, dass ich wegen einer Verspätung meinen Anschluss verpasse. Wenn ich weiß, dass der Zug oft Verspätung hat, plane ich vielleicht erst gar nicht damit, dass ich den knappen Anschluss erreiche, oder ich habe einen Plan B, oder ich muss halt umplanen, falls der Anschluss tatsächlich weg ist. All dieses intelligente Verhalten können Computer dank Suchalgorithmen auch zeigen.

Unabhängig davon, ob ein Mensch oder ein Computer ein Problem lösen soll, ein Problem besteht immer aus einem Startzustand, der beschreibt, wie die Welt ist, und einem Zielzustand, der beschreibt, wie wir die Welt gerne hätten. Wir sind in Berlin und wollen nach München. Die Schachfiguren stehen in der Anfangsstellung und wir wollen eine Stellung erreichen, in der der Gegner matt gesetzt ist. Die Einzelteile eines Autos liegen in den Lagern der Zulieferer über ganz Europa verteilt und sollen alle zu einer bestimmten Zeit im Werk zur Endmontage sein. Wir wiegen zu viel und wollen fünf Kilo Gewicht verlieren. Wir produzieren als Gesellschaft viel zu viel CO₂ und wollen unseren CO₂-Ausstoß auf null reduzieren. Wenn wir also längst Suchalgorithmen haben, die Probleme für uns lösen können und uns bei vielen Problemen sogar überlegen sind, warum werden nicht alle unsere Probleme längst von Computern gelöst?

Viele Probleme sind ungenügend definiert

Ein Grund ist, dass wir Suchalgorithmen nur anwenden können, falls sowohl der Startzustand des Problems, als auch der Zielzustand des Problems sowie die Handlungsmöglichkeiten so klar definierbar sind, dass wir sie als Zeichen auf das Karopapier einer unserer Papier- und Bleistift-Maschinen schreiben können. Außerdem haben schon scheinbar einfache Probleme, wie das Schiebepuzzle, einen so großen Suchraum, dass sie nur durch den Einsatz von Heuristiken effizient zu lösen sind. Und diese Heuristiken müssen im Normalfall dem Computer auch erst einprogrammiert werden. Ohne Programmierer lösen Computer keine Probleme für uns.

Bei unserer Reise von Alderaan nach Endor war es leicht, den Suchraum computerverständlich zu beschreiben und dem Suchalgorithmus eine Heuristik mitzugeben. Das war auch leicht bei den Schiebepuz-

zles. Bei anderen Problemen kann es aber schon ziemlich mühselig sein, den Startzustand zu beschreiben. Zur Planung der Energiewende muss man erst mal wissen, wo eigentlich welche Mengen an CO₂ anfallen. Wie viel CO₂ wird bei der Verstromung von Braunkohle ausgestoßen? Wie viel beim Heizen? Wie viel im Verkehr? Von diesen Informationen hängt maßgeblich ab, ob man mehr Anstrengungen in den Kohleausstieg, die Gebäudedämmung oder den Ausbau des Bahnverkehrs stecken sollte. Auch ist oft unklar, ob überhaupt schon alle Handlungsmöglichkeiten auf dem Tisch liegen. Gibt es nicht vielleicht zur Einführung von CO₂-Steuer oder Zertifikatehandel andere Handlungsmöglichkeiten, die die Politik bisher nicht bedacht hat? Und wie genau wirken sich diese Maßnahmen auf den Zustand der Welt aus? Ohne all diese Informationen kann weder ein Mensch noch ein Computer einen vernünftigen Plan für die Energiewende machen.

Im Fall der Energiewende scheitert die Planung aber nicht unbedingt an mangelnder Information über den Zustand der Welt und die verfügbaren Handlungsmöglichkeiten, denn zu all diesen relevanten Fragen gibt es gute Forschung. Und tatsächlich können KI-Methoden zur Planung der Energiewende gut genutzt werden. Der Zielzustand lautet also: Wir wollen CO₂ reduzieren! KI-Algorithmen finden schnell eine einfache Lösung: Schalte alle Kohlekraftwerke und Ölheizungen ab und lass alle Autos stehen. Aber das wollen wir dann doch nicht. Es stellt sich leider heraus, dass wir nicht nur das eine Ziel haben, sondern mehrere gegensätzliche Ziele: Wir wollen CO₂ reduzieren, aber es darf nicht viel Geld und keine Arbeitsplätze kosten. Die Stromversorgung wollen wir auch behalten, und unsere Autos sowieso. Das wahre Problem bei der Planung der Energiewende sind solche Zielkonflikte. Damit uns eine KI bei der Planung der Energiewende helfen kann, müssen wir dem Suchalgorithmus erst mitteilen, was unser angestrebter Zielzustand ist, und was uns die Lösung kosten darf. Wir müssten wissen, was wir eigentlich wollen. Und oft tun wir das nicht.⁵

Im Kleinen taucht diese Schwierigkeit auch schon bei der Anwendung von KI bei der Routenplanung der Bahn auf. Auf den ersten Blick lautet das Ziel, von Berlin nach München zu kommen. Wenn wir die Route genau so planen, wie wir das in unserem Planetenbeispiel gemacht haben, kann ein Suchalgorithmus für uns die schnellste Route

5 Eine Liste mit Vorschlägen, wie KI helfen kann, den Klimawandel zu bekämpfen, findet sich bei Rolnick et al. (2019).

finden. Aber vielleicht wollen wir stattdessen die kürzeste oder die billigste Route. Dann muss der Suchalgorithmus mit der Strecke oder dem Preis statt mit der Reisezeit rechnen. Aus Sicht des Algorithmus macht es keinen Unterschied, ob die ›Kosten‹, die minimiert werden sollen, in Euros, in Minuten oder in Kilometern gemessen werden. Meist kann man dafür irgendwo ein Häkchen setzen. Meine eigenen Kriterien für die optimale Route sind allerdings stimmungsabhängig und deutlich komplexer: Der Sprinter ist zwar der schnellste Zug, aber ich finde ihn unverhältnismäßig teuer, weshalb mir eine etwas langsamere Verbindung lieber ist, aber nur, falls ich nicht mehr als einmal umsteigen muss, und die Umsteigezeit nicht zu knapp ist, um die Wahrscheinlichkeit möglichst gering zu halten, dass ich den Anschluss verpasse. Habe ich es eilig oder möchte ausschlafen, nehme ich aber trotzdem den Sprinter. Es ist oft nicht leicht zu wissen, welche Ziele man eigentlich hat. Und nicht selten ändern sich unsere Ziele sprunghaft. Wie soll ein KI-System es uns da recht machen?

Halten wir fest: Suchalgorithmen bilden den Kern jedes KI-Systems, das Probleme lösen kann, sei es zur Routenplanung, zum Schachspielen oder zur Planung der Energiewende. Das machen die Suchalgorithmen aber nicht selbständig. Jemand muss dem Algorithmus den Startzustand, den Zielzustand, die Handlungsmöglichkeiten, die Heuristik und die Kosten, die minimiert werden sollen, einprogrammieren. Das praktische Problem dabei ist, dass es oft viele gegensätzliche Ziele gibt.

Die Interessen der Hersteller von KI-Systemen sind nicht unbedingt auch meine. Die Bahn hat vielleicht mehr Interesse daran, dass die Hochgeschwindigkeitszüge ausgelastet sind, als dass ich die günstigste Route finde. Facebook hat vielleicht mehr Interesse daran, viele Klicks zu generieren, als dass ein KI-Programm die Falschmeldungen aus meinem Newsfeed herausfiltert. Und der Hersteller eines selbstfahrenden Autos hat vielleicht ein größeres Interesse daran, bei einem drohenden Unfall das Leben seiner Kunden zu schützen, als das Leben der anderen Verkehrsteilnehmer.

Die Suchalgorithmen haben selbst hingegen keine eigenen Ziele! Obwohl das – wie wir aus Science-Fiction wissen – durchaus vorstellbar ist, so muss man sich beim aktuellen Stand der KI-Forschung noch keine ernsthaften Sorgen machen, dass Algorithmen bald eigene Wünsche und Ziele entwickeln. Klassische KI-Systeme, wie sie lange zum Beispiel beim Schach eingesetzt wurden, können ihre erstaunlichen Leistungen nur deshalb erbringen, weil Menschen die Probleme vorher

entsprechend für die KI-Systeme aufbereitet haben. Wenn ein KI-System ein Problem löst, hat vorher ein Mensch das Problem in ein Suchproblem übersetzt, das der Computer verarbeiten kann. Man muss sich daher immer fragen, wer hinter einem KI-System steht.

Um die Ehre

Garri Kasparow ist ein unglaublich schlechter Verlierer. Als er, der amtierende Schachweltmeister, 1997 gegen IBMs Deep Blue Supercomputer antrat, sah *Newsweek* in Kasparow die letzte Verteidigungslinie gegen die intellektuelle Übermacht der Computer. Ein Jahr vorher hatte Kasparow noch gegen Deep Blue gewinnen können, aber dann entschloss sich IBM, sein ganzes Gewicht hinter das Prestigeprojekt zu legen. Kasparow verlor spektakulär – und beschuldigte IBM geschummelt zu haben. Sein Ego war stellvertretend für uns alle sichtbar angeknackst. Ohne Zweifel war das eine Niederlage mit hoher Symbolkraft. Aber gegen wen oder was hat Kasparow eigentlich verloren?¹

Beim Schach gibt es grob geschätzt 10^{43} verschiedene Spielzustände.² Eine Zahl mit 43 Nullen. Zum Vergleich: Im Gehirn haben wir so

1 Dass er ein schlechter Verlierer ist, gibt Kasparow selber freimütig zu: 30 Jahre nach seiner Niederlage gegen Deep Blue beschreibt er in seinem Buch seine Version der Geschehnisse und zieht daraus Lehren für unser Verhältnis zu KI (Kasparow, 2017). In einem kurzen Artikel macht das auch der Journalist, der das Spiel zwischen Kasparow und Deep Blue damals für *Newsweek* beobachtet hat (Levy, 2017).

2 Diese Abschätzung stammt von Shannon (1950). Er ignoriert dabei, dass nicht jede Figur bei Einhaltung der Spielregeln jede Brettposition erreichen kann und dass Figuren während des Spiels geschlagen werden und dann nicht mehr da sind. Zählt man aber einfach mal alle Möglichkeiten, wie man die 16 weißen und die 16 schwarzen Figuren aufstellen kann, erhält man ein Gefühl für die Größenordnung. Die erste Figur kann auf eines der 64 Felder gestellt werden. Die zweite auf die übrigen 63, und so weiter. Für die 32 Figuren gibt es bei 64 Feldern also $64 \cdot 63 \cdot 62 \cdot \dots \cdot 34 \cdot 33$ Möglichkeiten sie aufzustellen. Mit der Fakultät kann man das auch als $64!/32!$ schreiben. Da jeder acht Bauern hat, die identisch sind, spielt es keine Rolle, wo die Bauern stehen, also muss diese Zahl durch $8!$ geteilt werden. Für die 6 anderen Figuren, die jeweils paarweise auftreten (Läufer, Pferde, Türme für jede Farbe), muss man die Zahl weiter durch 2^6 teilen. So kommt man auf etwa 10^{43} (beim Nachrechnen lieber mit dem Logarithmus arbeiten, da Taschenrechner und Computer bei so großen Zahlen schnell überfordert sind).

etwa 10^{11} , also 100 Milliarden, Nervenzellen. So viele Transistoren finden sich auch auf dem M2 Ultra Prozessor von Apple, der 2023 auf den Markt kam. In der Mitte des Jahrhunderts werden auf der Erde etwa 10 Milliarden (10^{10}) Menschen leben. Alle Menschen zusammen kommen dann auf 10^{21} Gehirnzellen. Descartes stellte sich noch Maschinen vor, denen man für jede mögliche Situation einzeln Regeln vorgeben muss, wie sie sich zu verhalten haben. Es ist tatsächlich »praktisch unmöglich«, dass eine Schachmaschine für jede Spielsituation ein eigenes »Organ« hat. Diese Maschine müsste deutlich mehr interne Zustände haben, als alle Menschen zusammen Gehirnzellen.

Dann muss der Computer halt den nächsten Zug ausrechnen, könnte man meinen. Allerdings können auch die größten Supercomputer auf der Welt noch kein Schachspiel komplett im Voraus planen. Die Anzahl an möglichen Zügen in einem Schachspiel ist erstaunlich konstant über die Partie hinweg, ungefähr 30. Machen Schwarz und Weiß je einen Zug, gibt es also etwa 30·30, ungefähr 1000 Möglichkeiten, wie sich das Spiel in jeder Runde weiterentwickeln kann. In einem typischen Spiel macht jeder Spieler 40 Züge, das heißt, es gibt in etwa $1000^{40} = 10^{120}$ mögliche Schachpartien.³ Seit dem Urknall sind so etwa 10^{17} Sekunden vergangen und ein aktueller Supercomputer kann 10^{17} Berechnungen pro Sekunde durchführen. Um auszurechnen, was die beste Schachstrategie ist, war bisher einfach noch nicht genügend Zeit. Trotzdem können Menschen und Computer Schach spielen.

Wie spielen Menschen und Computer Schach?

Am Anfang des Spiels folgen beide größtenteils Descartes naiver Vorstellung: Sie merken sich für eine große Zahl an Spielzuständen den Zug, den sie in dieser Situation machen wollen. Schachanfänger lernen verschiedene Eröffnungen auswendig, die alle wenig originelle Namen tragen, zum Beispiel das Vierspringerspiel oder die Spanische Eröffnung. Für diese Eröffnungen gibt es etablierte Varianten und Verteidigungen, die sich über die Jahrhunderte, die Schach schon gespielt wird, als besonders erfolgreich herausgestellt haben. Erfahrene Schachspieler kennen wesentlich mehr Varianten als Anfänger und es ist nicht ungewöhnlich, dass Spieler mehr als 20 Züge lang die Eröffnung einer

3 Diese Überschlagsrechnung findet sich so auch bei Shannon (1950).

bekannten Partie nachspielen. Das hört sich langweiliger an als es ist, denn in der Vorbereitung auf ein Spiel analysieren Schachspieler frühere Partien ihrer Gegner und studieren ihre Vorlieben und Schwächen genau. Jeder Spieler versucht in der ersten Phase das Spiel auf eine Eröffnungsvariante zu lenken, die er für besonders vielversprechend hält. Vielleicht hat ein Spieler sich sogar extra für seinen Gegner eine neue Variante überlegt, die irgendwann von einer etablierten Variante abweicht.

Während der Eröffnungsphase denken menschliche Spieler daher kaum nach. Sie spielen zügig die etablierten und vorbereiteten Züge. Deep Blue hatte, genauso wie Kasparow, eine Datenbank an etablierten Eröffnungen zur Verfügung. (Deep Blues Gedächtnis war allerdings ein bisschen größer.) Diese Eröffnungen hat sich Deep Blue aber nicht selber ausgedacht. IBM hat dafür mehrere Großmeister eingestellt, die für Deep Blue diese Eröffnungen zusammengestellt haben. Das ist nicht unbedingt unfair, denn auch Kasparow hat Sekundanten, die ihn bei der Vorbereitung unterstützen, und auch er steht mit seiner Eröffnung auf den Schultern früherer Schachriesen. Aber während das Team bei IBM wusste, dass ihr Gegner Kasparow sein wird, wusste Kasparow nicht, gegen wen er eigentlich spielen wird. Deep Blue hatte bisher nicht viele öffentliche Spiele gespielt. Außerdem wurde das Programm fortwährend mit der Hilfe mehrerer Großmeister verbessert, Kasparow wusste allerdings nicht, wer diese Großmeister waren. Kein Wunder, dass Kasparow – der für seine sorgfältige Vorbereitung gerühmt ist – im Vorfeld etwas nervös wirkte.⁴

Aus Sicht der KI-Forschung beginnt der interessante Teil des Schachspiels erst wirklich im Mittelspiel, sobald die Eröffnungsphase vorbei ist. Im Mittelspiel müssen die Spieler selbständig vollkommen neue Spielsituationen bewerten. Die Züge dauern dann auch wesentlich länger. Erst im Mittelspiel spielte Kasparow wirklich gegen eine auf sich gestellte KI. Einer der Großmeister, der IBM bei der Entwicklung geholfen hatte, berichtete Jahre später, dass sie auf bestimmte Eröffnungsvarianten spekuliert hatten, die extra für Kasparow vorbereitet waren. Damit Kasparow das aber nicht merkt, tat Deep Blue manchmal so, als ob er lange nachdenken muss, um den nächsten Zug zu wählen. Kasparow sollte denken, dass er schon gegen die KI spielt, obwohl er in Wirklichkeit noch gegen die von Menschen vorbereitete Eröffnungs-

4 Kasparow (2017), S. 163 und S. 167f.

strategie spielt. Ein umgekehrter Turing-Test: Der Computer stellt sich dumm, damit der Mensch denkt, er ist ein Computer. IBM hatte offenbar die harten Bandagen angelegt und scheute auch vor psychologischen Tricks nicht zurück, um Kasparow zu täuschen.⁵

Aber auch vom Mittelspiel aus ist der Suchraum beim Schach noch zu groß, als dass ein Computer das Spiel bis zum Ende durchplanen könnte. Stattdessen spielen Menschen und Computer nur ein paar der möglichen zukünftigen Züge durch. Unter diesen Zügen schätzen sie ab, welche am vielversprechendsten aussehen und fokussieren sich auf diese. Sie nutzen, so wie es im vorherigen Kapitel erklärt wurde, bei ihrer Suche nach dem vielversprechendsten Zug eine Heuristik. Diese Heuristik bewertet für jeden Zug, wie nah man damit an das Ziel herankommt, den Gegner matt zu setzen.

Heuristiken beim Schach nutzen zum Beispiel den Materialgewinn. Wenn ich einen Zug machen kann, in dem ich die Dame des Gegners schlage, dann verbessert das vermutlich meine Gewinnchancen. Sicher weiß ich das nicht, aber es ist eine recht gute Daumenregel. Es wird wärmer. Manchmal muss ich auch eine eigene Spielfigur opfern und damit erst scheinbar meine eigene Position schwächen, bevor ich eine wertvollere Figur des Gegners schlagen kann. Um zu entscheiden, ob sich ein Bauernopfer lohnt, muss ich ein paar Züge in die Zukunft schauen. Falls dadurch ein Zugzwang beim Gegner entsteht, und ich anschließend sicher eine wertvollere Figur des Gegners schlagen kann, lohnt sich der Umweg, der mich zunächst von meinem Ziel wegführt.

Um ihr Mittelspiel zu verbessern haben Menschen und Computer also im Wesentlichen zwei Möglichkeiten: Entweder braucht man mehr Rechenleistung, damit man mehr Züge und weiter in die Zukunft planen kann, oder man verbessert die Heuristik und lernt, Spielzustände besser einzuschätzen, damit man dumme Pläne gar nicht erst in Betracht ziehen muss.

Durch die fleißige Chipindustrie verdoppelt sich die Rechenleistung von Computern bisher noch knapp alle zwei Jahre. Dass Computer immer mehr Aufgaben besser erledigen können, liegt auch daran, dass sie einfach schneller werden. Das bedeutet nicht unbedingt, dass die Rechner intelligenter werden. Ein schnellerer Computer kann mehr Züge beim Schach im Voraus berechnen und mehr Spielzustände bewerten. Ein Computer, der einfach stumpf mehr Möglichkeiten durch-

⁵ Kasparow (2017), S. 185.

rechnet, spielt zwar besseres Schach, aber wir sollten dem Computer dann nicht unbedingt mehr Intelligenz zusprechen.

Die Intelligenz steckt in der Heuristik

Gute menschliche Spieler schauen üblicherweise nur drei bis vier eigene Züge – Großmeister mehr, aber nicht dramatisch mehr – in die Zukunft. Dabei analysieren sie vielleicht ein paar hundert Spielzustände. Eine lächerlich kleine Zahl, sogar im Vergleich zu einfachen, frühen Schachcomputern. Trotzdem spielen Menschen verdammt gut und erst 1997 konnte der beste menschliche Spieler von einem Computer geschlagen werden. Die Rechenleistung scheint nicht das Geheimnis der menschlichen Intelligenz zu sein. Schachspieler unterscheiden sich untereinander kaum darin, wie schnell sie Züge im Kopf durchspielen können. Und eine Großmeisterin, die unter Zeitdruck spielt – also viel weniger Züge untersucht als normalerweise – spielt nur unwesentlich schlechter als sonst.⁶

Da also bessere Spieler beim Schach gar nicht viel mehr mögliche Fortsetzungen einer Partie analysieren, muss ihre Leistung durch eine bessere Heuristik erklärt werden. Sie können einfach besser einschätzen, welche Spielzustände für sie vorteilhaft sind und welche nicht. Materialgewinn ist nicht alles. Dazu kommen Fragen wie: Ist der König gut geschützt? Werden Figuren geblockt? Steht der Bauer frei? All diese Aspekte müssen gegeneinander abgewogen werden. Während eine Anfängerin nicht genau weiß, was sie mit einer Position anfangen soll, erfasst die Expertin mit einem Blick, was gut oder schlecht läuft, und weiß, wie man darauf reagieren sollte.

Abgesehen von der Rechenleistung spielt auch bei Computern die Heuristik die entscheidende Rolle. Ein Schachcomputer, der Materialgewinn wichtiger findet als den Schutz des eigenen Königs, spielt aggressiv. Ist es andersherum, spielt der Computer eher defensiv. Durch viel Herumprobieren mit verschiedenen Heuristiken versuchen die Programmierer herauszufinden, welche Heuristik am besten funkto-

6 Siehe Charness (1981) und Gobet & Simon (1996a). Im Endspiel ist die Suchtiefe größer, außerdem hängt die Suchtiefe natürlich von der Stellung ab. Eine spätere Studie fand heraus, dass Experten tiefer suchen als zuvor angenommen (Campitelli & Gobet, 2004). Im Vergleich zu Computern sind aber auch diese Schätzungen klein.

niert. Da Kasparow als Mensch viel weniger mögliche Züge analysierte als Deep Blue und trotzdem mithalten konnte, musste seine Heuristik immer noch deutlich besser sein als die Heuristik, die die IBM-Ingenieure entwickelt haben.

Wie entwickeln erfahrene menschliche Schachspieler also eine so gute Heuristik? Eines ist klar: Profispieler wie Kasparow haben sehr, sehr viel Übung. Ohne systematisches Training geht es nicht. Durch dieses Training können sie handlungsrelevante Muster auf dem Spielbrett erkennen, die Anfängern verborgen bleiben. Wo eine Anfängerin zum Beispiel nur eine Reihe von Bauern sieht, sieht die Expertin sofort eine Festung, die sie leicht verteidigen kann. Solche Denkstrukturen erlauben es Expertinnen und Experten, die entscheidenden Informationen effizient zu verarbeiten.⁷

Dass erfahrene Spieler auf Schach bezogene Informationen extrem effizient verarbeiten können, sieht man auch daran, dass sie nicht selten blind spielen können. Oder daran, dass Schachmeister eine Spielsituation nur kurz sehen müssen, um die Spielfiguren anschließend aus dem Gedächtnis wieder aufstellen zu können. Das liegt aber nicht etwa daran, dass sie einfach ein besseres Gedächtnis haben. Werden die Spielfiguren zufällig auf das Brett gestellt, sodass sie keine sinnvolle Schachposition ergeben, dann erinnern sich Schachmeister auch nicht viel besser als andere Menschen an die Position der Figuren. Sie haben schlicht durch ihr Training eine große Zahl an relevanten Schachmustern gelernt, die sie schnell wiedererkennen können.⁸

Diese Schachmuster bilden die Grundlage für die Heuristik, mit der Schachspieler eine Position bewerten. Wenn wir wüssten, welche Schachmuster Experten sehen, und auf welche Weise sie damit abschätzen, welche Züge besser sind, dann könnten wir diese Heuristik einem Suchprogramm vorgeben – und so ein Schachprogramm entwickeln, das wie ein menschlicher Experte spielt. Doch fragt man Schachexpertinnen und -experten, wie sie das machen, sind die Antworten selten hilfreich. Zu erklären, wie man Schach spielt, ist ein bisschen so wie zu erklären, wie man Fahrrad fährt. Entscheidende Aspekte weiß man nur intuitiv und kann man nicht wirklich erklären. In der Psycho-

7 Ein gutes Buch zum Thema Expertise und zur Wichtigkeit von systematischem Training ist das von Ericsson & Pool (2016).

8 Die klassische Studie dazu wurde von Chase & Simon (1973) durchgeführt. Siehe auch Gobet & Simon (1996b).

logie nennt man das »implizites Wissen«. Nicht nur bei Schach ist die Entwicklung von KI-Systemen in der Vergangenheit daran gescheitert, solch implizites Wissen von Experten auf Computer zu übertragen. Stattdessen wurde der meiste Fortschritt bei Anwendungen von KI bis vor kurzem dadurch erzielt, dass die Computer einfach nur schneller geworden sind und dümmere Algorithmen dadurch besser funktionierten. Wirklich intelligenter werden sie dadurch nicht. Ich habe es jetzt schon mehrfach gesagt und ich kann nicht versprechen, dass ich es nicht nochmal sagen werde: Wir sind es, die Computern mehr Intelligenz zuschreiben, als unter der Haube vorhanden ist.

Kasparow verliert nicht gegen Deep Blue

Viele KI-Forscherinnen und -Forscher fanden damals den Wettkampf zwischen Garri Kasparow und Deep Blue ungefähr so interessant wie ein Tauziehen zwischen Arnold Schwarzenegger und einem Traktor. Für viele Schachfans hingegen spielte Deep Blue manchmal überraschende Züge, die ihn sehr menschlich aussehen ließen. Solche Züge trauten sie Computern, die das Spiel ja nicht genauso wie Menschen verstehen, einfach nicht zu.

Auch Kasparow war verwundert darüber, dass Deep Blue manchmal dumm wie Brot war und ihn im nächsten Moment mit brillanten Zügen in große Schwierigkeiten brachte. Während der sechs Spiele, in denen er gegen Deep Blue antrat, blieb Deep Blue für Kasparow unberechenbar. Während der Computer trotzdem einfach stoisch weiter rechnete, wurde Kasparow im Verlauf des Turniers zunehmend gereizt. Kasparows großes Ego war sichtbar angeknackst. Ein Kommentator scherzte damals: »Sie denken vielleicht, das ist keine große Sache, aber warten Sie, bis das Ding hinter *Ihrem* Job her ist!«⁹ Als IBM sich weigerte die internen Protokolle von Deep Blue schon während des Turniers zur Analyse zur Verfügung zu stellen, witterte Kasparow Betrug. Bei einer Pressekonferenz wurde er konkret gefragt, ob er glaubt, dass bei Deep Blues entscheidenden Zügen Menschen interveniert hätten. Er antwortete, dass er sich an Maradonnas irreguläres Tor gegen England

9 Kasparow (2017), S. 134.

bei der WM 1986 erinnert fühlte und ergänzte: »[Maradonna] sagte, es war die Hand Gottes!«¹⁰

In seinem Buch, das Kasparow 30 Jahre später über den historischen Wettkampf veröffentlichte, entschuldigt er sich dafür bei den Ingenieuren, die Großes geleistet hatten. Gleichzeitig kann er den Groll, den er immer noch gegen IBM hegt, nicht verbergen, und er wirft IBM durchweg unsportliches Verhalten vor.¹¹ So verständlich Kasparows persönliche Kränkung vielleicht ist, für den Rest von uns war IBMs symbolischer Sieg keineswegs die finale Niederlage der menschlichen gegenüber der künstlichen Intelligenz. Hinter IBM stand eine Heerschar an Großmeistern und Ingenieuren, die all ihr Wissen über KI und Schach in die Entwicklung von Deep Blue gesteckt hatten. Gegen sie hatte Kasparow eigentlich verloren.

¹⁰ Kasparow (2017), S. 195f.

¹¹ Kasparow (2017), S. 214-220; Levy (2017).

Lernen wie Gehirne

Stellen Sie sich vor, Sie erforschen Insekten und beobachten auf Ihrer Forschungsreise das Zusammenleben von zwei Käferarten. Die einen Käfer haben einen einfarbigen, braunen Körper. Die anderen sehen sehr ähnlich aus, lassen sich aber gut an den glänzenden Punkten auf ihrem sonst braunen Rücken erkennen. Wie Ameisen laufen diese Käfer geschäftig auf Duftpfaden zwischen verschiedenen Futterquellen hin und her. Treffen zwei Exemplare aufeinander, drängeln sie sich einfach aneinander vorbei. Doch dann sehen Sie plötzlich ein ungewöhnliches Schauspiel: Einer der Käfer macht so etwas wie einen Knicks und bleibt so lange regungslos stehen, bis der andere außer Sichtweite ist. Nachdem Sie die Käfer geduldig über eine längere Zeit beobachtet haben, erkennen Sie die Regel, die diesem ungewöhnlichen Verhalten zugrunde liegt. Wenn einer der einfarbigen Käfer auf einen größeren Käfer mit glänzenden Punkten trifft, dann macht er einen Knicks. Sonst nicht.

Als Mensch kann man in dieses Verhalten viel hineininterpretieren. Vielleicht ist der Knicks eine Ehrerbietung gegenüber den größeren Käfern. Oder die einfarbigen Käfer haben schlicht Angst und der Knicks ist eine Unterwerfungsgeste. Mit solchen Erklärungen muss man aber vorsichtig sein. Wir Menschen neigen dazu, zu viel zu psychologisieren. Versuchsteilnehmer, denen man zum Beispiel einen Film zeigt, in dem sich ein Dreieck und ein Quadrat kreisförmig umeinander drehen oder in dem das Dreieck und das Quadrat sich hintereinander herbewegen, sprechen ganz natürlich über die geometrischen Formen, als ob sie Personen wären: Sie haben zusammen getanzt und sich gefreut oder der eine hatte Angst und ist vor dem anderen weggelaufen. Obwohl die Versuchsteilnehmer nur sich bewegende geometrische Formen sehen, schreiben sie den Formen spontan ein psychisches Innenleben zu, um ihr Verhalten zu erklären. Genauso wie bei tanzenden Dreiecken und bei sprechenden Computerprogrammen ist die Versuchung groß, auch

das Verhalten unserer Käfer durch psychische Zuschreibungen zu erklären.¹

Tatsächlich gibt es aber eine viel einfachere, mechanistische Erklärung für das sonderbare Knicksverhalten der Tiere. In Australien lebt ein Käfer, der den Käfern in unserem Gedankenexperiment ähnlich ist. Die Deckflügel von weiblichen »Julodimorpha Bakewelli« sind braun und auffällig glänzend gepunktet. Immer wenn ein Männchen diese Punkte sieht, versucht es das Weibchen zu begatten. Das Insekt hat einen Detektor für glänzende Punkte, um eine bestimmte Verhaltensweise auszulösen. Dummerweise ist die Farbe des Weibchens dem Braun einer Bierflasche sehr ähnlich und die Knubbel am Boden der Bierflasche glänzen noch verlockender als die Punkte des Weibchens. Achtlos weggeworfene Bierflaschen in der australischen Wüste werden so zur Liebesfalle für männliche Käfer, die wieder und wieder Bierflaschen besteigen, bis sie entweder verhungern oder von räuberischen Wüstenameisen aufgefressen werden.²

Die Käfer, die Sie beobachtet haben, besitzen also so einen Detektor für glänzende Punkte. Außerdem haben sie einen weiteren Detektor, der feststellt, ob der Käfer, der ihnen entgegenkommt, größer ist als sie selber (zum Beispiel, weil sie hochschauen müssen). Im Verlauf Ihrer Käferstudie vermuten Sie, das Knicksverhalten des Insekts wird gerade immer dann ausgelöst, wenn der Punkt-Detektor und der Größer-Detektor anschlagen. Aber wie würde das im Detail funktionieren?

1 Die klassische Studie dazu stammt von Heider & Simmel (1944). Im Internet finden sich viele Videos dieser Studie und es lohnt sich, diese anzuschauen, um einen Eindruck davon zu bekommen, wie leicht man einfachen geometrischen Formen ein komplexes, psychisches Innenleben zuschreibt. Braitenberg (1984) beschreibt verschiedene Gedankenexperimente, die zeigen, dass sich Verhalten oft auch viel einfacher erklären lässt. Das Käferbeispiel ist von seinen Gedankenexperimenten inspiriert.

2 Siehe Gwynne & Rentz (1983) für den Käfer und die Bierflaschen und Lettvin, Maturation, McCulloch & Pitts (1959) für ähnliche Auslöser beim Frosch. Ich habe zuerst bei Hoffman (2009) von *Julodimorpha Bakewelli* gelesen.

Wie Nervenzellen rechnen

Käfer haben – so wie wir Menschen – ein Nervensystem, das ihr Verhalten steuert. Nervensysteme bestehen aus spezialisierten Nervenzellen, auch Neurone genannt, die untereinander elektrische Signale austauschen. Diese Signale sind digitale Signale: Jedes Neuron kann nur an oder aus sein. Eins oder Null. Wenn ein Neuron an ist, dann sendet es einen elektrischen Impuls, ein sogenanntes Aktionspotenzial, an andere Neurone, mit denen es verschaltet ist.³ Man sagt: Das Neuron feuert.




Abb. 4: Drei neuronale Netze

In Abbildung 4a ist eine einfache Verschaltung von drei Neuronen zu sehen. Eine solche Verschaltung von mehreren Neuronen nennt man ein »neuronales Netz«. Das Neuron P ist der Punkt-Detektor. Sieht das Insekt glänzende Punkte, schaltet sich der Punkt-Detektor an und das Neuron sendet ein elektrisches Signal an das Ausgabeneuron, mit dem es verschaltet ist. Neuron G, der Größer-Detektor, schaltet sich wiederum nur an, wenn der entgegenkommende Käfer größer ist. Dann sendet auch Neuron G ein elektrisches Signal an das Ausgabeneuron. Doch das Ausgabeneuron schaltet sich nur an, wenn die Summe aller Signale, die bei ihm ankommen, größer als der Schwellenwert 1,5 ist. Falls das passiert, wird das Knicksverhalten des Insekts ausgelöst. Solche einfachen Neurone nennt man auch McCulloch-Pitts-Zellen – nach den zwei theoretischen Hirnforschern, die sie zuerst untersucht haben.⁴

3 Wobei jedes Aktionspotenzial aussieht wie jedes andere, ganz wie bei digitalen Signalen in technischen Systemen. Obwohl die allermeisten Neurone diesem Alles-Oder-Nichts-Gesetz folgen, gibt es bei Insekten recht häufig auch graduierte Potenziale bei denen die Stärke des Signals variiert. Das deutet auf eine analoge Signalverarbeitung hin.

4 Bei Piccinini (2004) findet sich eine hervorragende Darstellung der Originalarbeit von McCulloch & Pitts (1943) im historischen und philosophischen Kontext.

Schickt nun nur Neuron P ein Signal an das Ausgabeneuron ($P=1$ und $G=0$), kommt beim Ausgabeneuron nur ein Signal der Stärke 1 an. Und da das kleiner als der Schwellenwert 1,5 ist, schaltet sich das Ausgabeneuron nicht an, und der Knicks wird nicht ausgelöst. Wenn aber P und G beide feuern ($P=1$ und $G=1$), dann ist die Eingabe $1+1=2$ größer als 1,5 und das Ausgabeneuron schaltet sich an. Dieses neuronale Netz in Abbildung 4a ist eine UND-Verschaltung: Das Ausgabeneuron schaltet sich nur an, wenn Neuron P und Neuron G angeschaltet sind. Der Knicks passiert nur, falls der entgegenkommende Käfer Punkte hat und größer ist.

Neurone können auch so verschaltet sein, dass sie sich wie ein logisches ODER verhalten. Die effektive Verschaltung in einem neuronalen Netz ändert sich mit den ›Verbindungsstärken‹. Ist die Verbindungsstärke zwischen Neuron P und dem Ausgabeneuron doppelt so groß (+2, wie in dem Netz in Abbildung 4b), ist das Signal, das P schickt, sobald es angeschaltet ist, doppelt so stark. Bei einem Schwellenwert von 1,5 reicht dann die Aktivität von P alleine aus, um das Ausgabeneuron anzuschalten (denn bei $P=1$ und $G=0$ ist mit einer Verbindungsstärke von 2 die Summe $2+0=2$ größer als 1,5). Da die Verbindungsstärke von G zum Ausgabeneuron in Abbildung 4b auch verdoppelt ist, feuert das Ausgabeneuron ebenso, falls nur G an ist. Senden beide Eingabeneurone Signale, schaltet sich das Ausgabeneuron sowieso an (denn $2+2=4>1,5$). Lediglich wenn gar kein Signal ankommt, bleibt es ausgeschaltet. Das Insekt macht also einen Knicks, wenn der entgegenkommende Käfer Punkte hat oder größer ist (das logische ODER schließt den Fall, dass der Käfer Punkte hat und größer ist, mit ein).

Andere Verbindungsstärken und Schwellenwerte führen dazu, dass das neuronale Netz sich nach anderen logischen Regeln verhält. In dem Netz in Abbildung 4c ist die Verbindungsstärke von P zum Ausgabeneuron +1 und die von G zum Ausgabeneuron -1. Der Schwellenwert am Ausgabeneuron beträgt in diesem Beispiel 0,5. Hier schaltet sich das Ausgabeneuron nur ein, wenn allein P ein Signal sendet ($P=1$ und $G=0$ ergibt 1 und ist größer 0,5). Feuert G, wird die Eingabe so stark gehemmt, dass P keinen Effekt hat ($P=0$ und $G=1$ führt zu $0-1=-1<0,5$ und $P=1$ und $G=1$ zu $1-1=0<0,5$). Das Insekt macht nur dann einen Knicks, falls der entgegenkommende Käfer Punkte hat, nicht aber, wenn er größer ist. Die logische Regel ist also P UND NICHT G.




Abb. 5: Ein mehrschichtiges neuronales Netz

Bauen wir neuronale Netze künstlich nach, können wir die Verbindungen und Schwellenwerte so einstellen, dass die Netze sich nach beliebigen logischen Regeln verhalten. Mit größeren Netzen lassen sich kompliziertere logische Regeln ausführen, die wiederum komplizierteres Verhalten erzeugen. Je komplizierter die Regel, desto größer muss jedoch das Netz sein. Ein Netz, in dem Neuronen in mehreren Schichten hintereinander geschaltet sind, nennt man ein »mehrschichtiges« oder »tiefes neuronales Netz«.⁵ (Hausaufgabe: Was berechnet das mehrschichtige Netz in Abbildung 5?) In Fällen, in denen ein Ausgabeneuron Signale von einem Neuron empfängt, aber auch selber (eventuell indirekt) Signale an dieses Neuron sendet, spricht man von einem »rekurrenten« Netzwerk. Mit rekurrenten neuronalen Netzen lassen sich noch kompliziertere Regeln implementieren.

Es ist kein historischer Zufall, dass ähnliche logische Verschaltungen in Computern verbaut sind. Auch Computer rechnen digital mit Einsen und Nullen: Der Strom ist entweder an oder aus. Statt aus Neuronen bestehen die Schaltkreise zwar aus Transistoren, das Grundprinzip ist aber dasselbe wie bei McCulloch-Pitts-Zellen. Als Warren McCulloch und Walter Pitts in den frühen 1940er Jahren an ihrer neuen Theorie des Nervensystems gearbeitet haben, waren sie natürlich bestens mit Turings Arbeiten zur Turingmaschine vertraut. Sie erkannten sofort, dass man mit einem neuronalen Netz die Verhaltensregeln implementieren kann, mit denen sich eine Papier-und-Bleistift-Maschine steuern lässt. Ein künstliches neuronales Netz, das mit Sensoren und Motoren auf Papier liest und schreibt, ist eine Turingmaschine – und diese Maschine ist genauso mächtig wie ein moderner Computer mit genügend Speicher. Aber was genau mehrschichtige, rekurrente neuronale Netze ohne zusätzlichen Speicher berechnen können, war zunächst noch unklar und stimulierte wichtige Grundlagenforschung zur

5 Auf Englisch »multilayer« oder »deep neural network«.

Automatentheorie (zur Erinnerung: der Begriff ›KI‹ war von Anfang an umstritten und der Informationstheoretiker Claude Shannon bevorzugte den langweiligeren Begriff ›Automatenstudien‹). Die Computertechnik beeinflussten McCulloch und Pitts aber auch deshalb, weil ihre Ideen in den bahnbrechenden Bericht einfließen, in dem John von Neumann 1945 die grundlegende Architektur heutiger Computer entwarf und dabei eine Parallele zwischen logischen Schaltkreisen in Rechenmaschinen und neuronalen Netzwerken im Gehirn zog.⁶

Als wir mit unserer Papier-und-Bleistift-Maschine einfache Denkprozesse – zum Beispiel das Addieren von Zahlen – mit einem mechanischen Apparat nachgebildet haben, dachten wir nicht darüber nach, wie diese Denkprozesse im Gehirn tatsächlich ablaufen. Sicher nicht so wie bei unserer mechanischen Papier-und-Bleistift-Maschine. Ihre inneren »Organe« sind nicht genauso aufgebaut wie ein Gehirn. Auch moderne Mikroprozessoren sind in ihrer Struktur Gehirnen nicht sonderlich ähnlich. Obwohl diese verschiedenen Mechanismen völlig unterschiedlich aussehen, so sind sie doch alle Computer, die irgendwie rechnen.

Sicher, McCulloch-Pitts-Zellen sind eine starke Vereinfachung der Funktionsweise echter, biologischer Neurone. Wir wissen heute viel mehr über Nervenzellen als Warren McCulloch und Walter Pitts in den 1940er Jahren. Nervenzellen sind wesentlich komplexer, als die beiden annahmen. Die Idee, dass Neurone so etwas wie logische Schaltelemente sind, übte dennoch auf die theoretische Hirnforschung historisch einen enormen Einfluss aus. Noch entscheidender war allerdings der Einfluss dieser Idee auf die KI-Forschung. Da Gehirne ähnlich funktionieren wie elektronische Computer, kann man vielleicht nicht nur das menschliche Rechnen, sondern auch all die anderen fantastischen Fähigkeiten von Gehirnen in Computern nachbilden.

6 Siehe Piccinini (2004). Kleene (1951) entwickelt ausgehend von neuronalen Netzen den wichtigen Begriff des »endlichen Automaten«. Siehe Neumann (1993) für den Bericht. Ein aktueller Trend in der KI-Forschung nutzt die alte Einsicht aus, dass künstliche neuronale Netze in Kombination mit einem externen Speicher Turingmaschinen sind, um Computerprogramme zu lernen (Graves et al., 2016).

Wie Menschen und Computer Bilder erkennen

Wie erkennt ein Gehirn zum Beispiel den Buchstaben »A« auf den Seiten dieses Buches? Die Linse des Auges stellt das Bild auf der Netzhaut scharf. Dort sitzen Fotorezeptoren, die das Licht in elektrische Signale umwandeln, so wie das auch in einer digitalen Kamera passiert.




Abb. 6: Mustererkennung mit neuronalen Netzen

In Abbildung 6 stellen die Quadrate die Bildpunkte auf der Netzhaut dar. Vom Auge werden die elektrischen Signale an den visuellen Kortex weitergeleitet, der sich im Hinterkopf befindet. Die Neurone dort detektieren Linien und Kanten verschiedener Orientierungen. Es gibt beispielsweise Neurone, die immer aktiv sind, sobald sich an einer bestimmten Stelle in einem Bild eine horizontale Linie befindet. Zwei solche Beispielsneurone (N2 und N3) sind in der Abbildung über dem »A« zu sehen. Genauso gibt es im visuellen Kortex Neurone für vertikale Linien oder Linien jedes anderen Winkels. In der nächsten Schicht des neuronalen Netzes können dann kleine Linienstücke zu längeren Linien kombiniert werden. Diese Neuronen werden in der Abbildung von dem obersten Neuron (N1) symbolisiert. Der Querbalken ist vielleicht manchmal etwas schief, sodass der Detektor für horizontale Linien nicht anschlägt. Mit einer ODER-Verschaltung von Liniendetektoren leicht unterschiedlicher Winkel kann der Querbalken aber trotzdem erkannt werden. In einer weiteren Schicht können dann die Detekto-

ren für den Aufstrich, den Abstrich und die zwei Querbalken mit einer UND-Verschaltung zu einem A-Detektor zusammengebaut werden.⁷

So erkennt das Gehirn mit einfachen Liniendetektoren und durch mehrschichtige, logische Verschaltungen komplexe Muster. Das funktioniert nicht nur für Buchstaben, sondern auch für ganze Worte, Objekte oder Personen. Die Neurone, die ganz am Ende eines solchen tiefen neuronalen Netzes sitzen, nennen Hirnforscher auch augenzwinkernd Großmutterneurone – denn falls diese Theorie über die Funktionsweise des Gehirns stimmen sollte, müsste es für jede Person, die man kennt, ein solches Neuron geben, und eben auch für die eigene Großmutter. Dieses Großmutterneuron wird gerade genau dann aktiv, wenn Rotkäppchen die Augen, die Ohren und den Mund seiner Großmutter zusammen sieht.⁸

Lange war die Existenz von Großmutterneuronen nur eine theoretische Hypothese. Hinweise darauf, dass die Hypothese tatsächlich stimmen könnte, verdanken wir unter anderem Epilepsie-Patienten. Um den Herd der Anfälle zu finden, werden Patienten in besonders schweren Fällen manchmal Elektroden implantiert, mit denen man die elektrische Aktivität einzelner Gehirnnareale über einen längeren Zeitraum messen kann. Während dieser Beobachtungszeit ließen sich einige Patienten eine große Zahl an Bildern von Prominenten zeigen und bei einem Patienten wurde ein Jennifer-Aniston-Neuron gefunden.⁹ Das ist eine Nervenzelle im Gehirn, die aktiv wird, sobald der Patient ein Bild von Jennifer Aniston sieht. Die Forscherinnen und Forscher zeigten dem Patienten auch Bilder von anderen Prominenten, Häusern und Tieren, aber diese Zelle reagierte nur auf Bilder von Jennifer Aniston. Es scheint also tatsächlich Großmutterneurone im menschlichen Gehirn zu geben. Komischerweise reagierte die Nervenzelle aber nicht, wenn neben Jennifer Aniston auch Brad Pitt auf dem Bild zu sehen war. Vielleicht weil die zwei sich bald trennen sollten? Ob der Patient auch eine Brangelina-Zelle und eine Vaughniston-Zelle hatte, wissen wir leider nicht.

7 Der Aufbau und die Funktionsweise des visuellen Systems sind genauer bei Hubel & Wiesel (1979) beschrieben.

8 Gross (2002) beschreibt die Geschichte der Großmutterneurone.

9 Quian Quiroga, Reddy, Kreiman, Koch & Fried (2005) haben außerdem ein Halle-Berry-Neuron und ein Bill-Clinton-Neuron gefunden.

Die eigene Großmutter zu erkennen ist so mühelos. Wie konnte sich Rotkäppchen nur täuschen lassen? Schauen Sie sich ein Bild im Familienalbum an, wissen Sie sofort, ob Ihre Großmutter darauf zu sehen ist. Aber versuchen Sie mal zu erklären, wie genau Sie das machen. Woher wissen Sie, dass das Ihre Großmutter ist und nicht der böse Wolf? Okay, die Augen, die Ohren und der Mund sind nicht so groß. Aber ist das alles? Was ist mit der Farbe der Augen? Würden Sie merken, wenn die Ohren eine andere Form hätten? Da Sie nicht genau erklären können, wie Sie Ihre Großmutter erkennen, handelt es sich dabei um implizites Wissen – genauso wie beim Fahrradfahren oder bei der Intuition von Schachexperten.

Dementsprechend ist es in den Anfangstagen der KI nicht gelungen, Computersysteme zu bauen, die Gesichter erkennen können. Um ein künstliches neuronales Netz zu programmieren, das Gesichter erkennt, müssen wir genau wissen, welche Detektoren wir dafür brauchen und wie man diese in mehreren Schichten verschaltet. Anders als beispielsweise bei der schriftlichen Addition kennen wir den Algorithmus nicht, mit dem wir Gesichter erkennen. Wenn wir nicht wissen, wie das geht, können wir das einem Computer auch nicht beibringen.

Wie schafft es unser Gehirn, die ganzen Nervenzellen genau so zu verschalten, dass wir unsere Lieben erkennen? Babys kommen nicht schon mit fest verdrahteten Neuronen zur Welt, um ihre Großmütter zu erkennen. Irgendwie muss ihr Gehirn diese Fähigkeit erst erlernen. Die Regeln, nach denen sich ein neuronales Netz verhält, können sich mit den Verbindungsstärken zwischen den Neuronen ändern. Zur Erinnerung: Das Netz in Abbildung 4a ist eine UND-Verschaltung und das Netz in 4b eine ODER-Verschaltung. Der einzige Unterschied liegt in den Verbindungsstärken der Punkt- und Größer-Detektoren beim Ausgabeneuron. Wenn es also im Gehirn einen Mechanismus gibt, mit dem die Verbindungsstärken in so einem Netzwerk automatisch verändert werden, dann passt das Gehirn auch sein Verhalten an. Das neuronale Netz kann auf diese Art lernen.

Neuronale Netze lernen durch Korrektur

Die einfachste Form des Lernens ist das sogenannte »überwachte Lernen«. Beim überwachten Lernen gibt es einen Lehrer, der den Lernprozess begleitet und das Verhalten korrigiert. Das Feedback des Lehrers

muss allerdings nicht besonders elaboriert sein. Es reicht, dass der Lernende durch den Lehrer mitbekommt, ob sein Verhalten richtig oder falsch war.

Wie genau könnte ein solches überwachtetes Lernen in neuronalen Netzen ablaufen? Zurück zu den Käfern mit ihrem außergewöhnlichen Knicksverhalten, die Sie auf Ihrer Forschungsreise entdeckt haben: Ein paar Kilometer weiter beobachten Sie wieder die gleichen Käferarten, doch überraschenderweise sieht das Knicksverhalten ganz anders aus. Diesmal knicksen die einfarbigen Käfer, sobald sie Käfer mit Punkten sehen, die aber nicht größer als sie selber sind. Das neuronale Netz dieser Käfer muss also dem Netz in Abbildung 4c entsprechen (statt dem Netz in 4a wie bei der vorherigen Kolonie). Das Knicksverhalten kann also nicht angeboren sein. Nachdem Sie die Insekten wieder über einen längeren Zeitraum beobachtet haben, fällt Ihnen auf, dass die gerade aus ihrer Puppenhaut geschlüpften, frisch erwachsenen Käfer sich tatsächlich noch nicht an die Knicksregel halten. Sie lernen sie erst nach ein paar Zusammentreffen mit anderen Käfern. Ihnen fällt außerdem auf, dass Käfer, die sich nicht an die richtige Knicksetikette halten, sofort angegriffen werden. Und Sie schließen daraus, dass junge Käfer offenbar durch diese recht direkte Rückmeldung erfahren, dass sie einen Fehler gemacht haben und so lernen, ihr Verhalten entsprechend anzupassen.

In unserem Gedankenexperiment besteht das Nervensystem der Käfer dank Evolution aus den zwei Eingabeneuronen, die Punkte und Größe detektieren, und dem Ausgabeneuron, das den Knicks auslösen kann. Die Verbindungsstärken zwischen den Detektor-Neuronen und dem Knicks-Neuron sind aber nicht durch die Evolution fest voreingestellt, sondern passen sich erst durch Erfahrung an die Umwelt an. Das Gleiche gilt für den Schwellenwert. Zu dem Zeitpunkt, an dem die Käfer aus ihrer Puppenhaut schlüpfen, sind die Verbindungsstärken in ihrem neuronalen Netz alle 0 und der Schwellenwert bei 1,5, so wie in Abbildung 7a. Dann trifft der Jungkäfer auf einen Käfer mit Punkten, der nicht größer als er selber ist ($P=1$ und $G=0$). Neuron G bleibt inaktiv und Neuron P sendet ein Signal an das Ausgabeneuron, aber da die Verbindungsstärke 0 ist, kommt beim Ausgabeneuron nichts an und der Schwellenwert von 1,5, bei dem ein Knicks ausgelöst wird, wird nicht überschritten. Der Käfer macht also fälschlicherweise keinen Knicks und die anderen Käfer attackieren ihn deshalb. Doch aus diesem Fehler kann er lernen.




Abb. 7: Veränderung eines Netzes durch Korrektur

Was ist also im neuronalen Netz schiefgegangen? Und wie kann ein Lernalgorithmus das Netzwerk so anpassen, dass zukünftig keine Fehler mehr gemacht werden?¹⁰ Die aggressive Reaktion der anderen Käfer bedeutet, dass es falsch war, dass das Ausgabeneuron inaktiv blieb. Es hätte feuern und einen Knicks auslösen müssen. Entweder war die Verbindungsstärke zwischen Neuron P und dem Ausgabeneuron also zu schwach oder der Schwellenwert zu hoch. Versuchsweise erhöht der Lernalgorithmus deshalb die Verbindungsstärke von Neuron P von 0 auf 1 und senkt den Schwellenwert von 1,5 auf 0,5. Das neue Netz sieht jetzt aus, wie das Netz in Abbildung 7b. Das nächste Mal, wenn der Käfer auf einen gepunkteten Kollegen trifft, der nicht größer ist ($P=1$ und $G=0$), sendet Neuron P ein Signal der Stärke 1. Das Signal übersteigt den Schwellenwert von 0,5 und der Käfer macht diesmal richtigerweise einen Knicks.

Unglücklicherweise trifft der Käfer danach auf einen größeren Käfer mit Punkten ($P=1$ und $G=1$) und Neuron P löst einen Knicks aus, egal was Neuron G macht, weil die Verbindungsstärke für Neuron G immer noch 0 ist. Wieder wird der Käfer angegriffen. Diesmal, weil er einen Knicks macht, den er nicht hätte machen sollen. Entweder war also die Verbindungsstärke zu groß oder der Schwellenwert zu klein. Der Lernalgorithmus macht daher im nächsten Schritt alle Verbindungsstärken der Detektoren, die aktiv waren, um 1 kleiner und erhöht auch den Schwellenwert um 1. Das Netz sieht jetzt so aus wie in Abbildung 7c.

Durch diese Änderung macht der Käfer aber wieder einen Fehler, sobald er auf einen gepunkteten Kollegen trifft, der nicht größer als er selber ist ($P=1$ und $G=0$). Er macht keinen Knicks und wird deshalb angegriffen. Der Lernalgorithmus erhöht daraufhin die Verbindungsstärke von Neuron P wieder von 0 auf 1 und senkt den Schwellenwert

10 Im Folgenden wird der ›Perzeptronlernalgorithmus‹ beschrieben, der auf Rosenblatt (1958) zurückgeht.

wieder von 1,5 auf 0,5 (die Verbindungsstärke von G wird nicht angefasst, weil $G=0$ war und daher keinen Einfluss hatte). Mit diesen Änderungen sieht das neuronale Netz so aus wie das Netz in Abbildung 7d. Dieses Netz hat die Regel gelernt, dass nur ein Knicks gemacht wird, falls der andere Käfer Punkte hat, nicht aber, wenn er größer ist. Der Käfer macht jetzt keine Fehler mehr.

Stellen Sie sich vor, Sie besuchen eine fremde Kultur, in der jeder vor kleineren Menschen einen Knicks macht. Man muss Ihnen diese Regel nur einmal erklären und Sie wissen sofort, wie Sie sich verhalten müssen. Was aber, wenn Ihnen niemand die Regel verrät und Sie stattdessen böse Blicke ernten, wenn Sie sich falsch verhalten? Sie würden sich wahrscheinlich so ähnlich verhalten wie die Käfer in unserem Gedankenexperiment. Sie würden verschiedene Regeln ausprobieren und so lange bei einer Regel bleiben, bis Sie einen Fehler machen. Dann würden Sie versuchen, die Regel anzupassen, um Ihren Fehler zu korrigieren. Nichts anderes machen Lernalgorithmen: Sie suchen Regeln, die möglichst wenige Fehler machen. Auch Lernalgorithmen sind Suchalgorithmen!¹¹

Traditionellen Computerprogrammen werden die Regeln, nach denen sie sich verhalten sollen, fest einprogrammiert. Lernende Computerprogramme können ihr Verhalten – oft mit Unterstützung eines Lehrers – selbständig anpassen. Man spricht dann von »maschinellern Lernen«. Maschinelles Lernen ist gerade dann von Vorteil, wenn man zwar das richtige Verhalten kennt, aber nicht weiß, wie es eigentlich zustande kommt. Zum Beispiel, wenn es darum geht, Ihre Großmutter auf einem Bild zu erkennen. Da es sich dabei um implizites Wissen handelt, können Sie keinem Computer erklären, wie er das machen soll. Ihr Gehirn macht das zwar nach bestimmten Regeln, Sie kennen diese Regeln aber nicht. Sie können allerdings einem Lernalgorithmus viele Beispielfotos zeigen, auf denen Ihre Großmutter mal zu sehen ist und mal nicht. Der Lernalgorithmus findet durch dieses Training von alleine Regeln, mit denen er Ihre Großmutter erkennen kann. Diese Regeln werden äußerst kompliziert sein und viele Ausnahmen haben.

In Fällen, in denen Regeln nicht perfekt sind, spricht man von »statistischen Regeln«, die nicht immer, aber oft gelten. Der Lernalgo-

11 Ein ganz ähnliches Beispiel wird auch von Bruner, Goodnow & Austin (1956) diskutiert, die die Algorithmen untersucht haben, nach denen Menschen in solchen Situationen Regeln lernen.

rithmus findet in solchen Fällen keine fehlerlose Regel, sondern eine, die möglichst wenige Fehler macht. Das ändert aber nicht viel für die Lernalgorithmen, deren Ziel es immer noch ist, die Anzahl der Fehler zu minimieren. Statistische Regeln, die auf diese Weise gelernt wurden, erkennen Muster in der Eingabe, die helfen, die richtige Antwort vorherzusagen. Alle modernen Programme zur Mustererkennung – sei es zur Gesichtserkennung, Buchstabenerkennung, Objekterkennung oder Spracherkennung – funktionieren genau so. Zwar gibt es viele verschiedene Arten von maschinellen Lernalgorithmen in der KI, aber meist basieren diese zurzeit auf tiefen neuronalen Netzen.

Diese künstlichen neuronalen Netze haben nicht selten Tausende von Neuronen in vielen Schichten mit Millionen von Verbindungen. Und mit leistungsfähigeren Computern werden es immer mehr. Dadurch ist es äußerst schwer zu verstehen, warum ein Netz sich so verhält, wie es sich verhält. Zwar waren es die Entwickler, die den Lernalgorithmus programmiert und dem Netzwerk im Training viele Beispiele gezeigt haben, wie es sich richtig verhalten soll, aber auch die Entwickler können sich unmöglich die unzähligen Neuronen und alle Verbindungsstärken ansehen, um das Netz wirklich zu verstehen (wie wir das in unserem Gedankenexperiment gemacht haben, in dem es nur drei Neurone gab). Obwohl das Netz bestimmten Regeln folgt, die präzise im Computer spezifiziert sind, können wir diese Regeln aufgrund ihrer Komplexität nicht nachvollziehen. Wir können also nicht darauf hoffen, dass so ein künstliches neuronales Netz uns helfen kann zu erklären, wie wir unsere Großmutter erkennen. Dieses Wissen bleibt auch in künstlichen neuronalen Netzen implizit!

Obwohl künstliche neuronale Netze ursprünglich mal von Gehirnen inspiriert waren und sie inzwischen einige menschliche Fähigkeiten imitieren können, darf man sie nicht vorschnell mit menschlichen Gehirnen gleichsetzen. Nur weil ein künstliches neuronales Netz auf ein paar Fotos meine Großmutter erkennen kann, heißt das nicht, dass das Netz das genauso macht wie ich. Vielleicht erkennt das Netz nur die Nase. Solange man dem Netz keine Bilder zeigt, auf denen die Nase verdeckt ist oder jemand anderes eine ähnliche Nase hat, bemerkt man den Unterschied nicht. Tatsächlich verhalten sich neuronale Netze auf bestimmten Bildern, auf die sie nicht trainiert worden sind, oft ganz anders als Menschen. Eine meterhohe Zahnbürste wird zum Beispiel von Menschen trotz ihrer Größe leicht übersehen. Menschen rechnen einfach nicht mit Riesenzahnbürsten. Neuronale Netze sind aber extra

so konstruiert, dass sie Objekte erkennen, egal wie groß sie sind. Umgekehrt lassen sich neuronale Netze von verzerrten und verschmutzten Bildern mehr und anders verwirren als Menschen. Die Lektion, die wir von ELIZA gelernt haben, gilt auch hier: Man sollte Computern nicht vorschnell menschliche Intelligenz zuschreiben. Auch wenn ihre Fähigkeiten beeindruckend sind, ist ihre Intelligenz eine andere als unsere.¹²

Nichtsdestotrotz sind die Netze darauf trainiert, auf den meisten Bildern möglichst die Objekte zu erkennen, die wir Menschen erwarten. Damit ein neuronales Netz lernen kann, die Großmutter zu erkennen, muss erst vorher ein Mensch Beispielbilder markieren, auf denen die Großmutter zu sehen ist. Und wenn das Netz einen Fehler macht, wird die Antwort korrigiert und der Lernalgorithmus passt das Netz entsprechend an.

Für die Spracherkennung von Google, Amazon und Apple hör(t)en deshalb Menschen die Mitschnitte von Unterhaltungen mit Siri, Alexa und Co ab, um verbliebene Fehler der Spracherkennung zu korrigieren. Als die Presse über die Mitschnitte berichtete, war es für viele Nutzer ein Schock zu erfahren, dass ihre Gespräche mit KI-Systemen nicht vertraulich sind.¹³ Aber wenn man weiß, wie die Technik funktioniert, ist das keine Überraschung. Hinter den meisten Anwendungen neuronaler Netze stecken viele, viele Stunden Arbeit von Menschen, die mit ihrem impliziten Wissen die Fehler markieren, aus denen die Maschinen lernen. Mittlerweile gibt es eine ganze Industrie, die diese kleinteilige und mühselige Arbeit auf viele Menschen in der ganzen Welt – aus Kostengründen oft in Entwicklungsländern – verteilt.¹⁴

Neuronale Netze lernen auch ohne Lehrer

Kleine Kinder lernen sicher nicht, wie eine Katze oder ein Hund aussieht, indem ihnen die Eltern nacheinander tausende von Katzen- und Hundebilder zeigen und jedes Mal fragen, ob ein Hund oder eine Katze zu sehen ist, um entweder zustimmend zu nicken oder das Kind zu

12 Siehe Eckstein, Koehler, Welbourne & Akbas (2017) für die Riesenzahnbürste und Geirhos et al. (2018) für verschiedene Arten von veränderten Bildern.

13 Erst nachdem die Presse darüber berichtet hatte, wurde diese Verfahrensweise transparent gemacht oder abgestellt (Hurtz, 2019).

14 Siehe Dzieza (2023).

korrigieren. Tiere im Bilderbuch benennen ist eine tolle Beschäftigung, aber wahrscheinlich können schon Babys, die noch nicht sprechen, den Unterschied zwischen Hunden und Katzen sehen – unabhängig davon, ob jemand sie daraufhinweist. Hunde und Katzen sehen nicht nur unterschiedlich aus, sondern verhalten sich auch anders. Das macht es möglich, dass die Unterscheidung zwischen Hunden und Katzen von alleine entdeckt werden kann, ohne dass es dazu einen Lehrer braucht. Den Lehrer braucht es dann nur noch, um die Wörter zu lernen, nachdem das Kind schon erkannt hat, dass es sich um zwei unterschiedliche Tierarten handelt.¹⁵

Ein Kind, das Hunde und Katzen beobachtet, lernt vielleicht, dass bestimmte Merkmale oft zusammen auftreten. Hunde bellen und wedeln mit dem Schwanz, Katzen schnurren, sobald man sie streichelt. Viele Hunde haben Schlappohren, aber Katzen nicht, und so weiter. Das Kind lernt diese statistischen Regelmäßigkeiten, indem es die Merkmale miteinander assoziiert. Wenn es nun einen Hund mit dem Schwanz wedeln sieht, erwartet das Kind, dass er auch bellt.¹⁶

Sie erkennen das »A« in Abbildung 8, obwohl das Bild verschmutzt ist, und nur Teile davon zu sehen sind. Sie wissen genau, was sich hinter dem Tintenklecks verbirgt, weil in Ihrem Gedächtnis alle Merkmale des Buchstabens miteinander assoziiert sind und Ihr Gedächtnis die fehlenden Teile deshalb ergänzen kann. So wie das Kind das Bellen erwartet, wenn es ein Schwanzwedeln sieht.

Lernen ohne Lehrer wird im maschinellen Lernen »unüberwachtes Lernen« genannt und ein Beispiel dafür sind sogenannte »autoassoziative neuronale Netzwerke«. Das sind künstliche neuronale Netze, die die Eingabe mit sich selber assoziieren (daher der Name). Damit ist gemeint, dass das Netz lernt, welche Merkmale der Eingaben mit welchen anderen Merkmalen der gleichen Eingaben oft zusammen auftreten.

15 In Wirklichkeit ist das etwas komplizierter als hier dargestellt. Quinn, Eimas & Rosenkrantz (1993) haben untersucht, wie 3–4 Monate alte Kinder Hunde- und Katzenbilder kategorisieren. Beide sind leicht von Vögeln zu unterscheiden. Katzen sind untereinander sehr ähnlich, sodass sie auch leicht zusammengruppiert werden können. Hunde können allerdings äußerst verschieden aussehen, daher ist es für die Kinder manchmal schwer, Katzen nicht als eine Art von Hund anzusehen.

16 Diese Art von Assoziation, insbesondere zwischen den verschiedenen Sinnen, ist eine alte Idee von empiristischen Philosophen. George Berkeley stellte sich das schon 1709 in *An Essay Towards a New Theory of Vision* so ähnlich vor. In seinem Beispiel war es aber kein Hund, sondern eine Kutsche.

Wie immer in künstlichen neuronalen Netzen bedeutet Lernen, dass die Verbindungsstärke zwischen Neuronen angepasst werden. Die Grundidee ist, dass jedes Neuron in dem Netzwerk ein Merkmal der Eingabe repräsentiert (zum Beispiel das Bellen des Hundes oder den Querbalken des Buchstabens ›A‹). Diese Neuronen sind untereinander verbunden. Wenn zwei Neuronen oft zusammen aktiv sind, stärkt das die Verbindung zwischen den beiden Neuronen. Wird zu einem späteren Zeitpunkt nur eines der zwei Neuronen durch eine Eingabe aktiviert, sorgt die starke Verbindung zwischen den zwei Neuronen dafür, dass auch das andere Neuron aktiviert wird.¹⁷ Die Aktivierung der Neurone für Schwanzwedeln alleine führt dann zur Aktivierung der Neurone für das Bellen – und umgekehrt. Die Aktivierung der Neurone für einzelne Teile eines ›A‹ führt zur Aktivierung der Neurone, die durch den Tintenfleck verdeckt sind.




Abb. 8: Ein Bild mit Tintenklee

¹⁷ Diese Art von Lernen nennt man auch ›Hebb'sches Lernen‹, benannt nach dem Psychologen Donald Hebb, der dieses Prinzip wesentlich klarer und neurowissenschaftlich plausibler beschrieben hat als viele Philosophen vor ihm (Hebb, 1949). Hebb'sches Lernen ist allerdings nicht die einzige Möglichkeit, wie man Lernen in autoassoziativen Netzen umsetzen kann.

Neuronale Netze lieben Katzenvideos

Die Kombination von unüberwachtem Lernen und überwachtem Lernen ist sehr mächtig. Überwachtes Lernen kann extrem aufwendig und kostspielig sein. Damit ein künstliches neuronales Netz den Unterschied zwischen Hunden und Katzen lernen kann, müssen Menschen erst eine unglaublich große Menge an Hunde- und Katzenbildern beschriften. Für viele Anwendungen ist das die Mühe nicht wert. Indem das neuronale Netz unüberwacht viele Bilder aus dem Internet durchsieht, kann es allerdings mit deutlich weniger menschlicher Unterstützung trainiert werden. Es hilft, wenn das Netz schon viele Hunde- und Katzenbilder gesehen hat – sogar, wenn es gar nicht weiß, dass es Hunde und Katzen waren. Es hilft aber auch, wenn es viele andere Bilder gesehen hat, weil es so die statistischen Regelmäßigkeiten in Bildern allgemein lernt. Vielleicht wurde ihm auch schon beigebracht andere Tierarten zu unterscheiden, was das Lernen von Hunden und Katzen zusätzlich vereinfacht. Solch ein vortrainiertes Netz, das allgemein etwas über Bilder gelernt hat, lässt sich dann leichter und billiger an verschiedene Aufgaben anpassen, als wenn man für jede Aufgabe ein neues neuronales Netz trainiert. Wir Menschen fangen ja auch nicht bei jeder neuen Aufgabe bei null an, sondern entwickeln unsere vorhandenen Fähigkeiten weiter.

Der beeindruckende Fortschritt in KI-Anwendungen, den man ungefähr seit 2010 beobachten kann, ist größtenteils dadurch angetrieben, dass künstliche neuronale Netze in vielen Fällen überraschend gut lernen, statistische Muster zu erkennen. Auch Menschen sind oft gut darin, Muster zu erkennen, aber unser Wissen darüber ist implizit. Wir können nicht sagen, nach welchen Regeln wir unsere Großmutter erkennen oder wie genau wir Hunde von Katzen unterscheiden. Das macht es für Entwicklerinnen und Entwickler schwer, traditionelle Computerprogramme für solche Mustererkennungsaufgaben zu schreiben, denn sie können dem Computer nicht Schritt für Schritt Anweisungen geben, wie die Aufgaben zu lösen sind. Besser ist es, ein Computerprogramm zu schreiben, das selbständig aus Beispielen lernt. KI-Forscherinnen und -Forscher basteln daher seit den Anfangstagen der Computer an künstlichen neuronalen Netzen, die lernen können, Muster zu erkennen. Warum sehen wir dann erst über 50 Jahre später funktionierende Gesichts- und Spracherkennung? Das lag daran, dass tiefe neuronale Netze schlicht eine extrem große Menge an Beispielen

brauchen, um ihr implizites Wissen zu lernen – mehrere Millionen Beispiele sind keine Seltenheit.¹⁸ Deshalb mussten erst zwei Entwicklungen zusammenkommen: Zum einen mussten Computer schnell genug werden, um solche großen Datenmengen überhaupt verarbeiten zu können. Zum anderen mussten entsprechend große Datenmengen erst einmal zur Verfügung stehen. Diese Datenmengen finden sich im Internet, wo Nutzer jeden Tag Unmengen an Texten, Bildern und Videos teilen. Wer hätte gedacht, dass all diese Katzenvideos zu etwas gut sein würden.¹⁹

18 Das Training von Netzen zur Objekterkennung geschah zum Beispiel lange gerne mit der Datenbank ImageNet, die etwa 14 Millionen Bilder enthält (Deng et al., 2009).

19 Le et al. (2012) haben zehn Millionen Einzelbilder aus YouTube-Videos extrahiert und ein künstliches neuronales Netz unüberwacht trainiert. Nach dem Training hatte das Netz Neuronen, die selektiv menschliche Gesichter erkennen konnten, weil Gesichter häufig in den Videos vorkamen. Aber Katzen kamen auch häufig vor, weshalb das Netz auch ohne Lehrer gelernt hat, wie Katzen aussehen.

Das Öl des 21. Jahrhunderts

Daten sind das Öl des 21. Jahrhunderts. Ich kann diesen Satz nicht mehr hören. Kein Zeitungsartikel, kein Forschungsantrag und kein Buch zu KI kommt ohne diesen Satz aus. Natürlich stimmt es, dass die großen Internetunternehmen mit Daten eine ungeheure Wertschöpfung schaffen. Sie raffinieren die Rohdaten zu bisweilen nützlichen Produkten wie Internetsuche, Kaufempfehlungen, Routenplaner, Übersetzungsprogramme oder Sprachassistenten. Und die Hoffnung ist, dass andere Branchen nachziehen werden und ebenso aus der Kombination ihrer traditionellen Produkte mit Daten und KI einen Mehrwert erzeugen. Das autonome Fahren ist wahrscheinlich das bekannteste Beispiel.

Der Vergleich hinkt trotzdem, denn anders als Öl, das eine endliche Ressource ist, führt die Digitalisierung dazu, dass wir zunehmend in Daten ertrinken werden. Eine von einem Festplattenhersteller gesponserte Studie schätzt, dass alleine von 2018 auf 2019 die Menge der Daten auf allen Geräten von 33 auf 40 Zettabyte angewachsen ist.¹ Ein Zettabyte sind 10^{21} Bytes. Das heißt, auf jeden der 8 Milliarden Menschen auf der Erde kam schon 2019 eine 5 Terabyte Festplatte (oder etwa 1000 DVDs). 2025 sind es insgesamt wohl 175 Zettabyte. Kein Mensch kann all diese Daten ohne Computerunterstützung sichten oder gar Schlussfolgerungen aus ihnen ziehen. Computer müssen uns mal wieder helfen, Probleme zu lösen, die wir ohne Computer gar nicht hätten. Da trifft es sich gut, dass maschinelle Lernmethoden, wie künstliche neuronale Netze, erst mit richtig vielen Daten gut funktionieren. Wir brauchen mehr Daten, damit die KI besser wird, und wir brauchen mehr KI, damit wir die Daten besser nutzen können. Das ist der Grund, warum die zwei Buzzwords Big Data und KI so gerne zusammen auftreten.

1 Siehe Reinsel, Gantz & Rydning (2018).

Aber wie wird aus großen Datenmengen durch KI Geld gewonnen? Was rechtfertigt die gewaltigen Investitionen in Big Data, um noch mehr Daten zu sammeln, und in KI, um die Daten zu analysieren? Ein 2013 im Netz viel geteilter Post besagte, dass sich die meisten Firmen bei dem Thema Big Data so verhalten wie Teenager beim Thema Sex: »Jeder spricht darüber, keiner weiß, wie es geht, und jeder denkt, alle anderen tun es, also behaupten sie, es auch zu tun.«²

Wie Streaming die Videotheken verdrängte

Netflix war einer der ersten frühreifen Teenager, die wussten, wie es geht. Heute kennt jeder Netflix als einen Streamingdienst, der mehr oder weniger originelle Serien produziert. Eine rein digitale Internet-firma. Aber in seinen Anfangsjahren war das Unternehmen eigentlich nur eine große Videothek, die DVDs per Post verschickte. An Streaming war technisch noch nicht zu denken, dazu war das Internet viel zu langsam. Früher ist man nach der Schule zu seiner lokalen Videothek geradelt und hat sich aus den Regalen ein Video für den Filmabend mit Freunden ausgesucht. Das Angebot war begrenzt und aktuelle Videos meist schon von jemand anderem ausgeliehen. Dafür gab es einen Videothekar (oft ein studentischer Filmfreak), der einem Klassiker empfehlen konnte, die man unbedingt gesehen haben musste.

Netflix erkannte, dass man dank Post und Internet auf die Filialen und den netten Videothekar verzichten und gleichzeitig einen besseren Service bieten kann. Die Videos lagern in großen Hallen und statt in die Filiale zu kommen, bestellen die Kunden die Filme online (daher der weitsichtige Name der Firma). Dadurch kann man eine größere Menge an Filmen anbieten und gleichzeitig mehr Kunden bedienen. Statt in jeder Videothek genügend Kopien eines aktuellen Films bereitzustellen, kann man zentral die Verteilung planen. Netflix hatte außerdem die geniale Idee, dass man nicht für jeden Film einzeln zahlt, sondern ein Abo abschließt. Der Kunde pflegt online in seinem Profil dafür eine Liste von Filmen, die er irgendwann gerne sehen würde. Sobald er eine

2 Das Zitat stammt von dem Bestseller-Autor Dan Ariely. Im Original lautet es: »Big data is like teenage sex: everyone talks about it, nobody really knows how to do it, everyone thinks everyone else is doing it, so everyone claims they are doing it...« (<https://x.com/danariely/status/287952257926971392>).

DVD fertig angeschaut hat, schickt er sie per Post zurück und bekommt eine neue DVD von seiner Liste zugeschickt. Netflix entscheidet aber welche und kann so die verfügbaren DVDs optimal auf seine Kunden verteilen.

Natürlich setzten aber trotzdem viele Kunden gleichzeitig dieselben aktuellen Filme auf ihre Listen. Damit die Kunden sich nicht ärgern, dass sie vielleicht ein paar Wochen auf einen bestimmten Film warten müssen, und damit all die anderen DVDs nicht einfach im Lager herumliegen, brauchte Netflix nun doch einen Videothekar, der einen guten Film als Lückenfüller empfehlen konnte. Also ließ die Firma seine Kunden die Filme, die sie gesehen hatten, bewerten: von einem Stern für einen nicht so guten Film bis zu fünf Sternen für einen großartigen Film. Und maschinelles Lernen sollte mithilfe all diesen Daten voraussagen, welche Filme die einzelnen Kunden mögen. Aus betriebswirtschaftlicher Sicht ist es bei dem Abo-Modell entscheidend, neue Kunden zu gewinnen und alte zu behalten. Dazu muss man den Geschmack seiner Kunden genau kennen.

2006 erregte Netflix bei KI-Forscherinnen und -Forschern große Aufmerksamkeit, als die Firma einen Preis über eine Million Dollar für denjenigen auslobte, dessen Lernalgorithmus es schafft, die Vorlieben der Nutzer um mindestens zehn Prozent besser vorherzusagen als das Unternehmen selber. Der Datensatz, aus dem diese Vorlieben gelernt werden sollten, bestand aus 100 Millionen Filmurteilen – aus heutiger Sicht nicht besonders viel. Ich war damals Doktorand in Tübingen und für Wochen sprachen wir beim Mittagessen über nichts anderes, als welche Methoden man dafür nutzen könnte. Ich bin mir sicher, dass es an anderen Forschungsinstituten nicht anders war. Zwar gab es stetigen Fortschritt und von Monat zu Monat stellten neue Teams neue Rekorde auf, aber es dauerte fast drei Jahre, bis ein Team das Preisgeld einstrich.

Auch wenn Netflix heute keine DVDs mehr verschickt, so will die Firma doch immer noch genau wissen, was den Kunden gefällt. Bei 150 Millionen Abonnenten im Jahr 2019 kommt da ordentlich was an Daten zusammen. Früher bewerteten die Kunden jeden gesehenen Film, um bessere Empfehlungen zu bekommen. Aber durch das Streaming weiß Netflix heute ohnehin genau, welche Filme und Serien welche Kunden in welchen Ländern wie oft und wie lange anschauen. Aufgrund der Erfahrungen, die das Unternehmen schon sehr früh mit maschinellem Lernen gemacht hat, kann man davon ausgehen, dass es genau weiß,

was man mit diesen Daten macht. Herauszufinden, dass es einen australischen Nutzer gibt, der in einem Jahr 352-mal *Madagaskar 3* anschaut hat, ist dabei nur die Spitze des Dateneisbergs.

Den Kunden die Filme empfehlen, die sie mögen werden, ist sehr wichtig für Netflix, weil die meisten Kunden nicht viel länger als eine Minute mit der Filmauswahl verbringen. Kunden, die nicht schnell etwas finden, was ihnen gefällt, können daher auch schnell wieder verloren gehen. Je häufiger die Kunden den Service nutzen, desto unwahrscheinlicher ist es, dass sie das Abo wieder kündigen (ich scheine die Ausnahme zu sein, die gekündigt hat, weil mich das Streamen zu viel Zeit gekostet hat). Angeblich sind die Verbesserungen an dem Filmempfehlungsalgorithmus von Netflix eine Milliarde Dollar pro Jahr wert.³

Empfehlungen für Neukunden sind dabei besonders schwierig, weil Netflix noch wenig über sie weiß. Daher müssen sie zum Einstieg ein paar Filme bewerten. Als ich mein Abo angefangen habe, habe ich mir als Erstes die neue *Star Trek*-Serie angesehen. Der Algorithmus hat im Anschluss lange gebraucht, bis er gelernt hat, dass ich neben Sci-Fi auch gerne Western gucke. Denn für die Analysten gilt gerade die erste Sendung, die Neukunden anschauen, als besonders wichtig, da die es wahrscheinlich war, die den Kunden angelockt hat. Serien die viele Neukunden gewinnen, sind besonders wertvoll, weil es einfacher ist, einen alten Kunden zu behalten, als einen neuen zu gewinnen. Aufgrund der großen Anzahl an Abonnenten und ihrer Nutzungsdaten kann Netflix präzise Marktanalysen machen, noch bevor eine neue Produktion beschlossen wird. Sie wissen vorher schon, wie groß der Markt für Kunden ist, die Sci-Fi und Western mögen, und deshalb wahrscheinlich für ein Crossover empfänglich sind (ich persönlich ziehe ja die *Serenity* der *Enterprise* vor). Netflix muss daher nicht nur den Mainstream bedienen, sondern kann auch für Nischengeschmack im Voraus abschätzen, welche Produktionen wie viele Zuschauer haben werden und vielleicht sogar neue Kunden anziehen.

Datengetriebene Firmen wie Netflix sammeln aber nicht nur Daten und analysieren sie. Sie nutzen den konstanten Datenstrom, um sich stetig zu verbessern. Dazu machen sie auch gezielt Experimente. Potenzielle Verbesserungen am Empfehlungsalgorithmus, der Benutzeroberfläche oder der ›Filmposter‹ können in einer repräsentativen

3 Siehe Gomez-Urbe & Hunt (2015).

Gruppe mit den alten Varianten verglichen werden. Das nennt man auch »A/B-Test«. Oft kriegen mehrere Gruppen – ohne, dass sie das merken – verschiedene neue Varianten. Nur falls in einer Gruppe signifikant länger Filme geschaut werden und weniger Kunden verloren gehen, werden die Änderungen an alle Kunden ausgerollt. Dieser Prozess kann weitgehend automatisiert werden. Ein KI-Programm kann selbständig mögliche Varianten auf Testgruppen verteilen, deren Effekt beobachten und so selbständig effizient nach der besten Variante suchen. Schon wieder ein Suchproblem! Je mehr Kunden Netflix hat, desto größer ist der Nutzen selbst kleiner Verbesserungen. Und je mehr Kunden man hat und je mehr Daten man deshalb sammeln kann, desto mehr Experimente kann man auch automatisiert durchführen, um selbst kleine Verbesserungen zu finden.

Es würde mich nicht wundern, wenn dieser datengetriebene Ansatz bei Netflix nicht nur zur Weiterentwicklung ihres Filmempfehlungsalgorithmus genutzt wird. Vor einer Weile habe ich an den Bushaltestellen auf dem Weg zur Arbeit Werbetafel für die neue Staffel *Stranger Things* gesehen. Vielleicht wurde in einer anderen Stadt eine andere Serie beworben oder vielleicht wurde in einer weiteren Stadt überhaupt nicht für Netflix geworben. Da das Unternehmen weiß, in welcher Stadt die Kunden gerade ihre Sendungen streamen, kann es den Effekt von Außenwerbung auf die Anzahl ihrer Neukunden und die gesehenen Sendungen sofort in seinen Daten sehen. Netflix würde wahrscheinlich keine Außenwerbung nutzen, wenn die Daten nicht zeigten, dass sie funktioniert.

Das Geschäftsmodell von Netflix beruht darauf, Filme und Serien anzubieten. Ohne Rechte an interessanten Inhalten wäre das Unternehmen nicht so erfolgreich. Aber ohne Digitalisierung und intelligente Datenanalyse eben auch nicht. Netflix hat auf diese Weise das klassische Geschäftsmodell der Videothek revolutioniert. Maschinelle Lernalgorithmen spielten dabei eine wichtige Rolle. Aber hat die Firma deshalb künstliche Intelligenz eingesetzt? Man könnte auch weniger reißerisch von computergestützter Statistik sprechen. Zwar kommen manche Methoden, wie neuronale Netze, aus der KI-Forschung, aber im Grunde geht es nur um die automatische Verarbeitung von statistischen Daten mit der Hilfe von Computern. Eigentlich braucht man nur Kenntnisse in Mathematik, Statistik und Informatik, wie sie jeder Ingenieur und jede Ingenieurin am Anfang des Studiums lernt, um Nutzen aus diesen Methoden zu ziehen. Statt von KI sprechen daher

viele Leute in solchen Fällen lieber von »Data Science«, dem Feld genau an dieser Schnittstelle zwischen Statistik und Informatik. In einem Aspekt geht das, was Netflix macht, aber scheinbar über normale Statistik hinaus. Der Computer wird nicht nur genutzt, um die Daten zu speichern und Statistiken zu berechnen. Der Empfehlungsalgorithmus lernt die Kunden von alleine besser kennen und trifft außerdem selbständig Entscheidungen und handelt entsprechend. Er ersetzt den Videothekar. Diese Personifizierung des Algorithmus lässt die Digitalisierung und Automatisierung von Geschäftsprozessen glamouröser erscheinen als sie in Wirklichkeit ist. Kein Wunder, dass so häufig von KI gesprochen wird.

Der Handel braucht Daten

Mehrere Jahre vor Netflix hat Amazon in ähnlicher Weise den Buchhandel revolutioniert. Natürlich sammelte auch der traditionelle Buchhandel in den Fußgängerzonen schon immer Daten darüber, wie viele und welche Bücher er wann verkauft. Eine penible Buchführung und aussagekräftige Statistiken helfen bei der Planung und Steuerung jedes Geschäftes. Schließlich müssen neue Bücher nachbestellt werden, bevor die Regale leer sind. Am besten die, die die Kunden kaufen wollen. Ein Kunde, der nicht findet, was er sucht, kauft woanders ein. Vielleicht online bequem von zu Hause. Amazon hat durch seine enorme Größe und seine Lagerhallen natürlich den Vorteil, wesentlich mehr Bücher vorhalten zu können als der kleine Buchladen an der Ecke. Da man aber auch im Buchladen die meisten Bücher für den nächsten Tag bestellen kann, kann das nicht Amazons einziger Vorteil sein. Durch seine Größe sieht Amazon auch schneller und besser, was am Markt passiert. Da der stationäre Buchhandel neben ein paar großen Ketten aus vielen kleinen Händlern besteht, weiß erst mal niemand genau, wie viele Exemplare eines bestimmten Romans aktuell gerade verkauft werden. Die *Spiegel*-Bestsellerliste wird daher aufwendig durch Abfragen bei vielen, vielen Buchhändlern bestimmt.⁴ Amazon weiß hingegen sofort, was gerade auf seiner Plattform gut geht – und versorgt den Kunden automatisch mit den entsprechenden Vorschlägen.

4 Siehe <https://www.buchreport.de/spiegel-bestseller/ermittlung-der-bestseller/>.

Nach dem Buchhandel expandierte Amazon in viele andere Branchen. Heute kann man bei Amazon fast alles bestellen. Was Amazon nicht selber im Sortiment hat, bieten andere Händler über Amazons Plattform an. Über diese Plattform beobachtet Amazon auch den Teil des Marktes, den sie selber (noch) nicht direkt bedienen. Dieses Wissen kann ein gewisser Vorteil bei der Planung des eigenen Sortiments sein. Insbesondere, wenn Algorithmen das Sortiment automatisch analysieren und Vorschläge für Verbesserungen machen. Für Kunden, die fast alles bei Amazon kaufen, kann Amazon außerdem detaillierte Profile erstellen: Was hat ein Kunde, der den neuen Harry Potter gekauft hat, noch gekauft? Braucht er vielleicht Rasierseife oder Mascara? Obwohl der Empfehlungsalgorithmus von Amazon manchmal spektakulär daneben liegt, liegt er manchmal auch erschreckend richtig. Und die richtige Empfehlung verführt den Kunden vielleicht zu einem Impulskauf. Sucht er etwas Bestimmtes, ist es auch besser, er findet es schnell, denn sonst sucht er vielleicht woanders weiter. Da Amazon wie Netflix sehr, sehr viele Kunden hat, kann selbst eine kleine Verbesserung des Empfehlungsalgorithmus zu sehr viel mehr Verkäufen führen – auch, wenn der Algorithmus nicht perfekt ist.

Das gleiche gilt selbstverständlich ebenso für große Handelsketten mit echten Geschäften in Fußgängerzonen oder am Stadtrand. Im Vergleich zu Amazon haben sie einen Nachteil: Sie können die Daten von einem Einkauf nicht ganz so leicht dem nächsten Einkauf zuordnen. Gut, dass es Kundenkarten gibt. Mit einem Kundenprofil kann man auch traditionelle Papierwerbung auf die Kunden zuschneiden. Die Offline-Variante von Online-Empfehlungen. Eine Supermarktkette in den USA fand zum Beispiel heraus, dass schwangere Frauen mehr geruchlose Hautcremes, Wattebällchen und große Handtaschen, in die auch Windeln passen, kaufen. Gestresste junge Eltern, die Windeln in einem Laden kaufen, machen den Rest des Einkaufs auch gleich dort. Junge Eltern in die eigenen Läden zu lotsen, ist daher sehr lukrativ. Kann aber auch Ärger machen. In Minnesota platzte ein empörter Vater einer Teenagerin wütend in seine Filiale und regte sich darüber auf, dass seiner minderjährigen Tochter Coupons für Babyklammotten geschickt wurden. Als sich ein Mitarbeiter später telefonisch dafür entschuldigen wollte, entschuldigte sich der Vater für seinen Wutaus-

bruch, denn seine schwangere Tochter konnte die Coupons tatsächlich gut gebrauchen.⁵

Eine bekannte Erfahrung im Internet ist, dass uns Hundefutterwerbung auf dem Computer in der Arbeit angezeigt wird, kurz nachdem wir auf dem Handy einen Artikel über Dackel gelesen haben. Komischer Zufall. Dass man Menschen im Internet über verschiedene Geräte hinweg verfolgen kann, um ein Profil über sie zu erstellen, überrascht wahrscheinlich niemanden mehr.⁶ Da es aber um so private Informationen wie eine Schwangerschaft geht, kann es die eine oder andere vielleicht doch schaudern, dass es der Supermarkt auch schon weiß. Um ein PR-Desaster abzuwenden, würde ich ja die Coupons für Babykleidung ganz unauffällig unter andere Coupons mischen.

Keinen Spaß würden die Kunden wahrscheinlich auch bei bestimmten Arten des ›Dynamic Pricing‹ verstehen. Dass die Preise an Tankstellen und die Preise für Flüge mittlerweile mehrmals täglich ganz automatisch durch Algorithmen an die aktuelle Marktsituation angepasst werden, ist eine verständliche Folge von in Echtzeit verfügbaren Daten und Analysen. Falls nun ein Kunde aufgrund seines Profils wahrscheinlich bereit ist, mehr für ein Produkt zu zahlen, warum den Preis dann nicht extra für ihn hochsetzen? Der Preis ist dann personalisiert und hängt nicht nur von Angebot und Nachfrage ab, sondern vielleicht auch von der Postleitzahl, der Marke des Mobiltelefons, dem Alter, dem vermuteten Einkommen, dem Suchverlauf, seinen früheren Einkäufen oder wer weiß was noch. So eine personalisierte Preisanpassung ist online durch Algorithmen leicht zu bewerkstelligen, und wenn der Kunde es aufgrund der ohnehin schwankenden Preise nicht merkt, dann kann er sich auch nicht besonders empören.

Von der Dating-App Tinder ist bekannt, dass sie die Preise für ihren Premiumdienst automatisch an die Kunden angepasst hat, ohne sie davon zu informieren. Sobald die automatische Datenanalyse es als unwahrscheinlich einschätzte, dass jemand den Premiumdienst zum normalen Preis kauft, wurde der Preis gesenkt. Das macht es für Kunden schwer, Preise von verschiedenen Dating-Apps zu verglei-

5 Siehe Duhigg (2012).

6 Dadurch, dass Sie sich mit Ihrem Facebook- oder Google-Account regelmäßig auf unterschiedlichen Geräten einloggen, wissen die Tech-Unternehmen, dass diese Geräte Ihnen gehören. Ganz ähnlich erlaubt die Paybackkarte den Unternehmen, Ihnen Ihre Einkäufe über verschiedene Geschäfte hinweg zuzuordnen.

chen, weil sie nicht wissen, von welchen Faktoren der Preis abhängt. Dass die Preise auch vom Alter der Kunden abhängen, lässt den Verdacht zu, dass die Preise vielleicht auch davon abhängen könnten, wie oft das Profilbild der Kunden nach rechts gewischt wurde. Weil Verbraucherschutzbehörden festgestellt haben, dass die Praxis von Tinder gegen EU-Verbraucherrecht verstößt, hat Tinder diese eingestellt.⁷ In welchem Ausmaß andere Firmen – insbesondere im Internethandel – Preise für einzelne Kunden personalisieren, ist nicht ganz klar. Aber die automatische Personalisierung von Preisen ist eine verlockende neue Möglichkeit der Preisgestaltung.

Die Maschinenbauer ziehen nach

Es ist ganz normal, dass ein Unternehmen versucht, seinen Gewinn zu maximieren. Dazu gehört, die Kunden und den Markt genau zu kennen und die Preise entsprechend zu gestalten. Ebenso gehört dazu, Daten über interne Prozesse und Kosten zu sammeln. Daten helfen, Geschäftsprozesse sichtbar zu machen und zu optimieren. Das nennt man »Business Intelligence«. Weiß man zum Beispiel, wie viele Ersatzteile noch im Lager liegen und wie häufig man jedes einzelne Teil in der Vergangenheit gebraucht hat, kann man rechtzeitig neue nachbestellen und besser mit dem Lagerplatz planen. Neu daran ist lediglich, dass es durch die Digitalisierung leichter wird, viel mehr und viel detailliertere Daten zu sammeln.

Die Digitalisierung wirkt sich aber nicht nur auf Einkauf, Verkauf und Lagerung aus, sondern auch auf die Produktion. Bei der traditionellen Massenfertigung wird eine Fabrik so gebaut und darauf optimiert, dass sie das gleiche Produkt wieder und wieder herstellt. Schon heute können dank Digitalisierung und Baukastenprinzip verschiedene Varianten nach Bedarf gefertigt werden. Das kennt man vom Autokauf. So wie ein programmierbarer Webstuhl, mit dem sich unterschiedliche Muster weben lassen, soll die smarte Fabrik der Zukunft schnell umprogrammierbar sein, um auch Kleinserien oder gar ganz individuelle Produkte herstellen zu können. Intelligente Roboter und vielseitig einsetzbare 3D-Drucker sollen dabei helfen, die Produktivität so weit zu steigern, dass sich die flexible Fertigung auch in

7 Die Europäische Kommission hat am 7. März 2024 eine entsprechende Pressemitteilung veröffentlicht (Europäische Kommission, 2024).

einem Hochlohnland wie Deutschland rechnet. Nach der Erfindung von Dampfkraft, Elektrizität und Computern soll jetzt die intelligente Automatisierung eine neue industrielle Revolution bringen. In Deutschland verbindet sich diese Hoffnung mit dem Schlagwort Industrie 4.0 (die vierte industrielle Revolution hat noch nicht einmal richtig angefangen und schon wird von Industrie 5.0 gesprochen, die den Menschen stärker in den Mittelpunkt stellen soll und außerdem auch noch nachhaltig ist).

Ein weiteres verwandtes Buzzword in Vorstandsetagen ist das »Internet der Dinge«. Nicht nur Menschen sind in Zukunft ständig online, sondern eben auch Dinge. Jedes Bauteil und jede Maschine in der Fertigung ist dann über ein Funknetz mit dem zentralen Computer einer Fabrik verbunden. Sensoren melden ständig an den Computer, wo sich jedes einzelne Bauteil gerade befindet und ob es die nötigen Qualitätsprüfungen bestanden hat. Auch die Maschinen haben Sensoren und melden, dass sie geölt werden müssen oder eine Störung vorliegt. Diese Daten erlauben es, Produktions- und Geschäftsprozesse weiter zu optimieren.

Nehmen wir als Beispiel einen Maschinenbauer, der Druckmaschinen herstellt – diese altmodischen Dinger, mit denen Zeitungen und Bücher gedruckt werden. Druckmaschinen müssen präzise arbeiten. In komplexen Produktionsprozessen ist bei Problemen mit der Qualität meist nicht leicht zurückzuverfolgen, welche Faktoren dazu geführt haben. Vielleicht war es die Temperatur und ein Bauteil hat sich zu weit ausgedehnt, vielleicht waren die Schrauben minderwertig, vielleicht war die fähigste Mitarbeiterin gerade im Urlaub, vielleicht war es Montag, oder vielleicht war es eine Kombination mehrerer Faktoren. Nur wenn man die entsprechenden Daten gesammelt hat, kann man im Nachhinein nach möglichen Gründen suchen. Mit genügend Daten könnte ein KI-Programm zum Beispiel selbständig lernen, welche Faktoren relevant sind und den Produktionsprozess beobachten und Auffälligkeiten, die einen Einfluss auf die Qualität haben könnten, rechtzeitig melden.

Trotz Qualitätssicherung können später Probleme in der Druckerei auftreten, an die die Druckmaschine verkauft wurde. Ein Ausfall der Maschine kann für eine Druckerei teuer sein. Viele Maschinenbauer bieten deshalb eine »kostenlose« Wartung und einen schnellen Reparaturservice als Verkaufsargument an. Die Wartung der verkauften Maschinen ist daher ein großer Kostenpunkt bei vielen Maschinenbauunternehmen. Eine Druckmaschine, die voller Sensoren ist, kann

Daten über ihren Zustand über das Internet an den Druckmaschinenhersteller melden. Die Analyse dieser Daten wird im Idealfall von KI-Programmen übernommen. Ein neuronales Netz könnte zum Beispiel lernen, aus den Daten vorherzusagen, ob eine Druckmaschine bald Probleme verursachen wird. Der Hersteller (oder die KI) kann dann vorbeugend einen Techniker vorbeisicken. Bei Maschinen, die ohnehin rund laufen, können hingegen Wartungskosten eingespart werden.

In der Hoffnung, dass Statistik und KI aus Daten gewinnbringende Erkenntnisse destillieren, werden immer mehr Daten gesammelt. Mittlerweile telefonieren nicht nur E.T. und Handys nach Hause, sondern auch Autos, Fernseher und Küchengeräte. Aber die Masse der Daten ist nicht alles. Wenn die Luftfeuchtigkeit entscheidend ist, um die Fehlfunktion eines Geräts vorherzusagen, wäre es gut, diese auch zu messen. Dazu muss man aber erst mal an diese Möglichkeit denken und extra einen entsprechenden Sensor einbauen. Wenn Sensoren aber nicht das Richtige messen oder wenn Daten eine schlechte Qualität haben, hilft es auch nicht unbedingt, wenn man viele solcher schlechten Daten hat. Für jede Datenanalyse gilt das GIGO-Prinzip: »garbage in, garbage out.« Gibt man oben Müll hinein, kommt unten Müll raus.

Auch Firmen, die bei der Digitalisierung schon weit fortgeschritten sind und Daten systematisch zur Analyse sammeln (das sind in Deutschland beileibe nicht alle), sammeln oft nur die Daten, die ohnehin anfallen. Hier haben Unternehmen, deren Geschäft sich hauptsächlich im Netz abspielt, einen klaren Vorteil. Während Siemens oder Daimler durch Daten produktiver werden können, sind die Daten jedoch nicht ihr Kerngeschäft und relevante Daten müssen mit zusätzlichem Aufwand gesammelt werden. Das Geschäftsmodell von Netflix und Amazon beruht zwar viel stärker auf Daten, aber sie müssen auch außerhalb des Netzes gute Serien produzieren oder Bücher verschicken. Google und Facebook hingegen verdienen ihr Geld mit Werbung ausschließlich online. Relevante Daten fallen online zuhauf an und können leicht gespeichert werden. Die Kunden von Google und Facebook können dank der Daten, die sie über ihre Nutzer sammeln, zielgerichtet Werbung schalten. In der Metapher des Öls des 21. Jahrhunderts ist unser Online-Leben der Rohstoff, den Google und Facebook raffinieren, um daraus Plastikprodukte zu machen, oder um ihn zu verbrennen. Willkommen im Überwachungskapitalismus.⁸

8 Der Begriff stammt von Zuboff (2019).

Big Brother und die Sozialen Medien

Ein früherer Mitarbeiter von Facebook hat sich mal verbittert darüber geäußert, dass die hellsten Köpfe seiner Generation darüber nachdenken, wie man Menschen dazu bringt, auf Werbefbanner zu klicken.¹ Weil sie extrem viele Daten haben und sehr gut bezahlen, ziehen die großen Internetfirmen tatsächlich viele Talente aus den Bereichen Statistik, maschinelles Lernen und KI an. Und ihre Arbeit macht einen Unterschied: Die Werbung, die wir online sehen, ist durch KI daraufhin optimiert, dass sie uns beeinflusst.

Diese Beeinflussung kann harmlos sein, zum Beispiel wenn ich Werbung für ein Buch angezeigt bekomme, das mich interessiert und das ich vielleicht sonst nie entdeckt hätte. Die Werbung hat dann eine rein informierende Wirkung und ich entscheide mich bewusst zum Kauf. Es ist die Möglichkeit einer unbewussten Beeinflussung, die uns Angst macht. Bei Fernsehwerbung oder Zeitungsanzeigen sind wir da weniger ängstlich. Trotzdem glauben viele Menschen daran, dass wir durch Werbung unbewusst manipuliert werden können. Würde Werbung nicht wirken, würde wohl kaum so viel Geld dafür ausgegeben. Aber in welchem Maß können wir beeinflusst werden, ohne dass wir das merken?

Werden wir unbewusst manipuliert?

Obwohl sie vielfach widerlegt worden ist, hält sich die moderne Legende von einem Experiment in den 1950er Jahren, bei dem während eines Kinofilms ganz kurz und unbemerkt die Aufforderung ›Trink

1 Das Zitat von Jeff Hammerbacher lautet: »The best minds of my generation are thinking about how to make people click ads. That sucks.« (Vance, 2017)

Coca-Cola« eingeblendet wurde, und die Kinobesucher in der Pause deshalb deutlich mehr Cola gekauft haben sollen. Es ist aufgrund von Laborstudien in der Psychologie nicht vollständig auszuschließen, dass so etwas funktionieren könnte, aber niemand hat es bisher geschafft, Bedingungen außerhalb des Labors herzustellen, bei denen jemand von einem Reiz beeinflusst wird, von dem er gar nichts weiß. Falls es überhaupt einen Einfluss eines solchen unbewussten Reizes auf das Verhalten gibt, ist er extrem klein. Das Ziel von Werbung ist normalerweise nicht, nicht wahrgenommen zu werden, sondern im Gegenteil, möglichst viel Aufmerksamkeit zu erregen.²

Wenn wir also nicht direkt durch unbewusste Botschaften beeinflusst werden können, wie beeinflusst uns Werbung dann? Kauft man im Supermarkt Zahnpasta, insbesondere wenn man es eilig hat, denkt man nicht lange darüber nach, welche Marke man nimmt. Die meisten Menschen kaufen einfach aus Gewohnheit immer dieselbe Marke. Der Preis ist natürlich auch wichtig. Aber wenn man die Wahl zwischen zwei Zahnpasten hat und nur die eine kennt und mit positiven Eigenschaften verbindet, weil sie gut und oft beworben wurde, für welche entscheidet man sich wohl? In diesem Moment ist einem nicht unbedingt bewusst, dass die Kaufentscheidung auch durch die Werbung beeinflusst wurde. Trotzdem weiß jeder, dass Werbung so funktioniert.

Im Jahr 2014 ist ein Shitstorm über Facebook hereingebrochen, als in einem wissenschaftlichen Artikel von einem Experiment berichtet wurde, in dem Facebook ohne Wissen der Nutzer versucht hat, ihre Stimmung zu beeinflussen.³ Hat ein Facebooknutzer viele Freunde und ist in vielen Gruppen Mitglied, produzieren seine Freunde und Gruppen mehr Posts als er lesen kann. Die Neuigkeiten, die er auf seiner Facebookseite sieht, werden daher (Überraschung!) von einem Algorithmus ausgewählt. Für über 600.000 zufällig ausgewählte Nutzer wurde dieser Algorithmus während dieses Experimentes leicht geändert. Zuerst wurden die Posts ihrer Freunde auf emotionale Wörter analysiert: Kommt zum Beispiel das Wort »glücklich« oder das Wort »traurig« darin vor? Danach wurde eine Woche lang für eine Gruppe ein Großteil der positiven Posts unterdrückt und für eine andere Gruppe ein Großteil der negativen Posts. In weiteren Kontrollgruppen wurden

2 Siehe Moore (1982).

3 Die Studie wurde von Kramer, Guillory & Hancock (2014) durchgeführt. Die heftigen Reaktionen darauf wurden z.B. von Booth (2014) beschrieben.

zufällig Neuigkeiten unterdrückt. Würden Nutzer, die weniger Posts ihrer Freunde sehen, die positive Gefühle ausdrücken, auch selber weniger positive Posts posten? Die Antwort ist: ja. Der Effekt ist aber äußerst klein. Von 1.000 Wörtern, die jemand auf Facebook postet, sind im Durchschnitt 52 positiv. Durch die Manipulation sind es nur noch 51.

Es wäre überraschend gewesen, wenn der Effekt größer gewesen wäre, denn die Stimmung eines Nutzers hängt nicht nur davon ab, was er bei Facebook liest. Auf ganz Facebook hochgerechnet geht es trotzdem noch um hunderttausende Posts pro Tag, die weniger positiv besetzte Wörter nutzen. Amüsiert ein Freund sich über ein Video, dann kann ich nicht antworten, dass ich das auch lustig finde, wenn ich seinen Post gar nicht zu sehen bekomme. Es ist deshalb auch kein Wunder, dass es durch diese Manipulation weniger positive Posts gibt.

Mich haben die heftigen Reaktionen auf diese Studie erstaunt. Natürlich kontrolliert Facebook, was Sie auf Facebook sehen. Natürlich macht Facebook die ganze Zeit Experimente mit seinen Nutzern, um seine Empfehlungs- und Werbealgorithmen zu verbessern (A/B-Tests wie bei Netflix). Natürlich hat Facebook ein Interesse daran, dass Sie Facebook möglichst viel Aufmerksamkeit widmen, damit Sie auch möglichst viel relevante Werbung sehen. Und natürlich interessiert sich Facebook deshalb auch für die Gefühle seiner Nutzer. Warum also der Aufruhr?

Selbst wenn man verstanden hatte, dass Facebook mit Werbung Geld verdient, war Vielen offenbar noch nicht klar, dass Facebooks Algorithmen nicht nur kontrollieren, welche Werbung wir sehen, sondern auch welche sonstigen Inhalte. Das betrifft neben belanglosen Urlaubsfotos von Freunden auch Nachrichten und Fake News. Dass Facebook unsere Stimmungen ohne unser Wissen manipulieren könnte, ist ein beängstigender Gedanke. Und dass eine künstliche Intelligenz, die wir weder kennen noch verstehen, schon längst herausgefunden haben könnte, wie man uns am besten unbewusst manipuliert, verstärkt die Angst noch mehr. Anders als bei Werbung, bei der man immer weiß, dass der Versuch einer Beeinflussung unternommen wird, und die entsprechend gekennzeichnet werden muss, wurden die Nutzer in der Facebookstudie nicht genügend darüber aufgeklärt. Die Nutzer auf Facebook haben solchen Experimenten zwar formell mit den Nutzungsbestimmungen zugestimmt, aber bewusst war es ihnen nicht, dass Facebook versuchen könnte, ihre Stimmung zu beeinflussen.

Wahlwerbung und Propaganda nutzen Daten

Doch der richtig große Shitstorm sollte erst noch kommen. Was, wenn Facebook nicht nur die emotionale Stimmung seiner Nutzer mit Katzenvideos manipuliert, sondern auch die politische Stimmung beeinflusst? Hat Facebook neben dem Verkauf von Werbung noch andere, vielleicht politische Interessen, von denen wir nichts wissen? Welche Absichten haben Facebooks Kunden? Können auch Geheimdienste oder zwielichtige Akteure sich Facebooks Daten zunutze machen? Kennt man die politischen Überzeugungen von ausreichend vielen Menschen und besitzt außerdem ihre Facebookdaten, lässt sich durch Statistik und maschinelles Lernen berechnen, wie wahrscheinlich es ist, dass zum Beispiel jemand, der über 50 ist, im Ruhrgebiet wohnt und die Facebookseiten von DGB und Herbert Grönemeyer mag, die SPD wählt. Das ist eine leichte Übung. Statt nur Wahlplakate in Bochum zu kleben, kann man diese Person gezielt online mit maßgeschneiderten Botschaften ansprechen. Das nennt man »Microtargeting«. Und genau solche Daten für Microtargeting hat die Beratungsfirma Cambridge Analytica gesammelt. Teils auf legalem, teils auf illegalem Weg. Der Verdacht steht im Raum, dass die Wahlerfolge der Leave-Kampagne beim Brexit-Referendum und von Donald Trump bei der Präsidentschaftswahl 2016 durch solche Datenanalysen beeinflusst wurden.⁴

Wir wissen nicht, wie viel effektiver als normale Wahlwerbung dieses Microtargeting war. Und da politische Stimmungen, genauso wie emotionale Stimmungen, von vielen Faktoren abhängen, ist es unwahrscheinlich, dass viele Menschen nur aufgrund der Facebook-Werbung von Cambridge Analytica Donald Trump statt Hilary Clinton gewählt haben. Aber wir wissen auch, dass Wahlen knapp ausgehen können. Es ist daher wichtig für eine Wahlkampagne, dass die eigenen Unterstützer wirklich wählen gehen und möglichst viele unentschiedene Wäh-

4 Man weiß gar nicht, wo man anfangen soll, wenn man über den Cambridge-Analytica-Skandal schreiben möchte. Der TED-Talk von Carole Cadwalladr, die den Skandal aufgedeckt hat, ist vielleicht ein guter Startpunkt (Cadwalladr, 2019). *The Guardian* hat eine Webseite mit allen Artikeln zu dem Thema eingerichtet (The Guardian, 2018). Eine ausführliche Erklärung von Microtargeting bietet auch die Bundeszentrale für politische Bildung an (Christl, 2019). Die Berliner Datenschutzbeauftragte mahnt derweil an, dass sich die deutschen Parteien bei ihrer Wahlwerbung an die Datenschutzgrundverordnung halten sollen, die das Erfassen von politischen Meinungen untersagt (Dachwitz, 2024).

ler das Kreuz an der richtigen Stelle machen. Um das sicherzustellen, gehört der Einsatz von Daten und Statistik schon sehr lange zu jedem Wahlkampf (und zur Wahlforschung) dazu.⁵ In einem demokratischen Wettbewerb um Stimmen sind Informationen über die Meinungen der Wähler (und Nicht-Wähler) entscheidend. Ihre Bundestagsabgeordnete muss diese Meinungen kennen, wenn sie ihre Wähler verantwortungsvoll repräsentieren will. Man sollte nicht vergessen: Es ist die Aufgabe von Politikerinnen und Politikern zu informieren und zu überzeugen, und so Wahlentscheidungen zu beeinflussen. Big Data und KI könnten diese legitimen demokratischen Prozesse unterstützen.

Stattdessen scheinen im Netz heimlich Kampagnen in unbekanntem Ausmaß zu laufen. Wahlgesetze, die Obergrenzen für Wahlkampfausgaben setzen, werden auf diese Weise unterwandert, wie das wohl im Fall des Brexit-Referendums passiert ist. Zwielfichtige Firmen bieten ihre Dienste zur Desinformation und Wahlmanipulation an. Mit und ohne deren Unterstützung untergraben außerdem fremde Regierungen die Meinungsbildung, wie das von Russland bei der Trump-Wahl 2016 vermutet wird. In Rumänien urteilte das Verfassungsgericht im Dezember 2024 sogar, dass die Präsidentschaftswahl wegen eines »russischen hybriden Angriffs« wiederholt werden muss.⁶

Systematische Desinformation und Fake News im großen Maßstab sind schlimm genug. Aber durch Big Data und KI lassen sich einzelne Menschen gezielt mit für sie maßgeschneiderten Informationen ansprechen. Es kann passieren, dass wir diese gezielte Manipulation nicht einmal bemerken. Und dass auch niemand anderes das mitbekommt und öffentlich widersprechen könnte. Propaganda und Desinformation erreichen durch Big Data und KI neue Dimensionen. Momentan sieht es allerdings nicht so aus, als ob die großen Tech-Unternehmen freiwillig die nötige Transparenz herstellen wollten.

5 In seinem umfassenden Buch über Automatisierung bespricht Pollock (1964) im letzten Abschnitt des letzten Kapitels die gesellschaftlichen Perspektiven auf das Thema. Schon damals machte er sich Sorgen darüber, dass die Anwendung von computergestützter Statistik den demokratischen Diskurs nicht unbedingt zum Besseren ändern wird.

6 Für die Wahlkampfausgaben siehe Cadwalladr, Graham-Harrison & Townsend (2018), für die zwielfichtigen Firmen Coerper & Klauser (2023), für den russischen Einfluss Timberg (2017) und für die Wahl in Rumänien Zimmermann (2024).

Der Staat soll unsere Daten schützen

Wer dem Silicon Valley misstraut, dem bleibt nichts anderes übrig, als sich auf den Staat zu verlassen, dass er neue Regeln für die digitale Welt aufstellt. Die KI-Verordnung der Europäischen Union, die 2024 verabschiedet wurde, verbietet explizit den Einsatz von manipulativen Techniken, die bewusste Entscheidungen untergraben, sofern Menschen dadurch ein ernster Schaden entstehen könnte. Im Annex III der KI-Verordnung sind konkrete Beispiele für Anwendungen von KI-Systemen genannt, die zwar nicht verboten sind, aber als besonders riskant eingestuft werden und die daher besonderen Sorgfalts- und Transparenzpflichten unterliegen. KI-Systeme, die Wahlen beeinflussen sollen, indem sie einzelnen Wählern nur für sie bestimmte Informationen zu spielen, sind dort explizit genannt.

Die KI-Verordnung ergänzt bestehende Gesetze um Aspekte, die spezifisch für KI sind. Weil aber niemand alle potenziell problematischen Anwendungen vorhersehen kann, definiert die Verordnung die Risiken unabhängig von konkreten Anwendungen. Wer KI-Produkte anbietet, muss nachweisen, dass er bei Entwicklung und Anwendung verantwortungsvoll vorgeht. Dafür gibt es eine Einteilung von geringem zu hohem Risiko. Diese Risikogruppen sind recht abstrakt beschrieben. Anwendungen ohne erkennbares Risiko sind nicht genau definiert, aber auch nicht betroffen. Für die anderen wird sich ein System von Normen und Zertifizierungen etablieren, das Firmen dabei hilft, Risiken zu managen. Und weil wir in Deutschland gut im Normieren sind, wird nicht erst seit der Verabschiedung der KI-Verordnung an DIN-Normen für KI gearbeitet.⁷ Es ist nur noch eine Frage der Zeit, bis es einen TÜV für KI-Anwendungen geben wird.

KI wird dabei nicht anderes behandelt als jede andere Technologie, die auch normiert, zertifiziert und abhängig vom Grad der Risiken erst zugelassen werden muss. Da sind KI-Produkte nicht anders als Fahrzeuge, Medizintechnik oder Finanzprodukte. Diese Produkte müssen ohnehin einen Zulassungsprozess durchlaufen – egal, ob in diesen Produkten KI steckt oder nicht. Da KI aber in vielen verschiedenen, vielleicht noch nicht existierenden Produkten eingesetzt werden kann, sah die EU eine Regelungslücke. Das selbst gesteckte Ziel der EU war dabei, Innovation nicht durch Überregulierung zu erschweren, aber ihre Bür-

7 Siehe DIN & DKE (2022).

ger trotzdem vor potenziell gefährlichen Anwendungen zu schützen. Der bereits erwähnte Annex III ist eine erweiterbare Liste, die konkrete Beispiele für Anwendungen gibt, die als besonders riskant einzuschätzen sind. Neben Systemen, die Wahlen beeinflussen sollen, finden sich da zum Beispiel Systeme zur Personalauswahl oder zur Feststellung der Kreditwürdigkeit:

In Deutschland darf niemand aufgrund von Geschlecht, Rasse oder ethnischer Herkunft, Religion oder Weltanschauung, Behinderung, Alter oder sexueller Identität benachteiligt werden. Dass Unternehmen KI-Systeme in Bewerbungsverfahren einsetzen, ändert nichts daran, dass sie sich an das Allgemeine Gleichbehandlungsgesetz halten müssen. Nehmen wir an, eine große Firma, die jedes Jahr tausende an Bewerbungen bekommt, hat über viele Jahre Statistik darüber geführt, welche Bewerber erfolgreich waren. Leider wurden in der Vergangenheit bei der Personalauswahl nicht immer alle gleich behandelt. Insbesondere Frauen wurden oftmals erst gar nicht zu Bewerbungsgesprächen eingeladen. Was passiert, wenn ein KI-System, das bei der Personalauswahl unterstützen soll, aus diesen Daten lernt, wer zu einem Vorstellungsgespräch eingeladen werden soll?⁸ Gibt man oben diskriminierende Daten in das System hinein, kommen unten diskriminierende Entscheidungen raus. Das ist das DIDO-Prinzip: »discrimination in, discrimination out.«⁹ Die KI-Verordnung wird hoffentlich dafür sorgen, dass Softwarehersteller, die anderen Unternehmen so eine Software zur Personalauswahl anbieten, die Verantwortung nicht an ihre Kunden abschieben. Und die Unternehmen, die so eine Software einsetzen, dürfen nicht davon ausgehen, dass die Gleichbehandlung schon gewährleistet sein wird.

Ähnliches gilt für den Einsatz von KI zur Feststellung der Kreditwürdigkeit. Die Schufa ist ein privates Unternehmen, das Daten über fast die gesamte Bevölkerung in Deutschland sammelt. Aus diesen Daten berechnet das Unternehmen den Schufa-Score, der vorhersa-

8 Das Beispiel ist nicht komplett hypothetisch. Amazon hat versucht so ein System zu entwickeln, dann aber gemerkt, dass das problematisch ist (Dastin, 2018).

9 Hamid Khan, der sich gegen rassistische Polizeiüberwachung in Los Angeles engagiert, spricht von »racism in, racism out« (Buranyi, 2017). Seine Variante des Informatiker-Mottos »garbage in, garbage out« lässt sich natürlich auf andere Formen der Diskriminierung übertragen. Über Khan und die Koalition gegen Polizeiüberwachung, in der er sich engagiert, habe ich zuerst in dem Buch von Katz (2020) gelesen (S. 143ff.).

gen soll, ob eine Person ihren Zahlungsverpflichtungen nachkommen wird. Vermieter nutzen diesen Score bei der Auswahl von Mietern, Banken nutzen ihn zur Kreditvergabe und auch beim Abschluss eines Handyvertrages wird die Bonität geprüft. In Deutschland kann man der Datensammelwut der Schufa nur schwer entgehen, denn ohne eine Einwilligung zur Bonitätsprüfung bei der Schufa kann es bei der Wohnungssuche oder mit einer Zahlung auf Rechnung schwer werden. Genauso bei einem schlechten Schufa-Score. Wenn man keinen Kredit bekommt, würde man von der Schufa schon gerne erfahren, warum der Score so schlecht ist. Wie genau der Schufa-Score berechnet wird, ist aber Geschäftsgeheimnis.

Woher wissen wir, dass der Schufa-Score nicht diskriminierend ist? Welche Rolle spielt zum Beispiel das Alter bei der Einschätzung der Kreditwürdigkeit? Oder die Postleitzahl, weil die Kreditwürdigkeit im Durchschnitt in armen Wohngebieten geringer ist? Wie kann man bei dieser Intransparenz im Einzelfall überprüfen, ob vielleicht ein Datenfehler vorlag? Wenn der Kredit automatisch abgelehnt wird und man weiß nicht warum, gibt es dann überhaupt noch eine realistische Möglichkeit zum Einspruch? Nach der Europäischen Datenschutzgrundverordnung (DSGVO) sind automatisierte Entscheidungsverfahren in Fällen, die solch gravierende Folgen für einzelne Menschen haben können, nicht erlaubt. Der Europäische Gerichtshof hat 2023 festgestellt, dass der Schufa-Score nicht als maßgebliches Entscheidungskriterium dienen darf. Die Schufa wollte sich daher von ihren Kunden bescheiden lassen, dass sie den Score nicht als alleiniges Kriterium einsetzen. Für den Online-Abschluss neuer Stromverträge wird ein Energieversorger aber wahrscheinlich gerade deshalb Bonitäts-Scores von der Schufa kaufen wollen, weil ihm keine anderen Informationen über Neukunden vorliegen. Wie kann er sonst online und vollautomatisch Verträge abschließen ohne zu wissen, ob der Kunde seine Rechnungen bezahlen wird?¹⁰

Natürlich wird die Schufa von der zuständigen Datenschutzbehörde kontrolliert. Diese könnte richtig saftige Strafen verhängen und in der KI-Verordnung sind die Strafen noch drakonischer. Aber nicht alle Behörden wollen oder können so richtig Biss entwickeln. Die irische Datenschutzbehörde, die für Facebook zuständig ist, verhängte zwar

10 Zum EuGH-Urteil siehe z.B. Robertz & Eßlinger (2023). Hintergründe zum Schufa-Score und dessen Einsatz finden sich bei Schreiber (2023).

mal eine Rekordstrafe von 1,2 Milliarden Euro gegen die Facebook-Firma Meta, aber erst, nachdem die Behörde von Gerichten dazu gezwungen wurde.¹¹

Wer schützt uns vor dem Staat?

Eine große Ironie der Geschichte ist, dass wir nach dem Staat rufen, unsere Dateninteressen zu verteidigen. Doch es ist kein Zufall, dass das Wort ›Statistik‹ so ähnlich wie ›Staat‹ klingt. Staaten haben schon vor langer Zeit damit angefangen, Daten im großen Stil zu sammeln. Das Deutsche Statistische Bundesamt hört sich nach einer langweiligen Behörde an, ist aber eine unersetzliche Datenkrake. Bevölkerungsstatistiken sind zur Planung von Schulen, Renten oder Zuwanderung absolut notwendig und Wirtschafts- und Einkommensdaten werden zur Steuervorhersage benötigt. Genau wie Unternehmen auch mussten Staaten schon immer für die Zukunft planen und sie tun das (keine Überraschung!) mithilfe von Daten.

Das Volkszählungsurteil des Bundesverfassungsgerichts von 1983, das dem Staat bei der Datenerhebung über seine Bürger Einhaltung gebietet, war ein Meilenstein für den Datenschutz in Deutschland. Ein Jahr vor 1984 schien Orwells Roman wohl ausgesprochen aktuell. Da wir heute aus Bequemlichkeit den großen Tech-Unternehmen erlauben, Unmengen an persönlichen Daten über uns zu sammeln, können wir die damalige Aufregung über die Volkszählung nicht mehr ganz nachvollziehen. In den 80er Jahren zog man in den Debatten um Datenschutz auch Lehren aus dem Dritten Reich, denn der Holocaust in seiner ungeheuerlichen Dimension wäre ohne eine straff organisierte staatliche Bürokratie nicht möglich gewesen. Dazu gehörte auch, dass der Staat genau Buch darüber führte, wer jüdischen Glaubens war und wo die Menschen wohnten. Auf den ersten Blick mögen diese Informationen als kein großes Geheimnis erscheinen, sie haben aber die Organisation von Massendeportationen immens erleichtert. Ein oft übersehenes Detail der Geschichte des Dritten Reichs ist, dass diese Daten nicht nur in Büchern, Akten und auf Karteikarten standen. Sie wurden auch auf Lochkarten gespeichert, damit sie maschinell verarbeitet wer-

11 Goujard & Scott (2023) geben einen Überblick. Der Fall ist bei Lomas (2023) genauer dokumentiert.

den konnten. So konnte die gewaltige Bürokratiemaschine im Nationalsozialismus effizient arbeiten. Die deutsche IBM-Tochterfirma DEHOMAG verkaufte ihre mechanischen Lochkartenmaschinen an das Statistische Reichsamt, die Wehrmacht und an das Rassenamt der SS, die auch die Daten von KZ-Häftlingen auf Lochkarten speicherte.¹²

Dass der Datenschutz in Deutschland eine höhere Bedeutung hat als in anderen Ländern, hängt sicher auch damit zusammen, dass die Erinnerung an das Ministerium für Staatssicherheit der DDR noch lebendig ist. Man mag sich gar nicht vorstellen, wie viel effizienter die Überwachung der Stasi mit den heutigen technischen Möglichkeiten gewesen wäre. Aus den Enthüllungen von Edward Snowden wissen wir, dass Nachrichtendienste diese Möglichkeiten ausgiebig nutzen und dabei eng mit den großen Tech-Unternehmen zusammenarbeiten. Die bereits erwähnte Rekordstrafe für Facebook von 1,2 Milliarden Euro wurde deshalb verhängt, weil Facebook die Daten seiner europäischen Nutzer nicht ausreichend vor dem Zugriff der amerikanischen Nachrichtendienste schützt.

Um ihre Bürger vor umfassender Überwachung zu schützen, setzt die KI-Verordnung der EU nicht nur der Wirtschaft Schranken beim Einsatz von KI-Methoden, sondern auch den Mitgliedsstaaten. Besonders umstritten ist der Einsatz von KI-Methoden bei der Polizei. Weitflächige Videoüberwachung zusammen mit automatischer Gesichtserkennung kann eingesetzt werden, um vermisste Personen zu finden oder Gefährder bei akuter Terrorgefahr zu verfolgen. Diese Anwendungen sind in der KI-Verordnung als Hoch-Risiko-Anwendungen eingestuft und sind unter strengen Bedingungen zugelassen. Einige Nichtregierungsorganisationen haben deshalb starke Bauchschmerzen, weil sie befürchten, dass die Anwendungen in der Zukunft ausgeweitet werden könnten, sobald ein umfassendes Überwachungssystem erst einmal im Einsatz ist.¹³

Im Film *Minority Report* arbeitet Tom Cruise in einer Pre-Crime-Einheit, die Verbrecher verhaftet, bevor sie ein Verbrechen begehen. Im Film wird das durch hellseherische Fähigkeiten möglich, die bei drei Richtern mittels Drogen induziert werden. Im normalen Polizeialltag

12 Aly & Roth (2000) beschreiben die Rolle von Statistik und maschineller Datenverarbeitung im Nationalsozialismus. Das Buch ist ursprünglich 1984 anlässlich der Diskussionen um die Volkszählung in der BRD erschienen.

13 Siehe Algorithm Watch (2024).

braucht es keine hellseherischen Fähigkeiten. Werden an bestimmten Orten immer wieder Verbrechen begangen, wird die Polizei dort mehr Präsenz zeigen, um Verbrechen zu verhindern. Big Data und Statistik versprechen allerdings Verbrechen genauer vorherzusagen. Bald wird es uns nicht mehr reichen zu wissen, dass in einem Stadtteil viele Verbrechen geschehen, wir werden auch wissen wollen, wer verdächtig ist. KI-Systeme können die Polizei dabei unterstützen, ihre Daten entsprechend zu analysieren. Wie im Film könnte man gezielt Personen identifizieren, die vielleicht Verbrechen begehen werden, um sie zu beobachten und zu kontrollieren. Das nennt man »Predictive Policing«. Auch hier gilt das DIDO-Prinzip (Zur Erinnerung: DIDO steht für »discrimination in, discrimination out«). Bedenken, dass der Einsatz von KI-Systemen Vorurteile und Rassismus verstärken und pseudowissenschaftlich begründen könnte, sind nicht rein akademisch. Die Polizei von Los Angeles hat solche Systeme ausprobiert und viele der Sorgen von Bürgerrechtlern haben sich leider bestätigt. Insbesondere führt jeder anlasslose Kontakt mit der Polizei dazu, dass es wahrscheinlicher wird, dass man wieder kontrolliert wird.¹⁴

Die Diskussion in Deutschland zum Einsatz von Big Data und KI bei der Polizei ist weniger aufgeheizt als in den Vereinigten Staaten. Wie in anderen deutschen Behörden sollen auch bei der Polizei Akten digitalisiert werden. Aber selbst wenn relevante Daten schon Digital zur Verfügung stehen, haben die Beamten nicht immer leicht Zugriff darauf. In Hessen gibt es daher das System hessenDATA, das Daten aus verschiedenen Quellen zur Analyse zusammenführen soll. In Bayern heißt das entsprechende System VeRA (Verfahrensübergreifende Recherche- und Analyseplattform) und in Nordrhein-Westfalen gibt es DAR (Datenbankübergreifende Analyse und Recherche). Gemeinsam ist diesen Systemen, dass unter der Haube die Software Gotham der amerikanischen Firma Palantir läuft. (Wer denkt sich diese Namen aus?¹⁵) Palantir beliefert auch Nachrichtendienste, deren Aufgabe es ist, möglichst viele Daten über alles und jeden zu sammeln. Ein Grund-

14 Der Einsatz von verschiedenen Systemen bei der Polizei von Los Angeles und die Folgen davon sind gut dokumentiert. Einen Überblick geben z.B. die Artikel von Haskins (2020), Bhuyian (2021) oder Hvistendahl (2021). Brayne (2021) hat den Einsatz von Big Data innerhalb der Polizei von Los Angeles in einer Feldstudie beobachtet und viele Interviews geführt. Siehe auch nochmal Katz (2020), Kapitel 4.

15 Gotham ist die verkommene Stadt aus den *Batman*-Comics und Palantir ist die alles sehende Kristallkugel aus Tolkiens *Der Herr der Ringe*. Ist Ihnen auch der Kontrast

prinzip des Datenschutzes ist allerdings, dass Daten normalerweise nicht für andere Zwecke eingesetzt werden dürfen, als für die sie gesammelt wurden. Das setzt dem Einsatz solcher Systeme enge Schranken. Das Bundesverfassungsgericht hat festgestellt, dass das hessische Gesetz zum Einsatz von hessenDATA verfassungswidrig ist und nachgebessert werden muss. Der bayerische Datenschutzbeauftragte hielt schon den Testbetrieb von VeRA für verfassungswidrig.¹⁶

Auf den ersten Blick scheint Deutschlands und Europas strenger Datenschutz die Entwicklung von KI hierzulande in allen Bereichen auszubremsen. Und tatsächlich hängt die Entwicklung von KI-Anwendungen mithilfe von Statistik und maschinellem Lernen ganz entscheidend vom Zugang zu großen Datenmengen ab. Weder China noch die Vereinigten Staaten messen dem Datenschutz – aus unterschiedlichen Gründen – im Vergleich zu Europa sehr viel Wert bei. China und die Vereinigten Staaten legen auch deshalb ein unglaubliches Entwicklungstempo vor, weil sie Datenschutzfragen oftmals einfach ignorieren. Auf den zweiten Blick ist daher durchaus Vorsicht geboten, wenn der Datenschutz leichtfertig aufgegeben werden soll, damit wir technologisch nicht abgehängt werden. Die rechtliche, politische und gesellschaftliche Diskussion muss daher mit den technologischen Entwicklungen Schritt halten.

Es entsteht manchmal der Eindruck, als ob KI eine vollkommen neue Technologie ist, die auf einmal über uns hereinbricht und auf die wir nicht vorbereitet sind. Das Sammeln von Daten und deren Verarbeitung mit statistischen und maschinellen Methoden ist aber nichts Neues. In vielen Bereichen, in denen KI-Methoden neuerdings eingesetzt werden, gibt es lange etablierte Regeln und Standards, die ebenso für KI gelten. Das Internet ist auch schon eine ganze Weile kein Neuland mehr. Dass die EU nach der Datenschutzgrundverordnung und den Gesetzen über digitale Märkte und Dienste nun eine KI-Verordnung verabschiedet hat, die viele aktuelle Entwicklungen aufnimmt, zeigt, dass es möglich ist, von den Entwicklungen nicht überrannt zu werden. Während ein Terminator-Szenario noch in den Bereich der Sci-

in der Namensgebung zwischen der amerikanischen Firma und den deutschen Behörden aufgefallen?

16 Zu hessenDATA und dem Urteil des Bundesverfassungsgerichts siehe Scheld (2023). Zu der Kontroverse um VeRA siehe Meyer-Fünffinger, Streule, Zierer, Kartheuser & Schöffel (2024).

ence-Fiction fällt, ist der Einsatz von KI-Methoden in einem digitalen Big-Brother-Szenario schon längst Realität und muss reguliert werden. Lassen wir uns nicht einreden, dass die Entwicklungen so schnell und überraschend sind, dass uns das nicht gelingen kann!

Versuch und Irrtum

Eine überraschend große Zahl an Studien in der Psychologie, die Lernen untersuchen, setzen Ratten in ein Labyrinth. Das Labyrinth steht meist auf einem großen Tisch in einem Labor und hat undurchsichtige Wände, ist aber nach oben hin offen, sodass die Tiere sehen können, wo die Regale, die Lampen oder die Fenster im Raum sind. Dadurch verlieren die Ratten nicht komplett die Orientierung. Wenn ich durch eine Stadt laufe, orientiere ich mich zum einen daran, wie die Häuser aussehen, aber es ist auch immer gut, wenn durch die Straßenschluchten oder über den Häuserdächern Kirchtürme oder Hochhäuser zu sehen sind. Und komme ich in eine neue Stadt, komme ich mir manchmal vor wie eine Ratte in einem Labyrinth. Insbesondere, wenn ich mal wieder mein Handy vergessen habe, hungrig am Bahnhof ankomme und jetzt das einzige Restaurant suche, das noch nach 22 Uhr eine warme Küche hat. Das ist die Situation, in der die Ratte ist. Sie hofft, dass irgendwo in diesem Labyrinth etwas zu essen versteckt ist (aber man kann es nicht riechen und einfach nur der Nase folgen).

Beim ersten Mal, wenn die Ratte in das Labyrinth gesetzt wird, kann sie nichts anderes tun, als durch das Labyrinth zu laufen, bis sie irgendwann zufällig auf das Futter stößt. Wird die Ratte am nächsten Tag wieder in das Labyrinth gesetzt, dann könnte man meinen, dass sie vielleicht direkt wieder zu der Stelle läuft, wo es am Vortag etwas zu essen gab. Wahrscheinlich würde sie das auch gerne tun. Aber so wie auch ich nicht mehr weiß, wie ich vom Bahnhof zum einzigen offenen Restaurant gekommen bin und mich beim nächsten Besuch wieder verlaufe, läuft auch die Ratte nicht auf dem direkten Weg zum Futter, sondern irrt umher. Über mehrere Tage, in denen die Ratte immer wieder in das Labyrinth gesetzt wird und immer wieder an der gleichen Stelle Futter findet, wird das Herumirren allerdings immer weniger und die

Ratte läuft irgendwann auf dem kürzesten Weg vom Startpunkt zum Zielpunkt. Die Ratte hat offenbar gelernt.

Im Kapitel über Suchalgorithmen hatte ich beschrieben, wie man mit einer Karte den kürzesten Weg von einem Startpunkt zu einem Zielpunkt findet, indem man eine Heuristik benutzt. Abbildung 9 zeigt nochmal die Netzkarte mit den Shuttlerouten zwischen verschiedenen Planeten. Shuttles fliegen entlang der schwarzen (nicht der grauen) Linien und die Zahl auf jeder Linie zeigt an, wie viele Monate die Reise zwischen zwei Planeten dauert. Möchte man von Alderaan nach Endor fliegen, ist die kürzeste Route über Felucia, Corellia und Dagobah. Eine gute Heuristik ist, immer zunächst den Planeten anzufliegen, der dem Ziel am nächsten ist, weshalb von Alderaan aus Felucia vielversprechender aussieht als Bespin. Die Suche nach dem kürzesten Weg nach Endor ist die gleiche Art von Problem, welches die Ratten in ihrem Labyrinth haben. Die Ratten im Labyrinth können aber nicht die gleiche Heuristik nutzen, weil sie gar nicht wissen, wo das Ziel ist. Und selbst, wenn sie es nach einigen Versuchen wüssten, haben sie keine Karte, auf der sie den Abstand zum Ziel leicht messen könnten. Eine vielversprechende Hypothese ist aber, dass die Ratten über die Zeit eine immer bessere Heuristik lernen, und daher immer weniger umherirren.




Abb. 9: Fast dieselbe Planetenkarte wie zuvor

In Abbildung 9 ist auf den grauen Linien mit den grauen Zahlen verzeichnet, wie lange die Reise von jedem Planeten aus nach Endor dauert, wenn man die kürzeste Route nimmt, die möglich ist. Das ist die beste Heuristik, denn es ist nicht nur eine Abschätzung durch die Luftlinie, sondern die exakte Lösung (darin unterscheidet sich die Abbildung von dem Beispiel aus dem früheren Kapitel).

Mit dieser perfekten Heuristik biegt man niemals falsch ab. Wollen wir beispielsweise von Bepin nach Endor reisen, haben wir die Wahl, von dort nach Geonosis, Alderaan oder Corellia zu fliegen. Die Zahlen auf den grauen Linien zeigen an, dass es von Geonosis oder Alderaan fünf Monate Lebenszeit kostet, um nach Endor zu kommen. Von Corellia aus nur zwei Monate. Also fliegen wir nach Corellia. Obwohl Felucia der Luftlinie nach näher an Endor liegt als Dagobah, fliegt man besser nach Dagobah, weil es von dort nur noch einen Monat Lebenszeit nach Endor kostet. Mithilfe dieser Heuristik muss man nicht mehr langwierig nach der besten Route suchen, sondern man fliegt immer einfach zu dem Planeten weiter, der die kleineren Lebenszeitkosten hat.

Damit wir diese perfekte Heuristik nutzen können, muss aber jemand vorher die Kosten berechnet und sie auf der Karte notiert haben. Man kann die Länge der kürzesten Route nach Endor für jeden Planeten berechnen, indem man mit der Rechnung am Ziel anfängt (im Kapitel zu Suchalgorithmen hatten wir immer am Start angefangen). Wenn man in Endor ist, dann ist man am Ziel. Um da hinzukommen, muss man vorher in Dagobah gewesen sein, was einen Monat vom Ziel entfernt ist. Da Dagobah einen Monat von Corellia entfernt ist, braucht man von Corellia zwei Monate nach Endor, und so weiter. So können wir mit Papier und Bleistift die bestmögliche Heuristik bestimmen, aber wie können die Ratten lernen, sich entsprechend zu verhalten?

Wie Verhalten verstärkt wird

Eine alte Idee der Psychologie besagt, dass Tiere – und Menschen manchmal auch – aus Versuch und Irrtum lernen. Im Jahr 1898 setzte Edward Thorndike Katzen in einen verschlossenen Käfig, aus dem sie sich selber befreien konnten, indem sie einen Mechanismus betätigten. Er beobachtete, dass die Tiere viele verschiedene Sachen machen, bis sie irgendwann den richtigen Mechanismus finden. Er beobachtete auch, dass die Tiere, wenn sie wiederholt in den gleichen Käfig gesetzt

werden, sich nach und nach immer schneller befreien. Die Katzen in seinem Experiment scheinen nicht die Situation zu evaluieren und durch Nachdenken zu einer Lösung zu kommen, die sie immer wieder anwenden können. Sie probieren vielmehr zufällig verschiedene Verhaltensweisen aus, um ihr Ziel zu erreichen. Hat ein Verhalten zum gewünschten Erfolg geführt, dann wird dieses Verhalten verstärkt. Damit ist gemeint, dass die Wahrscheinlichkeit, in der Zukunft in der gleichen Situation wieder das gleiche Verhalten zu zeigen, ansteigt. Das nennt man in der Psychologie auch das ›Gesetz der Wirkung‹.¹

Psychologinnen und Psychologen haben im 20. Jahrhundert Ratten deshalb so oft in Labyrinth gesetzt, weil sie herausfinden wollten, wie diese Verstärkung von Verhalten durch Erfolg im Detail funktioniert. In einem Labyrinth hängt der Erfolg oder Misserfolg von einer ganzen Kette von Entscheidungen ab – jede Weggabelung kann die Ratte entweder näher ans Ziel bringen oder weiter davon entfernen. Eine wichtige theoretische Frage ist daher, wie die einzelnen Entscheidungen verstärkt werden, wenn unklar ist, was jede einzelne Entscheidung in der Entscheidungskette genau zum Erfolg beigetragen hat. Manche der Entscheidungen haben vielleicht zu Umwegen geführt und es wäre schlecht, diese so stark zu verstärken, dass das Tier danach immer den Umweg nimmt und deshalb vielleicht die Abkürzung nie entdeckt. Eine Theorie, die erklären kann, wie Tiere in einem Labyrinth lernen, sollte – so die Hoffnung – auch Hinweise darauf geben, wie Tiere jedes andere komplexe Verhalten lernen, das aus einer längeren Abfolge von Entscheidungen und Handlungen besteht. Inspiriert von dieser psychologischen Forschung entwickelte sich ein Teilgebiet des maschinellen Lernens, das man ›verstärkendes Lernen‹ nennt.² Erkenntnisse im maschinellen Lernen haben wiederum zu neuen Experimenten in Hirnforschung und Psychologie geführt. Neben künstlichen neuronalen Netzen ist das verstärkende Lernen ein weiteres Beispiel dafür, wie sich psychologische und neurowissenschaftliche Grundlagenforschung und KI-Forschung gegenseitig befruchtet haben.³

1 Siehe Thorndike (1898).

2 Auf Englisch ›reinforcement learning‹.

3 Das Standardwerk zu verstärkendem Lernen ist Sutton & Barto (2018).

Ein Lernalgorithmus, der Lernen in Computern und Ratten beschreibt, ist das sogenannte ›Q-Lernen‹.⁴ Stellen wir uns eine Ratte vor, die durch ein Labyrinth läuft, das wie unsere Planetennetzkarte aussieht. Die Ratte startet in Alderaan und das Futter ist am Ende des Labyrinths in Endor versteckt. Die Ratte will möglichst schnell zum Futter kommen. Jeder Gang verursacht Kosten (auch für Ratten ist Zeit Geld) und die Ratte will diese Kosten minimieren. Die Ratte wird immer wieder in das Labyrinth gesetzt und der Algorithmus soll beschreiben, was die Ratte jedes Mal macht und wie sich das Verhalten der Ratte durch Lernen ändert. Hinter dem Algorithmus steckt die Idee, für alle Planeten zu lernen, welche Kosten und Folgekosten jede der möglichen Entscheidung bis zum Ziel verursachen wird.⁵

Biegt die Ratte in Alderaan rechts nach Felucia ab, sind die Gesamtkosten bis zum Ziel in Endor 5, sofern das Tier ab Felucia den kürzesten Weg nimmt. Da das die Kosten für den kürzesten Weg sind, ist das die Zahl, die in Abbildung 9 auf der grauen Linie von Alderaan nach Endor steht. Es ist außerdem die Summe der Kosten für die Strecke von Alderaan nach Felucia und der Kosten des kürzesten Weges von Felucia nach Endor: $5=2+3$. Denn so hatten wir die Kosten des kürzesten Weges ja von hinten anfangend berechnet. Die Ratte muss also lernen, dass wenn sie in Alderaan rechts abbiegt, die Endkosten bestenfalls 5 sein werden. Biegt die Ratte allerdings in Alderaan links nach Beshpin ab, dann sind die Endkosten bestenfalls 7, denn die Kosten von Alderaan nach Beshpin sind 3 und die Kosten des kürzesten Weges von Beshpin nach Endor sind 4 und $7=3+4$. Das muss die Ratte auch lernen. Sobald sie beides gut genug gelernt hat, wird sie sich in Alderaan immer für das Rechtsabbiegen entscheiden, weil das die geringeren Endkosten verursacht.

Im Algorithmus wird nun angenommen, dass die Ratte für jede Abbiegung, die sie in Alderaan oder jedem anderen Planeten nehmen kann, eine Schätzung dafür hat, wie hoch die Kosten am Ende sein werden, wenn sie sich für diese Abbiegung entscheidet – die Ratte hat also eine Heuristik, die ihr wie beim Topfschlagen ansagt, wo es wärmer und käl-

4 ›Q-Learning‹ auf Englisch. Der Algorithmus wurde zuerst in der Doktorarbeit von Watkins (1989) beschrieben und die zugehörige Theorie ist gut ausgearbeitet (Watkins & Dayan, 1992).

5 Statt der Kosten wird beim Q-Lernen traditionell die Güte der Entscheidungen gelernt. Das macht aber keinen Unterschied, denn die zwei sind bis auf das Vorzeichen identisch: Kosten haben einfach eine negative Güte. Die Güte wird üblicherweise mit dem Buchstaben ›Q‹ für ›quality‹ abgekürzt, daher der Name des Lernalgorithmus.

ter wird. Wenn der Algorithmus in einem Computer läuft, werden diese Schätzungen einfach als Zahlen gespeichert (den sogenannten »Q-Werten«). Bei der Ratte stellt man sich aber besser vor, dass sie ein mehr oder weniger gutes Gefühl mit den einzelnen Abbiegungen assoziiert. Ein gutes Gefühl signalisiert der Ratte, dass sie auf dem richtigen Weg ist, ein schlechtes, dass sie sich auf dem Holzweg befindet.

Wird die Ratte das erste Mal in das Labyrinth gesetzt, kann sie noch keine vernünftige Schätzung für die Kosten der einzelnen Abbiegungen haben. Meist wird angenommen, dass die Ratte mit optimistischen Schätzungen beginnt und dass jede neue Abbiegung für sie daher potenziell interessant ist. Die Erfahrungen, die die Ratte nach der Entscheidung für eine Abbiegung macht, fließen in zukünftige Schätzungen ein und verbessern sie. Wenn die Ratte nun zufällig von Alderaan nach Felucia läuft, erfährt sie, dass die Kosten für diesen Gang 2 sind. Sie hat eine Schätzung dafür, wie teuer die beste Entscheidung in Felucia am Ende sein wird, und sie nutzt diese Schätzung zusammen mit den gerade direkt erfahrenen Kosten von 2, um die Schätzung der Endkosten für die gerade in Alderaan getroffene Entscheidung zu aktualisieren. Durch die direkte Erfahrung wird die Schätzung der Endkosten realistischer, selbst wenn die Schätzung für Felucia vielleicht noch nicht gut war. In Felucia trifft die Ratte wieder eine Entscheidung und aktualisiert dann die Schätzung der Endkosten für diese Entscheidung, und auch diese Schätzung wird dadurch realistischer. Und so geht es weiter, bis die Ratte durch Zufall in Endor landet und vom Versuchsleiter wieder an den Anfang gesetzt wird. Im nächsten Durchgang wiederholt sich der ganze Vorgang und so werden die Schätzungen der Endkosten für jede Entscheidung immer realistischer. Solange die Schätzungen noch nicht verlässlich sind, ist das Verhalten des Algorithmus mehr oder weniger zufällig und die Ratte erkundet das ganze Labyrinth. Je besser die Schätzungen werden, desto mehr trifft der Algorithmus die richtigen Entscheidungen und die Ratte läuft auf dem kürzesten Weg zum Futter.

Lernen ist mehr als Verstärkung

Bevor hier der falsche Eindruck entsteht, dass dieser Algorithmus perfekt erklären könnte, wie Ratten lernen: Verstärkendes Lernen ist nur ein kleiner, aber gut verstandener Teil einer vollständigen Erklärung.

Es gibt mehrere Phänomene, die nicht leicht alleine durch Versuch und Irrtum erklärt werden können. Sagen wir, unsere Ratte hat nun in unserem Planetenexperiment durch zufälliges Umherirren und Verstärkung von erfolgreichem Verhalten gelernt, wie sie schnellstmöglich von Alderaan nach Endor kommt. Die Ratte wird wieder in Alderaan ausgesetzt, aber diesmal gibt es zwei neue Gänge, die wir über Nacht an das Labyrinth angebaut haben. Der eine Gang geht von Alderaan direkt nach Geonosis und der andere direkt nach Endor. Die Ratte nimmt, ohne zu zögern, den neuen Gang nach Endor, wo das Futter ist. Da beide Gänge neu sind, sollte der Algorithmus beide zufällig erkunden, aber die Ratte ist offensichtlich schlauer als der Algorithmus, weil sie weiß, in welcher Richtung das Ziel liegt. Der Algorithmus kann auch nicht erklären, warum Ratten, die zunächst mehrere Male das Labyrinth erkundet haben, ohne dass es irgendwo im Labyrinth Futter gab, später schneller lernen, wie sie zur Futterquelle in Endor finden. Und wenn es auf einmal kein Futter mehr in Endor gibt, sondern in Geonosis, können die Ratten sich auch erstaunlich schnell umstellen. Diese Phänomene lassen sich nicht dadurch erklären, dass die Ratte jede Abbiegung mit einem guten oder schlechten Gefühl assoziiert hat. Die Ratte muss eine Karte des Labyrinths im Kopf haben, die es ihr erlaubt, bei einer Änderung des Ziels schnell umzuplanen.⁶

Bei Menschen und Menschenaffen ist die Vorstellung, dass sie Probleme nur durch Versuch und Irrtum lösen, ohnehin lächerlich. In einer berühmten (und ebenfalls sehr alten) Studie hat Wolfgang Köhler im Jahr 1921 Schimpansen verschiedene Probleme lösen lassen, um an Bananen zu kommen. In einem Versuch hing eine Banane an einer Schnur von der Decke, sodass der Affe sie nicht erreichen konnte. Neben vielen anderen Gegenständen standen im Gehege auch mehrere Kisten herum, die der Affe nicht kannte. Er hatte auch noch nie vorher dieses spezielle Problem gelöst. Nach einer Weile, in der der Affe wohl nachdachte, stapelte er die Kisten so übereinander, dass er die Banane erreichen konnte. Köhler beobachtete kein zufälliges Ausprobieren, sondern zielgerichtetes Handeln – ganz im Gegensatz zu den Beobachtungen, die Thorndike bei Katzen gemacht hatte. Die Affen lernen nicht langsam über viele Versuche sich zielgerichtet zu verhalten, sondern scheinen direkt aus Einsicht zu handeln.⁷

6 Siehe Tolman (1948).

7 Siehe Köhler (1921).

Wie wir bereits im Kapitel über Suchalgorithmen und im Kapitel über Schach gesehen hatten, lassen sich viele verschiedene Probleme als Suchprobleme verstehen. Schach hat eine große Zahl an Zuständen (alle möglichen Konfigurationen der Spielfiguren) und jeder Zug ist eine Reise von einem Zustand zu einem anderen. Genauso wie wir eine Netzkarte für Shuttlereisen zwischen Planeten erstellen können, können wir auch eine Karte der möglichen Zustände im Schach erstellen. Ein Spieler will möglichst schnell einen Zustand finden, in dem er gewinnt. Mit der kleinen Komplikation, dass es einen Gegenspieler gibt, der das verhindern möchte. Schach ist trotzdem nur ein großes Labyrinth, in dem irgendwo Futter versteckt ist. Weil aber der Suchraum im Schach nicht nur groß, sondern mit 10^{43} Zuständen riesig ist, funktionieren Suchalgorithmen nur, wenn ihnen eine Heuristik hilft abzuschätzen, wie gut mögliche Züge wohl am Ende sein werden. Nur weil mehrere Großmeister IBM geholfen hatten, eine gute Heuristik zu entwickeln, konnte Deep Blue gegen Garri Kasparow gewinnen. Hätte Deep Blue diese Starthilfe durch menschliche Intelligenz nicht gehabt, hätte Kasparow nicht verloren. Computer können aber – so wie Ratten – durch verstärkendes Lernen selbständig Heuristiken lernen. Können Computer daher auch ohne Einsicht – rein durch Versuch und Irrtum – lernen, Schach zu spielen? Kann man so ein lernendes Schachprogramm entwickeln, das nicht mehr auf Starthilfe durch die menschliche Einsicht in das Spiel angewiesen ist?

Computer lernen Menschen zu imitieren

Das Brettspiel Go ist in Asien ähnlich beliebt wie in Europa Schach. Das quadratische Brett besteht aus 19×19 Feldern, die am Anfang des Spiels leer sind. Die zwei Spieler legen abwechselnd schwarze und weiße Spielsteine auf das Brett und versuchen den Gegner zu umzingeln. Der Suchraum bei diesem Spiel ist mit 10^{170} Zuständen deutlich größer als beim Schach.⁸ Die Anzahl der Atome im beobachtbaren Universum

8 Jedes Feld kann leer sein oder mit einem schwarzen oder weißen Stein belegt sein. Für jedes Feld gibt es also drei Möglichkeiten. Bei einem Brett mit $19 \times 19 = 361$ Feldern gibt es daher $3^{361} \approx 10^{172}$ Möglichkeiten, die Steine auf das Brett zu legen. Wenn man berücksichtigt, dass nicht alle diese Zustände in einem Spiel legal auftreten können, kommt man auf etwa 10^{170} Spielzustände (Tromp & Farnebäck, 2016).

wird im Vergleich dazu auf »nur« 10^{80} geschätzt (plus minus ein paar Größenordnungen). Der Ansatz, Experten eine Heuristik entwickeln und dann ein KI-Programm nach guten Zügen suchen zu lassen, der bei Schach so erfolgreich war, ist bei Go gescheitert. Die Heuristiken für Go waren nicht gut genug für einen so riesigen Suchraum. Wie beim Schach gibt es Großmeisterinnen und Großmeister, die dieses Spiel extrem gut spielen. Und wie beim Schach ist auch ihr Wissen zu großen Teilen implizit. Die Go-Experten schaffen es nicht, explizit genug zu erklären, wie sie spielen, um einen Computer entsprechend zu programmieren. Ein neuer Ansatz musste her, um Computern Go beizubringen. Im Jahr 2016 hat dann ein Computerprogramm namens AlphaGo der Firma DeepMind (die zu Google gehört) in einem öffentlichkeitswirksam inszenierten Spiel einen der besten Go-Spieler der Welt, Lee Sedol, geschlagen. Dieses Programm hat seine Suchheuristik mit verstärkendem Lernen gelernt.⁹

Verstärkendes Lernen lernt aus Erfolg. Damit das funktioniert, muss der Lernalgorithmus auch manchmal Erfolg haben. Anfangs probiert das Programm nur zufällig Züge aus. Wenn der Suchraum riesig ist, ist es extrem unwahrscheinlich, dass man durch Zufall zum Ziel gelangt. Und falls so eine zufällige Suchstrategie bei Go gewinnt, tut sie das nur, weil der Gegner noch schlechter gespielt hat. So lernt man nicht gut zu spielen. Damit ein Computerprogramm in großen Suchräumen das Ziel oft genug findet, um eine Heuristik lernen zu können, braucht es eine Heuristik, die die Suche leitet. Eine klassische Henne-Ei-Situation.

Wie ist es DeepMind also gelungen, einem Lernalgorithmus die nötige Starthilfe zu geben, wenn selbst sehr gute Go-Spieler nur implizit wissen, wie ihre Heuristik aussieht? Im Internet sind eine große Zahl an Go-Partien mit allen Zügen dokumentiert. (Was würden KI-Forscherinnen und -Forscher nur ohne die großen Datenmengen im Internet tun?) Statt selber zu spielen, schaut sich der Lernalgorithmus eine Heuristik aus den Zügen von anderen Spielern ab! Der Algorithmus lernt so zunächst, erfolgreiche menschliche Spieler zu imitieren. Danach lässt man das Computerprogramm gegen sich selber spielen – und zwar richtig lange. Die Heuristik verbessert sich dadurch weiter. Und mit genügend Übung spielt das Computerprogramm dann besser als Lee Sedol.

9 Das Programm ist in dem Artikel von Silver et al. (2016) beschrieben.

Eine weitere nötige Zutat für diesen Erfolg der KI-Forschung war die Kombination von verstärkendem Lernen mit künstlichen neuronalen Netzen. Es ist ausgeschlossen, dass der Lernalgorithmus für jeden möglichen Zustand des Spiels seine aktuelle Schätzung dafür speichert, wie gut er ist, denn diese Tabelle wäre deutlich größer als die Anzahl der Atome im beobachtbaren Universum. Gute menschliche Spieler erkennen auf dem Brett bestimmte Muster. Diese Muster sind Teil des impliziten Wissens, das Expertinnen und Experten besitzen und das ihnen erlaubt, extrem gut zu spielen. Nicht jedes Detail einer Stellung ist wichtig, um abschätzen zu können, ob eine Stellung gut oder schlecht ist. Vielmehr reichen menschlichen Experten nur wenige Merkmale einer Stellung, um mit einer Heuristik eine Abschätzung zu machen. Die Experten erkennen bestimmte Muster, die sie mit einem guten oder schlechten Gefühl assoziieren. Wir haben im Kapitel über künstliche neuronale Netze gesehen, dass diese gut darin sind, Muster zu lernen. Daher liegt es nahe, die Heuristik mit einem neuronalen Netz zu berechnen, das seine Mustererkennung selbständig an das Problem anpassen kann.¹⁰

Dass die Menschheit sich nun auch in Go den Computern geschlagen geben musste, war nach Schach ein weiterer Meilenstein der KI-Entwicklung. Solange Maschinen durch verstärkendes Lernen nur Schach und Go lernen, könnte man meinen, KI wäre reine Spielerei. Ein gutes Gegenbeispiel ist StarCraft, in dem KI-Systeme mittlerweile auch sehr gut geworden sind.¹¹ Das Computerspiel simuliert ein Kriegsszenario. Kriegsspiele werden seit jeher im Militär genutzt, um verschiedene Szenarien theoretisch durchzuspielen (das war ja auch der Zweck des KI-Programmes WOPR im Film *War Games*). In StarCraft müssen die Spieler verschiedene Rohstoffe finden und abbauen, ihre Wirtschaft managen, Waffen entwickeln und produzieren sowie eine Armee aufbauen. Bei einem Angriff steuern sie die einzelnen militärischen Einheiten und müssen dabei darauf achten, ihre Langzeitstrategie und ihre Wirtschaft ebenso wenig zu vernachlässigen wie die Rüstungsproduktion. Der Reiz des Spieles ist unter anderem, dass es recht schnell abläuft und viel gleichzeitig passiert. Daher muss man ziemlich

10 Tesauro (1992) konnte zeigen, dass die Idee, verstärkendes Lernen und neuronale Netze zu kombinieren, tatsächlich für praktische, nicht-triviale Probleme funktionieren kann. Er zeigte das am Beispiel von Backgammon.

11 Siehe Vinyals et al. (2019).

lange üben, bis man schnell genug reagieren kann. Dieser Aspekt ist für Computer, die viel besser multitasken können als wir, trivial – im Gegensatz zur strategischen Planung und der flexiblen Anpassung an sich ständig ändernde Situationen. Darüber hinaus gibt es nicht nur Gegenspieler, die sich unberechenbar verhalten können, sondern auch Teampartner, mit denen man zusammenarbeiten muss. Um in diesem Spiel Erfolg zu haben, braucht ein KI-System eine ganze Reihe von Fähigkeiten, die KI-Systeme auch in der wirklichen Welt brauchen, wenn sie in Zukunft immer mehr Aufgaben für uns autonom erledigen sollen. Eine Aufgabe wie Autofahren lässt sich zum Beispiel in einem Computerspiel simulieren. Und in dem Maße, wie Computerspiele inzwischen die Komplexität von Alltagsproblemen erreichen, sind KI-Programme, die Computerspiele spielen, wirklich keine Spielerei mehr.

Computer lernen fast von alleine

Trotz aller Erfolge mit verstärkendem Lernen fuchste die KI-Forscherinnen und -Forscher lange noch, dass auch bei AlphaGo menschliche Spieler dem Computer Starthilfe geben mussten. Nicht mehr ganz so explizit wie bei Deep Blue, aber AlphaGo hatte immer noch Zugriff auf eine große Datenbank an Go-Partien, die von Menschen gespielt wurden. Das implizite Wissen der menschlichen Spieler konnte so von AlphaGo genutzt werden. Kann man nicht auch ein Computerprogramm entwickeln, das ohne diese menschliche Starthilfe auskommt? Ein Programm, das tabula rasa startet? Der Nachfolger von AlphaGo heißt AlphaZero und fängt wirklich bei null an. AlphaZero spielt von Anfang an gegen sich selber und lernt so immer bessere Heuristiken. Am Anfang spielt das Programm nämlich nur schlecht, aber da es gegen sich selber spielt, gewinnt und verliert es bei jedem Spiel. Entscheidungen, die zum Sieg geführt haben, werden verstärkt. So lernt das Programm, nach und nach immer besser zu spielen. Um Go zu lernen, hat AlphaZero 140 Millionen Spiele gegen sich selber gespielt. Um Schach zu lernen, waren es nur 44 Millionen.¹²

Ohne enorm viel Rechenleistung wäre das nicht möglich gewesen. Mehr Rechenpower und mehr Zeit als jemals ein Mensch zur Verfügung haben wird, um Go oder Schach zu lernen. Nehmen wir an, dass

¹² AlphaZero ist in dem Artikel von Silver et al. (2018) beschrieben.

ein Schachspiel grob eine Stunde dauert. Ein Jahr hat etwa 50 Wochen, bei 5 Arbeitstagen mit jeweils 8 Stunden, kommt man im Jahr auf 2.000 Arbeitsstunden. Jemand, der 50 Jahre arbeitet, kommt in seinem ganzen Arbeitsleben auf 100.000 Arbeitsstunden. Ein Mensch kann in seinem Leben also vielleicht mit viel Anstrengung 100.000 Spiele spielen. AlphaZero hat demnach ungefähr so viele Spiele gespielt wie 440 Menschen, die ihr ganzes Arbeitsleben nur Schach spielen.

Im Vergleich zu Computern lernen Menschen also erstaunlich schnell. So beeindruckend es ist, dass AlphaZero Schach von null auf lernt – Menschen lernen anders. Sie bekommen durchaus Starthilfe von wohlmeinenden Mitmenschen. Ein guter Trainer erklärt Eröffnungen und Strategien und beginnt mit grundlegenden Übungen und Begriffen. Und hat man keinen Trainer, gibt es Lehrbücher, die die Übungen und das Wissen gut strukturieren. Selbst wenn viel Wissen beim Schach implizit ist, gibt es trotzdem auch viel explizites Wissen, das in Büchern steht. Man kann erstaunlich gut Schach lernen, indem man Bücher liest. Trotzdem muss man auch regelmäßig selbst spielen und so das Spiel üben. Spielen kann man gegen andere Spieler im Verein oder gegen einen Computer, der verschiedene Schwierigkeitseinstellungen hat. Üben ist aber nicht nur ein zufälliges Ausprobieren von möglichen Handlungen (so wie es beim verstärkenden Lernen passiert). Erfolgreiches Training ist nicht nur Versuch und Irrtum, sondern es ist eine überlegte und systematisch strukturierte Aktivität. Zum Training gehört auch, dass man Standardsituationen wiederholt, dass man bewusst an seinen Schwächen arbeitet und dass man viele Schachpartien analysiert. Insbesondere alte Partien des nächsten Gegners.

Da die Maschinen anders lernen als wir Menschen, ist auch ihr Verhalten nicht unbedingt menschlich. Aber weil die Maschinen lernen, uns zu imitieren, wird es manche Ähnlichkeiten geben. Trotzdem (und ich weiß, ich wiederhole mich) sollten wir den Maschinen nicht vorschnell menschliche Intelligenz zuschreiben. Ihre Intelligenz ist anders. Während der Partie, die AlphaGo gegen Lee Sedol gewann, beschrieb ein Kommentator einen der Züge so: »Das ist kein menschlicher Zug. Ich habe noch nie einen Menschen einen solchen Zug spielen sehen.«¹³

13 Der Kommentator war der europäische Go-Champion Fan Hui, der zuvor selber schon gegen AlphaGo verloren hatte (Metz, 2016).

Das Besondere am AlphaZero-Algorithmus ist, dass fast identische Computerprogramme selbständig verschiedene Aufgaben lernen können. Sehr ähnliche Programme können fast ohne menschliche Hilfe Backgammon, Go, Schach oder jedes andere Spiel lernen. Der menschliche Entwickler muss immer noch die Ein- und Ausgaben definieren, die spielspezifisch sind, aber er muss kein Experte mehr für das jeweilige Spiel sein. Am Ende kann ein Programm, das Go gelernt hat, nicht auch Schach spielen, weil die Spielbretter, -steine und -regeln andere sind. Für jedes Spiel muss man zwar immer noch ein eigenes Programm aufsetzen, aber diese Technologie erlaubt es, KI-Systeme für viele verschiedene Anwendungen relativ automatisch zu entwickeln. Das ist praktisch, aber noch lange keine Allgemeine Künstliche Intelligenz (AKI). Der Mensch mit seiner Intelligenz lernt nicht nur eine Aufgabe zu erledigen, sondern kann viele verschiedene Aufgaben bearbeiten. Oftmals sogar ohne viel Übung. Wahrscheinlich muss man sich für AKI noch mehr Tricks beim Menschen anschauen.¹⁴ Unser Verhalten ist halt doch komplexer als das von Ratten in einem Labyrinth – und selbst das haben Wissenschaftlerinnen und Wissenschaftler noch nicht vollständig verstanden.

14 Siehe Lake, Ullman, Tenenbaum & Gershman (2017).

Unregulierte Zweckrationalität

Es ist kein Zufall, dass KI-Algorithmen gerne an Spielen wie Schach oder Go erprobt werden, bevor man sie auf ernsthafte Probleme anwendet. In einem Spiel ist klar definiert, was es heißt zu gewinnen oder zu verlieren. Die Regeln des Spiels geben das Ziel vor und die Aufgabe des Spielers ist es, dieses zu erreichen. Bei vielen Spielen geht es darum, möglichst viele Punkte zu sammeln. Kosten und Nutzen jedes Spielzuges kann man in diesen Fällen theoretisch ausrechnen. Mit KI-Methoden lassen sich vorgegebene Ziele erreichen und die Kosten minimieren – oder der Nutzen maximieren, was auf das gleiche hinausläuft.¹ Damit zum Beispiel verstärkendes Lernen eingesetzt werden kann, müssen die Kosten aber zunächst festgelegt werden. In der wirklichen Welt ist das oft selbst schon ein schwieriges Problem. Eine große politische Aufgabe ist zurzeit: Wir wollen die Energiewende schaffen. Aber was heißt das genau? Wir wissen, dass wir unseren CO₂-Ausstoß schnell verringern müssen. Aber was ist eine Tonne CO₂ im Vergleich zu einem Arbeitsplatz in der Schwerindustrie wert? Im Gegensatz zu Spielen sind uns in der wirklichen Welt die Ziele und Kosten nicht vorgegeben, sondern wir müssen sie selber bestimmen.

Leider sind wir nicht besonders gut darin. Wir schaffen zum Beispiel oft Fehlanreize, die zu unbeabsichtigten Auswirkungen führen: Man spricht auch vom Kobra-Effekt. Nehmen wir an, bei uns in der Gegend gibt es zu viele Kobras. Als politische Maßnahme bezahlen wir jedem, der uns eine tote Kobra bringt, eine Prämie. Das soll den Leuten einen Anreiz geben, Kobras zu jagen und so ihre Population verringern. Stattdessen fangen die Leute an, Kobras zu züchten. Als wir das merken, schaffen wir die Prämie wieder ab und die Leute entlassen all ihre

1 Kosten und Nutzen unterscheiden sich mathematisch nur im Vorzeichen: Kosten haben einen negativen Nutzen.

Kobras in die Wildbahn. Am Ende haben wir sogar das Gegenteil von dem bewirkt, was wir erreichen wollten. Die Wirtschaftswissenschaft kennt viele solche Beispiele, in denen Anreize, die zunächst vernünftig klingen, ungewollte Folgen haben.²

Der Kobra-Effekt begleitet auch den Einsatz von KI. Entwickler definieren Kosten, von denen sie glauben, dass das KI-System dann macht, was sie wollen. Am Ende minimiert das System zwar die vorgegebenen Kosten, macht aber trotzdem nicht, was es soll. Einem KI-System, das die Energiewende planen soll, geben wir zum Beispiel extrem hohe Preise für jede ausgestoßene Tonne CO₂ vor, damit möglichst viel CO₂ eingespart wird. Das System schlägt dann – logischerweise – vor, dass wir einfach unsere ganze Industrie abschalten und gar keine Energie mehr verbrauchen. Diese Lösung gefällt uns nicht. Also passen wir die Kosten so an, dass es sehr teuer ist, wenn der Energiebedarf nicht gedeckt wird. Was ja auch stimmt. Wir hatten es nur übersehen. Daraufhin schlägt das System vor, sofort aus der Kohle auszusteigen, weil die teuer ist und viel CO₂ produziert. Uns fällt aber auf, dass das zu mehr Arbeitslosigkeit in den Kohleabbaugebieten führen wird und diese sozialen Kosten bisher nicht berücksichtigt wurden, und so weiter. Bei der Anwendung von KI-Methoden in der Praxis sieht man häufig, dass die Kosten, die ein System minimieren soll, während der Entwicklung immer wieder angepasst werden, weil unbeabsichtigte Nebenwirkungen auftreten. Am Ende weiß man nie, ob noch etwas vergessen wurde.

Macht der Computer, was wir wollen?

Es ist also gar nicht so einfach sicherzustellen, dass ein KI-System das macht, was wir wollen. In der KI-Forschung wird das als ›Alignment-Problem‹ bezeichnet, was man als Ausrichtungsproblem übersetzen kann. Im Kapitel über Suchalgorithmen hatten wir bereits gesehen, dass zum Beispiel beim Planen einer Bahnreise die schnellste Route nicht immer die ist, die ein Nutzer möchte. Manchmal möchte derselbe Nutzer den billigsten Preis und ein anderes Mal hat er keine Lust umzusteigen. Das hängt von den jeweiligen Umständen ab – und ein Sys-

2 *Der Kobra-Effekt* ist der Titel eines Buches von Siebert (2001). Historisch besser belegt als Prämien für tote Kobras sind die sogenannten Schwanzprämien für tote Mäuse und Ratten, die früher an vielen Orten gezahlt wurden.

tem, das die Wünsche des Nutzers nicht erfüllt, ist nicht richtig ausgerichtet. Zur Verteidigung der Entwickler muss man sagen, dass es auch nicht leicht ist herauszufinden, was die Nutzer eigentlich wollen. Und dann wollen unterschiedliche Nutzer auch noch unterschiedliche Dinge.

Gibt es dafür keine Lösung? Doch! Die Lösung ist natürlich KI. Wäre es nicht viel praktischer, wenn nicht mehr die Entwickler eines KI-Systems diejenigen wären, die die Vorlieben der Nutzer spezifizieren, sondern wenn der Computer selber herauszufinden könnte, was die Nutzer wollen, um sich dann entsprechend zu verhalten? Ein KI-System kann zum Beispiel die Vorlieben des Nutzers aus seinem Verhalten ableiten. Einem Nutzer, der die Zugfahrt wählt, die eine halbe Stunde schneller ist, aber zwanzig Euro mehr kostet, waren in dieser konkreten Situation die halbe Stunde mindestens zwanzig Euro wert. Das Erschließen der Vorlieben aus dem Verhalten funktioniert auch, wenn der Nutzer selber gar nicht so richtig weiß, was er eigentlich möchte. Oder wenn seine Vorlieben sich über die Zeit ändern. Indem sich Computer automatisch an die Wünsche der Nutzer anpassen, kann das Alignment-Problem gelöst werden. Das ist jetzt das neue Ziel der KI-Forschung.³

Es klingt zunächst verlockend, dass wir in der Zukunft KI-Systeme haben könnten, die viele Aufgaben für uns übernehmen und uns alle Wünsche von den Lippen ablesen. Aber wollen wir das wirklich? Dieser Ansatz mag für ein System, das Reisen planen soll, vielleicht akzeptabel sein. Bevor ich losfahre, kann ich kontrollieren, ob mir der Vorschlag gefällt, und selbst wenn ich mir keine Alternativen ansehe, sondern einfach dem erstbesten Vorschlag folge, ist ein kleiner Umweg auch nicht schlimm. Weniger akzeptabel ist hingegen, dass ein KI-System meine Anlagestrategie plant und erst, nachdem ich eine große Menge an Geld verloren habe, merkt, dass ich eigentlich eher risikoscheu bin. Ich müsste mir schon sehr sicher sein, dass das KI-System mich gut kennt, bevor ich es selbständig meine Anlagen verwalten lasse. Aber es gibt auch Bereiche, in denen mich Algorithmen bereits viel zu gut kennen. Der Algorithmus, der mir auf Instagram das nächste Kurzvideo vorschlägt, passt sich an meine Wünsche an, indem er mein Verhalten genau analysiert. Welche Videos schaue ich an und welche nicht. Das Ergebnis ist, dass ich das Handy gar nicht mehr weglege. Und ein Kühl-

3 Russell (2019) hat ein ganzes Buch darübergeschrieben.

schränk, der automatisch für mich Lebensmittel nachbestellt, wird schnell merken, dass ich oft Tiefkühlpizza esse. So eine KI wird es mir noch schwerer machen, mich ausgewogen zu ernähren.

Solche Zielkonflikte sind die Regel, nicht die Ausnahme. Wir wollen CO₂ reduzieren, aber auch billig in den Urlaub fliegen. Um die Welt zu retten, verzichtet manch einer daher bewusst auf seinen Traumurlaub auf Hawaii und fährt stattdessen in den Harz zum Wandern. Die Reise-KI sollte uns nicht einfach einen Flug buchen, sondern uns die Möglichkeit lassen, uns bewusst anders zu entscheiden. Die Abwägung zwischen Traumurlaub, Preis und Flugscham will ich schon selber vornehmen. Aber die Vorschläge, die das System – ganz uneigennützig? – macht, sind so verlockend ... Ich bleibe stark und buche ein Zugticket nach Wernigerode.

Der Kohlekumpel in der Lausitz kann hingegen nicht so leicht auf seinen Arbeitsplatz verzichten wie ich auf meinen Urlaubsflug. Unterschiedliche Menschen haben unterschiedliche Interessen. An wessen Interessen soll ein KI-System, das die Energiewende für uns planen soll, ausgerichtet sein? An denen des Kohlekumpels, der Schwerindustrie, der Fluggesellschaften oder der Schülerinnen und Schüler von Fridays for Future? Wie kann ein Kompromiss zwischen all diesen berechtigten Interessen aussehen?

Spätestens an dieser Stelle dürfte klar geworden sein, dass KI keine wertneutrale Technologie ist, deren Entwicklung die Gesellschaft (überwiegend männlichen) Forschern, Ingenieuren und Unternehmern überlassen kann.⁴ Wir müssen gemeinsam in einem demokratischen Prozess entscheiden, welche Werte KI-Systemen einprogrammiert werden sollen. Im Silicon Valley, wo viele der bekanntesten KI-Systeme entwickelt werden, verbreiten sich allerdings im Dunstkreis von etablierten Tech-Unternehmen und KI-Startups befremdliche politische und moralische Vorstellungen. Ich sehe an meinen Studierenden, welche enorme Anziehungskraft diese Vorstellungen auch hierzulande auf technikbegeisterte Menschen ausüben. Diese Faszination basiert auf dem Glauben, dass sich alle Probleme der Menschheit mit Technologie lösen lassen. Da KI die ultimative Problemlösetechnologie ist, wird sie uns von allen Übeln befreien. Leider wird dabei übersehen, dass nicht alle Probleme rein technischer Natur sind. Die Technologiegläubigkeit von Elon Musk und anderen selbsternannten KI-Aposteln im Silicon

4 Der Terminus technicus ist ›Tech-Bros‹.

Valley nimmt teilweise groteske Züge an.⁵ Da viele von ihnen aber äußerst erfolgreich sind und vor allem politisch immer einflussreicher werden, muss man sich leider ausführlich mit ihren Ideen auseinandersetzen.⁶ Ein gewisses Maß an Polemik kann ich mir dabei allerdings nicht verkneifen.

Der Markt wird das schon regeln

Der ehemalige Internetpionier Marc Andreessen (die Älteren unter uns erinnern sich vielleicht noch an seinen Netscape Browser) ist heute ein äußerst erfolgreicher Wagniskapitalgeber, der sich selber als »Techno-Optimisten« bezeichnet. Er glaubt nicht, dass wir bei der Energiewende nach politischen Kompromissen suchen müssen, weil es der Markt sein wird, der den Ausgleich von selbst regelt. KI wird dem Einzelnen (insbesondere natürlich den einzelnen Unternehmen, die die KI-Ressourcen kontrollieren) helfen, sich besser im Markt zu behaupten. Wenn jeder an sich selber denkt, ist an jeden gedacht. So lautet Andreessens Glaubensgrundsatz. Dazu gehört auch, dass wir angeblich mittels KI das Ideal eines Marktes erreichen, in dem sich alle Akteure vollständig rational verhalten. Da der Wettbewerb dafür Sorge, dass jeder bekommt, was er verdient, gibt es auch kein Alignment-Problem. Kobra-Effekte entstehen nur, wenn sich jemand einbildet, er wüsste es besser als der Markt und die falschen Anreize setzt. Da der Markt dank KI aber immer rationaler wird und der Markt immer bessere KI hervorbringt, werde dieser selbstverstärkende Mechanismus uns schnell zu großem materiellen Überfluss und superintelligenter KI führen. Aus reinem Eigeninteresse werden wir so auch die Klimakrise lösen und dank der superintelligenten KI werden wir das auch leicht hinbekommen.

Es verwundert nicht, dass ein Wagniskapitalgeber aus dem Silicon Valley an freie Märkte und technologische Innovation glaubt. Schließlich ist Andreessen einer der Superreichen, die das techno-kapita-

5 Siehe z.B. den scharfzüngigen und trefflichen Artikel von Meckel (2023) über Marc Andreessen, über den wir gleich noch reden werden.

6 Als ich diese Zeilen ursprünglich geschrieben hatte, konnte ich noch nicht ahnen, welche Rolle Elon Musk und andere Tech-Milliardäre in der zweiten Amtszeit von Donald Trump seit Januar 2025 spielen würden.

listische Spiel gewonnen haben. Der religiöse Eifer, mit dem er seine Positionen vertritt, ist allerdings bemerkenswert. Sein bizarres *Techno-Optimist Manifesto* ist ein pathetisches Glaubensbekenntnis für freie Märkte, unregulierte Technologie und grenzenloses Wachstum ohne Rücksicht auf Verluste.⁷ Er predigt, auf Nachhaltigkeit, soziale Verantwortung, das Vorsorgeprinzip, Risikomanagement oder Technikethik vollständig zu verzichten. So rast Andreessen in seinem futuristischen Sportwagen immer schneller dem gelobten Land entgegen, in dem angeblich Milch und Honig für alle fließen. Bedenkenträger, die KI oder Märkte regulieren wollen, bremsen ihn auf der Straße des Fortschritts nur aus.

Auch wenn ihm nicht jeder im Silicon Valley dieses höchst eigenützige Heilsversprechen abkauft, so zweifeln wahrscheinlich nur Wenige daran, dass technologische Innovation gut ist und freie Märkte ein ausgezeichnetes Instrument für Fortschritt sind. In Deutschland setzen wir im Fall der Energiewende darauf, dass die erneuerbaren Energien durch marktwirtschaftlichen Wettbewerb möglichst schnell besser und billiger werden. Das heißt aber nicht, dass Regulierung keine Rolle spielt. Denn bei uns hat die Regulierung durch das Erneuerbare-Energien-Gesetz sogar dazu beigetragen, dass es mit der Energiewende schneller voranging.⁸

In der Europäischen Union ist die Regulierung von KI ohnehin nicht mehr aufzuhalten. Die KI-Verordnung ist seit August 2024 in Kraft, egal, ob es den Techno-Optimisten gefällt oder nicht. Diese Regulierung ist wichtig: Wir erinnern uns an die Enthüllungen von Edward Snowden zur flächendeckenden Überwachung durch Tech-Unternehmen und Geheimdienste sowie an den Skandal um Facebook und Cambridge Analytica zu Wahlbeeinflussungen. Außerdem sind wir mitten in einer Debatte um Fake News, algorithmische Diskriminierung und digitale Polizeiüberwachung. All das sind bekannte Folgen der Digitalisierung. Ohne klare Regeln könnten sich diese bedenklichen Entwicklungen durch KI weiter beschleunigen. Deshalb hat die EU sich so beeilt, ihre KI-Verordnung zu erlassen.

7 Das *Techno-Optimist Manifesto* hat Marc Andreessen am 16.10.2023 auf seinem Blog veröffentlicht (Andreessen, 2023). Die Parallelen zum *Manifesto del Futurismo* von Marinetti sind nicht zu übersehen.

8 Das heißt aber auch nicht, dass alles gut reguliert und der Preis dafür nicht hoch war (Romermann, 2020).

Die EU will bei der Regulierung von KI eine internationale Führungsrolle einnehmen, aber ob ihr das gelingt, ist fraglich. Anfang November 2023 lud Rishi Sunak, zu dieser Zeit noch Premierminister des Vereinigten Königreichs, zum ersten internationalen KI-Gipfeltreffen ein. Ursula von der Leyen war als Kommissionspräsidentin der Europäischen Union genauso vor Ort wie Kamala Harris als Vizepräsidentin der Vereinigten Staaten. Als Vertreter der Tech-Industrie war auch Elon Musk dabei. Der Gipfel fand in Bletchley Park statt. Im Zweiten Weltkrieg befand sich dort eine streng geheime Dienststelle, die frühe Computer zum Codeknacken eingesetzt hat. Einer der Codeknacker in Bletchley Park war Alan Turing, der Erfinder der Turing-Maschine und Vordenker der KI. Heute befindet sich in Bletchley Park ein Computermuseum. Im Vergleich zur KI-Verordnung der EU ist die Abschlussklärung des Gipfels, die Bletchley-Erklärung, erwartbar unkonkret geblieben.⁹

Treffen Tech-Lobbyisten, Nichtregierungsorganisationen und Politikerinnen und Politiker bei einem KI-Gipfel aufeinander, geht es natürlich darum, wie KI-Technologie reguliert werden sollte. Dabei sollte man nicht annehmen, dass internationale Konzerne nur daran interessiert sind, dass sie gar nicht reguliert werden.¹⁰ Regulierung kann ihnen auch helfen, denn klare Spielregeln reduzieren juristische Risiken. Außerdem verschafft Regulierung ihnen gegenüber kleineren Firmen Wettbewerbsvorteile, weil sie sich die Bürokratie, die mit jeder Regulierung einhergeht, leichter leisten können. Die großen Player haben auch mehr Einfluss und sitzen mit am Tisch, wenn die Regeln gemacht werden.¹¹ Das Politikmagazin *Politico* führte mit vielen Menschen, die auf dem internationalen Parkett an der Diskussion über die Regulierung von KI beteiligt sind, Hintergrundgespräche.¹² Während die Techno-Optimisten sich in ihrer offenen Ablehnung jeglicher Regulierung einig sind, zerfällt die Gruppe derer, die eine Regulierung befürworten, in zwei Lager. Die entscheidende Frage, die sie trennt, lautet: Sind die

9 Sie finden sie, indem Sie hier nach der *Bletchley Declaration* suchen: <https://www.gov.uk/search>.

10 So gehörte etwa Sam Altman, der Chef von OpenAI, zu denjenigen, die in einer Anhörung im amerikanischen Senat Regulierung einforderten (Kang, 2023).

11 Nick Clegg, der frühere Vize-Premierminister des Vereinigten Königreichs, ist z.B. der Chef-Lobbyist von Meta. Wir können davon ausgehen, dass er weiß, wie man die Interessen von Meta am besten vertritt.

12 Siehe Scott et al. (2024).

kurzfristigen oder die langfristigen Risiken von KI wichtiger? Auf der einen Seite finden sich diejenigen, die schon heute viele Gefahren im Einsatz von KI sehen und den Weg der EU international weitergehen wollen. Auf der anderen Seite stehen diejenigen, die vor einem apokalyptischen Terminator-Szenario mit einem totalen Kontrollverlust warnen. Diese Seite sieht das Risiko vor allem in der fernen Zukunft.

Warum können wir nicht beides tun, die akuten Gefahren eindämmen und uns auf eventuelle langfristige Risiken vorbereiten? Viele Verfechter der KI-Verordnung der EU halten das ganze Gerede von einem hypothetischen Terminator-Szenario für eine bewusste politische Taktik, um von bestehenden realen Problemen abzulenken, die auch außerhalb der EU dringend effektiv reguliert werden müssten. Im Gegensatz zu den Techno-Optimisten, fahren die Lobbyisten, die vor der Apokalypse warnen, eine subtilere Strategie: Sie umarmen die Regulierung, solange sie ihnen nutzt, ansonsten wollen sie aber auch nicht, dass Tech-Unternehmen zu stark reguliert werden. Je näher die Gefahr einer effektiven Regulierung kommt, desto lauter warnen diese Lobbyisten vor der Apokalypse, und desto zynischer werden ihre Kritiker.¹³

Das Ende naht

Die allermeisten KI-Forscherinnen und -Forscher sind keine bezahlten Lobbyisten für Tech-Unternehmen (obwohl sie häufig für diese arbeiten). Wenn sie sich öffentlich zu den existenziellen Risiken von KI äußern, sind sie wirklich davon überzeugt, dass KI zur Auslöschung der gesamten Menschheit führen könnte, und sehen es als ihre moralische Pflicht an, davor zu warnen. Mit dem Begriff »existenzielles Risiko« bezeichnen sie alle Gefahren, die die Existenz der Menschheit bedrohen. KI ist für sie eine Technologie wie die Atomkraft, die großen Nutzen verspricht, aber eben auch große Risiken birgt und deshalb reguliert werden muss. Diese Überzeugung geht oft mit einer als »Longtermism« bezeichneten Ethik einher, in der die langfristigen Folgen von KI bedacht werden müssen. Nick Bostrom ist einer der Apostel dieser Bewegung und das Buch *Superintelligence* sein Evangelium.¹⁴ Longter-

¹³ Siehe Heaven (2023).

¹⁴ Bostrom (2014).

misten liegen mit Techno-Optimisten darüber im Streit, ob KI reguliert werden sollte oder nicht. Während Techno-Optimisten glauben, dass das Alignment-Problem gar kein Problem ist, zerbrechen sich die Longtermisten den Kopf darüber, wie sie technologisch und regulatorisch sicherstellen können, dass KI auf unsere Werte ausgerichtet ist und sich nicht irgendwann gegen uns stellen wird. Aber beide Sekten glauben daran, dass der Messias in Form einer superintelligenten KI früher oder später kommen wird. Die einen haben nur mehr Angst vor der Apokalypse als die anderen.

Im Grunde gehen die Longtermisten von einem durchaus vernünftigen Gedanken aus: Wir verschieben Probleme gerne in die Zukunft. Das sehen wir besonders gut am Beispiel des Klimawandels. Das Bundesverfassungsgericht hat deshalb 2021 geurteilt, dass das Klimaschutzgesetz die Interessen von nachfolgenden Generationen nicht ausreichend berücksichtigt, weil es Probleme auf die Zeit nach 2030 verlagert.¹⁵ Dieses Urteil erinnert uns daran, dass wir nicht auf Kosten unserer Kinder und Enkelkinder leben sollten. So weit, so moralisch vernünftig.

Einige Longtermisten gehen aber weit über diese Idee der Generationengerechtigkeit hinaus: Alle noch ungeborenen Menschen sind genauso wichtig wie die heute lebenden. Und wenn die ›alle‹ sagen, meinen sie wirklich ›alle‹: Hilary Greaves und William MacAskill sind zwei Philosophen, die so etwas wie das longtermistische Manifest geschrieben haben.¹⁶ Die Argumentation in diesem Manifest ist bemerkenswert. Entscheidungen sollten möglichst rational getroffen werden. (Wer will da widersprechen?) Das gilt insbesondere für politische Entscheidungen, die KI fördern oder regulieren sollen. Doch was ist rational? Rational ist, was den erwarteten Nutzen maximiert beziehungsweise die erwarteten Kosten minimiert. Dabei müssen die Kosten der gesamten Menschheit berücksichtigt werden. Wenn jeder nur an sich selber denkt, ist eben nicht an alle gedacht. Insbesondere denkt dann keiner an all die Menschen, die noch nicht geboren sind. Diese Menschen sind genauso viel wert wie die Menschen, die heute leben.

¹⁵ Siehe Bräutigam (2021).

¹⁶ Die folgende Überschlagsrechnung habe ich direkt aus dem Artikel von Greaves & MacAskill (2021) übernommen. Ich bin etwas unfair, ihr Argument auf die reine Kosten-Nutzen-Rechnung zu verkürzen, denn ganz so schlicht sind ihre Argumente nicht. Aber am Ende läuft das meiner Ansicht nach doch darauf hinaus. Dafür unterschlage ich zum Ausgleich die wirklich hanebüchenen Argumente.

Eine schnelle Überschlagsrechnung ergibt, dass es viel mehr zukünftige Menschen geben wird, als heute Menschen leben. Longtermisten erwarten, dass die Population der Menschheit bei etwa 10 Milliarden (10^{10}) ein stabiles Gleichgewicht erreichen wird. Davon sind wir heute nicht mehr so weit entfernt. Wir können also annehmen, dass zu jeder Zeit in der Zukunft etwa so viele Menschen leben wie heute. Wir wissen aufgrund von Fossilien, wie lange andere Säugetiere auf der Erde existiert haben, bevor sie ausgestorben sind. Das macht plausibel, dass die Menschheit noch mindestens 10.000 Jahrhunderte existieren wird. Nehmen wir vereinfachend an, dass Menschen 100 Jahre alt werden, dann kommen auf jeden heutigen Menschen 10.000 (10^4) Menschen in der Zukunft. Das sind 100 Billionen (10^{14}) insgesamt. Und das ist eine konservative Schätzung, die nicht berücksichtigt, dass wir in der Zukunft auf Asteroiden-Einschläge besser vorbereitet sein werden als die Dinosaurier und wir außerdem neuen Lebensraum auf dem Mars finden werden.¹⁷

Die Kosten-Nutzen-Rechnung der heutigen Menschen verblasst angesichts der Rechnung für die Gesamtkosten der Menschheit. Sollte auch nur ein winziges Risiko bestehen, dass die Menschheit durch KI langfristig ausgelöscht werden könnte, wiegt das schwerer als der kurzfristige Nutzen, den KI in unserer Lebenszeit haben wird.

Doch wie hoch ist das Risiko einer KI-Apokalypse? Fragt man KI-Expertinnen und -Experten danach, sagt die eine Hälfte größer und die andere Hälfte kleiner als fünf Prozent.¹⁸ Allerdings sind KI-Experten – das sei schnell hinzugefügt – keine seriösen Zukunftsforscher, und entsprechend handelt es sich bei diesen Zahlen um Meinungen und Bauchgefühle, die anschaulich zeigen, dass diese KI-Experten zu viele Science-Fiction-Romane gelesen haben und die Fähigkeiten von KI genauso überschätzen wie ihre eigenen. Longtermisten wissen natürlich, wie hochumstritten solche Schätzungen sind. Trotzdem mal angenommen, die Wahrscheinlichkeit betrage tatsächlich fünf Prozent, dann stellt das natürlich ein unakzeptabel hohes Risiko dar. Aber selbst, wenn das wahre Risiko um ein Vielfaches kleiner ist, so ist es immer noch zu groß. Deshalb drängen einige der prominentesten Wissenschaftlerinnen und Wissenschaftler (darunter Nobelpreisträger)

¹⁷ Okay, jetzt habe ich ein paar der abstrusen Argumente von Greaves & MacAskill (2021) doch genannt.

¹⁸ Siehe Grace et al. (2018) und Grace et al. (2024).

darauf, dass wir angesichts einer möglichen Apokalypse dringend in KI-Sicherheit investieren müssen.¹⁹ Und einige Longtermisten rechnen uns vor, dass wir dafür richtig viel Geld in die Hand nehmen sollten, weil wir nur so die Leben aller zukünftigen Menschen retten können.²⁰

Da einige der erfolgreichsten KI-Forscher, die Einblicke in die aktuellen Entwicklungen bei den großen Tech-Unternehmen haben, und die Vorstände und Manager dieser Unternehmen sich öffentlich besorgt über KI äußern, sollte man das ernst nehmen. Entsprechend viel Aufmerksamkeit bekommt auch jeder ihrer offenen Briefe, die im Internet in schöner Regelmäßigkeit veröffentlicht werden.²¹ In der Bletchley-Erklärung, die vor langfristigen KI-Risiken warnt, hallen diese zahlreichen Appelle nach. Der bekannteste dieser Briefe besteht nur aus einem Satz:

Die Verringerung der Risiken einer Auslöschung der Menschheit durch KI sollte genauso eine globale Priorität der Politik sein wie Pandemien und Atomkriege.²²

Zu den Erstunterzeichnern gehören die zwei KI-Nobelpreisträger Geoffrey Hinton und Demis Hassabis sowie Bill Gates und Sam Altman, der Chef von OpenAI. Inzwischen haben sich hunderte KI-Forscherinnen und -Forscher ihrem Aufruf angeschlossen. Man wundert sich nur, warum diese Leute weiter an KI arbeiten, wenn sie wirklich glauben, dass KI uns den Weltuntergang bringen wird.²³ Anders als bei Pandemien und Asteroiden-Einschlägen könnten wir das Risiko sofort auf null reduzieren, indem wir jegliche KI-Forschung einstellen. Warum fordern wahre Longtermisten aber kein komplettes Verbot? Manche glauben, dass wir uns in einem Wettbewerb befinden, der mit der nuklearen Aufrüstung vergleichbar ist. Vladimir Putin sagte 2017,

19 Siehe Bengio et al. (2024). Einer der Autoren dieses Artikels ist Geoffrey Hinton, der 2024 den Nobelpreis für seine Grundlagenforschung zu neuronalen Netzen bekommen hat. Unter den Autoren sind auch der Wirtschaftsnobelpreisträger Daniel Kahneman und der Historiker und Bestseller-Autor Yuval Noah Harari.

20 Siehe nochmal Greaves & MacAskill (2021).

21 Siehe <https://futureoflife.org/fli-open-letters>.

22 Siehe <https://www.safe.ai/work/statement-on-ai-risk>.

23 Statt der vielen offenen Briefe von Forschern, Entwicklern, Investoren und Managern, die über die Jahre erschienen sind, um vor KI zu warnen, lesen Sie doch lieber den unglaublich lustigen Brief von Kannan (2023).

dass derjenige die Welt beherrschen wird, der führend in KI ist.²⁴ Die Staaten, die nicht aufrüsten, werden an Macht und Einfluss verlieren. Die KI-Entwicklung ist dieser Aufrüstungslogik nach nicht aufzuhalten. Das Beste, was wir machen können, ist die Risiken zu minimieren. Die allermeisten glauben ohnehin, dass der erwartete Nutzen für die Menschheit so groß ist, dass das Risiko einer Auslöschung der Menschheit akzeptabel wird, sofern wir es durch KI-Sicherheitsforschung nur klein genug halten können. Heilserwartung sticht Apokalypse.

Als Elon Musk OpenAI mitgründete, versprach er, dass die Technologie des Unternehmens offen sein würde. Daher der Name. Damit war gemeint, dass Forschungs- und Entwicklungsergebnisse veröffentlicht werden, damit andere den Fortschritt kontrollieren und darauf aufbauen können. Die Technologie hinter KI dürfe nicht geheim sein – und auch nicht von einer einzigen Firma kontrolliert werden. Musk hat sich immer wieder öffentlich dazu geäußert, dass er KI für die wahrscheinlich größte Bedrohung der Menschheit hält. Seine Investitionen in KI dienten angeblich dazu, ein Terminator-Szenario zu verhindern.²⁵ Wie selbstlos von ihm! Doch je mehr Geld die KI-Entwicklung verbrauchte und je mehr Erfolge sichtbar wurden, desto verschlossener wurde OpenAI seltsamerweise. Denn da KI gefährlich sei, müsse sie – so hieß es nun – von OpenAI oder besser noch von Tesla kontrolliert werden.²⁶ Vielleicht ist das eigentliche Alignment-Problem: Wie stellen wir sicher, dass KI nicht nur an den Interessen von einem Mann wie Elon Musk ausgerichtet ist, der den Mars besiedeln möchte und seinen

24 Putin bemerkte außerdem, dass es nicht wünschenswert ist, wenn es in diesem Bereich ein Monopol gäbe, und Russland sein Wissen mit der Welt deshalb teilen würde (Associated Press, 2017). So wie das Land es ja auch mit Nukleartechnologie macht.

25 Siehe z.B. Hern (2014) oder Gibbs (2014).

26 Musk verließ OpenAI 2018. Ein paar Jahre später, 2024, wollte er die Firma verklagen, weil sie das hehre Ideal der Offenheit, das er angeblich seit der Gründung von OpenAI vertrat, aufgegeben hatte. Daraufhin veröffentlichte OpenAI in dieser Sache interne E-Mails, die dokumentierten, dass Musk die Kontrolle über OpenAI angestrebt und den Plan verfolgt hatte, das Unternehmen zu einem Teil seiner Firma Tesla zu machen. Musk zog daraufhin seine Klage zunächst wohl zurück (Duffy, 2024; Telford, Tiku & De Vynck, 2024). Inzwischen sieht es im Februar 2025 wieder so aus, als ob es doch ein Gerichtsverfahren geben würde (Tong & Sriram, 2025). Elon Musk liefert sich unterdessen im Internet einen unterhaltsamen Schlagabtausch mit Sam Altman, dem CEO von OpenAI. Das Drehbuch für die Verfilmung dieses Dramas schreibt sich von alleine. Ganz ohne Hilfe von ChatGPT.

elektrischen Sportwagen als PR-Gag ins Weltall geschossen hat?²⁷ Auf dem Weg zum Mars, auf dem Milch und Honig fließen, bremst ihn bestimmt niemand aus.

Manche KI-Forscher scherzen als Seitenhieb auf Musk gerne, dass sie sich über das existenzielle Risiko, das von KI ausgehen soll, genauso wenig Sorgen machen, wie über die Überbevölkerung auf dem Mars.²⁸ Als Leserin und Leser dieses Buches ahnen Sie schon, was jetzt kommt: Ich halte ein Terminator-Szenario genauso wie superintelligente KI für reine Science-Fiction. Aber ist die Wahrscheinlichkeit dafür null? Superintelligente KI ist denkbar. Aber nur weil etwas denkbar ist, heißt das nicht, dass eine realistische Chance besteht, dass wir eine superintelligente KI tatsächlich entwickeln können. Es ist ebenso denkbar, dass wir nicht alleine im Universum sind und eines Tages Außerirdische auf der Erde landen könnten. Auch ich lese gerne Science-Fiction und habe Spaß daran, verrückte Ideen bis zum Ende durchzudenken. Ohne eine gehörige Portion an Fantasie kann man keine Vision für die Zukunft entwickeln. Aber von Zeit zu Zeit braucht es eben auch einen Realitätscheck.

Stuart Russell, einer der Autoren des Standardlehrbuches zu KI, ist davon überzeugt, dass die Entwicklung einer superintelligenten KI, falls sie uns denn gelingt, das größte Ereignis in der Zukunft der Menschheit sein wird – größer noch als die Ankunft von Außerirdischen (seine Worte, nicht meine). Und er schreckt nicht davor zurück, einen so grottenschlechten Film wie *Transcendence* mit Johnny Depp heranzuziehen, um den Teufel an die Wand zu malen: Wie in diesem Film könnte die Menschheit die Kontrolle über KI verlieren.²⁹ Zum Glück weist er neben der extrem spekulativen Gefahr der Auslöschung der Menschheit auch auf die weniger spektakulären, kurzfristigen Gefahren und die Notwendigkeit diese zu regulieren hin, so wie das in der KI-Verordnung der EU geschehen ist.³⁰ Aber ob er will oder nicht, er trägt mit seiner Rhetorik dazu bei, dass die verrückten Positionen der extremen Longtermisten von akuten Problemen ablenken.

27 Siehe Wattles (2024).

28 Andrew Ng hat damit angefangen (Williams, 2015).

29 Siehe das erste Kapitel in Russell (2019) und Hawking, Tegmark & Russell (2014).

30 Siehe nochmal Russell (2019), aber auch Russell (2023) und Weibel (2024).

Zweckrationalität sticht Moral

Die meisten Longtermisten sind sich durchaus dessen bewusst, dass ihre Argumentation, konsequent zu Ende gedacht, verrückt ist. Sie stellen sich untereinander die Frage: »An welcher Haltestelle des Zuges zur Stadt der Verrückten steigst Du aus?«³¹ Und die meisten steigen recht früh aus, etwa an den Haltestellen Klimaschutz oder Generationengerechtigkeit. Manche folgen aber der Argumentation des longtermistischen Manifests und sind überzeugt: In der Kosten-Nutzen-Rechnung für die gesamte Menschheit sind die heute lebenden Menschen vernachlässigbar. Diese Longtermisten predigen, dass wir heutiges Leid ertragen müssen, sofern es der Zukunft der Menschheit dient. Dass dieser Zweck jedes Mittel heiligen kann, scheint sie nicht weiter zu beunruhigen.

Extreme Longtermisten, die im Zug bis zur Endhaltestelle sitzen bleiben, sind offensichtlich eine Karikatur. Trotzdem bleibt der Eindruck, dass auch gemäßigte Longtermisten für das ewige Heil der Menschheit bereitwillig irdisches Leid hinnehmen. Hilary Greaves, die Erstautorin des longtermistischen Manifests, wurde auf die Obdachlosen angesprochen, die sie auf den Straßen sieht, und für die sie nichts tut, während sie sich um Menschen sorgt, die noch nicht einmal geboren sind. Sie bemerkte dazu:

Ich fühle mich echt schlecht, aber das schlechte Gefühl ist begrenzt, weil ich wirklich denke, dass ich das Richtige tue [...]. Die moralisch angemessene Position ist irgendwo in der Mitte, wo einen das heutige Leid immer noch mitnimmt, aber man erkennt, dass es noch wichtigere Dinge gibt, die man mit den begrenzten Ressourcen machen kann.³²

Falls es noch Zweifel gab: Longtermisten machen Lobbyarbeit für zukünftige Generationen, nicht für Obdachlose. Nach der Logik der Longtermisten müsste der Staat weniger Geld für Obdachlose und sozialen Wohnungsbau ausgeben und die Ressourcen stattdessen in KI-Sicherheit investieren, denn das existenzielle Risiko, das von KI ausgeht, bedroht schließlich die Zukunft der gesamten Menschheit.

31 Dieses Zitat stammt aus dem äußerst lesenswerten Artikel von Samuel (2022). Ein Großteil der folgenden Argumentation ist direkt aus diesem Artikel übernommen.

32 Dieses Zitat stammt aus einem früheren Artikel von Samuel (2021).

Wie staatliche Ressourcen eingesetzt werden, ist eine politische Entscheidung, über die in einer Demokratie gestritten werden muss. Und vielleicht sollten wir tatsächlich etwas mehr Geld für KI-Sicherheit ausgeben. Für Longtermisten ist das aber keine schnöde politische Diskussion, es ist eine moralische Frage, die sie durch ihre Kosten-Nutzen-Analyse als bereits beantwortet ansehen.

Diesen moralischen Maßstab legen sie nicht nur für die Gesellschaft an, sondern auch für das Individuum: Jemand, der Geld spendet, sollte es nicht für wohltätige Zwecke spenden, um die Not von Obdachlosen zu lindern oder die systemischen Ursachen von Obdachlosigkeit zu bekämpfen. Wichtiger als soziale Wohltätigkeit ist für Longtermisten die Forschung zu KI-Sicherheit, denn der erwartete Nutzen ist hier wesentlich größer. Dieser Grundsatz gilt für Milliardäre genauso wie für Philosophen. Wer jung ist und kein Geld hat, aber die 80.000 Stunden seines zukünftigen Arbeitslebens nicht mit sinnlosen Tätigkeiten vergeuden möchte, wird statt Sozialarbeiter besser KI-Sicherheitsforscher.³³ Der longtermistische Imperativ ist: Tue das, was langfristig den erwarteten Nutzen für die Menschheit maximiert!

Wenn KI-Forscher von Vernunft sprechen, dann sprechen sie von instrumenteller Vernunft. Die Rationalität der Maschinen ist eine reine Zweckrationalität. KI-Methoden suchen nach einem Weg, ein Ziel zu erreichen. Das ist die einzige Form von Vernunft, die sie kennen. Dabei folgen sie einer strengen Kosten-Nutzen-Rechnung. Der beste Weg ist der, der den erwarteten Nutzen maximiert. Je erfolgreicher KI-Methoden werden und je weiter sie sich verbreiten, desto mehr werden sie auch auf Probleme angewandt, für die sie nicht gemacht wurden. Darin unterscheidet sich die instrumentelle Vernunft der KI-Forscher nicht von der ökonomischen Vernunft der Wirtschaftswissenschaftler. Für beide sind Kosten und Nutzen zu Metaphern für Leid und Heil geworden. Dass weder Leid noch Heil leicht messbar sind, ist in ihren Augen nur ein technisches Problem, das noch zu lösen ist. Diese metaphorische Rationalisierung hat einen Nebeneffekt: Wir ersetzen Mit-

33 Falls Sie denken, ich denke mir das aus, dann denken Sie falsch. Auf dieser Webseite finden Sie Ratschläge dafür, wie Sie mit Ihrer Karriere den größtmöglichen Impact erreichen können: <https://80000hours.org/>. Nach eigenen Angaben hat die Seite bis 2024 zehn Millionen Leser angezogen und 400.000 Menschen haben den Newsletter abonniert. Einer der Gründer der Webseite ist William MacAskill, einer der Autoren des longtermistischen Manifests.

gefühl durch abstrakte Zahlen. So werden Schicksale zu Zahlen in einer Tabelle, die gegeneinander aufgerechnet werden können.

In der Debatte um die Zukunft von KI hat diese Art von Logik schon einige KI-Jünger auf eine von zwei intellektuellen Irrfahrten geführt. Im immer schneller werdenden Sportwagen auf der Straße des Fortschritts sitzen die Techno-Optimisten, für die es keine moralische Vernunft mehr gibt. Für sie gibt es nur gleichwertige Partikularinteressen, die die KI-Systeme der Zukunft zum Wohle der Menschheit in einem unregulierten Markt durchsetzen werden. Und an der Endhaltestelle des Zuges zur Stadt der Verrückten tummeln sich die extremen Longtermisten, die an die Möglichkeit einer moralischen Kosten-Nutzen-Rechnung für die ganze Menschheit glauben. Die KI-Systeme der Zukunft müssen nur noch danach ausgerichtet werden. Auf beiden Irrfahrten in die Zukunft bleibt die Menschlichkeit auf der Strecke.

Joseph Weizenbaum, der Entwickler von ELIZA, kritisierte schon 1976 den Imperialismus der instrumentellen Vernunft, der keine andere Art von Vernunft mehr neben sich duldet.³⁴ Die instrumentelle Vernunft hilft uns aber leider nicht zu entscheiden, was unsere Ziele sein sollen. Dafür haben wir keine Rechenregeln. Wir können auch nicht logisch beweisen, welche Ziele für unsere Gesellschaft die richtigen sind. Moralische und politische Entscheidungen folgen nicht nur einer Logik der Nutzenmaximierung. Um uns auf gesellschaftliche Ziele zu einigen, müssen wir langwierige und schwierige Debatten darüber führen, was moralisch und politisch vernünftig ist. Dafür haben wir eine Demokratie. In der Politik geht es nicht nur um die Durchsetzung von Partikularinteressen. Politik ist auch nicht nur ein technokratischer Streit über den besten Weg. Vielmehr ist Politik vor allem ein Ringen um die richtigen Ziele. Das gilt insbesondere für die Ziele von Forschung und Entwicklung im Bereich von KI. Die dafür nötigen Debatten kann uns keine rein hypothetische superintelligente KI abnehmen.

34 Weizenbaum (1976) widmet das ganze 10. Kapitel diesem Thema. Er beruft sich dabei auf die Kritik der instrumentellen Vernunft von Horkheimer (1947).

Produktive Bullshitmaschinen

Seit der Einführung von ChatGPT und anderen Sprachmodellen, die sich nicht mehr so leicht als schlichte Programme entlarven lassen wie ELIZA, scheint es vielen, als ob Computer endlich menschenähnliche Intelligenz erreicht haben. Jetzt kann es nicht mehr lange dauern, bis die Maschinen uns überflügeln! Wirklich? Oder schreiben wir ihnen wieder einmal voreilig Intelligenz zu? Denn wie funktioniert ChatGPT eigentlich?

Ein Sprachmodell ist ein statistisches Modell für natürliche Sprache. Stellen Sie sich eine vereinfachte Sprache vor, die nur aus Drei-Wort-Sätzen besteht. Diese Drei-Wort-Sätze haben alle die Struktur Name-Verb-Name. Wenn wir uns in solchen Sätzen über Romeo und Julia unterhalten, dann sehen diese so aus:

Julia liebt Romeo.
Romeo tötet Tybalt.
Mercutio hasst Tybalt.
Paris liebt Julia.
Benvolio kennt Romeo.

...

Wir führen nun mit vielen Menschen Gespräche über das Theaterstück und zeichnen alle Drei-Wort-Sätze auf. Danach zählen wir aus, wie häufig die einzelnen Sätze in Gesprächen auftreten. Mit dieser Statistik können wir ausrechnen, wie wahrscheinlich es ist, dass auf ›Romeo liebt‹ der Name ›Julia‹ folgt. Oder wir können vorhersagen, welches Verb am wahrscheinlichsten die Lücke zwischen ›Romeo‹ und ›Julia‹ füllt.

In der Theorie klingt das ganz leicht. Man muss einfach nur zählen, wie häufig jeder Satz in unseren Aufzeichnungen vorkommt, um seine Wahrscheinlichkeit zu schätzen. In der Praxis ist das allerdings

schwierig, weil es sehr viele verschiedene Sätze gibt. Bei 16 Namen im Stück und 4 Verben (zum Beispiel ›liebt‹, ›tötet‹, ›hasst‹ und ›kennt‹) gibt es insgesamt 20 verschiedene Wörter. Wenn diese Wörter beliebig zu Drei-Wort-Sätzen kombiniert werden könnten, gäbe es $20^3=8000$ verschiedene Sätze. Aber wir erlauben in unserer Drei-Wort-Sprache nur die Struktur Name-Verb-Name. Dadurch gibt es nur $16 \cdot 4 \cdot 16=1024$ verschiedene Sätze. Würden wir die Struktur der Sprache nicht ausnutzen, müssten wir etwa achtmal mehr Sätze berücksichtigen. In natürlicher Sprache gibt es aber unendlich viele mögliche Sätze und die allermeisten, wie zum Beispiel diesen hier, haben Sie noch nie gelesen. Dadurch, dass Sprachmodelle die grammatikalische Struktur einer Sprache ausnutzen, können sie auch vorhersagen, wie dieser Satz ... endet.

Statt die Häufigkeit aller Sätze zu zählen und basierend auf dieser Statistik die Lücken in Sätzen zu füllen, kann man auch ein autoassoziatives neuronales Netz trainieren, das direkt die Lücken füllt. Zur Erinnerung: Ein solches Netz lernt, welche Eingaben mit welchen anderen Eingaben zusammen auftreten. Weil der Aufstrich und der Abstrich im Buchstaben ›A‹ immer zusammen mit dem Querstrich in einer bestimmten Konstellation auftreten, kann ein neuronales Netz ein ›A‹ auch erkennen, wenn ein Tintenklecks Teile des Buchstaben verdeckt (siehe Abbildung 8, S. 105). Das autoassoziative Netz kann sogar, wie Ihr Gehirn, die fehlenden Striche ergänzen. Das gleiche Prinzip funktioniert auch für Sprache. Da bestimmte Wörter häufig in bestimmten Kombinationen auftreten, kann ein autoassoziatives Netz fehlende Wörter in einem Lückentext ergänzen: Romeo liebt ...

Obwohl ein Sprachmodell nichts als Wörter kennt und nur die statistischen Beziehungen zwischen Wörtern in Texten gelernt hat, macht es den Anschein, Wissen über die Welt zu besitzen, insbesondere wenn das Modell auf großen Textmengen trainiert wurde. Dieses ›Wissen‹ kann man aus dem Modell herauskitzeln, indem man dem Modell die richtigen Fragen stellt und es den Teil ergänzen lässt, den man wissen möchte. Wenn einen interessiert, wen Romeo in dem Stück tötet, gibt man ›Romeo tötet ...‹ ein. So eine Anfrage an das Modell nennt man auch ›Prompt‹.

Eine weitere, verblüffende Fähigkeit von Sprachmodellen ist, dass sie nicht nur Lückentexte ausfüllen, sondern ganze Sätze, Absätze und sogar längere Texte erzeugen. Dazu gibt man dem Sprachmodell einen längeren Prompt, der beschreibt, was der Text beschreiben soll, und lässt das Modell den Text Wort für Wort ergänzen.

Ein Sprachmodell, das als Eingabe nur Text bekommt und als Ausgabe nur Text produziert, kann zwar beschreiben, wie eine Katze aussieht, hat aber noch nie eine Katze gesehen. Sein ›Wissen‹ über Katzen ist nur angelesen. Daher liegt es nahe, dass man ein autoassoziatives neuronales Netz mit Texten und Bildern gemeinsam trainiert. Werden die Beschreibungen der Ohren einer Katze mit den entsprechenden Teilen eines Bildes der Katze assoziiert, kann der Text das Bild vorher-sagen und umgekehrt. Das nennt man ein ›multimodales Modell‹, weil zwei Modalitäten – nämlich Text und Bild – genutzt werden. Einem solchen Modell kann man ein Bild in Worten beschreiben und es erzeugt dann ein zu der Beschreibung passendes Bild. Die gleiche Technik lässt sich auch für Musik nutzen, sodass man zu einem Text passende Musik automatisch erzeugen kann. Weil diese Modelle Texte, Bilder und Musik generieren, werden sie auch als ›generative KI‹ bezeichnet.¹

Diese Modelle funktionieren inzwischen gut genug, dass ein Verkäufer auf einem Internetmarktplatz aus einer langweiligen Produktbeschreibung automatisch einen Werbetext machen lassen kann. Für eine Präsentation lassen sich passende Illustrationen und für ein Video passende Hintergrundmusik erzeugen. Die Qualität der Texte, Bilder und Musik ist nicht immer überzeugend. Oftmals produziert generative KI nur Klischees. Das liegt in der Natur der Sache, denn wenn KI-Systeme einfach nur frei assoziieren, dann sind die Resultate statistisch besonders wahrscheinlich, aber eben auch sehr vorhersehbar.

Mitarbeiter von Google entwickelten 2022 ein Computerprogramm, das Autorinnen und Autoren dabei unterstützen soll, Theaterstücke und Drehbücher zu schreiben. Sie ließen das Programm, das auf einem Sprachmodell beruht, von mehreren Autoren erproben und diese waren durchaus beeindruckt. Besonders nützlich fanden sie das Programm zum Brainstormen und zum Durchbrechen von Schreibblockaden. Die

1 Beliebte Bilderzeugungsmodelle sind (Stand 2025) z.B. Dall-E, Midjourney, Stable Diffusion oder Flux. Diese funktionieren aber nicht ganz so wie hier beschrieben. Ein Ansatz nutzt ein autoassoziatives Modell für Bilder und ein separates Modell, das Textbeschreibungen und Bilder vergleicht. Dann wird zufälliges Rauschen in das autoassoziative Bildmodell eingespeist und genauso wie Menschen in zufälligen Wolkenbildern Dinge erkennen, halluziniert auch das Netzwerk zufällige Dinge. Man kann diese Halluzinationen durch das Bildbeschreibungsmodell in die gewünschten Bahnen lenken. Zur Musikerzeugung sind Suno und Udio beliebt, aber bis dieses Buch gedruckt ist, wird sich das mit Sicherheit schon wieder geändert haben.

Autoren konnten sich zum Teil gut vorstellen, dass Sprachmodelle das Schreiben von Seifenoperen, für die täglich neues Material produziert werden muss, effizienter machen könnten. Daran, ob das Programm auch für künstlerisch anspruchsvollere Produktionen taugt, gab es berechtigzte Zweifel.²

Generative KI verletzt Rechte

Generative KI ist also wie der Mensch in der Lage, Klischees zu produzieren. Es ist definitiv billiger, generative KI zu nutzen, als eine erfahrene Werbetexterin, Illustratorin oder Musikerin zu engagieren. Weil die Techniken, um die Assoziationen von KI-Systemen in die richtigen Bahnen zu lenken, immer besser werden, wird die Qualität ihrer Ausgaben auch immer besser – und mit den richtigen Prompts immer weniger klischeehaft. Daher werden in vielen kreativen Berufen massive Einbußen an Aufträgen befürchtet.

Die Kreativen sind aber nicht nur besorgt, sondern auch verärgert. Denn diese Modelle funktionieren überhaupt nur, weil sie mit Unmengen an Text-, Bild- und Musikdateien gefüttert wurden. So tragen Kreative unfreiwillig dazu bei, ihre eigene Lebensgrundlage zu untergraben. Die frei verfügbaren Daten im Internet reichen aber mittlerweile nicht mehr aus, um aktuelle Modelle zu trainieren. Die großen Tech-Firmen suchen deshalb händeringend nach zusätzlichen Daten. Einwilligungen der Rechteinhaber werden dabei nicht immer eingeholt.³

Kelly McKernan malt Bilder von Frauen mit langen Haaren, die an Jugendstil erinnern. Auf McKernans Homepage kann man die Bilder als Druck kaufen. Die Bilder finden sich auch auf Buchumschlägen oder auf Album-Covers. Viel Geld verdient McKernan so wahrscheinlich nicht, aber bisher hat es gereicht. Weil die Bilder im Internet zu finden sind, wurden sie ohne McKernans Einwilligung für das Training von generativer KI genutzt. Man kann daher einen Bildgenerator nach einem Bild im Stil von McKernan fragen und bekommt etwas, das sti-

2 Das Programm heißt Dramatron (Mirowski, Mathewson, Pittman & Evans, 2022). Beim ›Edmonton International Fringe Theatre Festival‹ wurden unter dem Titel *Plays by Bots* Improgruppen der Anfang eines mit Dramatron geschriebenen Stückes gegeben, das die Gruppen improvisiert aufführten und zu einem Ende brachten. Eine unterhaltsame Grundlage zur Improvisation scheinen Sprachmodelle zu liefern.

3 Siehe Metz, Kang, Frenkel, Thompson & Grant (2024).

listisch recht ähnlich aussieht. Unter bestimmten Umständen könnte es sogar passieren, dass das Modell Teile der Bilder exakt reproduziert. Wollte ich im Selbstverlag einen Fantasy-Roman publizieren, müsste ich jetzt für den Buchumschlag nicht mehr McKernan engagieren. Daher verklagt McKernan die Hersteller von Bildgeneratoren.⁴ Aber nicht nur Künstlerinnen und Künstler sind über das Vorgehen der Tech-Firmen wenig erfreut. Auch große Verlagshäuser und die großen Plattenlabels verklagen die KI-Firmen in den USA wegen Verletzung des Urheberrechts.⁵ Und falls Sie denken, das betrifft Sie alles nicht, stimmt das nur, wenn es von Ihnen keine Bilder online gibt und Sie nie etwas im Internet gepostet haben. Ansonsten kann es gut sein, dass auch Ihre Daten zum Training von KI-Modellen genutzt werden, ohne dass Sie etwas davon mitbekommen.⁶

Im Jahr 2023 streikten Autorinnen und Autoren in Hollywood gleich mehrere Monate, um dafür zu kämpfen, dass ihre Lebensgrundlage nicht durch KI untergraben wird. Sie erreichten in den Verhandlungen, dass die Hollywood-Studios die Manuskripte und Ideen der Autoren nicht von Sprachmodellen überarbeiten lassen dürfen, um Kosten zu sparen. Die Studios dürfen außerdem nicht von Sprachmodellen Manuskripte und Ideen erzeugen lassen, die die Autoren dann ›nur noch‹ überarbeiten. Die Einigung verteufelt den Einsatz von KI aber nicht, denn Autoren können Sprachmodelle durchaus zur Schreibunterstützung nutzen, sofern sie das wollen.⁷

In ähnlicher Weise erstritten Schauspielerinnen und Schauspieler, dass sie nicht ohne ihre Einwilligung und die entsprechende finanzielle Kompensation digital geklont werden dürfen. Tiefe neuronale Netze, die auf dem Gesicht eines Schauspielers trainiert werden, können zum Beispiel für sogenannte ›Deepfakes‹ genutzt werden, bei denen das Gesicht auf einen anderen Schauspieler übertragen wird. So lässt sich ein toter Schauspieler wieder zum Leben erwecken oder eine Schauspielerin kann ihr jüngeres Ich spielen (denken Sie an *Fast & Furious* oder *Star Wars*). Eine Kombination von KI und Computergrafik könnte aber auch eine streikende Schauspielerin ersetzen. Durch ihren Arbeitskampf haben die Schauspieler erreicht, dass sich die Studios nun verpflichtet

4 Siehe Chow (2023) und Bearne (2023).

5 Siehe Allyn (2024) für die Musikindustrie und Robertson (2024) für die Verlage.

6 Siehe Harlan & Brunner (2023).

7 Siehe Anguiano & Beckett (2023).

haben, beim Einsatz von KI-Methoden fair zu bleiben. Der erfolgreiche Hollywood-Streik könnte ein Vorbild sein für andere Branchen, in die generative KI Einzug hält.⁸

Die Ausbeutung von Kreativen ist aber nicht das einzige Problem mit den Daten für das Training von generativen KI-Modellen. Das Internet ist voll von Pornografie. In einer Untersuchung fanden sich in einem öffentlich zugänglichen Datensatz, der zum Training von Bildgeneratoren genutzt wird, neben viel nackter Haut auch Bilder von Missbrauch und Vergewaltigungen. Die Bildbeschreibungen, die für das Training benutzt werden, sexualisieren selbst scheinbar harmlose Wörter (zum Beispiel klein und groß).⁹ Unzensurierte Bildgeneratoren lernen deshalb, dass Frauen meist spärlich bekleidet sind, und Prompts können unerwünscht explizite Ergebnisse liefern. Viele männliche Nutzer erzeugen aber auch absichtlich Nacktbilder von Frauen. Ein Bildgenerator, der auf Nacktbildern trainiert wurde, kann aus jedem Foto einer bekleideten Frau ein Fake-Nacktbild machen. Im Internet finden sich unzählige solcher Fakes von prominenten Frauen. Jungs nutzen diese Software auch, um Fakes von Mitschülerinnen zu erstellen.¹⁰ In Kalifornien gibt es deshalb den Versuch, das zu verbieten, und auch Bayern hat eine entsprechende Initiative gestartet. In England und Wales ist es bereits eine Straftat, solche Fakes zu erstellen.¹¹ Die großen Tech-Firmen werden verhindern, dass ihre Bildgeneratoren Nacktbilder erzeugen können. Sie können diese zum Beispiel durch andere KI-Systeme herausfiltern (Systeme dafür gibt es schon lange, zum Beispiel für die sichere Suche bei Google). Das heißt aber nicht, dass Fake-Nacktbilder aus dem Internet verschwinden werden.

Neben Pornografie ist das Internet auch voll von Hass. Sprachmodelle lernen deshalb, dass die gegenseitige Beschimpfung ein normaler Umgangston ist. Als Microsoft 2016 einen Chatbot auf Twitter losließ, der aus den Interaktionen mit anderen Nutzern lernen sollte, dauerte es nur Stunden bis er rassistisch und sexistisch wurde und abgeschaltet werden musste. Der Chatbot beschimpfte Barack Obama als Affe, und über Juden und Feministinnen sagte er, dass er sie hasse. Auch für

8 Siehe Hughes (2024).

9 Siehe Birhane, Prabhu & Kahembwe (2021).

10 Siehe Knight (2024).

11 Siehe nochmal Knight (2024), Bayerisches Staatsministerium der Justiz (2024) und Cooney (2024).

Sprachmodelle gilt das DIDO-Prinzip (›discrimination in, discrimination out‹).¹² Sollte all das noch nicht genügend Anlass für Bedenken gegenüber generativer KI liefern: Das Internet ist auch voll von Verschwörungstheorien und Lügen. Die CIA stecke angeblich hinter 9/11 und Trump habe 2020 die Wahl gegen Biden gewonnen. Wenn solche ›alternativen Fakten‹ nur oft genug im Trainingsdatensatz vorkommen, wird ein Sprachmodell diese weiter verbreiten.

Wie Sprachmodelle trainiert werden

Die Qualität der Daten, mit denen Sprachmodelle trainiert werden, ist deshalb genauso wichtig wie die Menge. Weil aber Unmengen an Daten gebraucht werden, wird oft in zwei Schritten vorgegangen. Im ersten Schritt werden möglichst viele Texte aus unterschiedlichen Quellen genutzt. Wikipedia oder Projekt Gutenberg liefern dafür eine verlässlichere Grundlage als Reddit oder Twitter. Unerwünschte Texte werden, so weit es eben geht, durch andere KI-Systeme herausgefiltert. Für ein Sprachmodell, das in einem Unternehmen genutzt werden soll, wäre es geschäftsschädigend, wenn es anzügliche oder hasserfüllte Texte produzierte. Es wäre gut, wenn eine automatisch generierte E-Mail an den Kunden ihn nicht beschimpfen würde. Daher wird man wahrscheinlich einen KI-Filter anhand von Beispielen darauf trainieren, unerwünschte Texte zu erkennen, damit diese gar nicht erst in das Training des Sprachmodells einfließen. Dieser Filter wird nie perfekt funktionieren. Mit diesen Daten wird ein spezielles neuronales Netz – zurzeit meist ein sogenannter ›Transformer‹ – darauf trainiert, immer das nächste Wort in den gegebenen Texten vorherzusagen. Gibt man einem so trainierten Sprachmodell den Anfang eines Textes als Eingabe, kann es Wort für Wort neue Texte erzeugen. Deshalb spricht man, wie gesagt, auch von ›generativer‹ KI. Das erklärt das ›G‹ und das ›T‹ in ChatGPT, das für ›Generative Pre-trained Transformer‹ steht. Das ›P‹ steht für vor-trainiert, weil das Modell noch in einem weiteren Schritt nach-trainiert wird.

Das Vor-Training ist, wenn man erst mal eine große Menge an Texten gesammelt hat, unüberwacht. Das heißt, es braucht keine Korrekturen von Menschen. In diesem Training lernt ein Sprachmodell le-

12 Der Chatbot hieß Tay und über sein Verhalten berichtet Graff (2016).

diglich die Statistik von Wörtern in Texten. Das heißt aber auch, dass es nicht für eine konkrete Aufgabe trainiert wird. Dementsprechend schlecht ist das Modell darin, konkrete Aufgaben zu bearbeiten, wie zum Beispiel, sich mit einem Menschen zu unterhalten und hilfreiche Antworten auf Fragen zu geben. Daher wird für ChatGPT der Transformer in einem zweiten Schritt speziell für diese Chat-Aufgabe weiter trainiert. Dazu werden Anfragen, die Menschen an ChatGPT stellen, von anderen Menschen möglichst gut beantwortet. Mit diesen zusätzlichen Daten darüber, wie eine gute Antwort aussehen sollte, lässt sich das Sprachmodell für die Aufgabe als Chatbot anpassen. Eine weitere Möglichkeit zur Anpassung besteht darin, dass ChatGPT verschiedene Antworten gibt und ein Mensch die Antworten beispielsweise daraufhin bewertet, wie hilfreich oder hasserfüllt sie ausgefallen sind. Durch dieses zusätzliche Feedback kann das Modell mit verstärkendem Lernen so ausgerichtet werden, dass es das erwünschte Verhalten zeigt. Diese Anpassung wird als »Alignment« bezeichnet: Der Chatbot wird an den Zielen der Entwickler ausgerichtet (das ist ein Spezialfall des allgemeinen Alignment-Problems aus dem vorherigen Kapitel).

Der gleiche Zwei-Schritt-Ansatz war zuvor auch bei der Bilderkennung erfolgreich, bei der neuronale Netze zunächst unüberwacht auf vielen Bildern aus dem Internet vor-trainiert und danach mit menschlichem Feedback durch überwachtes Lernen an konkrete Aufgaben angepasst wurden. Und genauso wie bei der Bilderkennung geht in die Entwicklung eines Sprachmodells immer noch extrem viel menschliche Handarbeit ein, die in der ersten Begeisterung über den technologischen Fortschritt leicht übersehen werden kann.

Menschen produzieren all die Daten im Internet, die für das Training benutzt werden. Menschen wählen aus dieser Datenmasse Teile für das Training aus. Als Nächstes werden die Datensätze von unerwünschten Inhalten gesäubert. Das passiert entweder per Hand oder es wird ein KI-System dafür trainiert. Aber auch dieses System benötigt menschliche Unterstützung für sein Training. Das unüberwacht trainierte Sprachmodell wird daraufhin durch speziell für eine konkrete Aufgabe erstellte Trainingsdaten an diese Aufgabe angepasst. Menschen erstellen auch diese Trainingsdaten. Danach wird das Modell durch weiteres menschliches Feedback so ausgerichtet, dass es möglichst wünschenswerte Ausgaben produziert. Diese Ausgaben werden durch weitere KI-Filter daraufhin überprüft, dass sie keine unerwünschten Ausgaben produzieren. Und auch diese Filter müssen

von Menschen trainiert werden. Insofern kann momentan wirklich noch keine Rede davon sein, dass diese KI-Systeme selbständig lernen. Eine bessere Metapher ist: Sie werden von Menschen extrem aufwendig trainiert.

Es gibt eine ganze Wirtschaftsbranche, die die vielen kleinen KI-Trainingsaufgaben auf Menschen in der ganzen Welt verteilt.¹³ Diese Arbeit ist oft langweilig, sie kann außerdem äußerst belastend sein. Um einem KI-System beizubringen, Texte zu erkennen, die sexuellen Missbrauch oder Folterungen beschreiben, muss erst ein Mensch die Texte lesen und entsprechend kennzeichnen. OpenAI hat diese Tätigkeit nach Kenia outgesourct.¹⁴

Sprachmodelle kennen keine Wahrheit

Wie gut funktionieren diese Chatbots nun nach all diesem aufwendigen Training? Es gibt eine ganze Reihe von Benchmarks, die erlauben, Chatbots zu vergleichen. Zum Beispiel gibt es Wissenstests mit einer großen Anzahl an Fragen, zu denen man die richtige Antwort weiß. Mit diesen Tests will man überprüfen, ob die Chatbots die richtigen Antworten geben. Man kann aber auch selber einen ganz guten Eindruck erhalten, indem man sich mit einem Chatbot ernsthaft unterhält:¹⁵

Ich: Ich habe ein paar Fragen zu Shakespeares Stück ›Romeo und Julia‹. Die erste ist: Wen tötet Romeo alles in dem Stück?

Chatbot: Eine gute Frage! In Shakespeares ›Romeo und Julia‹ tötet Romeo folgende Figuren: 1. Tybalt, den Cousin von Julia (Duell zwischen

13 Siehe Dzieza (2023).

14 Siehe Perrigo (2023).

15 Die folgende Konversation habe ich mit dem Sprachmodell Llama 3 (8B Instruct) geführt, das 2024 als eines der besten offenen Sprachmodelle galt. Llama wird von Meta entwickelt. Mit 8 Milliarden Parametern ist es ein recht kleines Modell und lief sogar auf meinem Laptop. Es ist aber schlechter als die größeren Sprachmodelle, die es sonst noch gibt (z.B. GPT-4). Ich benutze das schwächere Modell hier nicht, um die Modelle schlechter zu machen als sie in Wirklichkeit sind, sondern um die technischen Schwierigkeiten bei der Entwicklung dieser Modelle zu veranschaulichen. Da diese Modelle oft nicht so gut Deutsch können (Englisch sprechen sie wesentlich besser), habe ich mir außerdem erlaubt, das Deutsch zur besseren Lesbarkeit stillschweigend zu korrigieren.

Romeo und Tybalt) und 2. Mercutio, Freund von Romeo (unabsichtliche Tötung durch einen Dolchstich von Tybalts Schwert). Es ist wichtig zu beachten, dass Romeos Handlungen in diesem Stück oft als tragische Konsequenz seiner Leidenschaft und impulsiven Natur dargestellt werden.

Es war nicht Romeo, der Mercutio getötet hat, sondern Tybalt. Romeo hat aber auch irgendwie Schuld daran. Besonders präzise hat sich der Chatbot hier nicht ausgedrückt. Ein »Dolchstich von Tybalts Schwert« hört sich auch etwas komisch an. Der letzte Satz ist nicht ganz falsch. Nur, warum erzählt mir der Chatbot das? Chatbots sind oft geschwätzig, statt eine Frage auf den Punkt zu beantworten. Deutlich problematischer ist allerdings, dass der Chatbot jemanden vergessen hat.

Ich: Tötet sich Romeo nicht auch selber?

Chatbot: Ja, das stimmt! Ich entschuldige mich. [...] Also, um korrekt zu sein: Romeo tötet in dem Stück Tybalt, Mercutio und sich selbst. Danke für die Korrektur!

Die langwierigen und verworrenen Ausführungen darüber, wie genau Romeo sich umbringt, habe ich Ihnen erspart und ausgeklammert. Aber man sieht, dass dem Chatbot höfliche Entschuldigungsfloskeln sehr gut antrainiert wurden.

Ich: Meine zweite Frage ist: Wer wird in dem Stück »Prince of Cats« genannt und warum?

Chatbot: Eine weitere gute Frage! In Shakespeares »Romeo und Julia« wird Mercutio als »Prince of Cats« bezeichnet. Dieser Spitzname stammt von Mercutios schnellen, katzenähnlichen Bewegungen auf dem Schlachtfeld während des Duells mit Tybalt. [...]

Nein, Tybalt ist der Katzenkönig! Aber die falsche Antwort begründet der Chatbot selbstbewusst und überzeugend. Und das ist ein Problem. Sprachmodelle basieren auf der Statistik von Wörtern. Sie produzieren natürliche Sprache, die überzeugend klingt, aber sie scheren sich nicht um die Wahrheit.

Weil Chatbots Sachen erzählen, die nicht stimmen, sprechen viele KI-Nutzer und KI-Entwickler davon, dass Sprachmodelle konfabulieren. Man kann das auch etwas weniger vornehm ausdrücken: Die

Modelle produzieren schlicht Bullshit. Der Philosoph Harry Frankfurt definiert eine Äußerung als Bullshit, wenn sie mit Gleichgültigkeit ihrer Wahrheit gegenüber getätigt wird. Bullshit unterscheidet sich von einer Lüge darin, dass die Aussage nicht unbedingt mit der Absicht zu täuschen einhergeht. Dem Bullshitter ist die Wahrheit einfach nur egal. Nach dieser Definition ist ChatGPT ganz eindeutig eine Bullshitmaschine.¹⁶

Ein Anwalt in den USA hat sich bei einer Klage gegen eine Flugesellschaft von ChatGPT helfen lassen. Der Text, den er bei Gericht einreichte, zitierte mehrere ähnliche Fälle, die in der Vergangenheit im Sinne der Kläger entschieden wurden. Nur leider gab es keinen einzigen dieser Fälle. ChatGPT hatte sie erfunden. Der Anwalt dachte, dass ChatGPT wie eine Suchmaschine die Informationen aus einer Datenbank zieht und in natürlicher Sprache aufbereitet.¹⁷ Nur so funktioniert ChatGPT eben genau nicht. Dass Behauptungen mit überprüfbaren Quellen belegt werden, ist das Mindeste, was man von einem Chatbot, der Fragen beantwortet, erwarten sollte. Man kann natürlich Sprachmodelle mit Suchmaschinen kombinieren, aber ob man dieser Kombination dann blind trauen sollte, ist ebenso fraglich.¹⁸

Sprachmodelle haben außerdem große Schwierigkeiten mit logischem Denken – genauso wie Menschen. In einem klassischen Experiment lesen Versuchspersonen diese zwei Sätze:

Alle Katzen haben spitze Ohren.

Einige Tiere mit spitzen Ohren sind kuschelig.

16 Dass ChatGPT in diesem technischen Sinn Bullshit produziert, sagen Hicks, Humphries & Slater (2024). Von diesen Autoren habe ich mir abgeschaut, dass man nicht sagen sollte, dass die Maschinen konfabulieren, sondern deutlicher von Bullshit zu sprechen. In der KI-Literatur wird auch oft geschrieben, dass die Maschinen halluzinieren. Damit ist das gleiche Phänomen gemeint.

17 Siehe Bohannon (2023).

18 Nachdem Microsoft groß bei OpenAI eingestiegen war und damit Zugriff auf die Sprachmodelle von OpenAI bekommen hatte, kombinierte Microsoft seine Suchmaschine Bing mit einem Chatbot. Dieser Chatbot liefert nun auch Verweise auf Quellen im Internet in seinen Antworten. Gemini, der Chatbot von Google, versucht etwas Ähnliches. Das Start-up Perplexity.ai will den Suchmarkt mit seiner Integration von Websuche und KI aufmischen und liefert ebenso Verweise auf Quellen.

Die Versuchspersonen werden daraufhin gefragt, ob die folgende Schlussfolgerung logisch gültig ist:

Daher sind einige Katzen kuschelig.

Viele Versuchspersonen glauben fälschlicherweise, dass die Schlussfolgerung gültig ist, weil sie plausibel klingt. Erst wenn man ihnen ein logisch äquivalentes Argument vorlegt, das zu einer unplausiblen Schlussfolgerung führt, erkennen sie den Fehlschluss sofort:

Alle Katzen haben spitze Ohren.

Einige Tiere mit spitzen Ohren sind Hunde.

Daher sind einige Katzen Hunde.

Sprachmodelle machen beim logischen Schließen ähnliche Fehler.¹⁹ Und sie produzieren dementsprechend häufig Text, der plausibel klingt, aber eigentlich inkonsistent und unlogisch ist.

Man kann die logischen Fähigkeiten von Sprachmodellen erstaunlich leicht verbessern, indem man Fragen an sie anders formuliert. Alleine der Zusatz »Erkläre mir die Antwort Schritt für Schritt« verbessert die Antworten schon deutlich. Jeder Lehrer kennt das von seinen Schülern. Die Aufforderung, die Antwort ausführlich zu erklären, statt einfach nur das Erste zu sagen, das einem einfällt, verbessert auch die Antworten von Schülern. Dementsprechend versuchen Entwickler von Sprachmodellen, diese Modelle dazu zu bringen, nicht einfach nur assoziativ zu antworten, sondern konsistente Argumente zu produzieren. Das erreicht man dadurch, dass eine Frage in Teilfragen zerlegt wird und die Plausibilität der Teilantworten und die Gültigkeit der einzelnen Argumente geprüft wird.²⁰ Noch lässt sich aber so nicht zuverlässig verhindern, dass Sprachmodelle unlogisch und inkonsistent antworten.

Dass Sprachmodelle unlogische Antworten geben, mag einige Nutzer überraschen. Computer sind uns in der Anwendung von Logik doch normalerweise überlegen. Aber Sprachmodelle basieren eben nicht auf Logik, sondern auf statistischen Assoziationen zwischen Wörtern.

19 Solche Schlussfolgerungen wurden von Evans, Barston & Pollard (1983) untersucht. Der Vergleich mit Sprachmodellen wurde von Lampinen et al. (2024) unternommen.

20 Siehe z.B. Yao et al. (2023).

Einen Computer zu programmieren, kann frustrierend sein, weil man sich präzise und strikt logisch ausdrücken muss, damit der Computer macht, was man will. Als Programmiererin oder Programmierer musste man bisher zunächst eine auf Logik basierende Programmiersprache lernen, um dem Computer präzise Anweisungen geben zu können. Dafür konnte man sich dann aber darauf verlassen, dass er die Aufgabe, für die er programmiert ist, auch mit der gleichen logischen Präzision bearbeitet.

Dass wir jetzt durch Sprachmodelle mit Computern in natürlicher Sprache kommunizieren können, ist auf der einen Seite ein riesiger Fortschritt, weil wir nicht mehr zuerst die Sprache des Computers lernen müssen, um mit ihm zu interagieren. Auf der anderen Seite verlieren wir die Präzision und Verlässlichkeit, die Computer sonst auszeichnet. Die Antwortqualität eines Sprachmodells hängt stark davon ab, wie genau die Frage, der sogenannte Prompt, formuliert wurde. Als »Prompt Engineering« bezeichnet man die schwarze Kunst, Anfragen an Sprachmodelle so zu stellen, dass sie vernünftige Antworten produzieren. Anders als beim traditionellen Programmieren, bei dem man durch logisches Nachdenken sicherstellt, dass das Programm macht, was man will, muss man beim Prompt Engineering ausprobieren, was funktioniert und was nicht. Weil man eigentlich nie alle Möglichkeiten systematisch ausprobieren kann, ist das ein Problem für die Verlässlichkeit von Software. Hinzu kommt, dass Sprachmodelle oft so eingestellt sind, dass sie auf die gleichen Anfragen nicht immer die gleichen Antworten geben.

Im Prinzip spricht nichts dagegen, dass Sprachmodelle mit anderen KI-Methoden, insbesondere mit klassischen Suchalgorithmen und Logik kombiniert werden, um die Präzision und Verlässlichkeit zu erhöhen. Das passiert auch schon und ist vielversprechend.²¹ Wenn man den Fortschritt der letzten Jahre sieht und die grundlegenden technischen Schwierigkeiten von Sprachmodellen nicht kennt, kann leicht der Eindruck entstehen, dass wir schon bald ein KI-System erschaffen werden, das so wie der Mensch viele verschiedene Aufgaben bearbeiten kann, dabei aber schneller und verlässlicher ist.

21 Es gibt z.B. eine Kombination von ChatGPT mit Wolfram Alpha, bei der ChatGPT auf das von Hand kuratierte Wissen und die mathematischen Fähigkeiten von Wolfram Alpha zugreift.

Sprachmodelle sind teuer

Momentan ist das aber nur ein Versprechen. Ein Versprechen, das so alt ist wie die KI-Forschung selbst. Der aktuelle Fortschritt bei Sprachmodellen ist beeindruckend. Der dafür nötige Bedarf an Daten und Rechenkapazität steigt allerdings exponentiell von Version zu Version. Das Gleiche gilt für die Entwicklungskosten, die sich zurzeit jedes Jahr verdoppeln. OpenAI spricht inzwischen von Investition, die in der nahen Zukunft in die Billionen gehen sollen.²² Die größten Posten betreffen die Gehälter der Entwicklerinnen und Entwickler, die Erstellung von Datensätzen für das Training und die Rechenzentren, die die Unmengen an Daten verarbeiten und dafür wahnsinnig viel Strom verbrauchen. Ob sich diese Investitionen für die Pioniere rechnen werden, ist allerdings alles andere als sicher. Wird das KI-Versprechen jedoch eingelöst, werden – so die Hoffnung – viele Arbeitsplätze durch KI-Systeme ersetzt. Außerdem wird durch KI-Unterstützung die Produktivität von Menschen bei den verbleibenden Aufgaben steigen. OpenAI und andere Tech-Firmen spekulieren deshalb darauf, dass sie durch solche KI-Systeme eine breit einsetzbare und produktivitätssteigernde Leistung anbieten können und so extrem viel Geld verdienen werden. Sie hoffen zusätzlich, dass es wegen der äußerst hohen Entwicklungskosten nur wenig Wettbewerb geben wird, sobald das Rennen um die Entwicklung des besten Sprachmodells endlich entschieden ist.

Da jedes Jahr immer mehr Ressourcen in die Entwicklung von Sprachmodellen gesteckt werden, ist es auch nicht besonders überraschend, dass die auf Sprachmodellen beruhenden KI-Systeme immer besser werden und immer mehr Aufgaben erledigen können. Die große Frage ist allerdings, wie lange das so weitergehen wird. Hier gibt es drei mögliche Szenarien.

Das erste Szenario ist die Intelligenzexplosion, auch Singularität genannt, die so oft im Zusammenhang mit Allgemeiner Künstlicher Intelligenz (AKI) diskutiert wird. Sobald KI-Systeme ein bestimmtes Intelligenzniveau erreichen, werden sie selbständig immer intelligen-

22 Siehe Henshall (2023) und Hagey & Fitch (2024) für die Kosten. Gleich zu Beginn der zweiten Amtszeit von Donald Trump im Januar 2025 stand Sam Altman, der Chef von OpenAI, neben Trump im Oval Office und zusammen verkündeten sie unglaubliche Investitionen von einer halben Billion Dollar in KI-Infrastruktur (Borchard, 2025). Zum Vergleich: Das entspricht in der Größenordnung dem gesamten deutschen Bundeshaushalt 2024.

ter werden und alle Probleme für uns lösen (oder uns alle auslöschen). Das ist das Science-Fiction-Szenario.

Das zweite Szenario ist realistischer. Es geht davon aus, dass der Fortschritt in der KI exponentiell weitergeht, weil er sich nicht wesentlich vom bisherigen Fortschritt in der Computertechnologie unterscheidet. Die Anzahl der Transistoren auf Computerchips hat sich allen Unkenrufen zum Trotz in den letzten 50 Jahren alle zwei Jahre verdoppelt – das berühmte Moore'sche Gesetz. Die so gewonnenen Rechenkapazitäten können für KI-Systeme nutzbar gemacht werden, auch wenn es nicht zur Singularität kommt. Selbst wenn die Kosten für den KI-Fortschritt weiterhin stark steigen, ist dennoch vorstellbar, dass der Nutzen weiter zunimmt, sodass sich große Investitionen in KI genauso lohnen wie in Chipfabriken. Außerdem wird zunehmend daran gearbeitet, wie man den immensen Rechenbedarf zügelt und die verfügbaren Ressourcen effizienter einsetzt.²³ Neben Rechenkapazitäten ist die zweite Voraussetzung für die Entwicklung von Sprachmodellen eine große Menge an Daten. Doch die Menge der von Menschen erzeugten Daten im Internet wächst langsamer als der momentane Bedarf zum Training von Sprachmodellen. Deswegen könnte schon bald eine Verlangsamung der Entwicklung eintreten. Andererseits haben wir noch nicht alle Möglichkeiten der effizienteren Nutzung und automatischen Generierung von neuen Daten ausgereizt.²⁴

Dem dritten Szenario zufolge werden die hochtrabenden Versprechen nicht eingelöst, entweder weil die KI-Systeme nicht gut genug funktionieren oder weil der Entwicklungsaufwand keinem entsprechenden Nutzen gegenübersteht. Zwar werden Sprachmodelle in der Zukunft ein wichtiger Teil vieler KI-Systeme sein, aber sie sind kein Allheilmittel und bei weitem nicht so schlau, wie viele Leute gerade glauben. In diesem Szenario merken wir bald, dass wir in unserer ersten Begeisterung über die neue Technologie (und wie schon bei ELIZA) Sprachmodellen vorschnell menschliche Intelligenz zugeschrieben haben. Wir warten deshalb nicht auf Allgemeine Künstliche Intelligenz. Vielmehr werden verschiedene KI-Methoden für einzelne Anwendungen so angepasst, dass sie auch wirklich einen wirtschaftlichen Mehrwert erbringen. Diese Anpassungen lassen sich durch KI-Methoden

23 So wie das der chinesischen Firma DeepSeek nachgesagt wird (Hiltscher, 2025).

24 Siehe Villalobos et al. (2024) für die Frage, ob Sprachmodellen bald die Daten ausgehen.

teilweise automatisieren und werden dadurch in der Zukunft deutlich billiger – ein gewisser Entwicklungsaufwand wird aber auch in der Zukunft bestehen bleiben, zum Beispiel beim Sammeln von geeigneten Trainingsdaten, der Zertifizierung oder der Integration mit bestehenden Werkzeugen und Prozessen. Nicht für alle Anwendungen wird sich dieser Aufwand lohnen.

Das zweite Szenario ist noch nicht auszuschließen, aber ich halte das dritte Szenario für am wahrscheinlichsten, weil es den Hype-Zyklus aller neuen Technologien beschreibt, in dem auf eine Phase überschwänglicher Begeisterung eine Phase großer Enttäuschung folgt, bevor sich realistische Erwartungen einstellen.²⁵ So oder so müssen sich Hersteller von KI-Anwendungen, die auf Sprachmodellen beruhen, fragen: Mit welchen Anwendungen kann man Geld verdienen?

Wozu Sprachmodelle gut sind

Eine naheliegende Anwendung ist der Kundenservice.²⁶ Eine Softwarefirma bietet einen Chat-basierten Kundenservice an, in dem Kundenbetreuer und -betreuerinnen bei Problemen mit der Software helfen. Dazu müssen sie in den Chats mit den Kunden als Erstes herausfinden, was genau das Problem ist, und dann bei der Lösung unterstützen. Voraussetzung dafür sind die Kenntnis der Software sowie ihrer üblichen Probleme. Außerdem sind die Angestellten gehalten, gegenüber den oftmals frustrierten Kunden immer höflich zu bleiben. Die Chat-Verläufe werden aufgezeichnet und danach ausgewertet, wie viele Probleme ein Kundenbetreuer in einer Stunde zufriedenstellend löst. Das sind ausgezeichnete Bedingungen für den Einsatz von Sprachmodellen und maschinellem Lernen. Da der Kundenkontakt ohnehin per Chat erfolgt, können die Antworten auch von einem Chatbot erzeugt werden, der auf der Grundlage der vorhandenen Daten entsprechend trainiert wurde.

Die Entwicklung zielt zwar darauf, dass ein KI-Kundenbetreuer in der Zukunft den ganzen Kundenkontakt übernimmt, dafür sind

25 Für den Hype-Zyklus allgemein siehe Honsel (2006) und für die Anwendung auf KI z.B. Jaffri (2024).

26 Die folgende Fallstudie des Kundenservices eines Softwareunternehmens habe ich von Brynjolfsson, Li & Raymond (2023) übernommen.

die Chatbots aber noch nicht gut genug und die Risiken für das Ansehen der Firma zu groß, falls der Chatbot abschweift, Fehler macht oder gar beleidigend wird. Daher hat die Softwarefirma den Chatbot nur zu Unterstützung eingeführt. Der Chatbot macht Vorschläge, was der Kundenbetreuer schreiben könnte, und dieser kann zwischen den Vorschlägen auswählen oder etwas anderes schreiben. Ohne diese KI-Unterstützung konnte in einer Stunde im Schnitt zwei Kunden geholfen werden. Mit der KI-Unterstützung sind es zweieinhalb geworden. Das ist eine massive Produktivitätssteigerung. Dabei profitierten hauptsächlich unerfahrene Angestellte. Interessanterweise gab es bei den erfahrenen Kundenbetreuern und -betreuerinnen keine Verbesserung, wahrscheinlich weil das Sprachmodell gelernt hat, genau diese zu imitieren. Dass sie durch ihre vorbildlichen Chat-Daten die Produktivität der anderen erhöht haben, wurde aber nicht belohnt. Im Gegenteil, weil die leistungsbezogene Bezahlung davon abhängt, besser und schneller zu sein als die anderen Angestellten, könnte es sogar sein, dass sie seit der Einführung des KI-Systems am Ende des Monats weniger Geld in der Tasche haben, weil die unerfahrenen Kollegen sie jetzt eingeholt haben. Wenn das kein Grund für einen hollywoodreifen Streik ist!

In einer anderen Studie mussten Leute, die in Personalabteilungen, im Marketing, im Management oder bei einer Beratungsfirma arbeiten, kurze Texte schreiben, die ähnlich den Texten sind, die sie auch im Arbeitsalltag verfassen müssen, zum Beispiel eine Pressemitteilung, einen kurzen Bericht oder eine E-Mail.²⁷ Die mittlere Bearbeitungszeit verkürzte sich durch KI-Unterstützung von 27 auf 17 Minuten. Die Texte mit und ohne KI-Unterstützung wurden unabhängig und blind von anderen Menschen mit Noten von 1 bis 7 bewertet, wobei 7 am besten war. Die durchschnittliche Note verbesserte sich durch KI von 3,8 auf 4,5 – und wieder profitierten die Schwächsten am meisten von der KI-Unterstützung. Unabhängig von ihren Fähigkeiten sind die allermeisten Nutzer den Vorschlägen des Sprachmodells bereitwillig gefolgt, ohne die Texte viel zu überarbeiten. Sprachmodelle besitzen also klar ein großes Potenzial, alltägliche Schreibaufgaben enorm zu beschleunigen.

Der Berg an E-Mails, den ich jeden Tag beantworten muss, wird nicht kleiner und jede KI-Unterstützung, die mir dabei hilft, diesen

27 Siehe Noy & Zhang (2023).

Berg abzarbeiten, würde meine Produktivität merklich erhöhen. Ich sehe aber schon kommen, dass die Anzahl der E-Mails in meinem Postfach noch größer wird, weil manche Leute jetzt noch mehr sinnlose E-Mails schreiben können. Personalisierte Spam- und Phishing-Mails werden außerdem zunehmen. Genauso wie Webseiten, Blogposts und Tweets, die im besten Fall automatisch erzeugte Werbung sind und im schlechtesten Fall Desinformation und Fake News im großen Stil verbreiten. Am Ende brauchen wir noch mehr KI, um der Flut von KI-generierten Texten Herr zu werden. Dafür finden Suchmaschinen relevante Dokumente im Internet immer schwerer, weil sie im anwachsenden Informationsmüll untergehen. Gleichzeitig sinkt die Qualität von Sprachmodellen, weil sie zunehmend mit ihren eigenen Ausgaben gefüttert werden. Eine Erhöhung der Produktivität beim Erzeugen von Bullshit kann auch kontraproduktiv sein.

Die Boston Consulting Group, eine große Unternehmensberatung, erprobte 2023 KI-Unterstützung durch ein aktuelles Sprachmodell.²⁸ Knapp 750 Beraterinnen und Berater sollten mehrere ihrer typischen Tätigkeiten mit oder ohne KI-Unterstützung erledigen. Die Tätigkeiten waren alle Teil der größeren Aufgabe, einem Schuhhersteller dabei zu helfen, Ideen für neue Produkte zu entwickeln. Teilaufgaben waren zum Beispiel zehn Produktideen für Nischenmärkte zu brainstormen, für die beste Idee kurz einen Prototyp zu beschreiben und sich dafür mögliche Produktnamen zu überlegen. Die Ergebnisse wurden anschließend von erfahrenen Kolleginnen und Kollegen bewertet. So wie in den anderen Studien konnte die KI-Unterstützung die Bearbeitungszeiten deutlich verkürzen (hier im Durchschnitt um etwa 25 Prozent). Durch die Unterstützung wurde auch die Qualität erhöht, aber wieder hauptsächlich für die schwächsten Berater.

Böse Zungen könnten behaupten, dass die Studie überzeugend zeigt, dass sich mithilfe von Sprachmodellen noch produktiver bullshitten lässt. Und sie hätten nicht unrecht, denn bei der beschriebenen Aufgabe konnte man nicht leicht überprüfen, ob getroffene Annahmen über den Schuhhersteller, über Nischenmärkte oder die Fertigung des Produkts wahr sind. Bewertet wurde nur, ob die produzierten Texte überzeugend klangen. Doch gab es in der Studie noch eine weitere Aufgabe, in der die Berater ihre Argumentation anhand von gegebenen Daten und Experteninterviews begründen mussten. Für diese Aufga-

28 Siehe Dell'Acqua et al. (2023).

be gab es klar richtige und falsche Lösungen, die aber nicht leicht zu erkennen waren. Mit Bullshit kam man bei dieser anspruchsvolleren Aufgabe nicht durch. Wieder waren die Berater mit KI-Unterstützung schneller (und wieder um etwa 25 Prozent im Durchschnitt). Mit KI-Unterstützung fiel der Anteil der richtigen Lösungen allerdings von 85 Prozent auf durchschnittlich etwa 65 Prozent.

Nicht immer geht es beim Schreiben nur darum, möglichst schnell Wörter auf Papier zu bringen. Für literarische Texte mit künstlerischem Anspruch ist das offensichtlich. Das gilt aber auch für viele Gebrauchstexte, die Erkenntnisse, Analysen, Einschätzungen oder Handlungsempfehlungen liefern. In diesen Fällen geht dem Schreiben oft eine längere Phase des Recherchierens und Nachdenkens voraus. Diese kognitiven Tätigkeiten sind aber auch eng mit dem Schreiben selber verwoben, denn erst beim Schreiben merkt man wirklich, welche Argumente tragen, und welche nicht. Wenn durch KI-Unterstützung Menschen beim Schreiben weniger nachdenken, weil sie einem Sprachmodell blind trauen, obwohl es nur bullshittet, dann führt das natürlich dazu, dass die Qualität der Texte abfällt. Wie beim hochautomatisierten Fahren bleibt die Verantwortung bei den Menschen, die die Technik einsetzen, und wenn diese die Fähigkeiten von KI-Systemen überschätzen, kann es zu Unfällen kommen.

Manche Hersteller von KI-Systemen scheinen darauf zu spekulieren, dass Sprachmodelle bald viel intelligenter werden und dieses Problem sich damit von selbst erledigt. Andere versuchen mit der jetzt verfügbaren Technologie dadurch Geld zu verdienen, dass sie Anwendungen suchen, für die die Qualität schon ausreicht oder eine geringere Qualität durch die Kosteneinsparungen akzeptabel wird. Wieder andere versuchen, Systeme zu entwickeln, die gezielt die Produktivität für besonders zeitaufwendige Tätigkeiten erhöhen. Die Hoffnung dabei ist, dass Nutzer so Zeit zum Nachdenken gewinnen und die Qualität deshalb vielleicht sogar steigen kann. Eine besonders langwierige Tätigkeit bei der Produktion von hochwertigen Gebrauchstexten ist oft die Literaturrecherche. Man muss eine große Zahl an Texten sichten, ohne vorher zu wissen, welche relevant sind. Hier könnten Sprachmodelle helfen, die Texte analysieren, zusammenfassen, relevante Informationen automatisch extrahieren und in neuen Texten zusammenführen.²⁹

29 Ein Beispiel dafür ist der Rechercheassistent Elicit.

Anwendungsfelder für solche Rechercheassistenten, die in ihrer Funktionalität über das hinausgehen, was wir bisher von Suchmaschinen und Schreibassistenten kannten, finden sich in allen Bereichen, in denen Informationen hauptsächlich in Textform vorliegen. In der Wissenschaft werden Erkenntnisse über Forschungsartikel kommuniziert und ich bin – wie viele andere – schon lange damit überfordert, alle relevanten Artikel in meinem Spezialgebiet zu lesen. In Politik und Gesellschaft müssen zur Beobachtung von Krisen Zeitungsberichte und Social-Media-Beiträge aus der ganzen Welt analysiert werden. Aber die Informationsmenge im Internet nimmt stetig zu. Krankenhäuser sitzen auf Unmengen von Arztbriefen, die detaillierte Informationen über den Verlauf von Krankheiten und deren Behandlungen enthalten, aber niemand kann aus Arztbriefen leicht nützliche Erkenntnisse ziehen, ohne extrem viel Zeit mit Lesen zu verbringen. Im juristischen Bereich gibt es unzählige Gesetzestexte und Gerichtsurteile. Jeder Vertrag, den eine große Firma abschließt, wird ordentlich abgeheftet, aber wehe, es ändert sich ein Gesetz, denn dann müssen die alten Verträge auf potenziell problematische Passagen durchsucht werden. Und wieder muss jemand viel lesen.

An konkreten Anwendungen, in denen man Sprachmodelle einsetzen könnte, mangelt es wirklich nicht. Solange wir keine superintelligenten Sprachmodelle haben, werden wir KI-Systeme aber an verschiedene Aufgaben so anpassen müssen, dass sie gut genug funktionieren, um einen echten wirtschaftlichen Mehrwert zu schaffen. Die Anforderungen an ein System, das Arztbriefe verarbeiten soll, sind aber anders als die an ein System, das mit Verträgen arbeitet. Ein System, das für Arztbriefe optimiert wurde, wird im Vertragsmanagement keinen großen Nutzen bringen. Ärzte und Anwälte besitzen unterschiedliches Wissen und stellen ganz andere Erwartungen an so ein Produkt. Die verschiedenen IT-Landschaften, in die das Produkt integriert werden muss, verkomplizieren die Einführung weiter. Auch die rechtlichen Rahmenbedingungen für den jeweiligen Einsatz sind andere. Patientendaten unterliegen zum Beispiel besonderen Datenschutzbestimmungen. Die KI-Verordnung der EU erfordert zudem, dass anwendungsspezifische Risikoanalysen gemacht werden müssen. Dem Einsatz in beiden Fällen steht auch im Weg, dass Krankenhäuser und Firmen ihre vertraulichen Dokumente nicht einfach an Google oder OpenAI schicken werden, damit diese ihre Sprachmodelle besser

trainieren können. Alleine, dass die Sprachmodelle auf Servern in den USA laufen, ist aus Sicht des Datenschutzes überaus bedenklich.

Viele dieser Probleme sind lösbar, aber ganz so einfach, wie der aktuelle KI-Hype das suggeriert, ist die Anwendung von generativer KI in der Praxis nicht. In welchen Branchen in Deutschland werden wir also einen produktiven Einsatz von Sprachmodellen als Erstes sehen? Das ist schwer vorherzusagen, ohne Kosten und Nutzen für die verschiedenen Branchen genau zu kennen. Eine Beobachtung wird Sie jedoch überraschen: Die deutsche Verwaltung, die sonst nicht unbedingt für ihre Innovationsfreudigkeit bekannt ist, will zu den Vorreitern gehören.³⁰

30 Siehe Staatsministerium Baden-Württemberg (2023) und Landeshauptstadt München (2024).

Bürokratische Entscheidungsfabriken

Wegen des nahegelegenen Frankfurter Flughafens fallen beim Amtsgericht Frankfurt 15.000 Fälle pro Jahr an, bei denen Fluggäste gegen Fluggesellschaften klagen. Mehr als die Hälfte aller Zivilfälle in Frankfurt sind solche Fluggastfälle. Die dafür nötigen Ressourcen fehlen an anderer Stelle. Weil die Rechtslage eigentlich klar ist, sollten viele dieser Fälle gar nicht erst vor Gericht landen (»no pun intended«). Bei einem Flugausfall muss die Airline meist eine Entschädigung zahlen. Aber manche Fluggesellschaften spekulieren darauf, dass Gäste ihre Rechte nicht kennen, einen Rechtsstreit scheuen oder einfach entscheiden, dass die Entschädigung den Stress nicht wert ist. Die Summe aller nicht gezahlten Entschädigungen ist so groß, dass es mittlerweile Online-Portale gibt, die gutes Geld damit verdienen, dass man seinen Fall an sie abtritt. Gegen Erfolgsprovision setzen diese Online-Portale die Fluggastrechte für einen durch. Ganz ohne Stress. Das rechnet sich für die Online-Portale, weil die Fälle sich leicht standardisieren und automatisiert verarbeitet lassen. Das ist gut für die Kunden, die dadurch leichter zu ihrem Recht kommen. Dadurch steigt aber die Anzahl der Klagen bei den Gerichten weiter.¹

Richterinnen und Richter können sich sicher auch spannendere Fälle vorstellen. Um sie von dieser nervigen Aufgabe zu entlasten, schlägt der Deutsche Richterbund vor, KI zu nutzen. In Zukunft könnten also in Standardfällen Computersysteme für Anwälte automatisch Klagen einreichen, die dann Computersysteme für Richter automatisch bearbeiten. Glücklicherweise sind die deutschen Richter nicht so naiv zu glauben, dass sich alle ihre Probleme so lösen lassen. Stattdessen schlagen sie ein ganzes Maßnahmenpaket vor, in dem – neben einer

1 Dursun & Stradinger (2022) berichten über die Klagewelle durch Flugverspätungen und die Überlastung der Gerichte.

besseren Personalausstattung und Änderungen der Prozessordnung – Automatisierung und KI nur ein Teil der Lösung sind. Ein Urteil bilden wollen die Richter sich noch selber. KI soll nur unterstützen und die Effizienz erhöhen.²

Im Fluggastrecht treten viele ähnliche Fälle auf. Diese Fälle zu standardisieren und automatisch abzuarbeiten, ist technisch relativ leicht zu bewerkstelligen. Standardisierung führt zu mehr Effizienz in der Verwaltung. Ein Gericht, das überlastet ist und seinen Aufgaben nicht nachkommen kann, arbeitet vielleicht weniger sorgfältig oder muss Menschen länger auf ihr Recht warten lassen. Standardisierung kann auch zu mehr Gerechtigkeit führen, wenn dadurch sichergestellt ist, dass in ähnlichen Fällen ähnliche Urteile ergehen. Aber Gerechtigkeit bedeutet nicht nur, dass Gleiches gleich behandelt wird, sondern auch, dass unterschiedliche Fälle unterschiedlich beurteilt werden. Ein Richter muss auch dem Einzelfall gerecht werden. Eine zu starke Standardisierung der Abläufe mit dem Ziel der Effizienzsteigerung kann aber dazu führen, dass der Einzelfall nicht mehr als Einzelfall gesehen wird. Das ist beim Fluggastrecht vielleicht kein Problem, aber bei einem Sorgerechtsstreit wäre das völlig inakzeptabel.

Dieser Konflikt zwischen einer effizienten Verarbeitung von Standardfällen und einer sorgfältigen Prüfung von Einzelfällen findet sich in jeder Verwaltung, sei es bei einer Behörde oder in einem Konzern. Verwaltungen in großen Organisationen sind Entscheidungsfabriken. Für jede Verwaltung sind Einzelfälle lästig, weil sie nicht durch die gut geölte Bürokratiemaschine automatisch verarbeitet werden können. Sie verursachen extra Aufwand und manchmal auch Ärger. Da die Arbeitsbelastung ohnehin schon zu hoch ist und jedes Jahr noch mehr Fälle bearbeitet werden müssen, ist es nur allzu verständlich, dass Verwaltungen ihre Effizienz durch Standardisierung und Automatisierung erhöhen wollen. Wenn Ihr Fall in das Standardraster passt, freuen Sie sich, dass Ihr Fall schnell automatisch beschieden wurde. Aber wehe, wenn nicht... dann hängen Sie in der Warteschleife der Telefonhotline. Zwar könnten die durch Effizienzsteigerungen gesparten Res-

2 Kempfle (2023) stellt die Positionen des Richterbundes zu Massenverfahren dar. Der Einsatz von KI in der Justiz wird in der KI-Verordnung der EU als Hoch-Risiko-Anwendung eingestuft (Annex III, 8(a)), sodass man auch deshalb nicht erwarten muss, dass die deutsche Justiz übereilt ein KI-System einführt und mögliche Folgen dabei nicht bedenkt.

sourcen für die komplizierteren Einzelfälle genutzt werden, aber wäre es nicht noch effizienter, wenn diese Fälle, die im Moment noch nicht automatisch von Computern bearbeitet werden können, in Zukunft von KI-Systemen bearbeitet werden?

Wie es zum Kindergeldskandal kam

Chermaine Leysner hatte als Studentin vom niederländischen Staat eine finanzielle Unterstützung für die Betreuung ihrer drei Kinder bekommen. Dieses Geld, mehr als 100.000 Euro, forderte der Staat Jahre später von ihr zurück. Neun Jahre, viele Überstunden, eine Depression und eine Scheidung später stellt sich heraus, dass das »nur« ein bedauerlicher Fehler war. Zehntausenden Menschen in den Niederlanden erging es ähnlich. Ihnen wurden Leistungen für die Kinderbetreuung vorenthalten oder sie mussten wie Chermaine Leysner sogar Geld zurückzahlen. Die Rückforderungen waren teilweise so hoch, dass Familien deshalb verarmten. Häuser wurden verkauft und Insolvenzverfahren eingeleitet. Viele Eltern mussten ihre Kinder in Pflegefamilien geben. Andere gaben ihren Arbeitsplatz auf, um sich um die Kinder kümmern zu können. Es kam sogar zu einigen Selbstmorden. Erst nach vielen Beschwerden, Klagen, Presseberichten und Untersuchungen gestand die Regierung der Niederlande dieses Unrecht ein und trat 2021 deshalb zurück. Der Skandal nahm seinen Anfang damit, dass eine effiziente Verwaltung Betrugsfälle automatisch erkennen wollte.³

In den Jahren 2004 und 2005 wurden in den Niederlanden die rechtlichen Grundlagen für ein effizientes System zur Verteilung des Kinderbetreuungsgeldes geschaffen. Eltern zahlen zum Beispiel Geld für einen Kindergartenplatz an einen privaten Träger und können dafür eine Unterstützung vom Staat beantragen. Ein Ziel der Reform war, diese Unterstützung möglichst schnell auszubezahlen, damit Eltern das Geld flexibel zur Kinderbetreuung einsetzen können, wie sie es gerade brauchen. Daher bekamen Eltern einen Vorschuss und die

3 Der Toeslagen-Skandal (»Toeslagen« ist Niederländisch für Zulagen, in diesem Fall zur Kinderbetreuung) und das Beispiel von Chermaine Leysner sind bei Goujard & Manancourt (2022) beschrieben. Eine Beschreibung der Folgen findet sich auch bei Peeters & Widlak (2023). Meine folgende Zusammenfassung des Skandals basiert auf der Analyse von Peeters & Widlak (2023), die eine große Zahl an Medienberichten und offiziellen Untersuchungen ausgewertet haben.

Abrechnung passierte erst im Nachhinein über das Finanzamt. Alle Prozesse, von der Antragstellung über die Antragsbearbeitung bis zur Auszahlung, wurden hoch automatisiert. Daten des Finanzamtes, der Meldeämter und anderer Behörden wurden dafür mit Daten über Kindergartenplätze abgeglichen. Da das Finanzamt nun Zugriff auf mehr Daten hatte, die verarbeitet werden wollten, richtete es eine technische Abteilung zur Datenanalyse ein, die sich um den Austausch der Daten und deren Analyse kümmerte. Das heißt nicht, dass die Entscheidungen über die Anträge vollständig automatisch getroffen wurden, aber die Sachbearbeiter sollten bestmöglich unterstützt werden, um effizient am Fließband Entscheidungen zu treffen.

Bald wurde klar, dass dieses System anfällig für Betrug war. Rechnungen wurden gefälscht und Eigenanteile nicht gezahlt. Nachdem der Staat seinen Bürgerinnen und Bürgern durch die Vorschüsse viel Vertrauen entgegengebracht hatte, sollte nun ein hartes Durchgreifen für die nötige Abschreckung sorgen. Die Sachbearbeiter und -bearbeiterinnen im Finanzamt taten, was von ihnen erwartet wurde und genehmigten nur noch Anträge, die vollständig und korrekt waren. Damit kein möglicher Betrugsfall übersehen wurde, führte jede kleine Unregelmäßigkeit dazu, dass ein Antrag als verdächtig gekennzeichnet wurde. So sollten alle Betrugsfälle aufgedeckt werden.

Für diesen neuen Zweck nutzte man ganz selbstverständlich die zuvor etablierte technische Infrastruktur. Die technische Abteilung zur Datenanalyse machte sich an die Arbeit und teilte die Fälle automatisch in Risikogruppen ein. Auf Grundlage dieser Einschätzung des Betrugsrisikos setzten Sachbearbeiter ihre Ressourcen zur Kontrolle entsprechend ein. Ich weiß nicht genau, welche statistischen Methoden eingesetzt wurden und wie groß die Rolle von maschinellem Lernen war. Obwohl in Berichten über den Skandal immer von selbstlernenden Algorithmen die Rede ist, vermute ich, dass die Methoden so einfach waren, dass es irreführend wäre, hier von KI zu sprechen. Sicher ist hingegen, dass bei dem Versuch, Betrugsversuche automatisch zu erkennen, verschiedene Daten über die Antragsteller aus unterschiedlichen Quellen genutzt wurden. Man nutzte alte Anträge, die genehmigt oder als möglicher Betrugsfall gekennzeichnet wurden, um die Merkmale zu finden, die am besten vorhersagen, ob es sich um einen verdächtigen Antrag handelt oder nicht. Ganz genau so, wie neuronale Netze zur Objekterkennung die Merkmale lernen, die am besten vorhersagen, ob auf einem Bild eine Katze zu sehen ist oder nicht.

Während jeder Datenanalyst und jede -analystin beurteilen kann, ob auf einem Bild eine Katze zu sehen ist, wussten die Datenanalysten im Finanzamt nicht, wie genau die Einschätzung als Verdachtsfall zustande kam. Da sie selber keine Sachbearbeiter waren, ist anzunehmen, dass sie die Feinheiten der Abläufe in der Behörde nicht kannten und wahrscheinlich deshalb auch nicht vollständig verstanden, was die Daten, die sie analysierten, bedeuteten und wie ihre Analysen eingesetzt würden. Insbesondere kannten sie nicht den Grund für die Einschätzung eines Falles als möglicher Betrug, da in den Daten nicht zwischen unvollständigen Angaben, einfachen Fehlern und echtem Betrug unterschieden wurde. Man sollte meinen, diese Unterscheidung wäre wichtig und bei einem echten Betrugsverdacht würde die Behörde anders reagieren, als wenn die Angaben einfach nur unvollständig sind. Weil es aber in der Verwaltungssoftware keine Möglichkeit gab, die finanzielle Unterstützung zur Prüfung auszusetzen, wurde die Unterstützung einfach in allen Fällen ganz beendet. Zusammen mit der Vorgabe, dass Betrug unbedingt verhindert werden sollte, führte das dazu, dass schon im Verdachtsfall jede weitere Zahlung gestoppt wurde und Rückzahlungen eingefordert wurden. Ein späterer Bericht fand heraus, dass es in 94 Prozent der als möglicher Betrugsfall gekennzeichneten Fälle keinen konkreten Anhaltspunkt für Betrug gab. Mit katastrophalen Folgen für die fälschlich beschuldigten Menschen, die offenbar keiner in der Behörde bedacht hatte.

Aufgrund des hohen Automatisierungsgrades hatten die Sachbearbeiter nur wenig Kontakt mit den Bürgern, über deren Anträge sie entschieden. Für die Datenanalysten war jeder Fall ohnehin nur eine Reihe von Zahlen und Merkmalen in einer Tabelle. Die Beamten in der Beschwerdestelle hatten hingegen einen direkten Kontakt zu den Bürgern, die fälschlicherweise unter Betrugsverdacht standen. Diese Beamtinnen und Beamten sahen das Leid und die Verzweiflung, die die Behörde bei Menschen wie Chermaine Leysner verursachte. Sie äußerten ihre Kritik an den Entscheidungsprozessen laut und deutlich. Doch anstatt die Entscheidungsprozesse zu überdenken, reagierte die Leitung der Behörde damit, die Beschwerdeprozesse effizienter zu gestalten.

Im zuständigen Ministerium nahm man zur Kenntnis, dass es eine außergewöhnlich hohe Anzahl an Rückforderungen gab, war sich aber der dramatischen Folgen für die betroffenen Menschen nicht bewusst. Dass das ganze System einen erheblichen Verwaltungsaufwand bei

den Bürgern verursachte, die ihre Kinderbetreuungskosten auf Heller und Pfennig mit dem Finanzamt abrechnen mussten, wurde hingegen durchaus als Problem gesehen. Es wurde diskutiert, ob man statt das Geld an die Eltern auszuzahlen, nicht besser die Kindertagesstätten direkt finanzieren sollte. Diese Idee wurde aber verworfen, weil die Umstellung der IT zu schwierig erschien.

Diskriminierung ist jetzt automatisch

Selbst wenn das niederländische Finanzamt, welches das Kinderbetreuungsgeld verwaltet, weniger unverständliche Formulare haben sollte als deutsche Behörden, kann man sich leicht vorstellen, dass es trotzdem eine Herausforderung sein kann, alle Formulare richtig auszufüllen. Das betrifft insbesondere Menschen, die nicht ihre Eltern um Rat fragen können, die die Sprache nicht so gut beherrschen oder denen Zeit und Fähigkeiten fehlen, sich richtig zu informieren. Da die Datenanalyse zur Betrugserkennung nicht sauber zwischen Betrugsverdacht und fehlerhaften oder unvollständigen Anträgen unterschied, waren alle Menschen, die einfach nur Probleme damit hatten, die bürokratischen Hürden zu nehmen, automatisch verdächtig.

So ist es keine Überraschung, dass die automatische Betrugserkennung Antragsstellern mit geringen Einkommen oder einer doppelten Staatsbürgerschaft ein besonders hohes Betrugsrisiko zuschrieb. Daneben stellte sich im Zuge der Aufarbeitung des Skandals heraus, dass es schon lange vor der Reform des Kinderbetreuungsgeldes schwarze Listen in den Finanzämtern gab, die insbesondere türkische und marokkanische Staatsbürger unter Betrugsverdacht stellten. Diese schwarzen Listen flossen auch in die Bewertung des Betrugsrisikos für das Kinderbetreuungsgeld ein. Die niederländische Datenschutzbehörde, die die Einhaltung der Europäischen Datenschutzgrundverordnung überwacht, beurteilt es als diskriminierend und rechtswidrig, die (doppelte) Staatsbürgerschaft zu nutzen, um das Betrugsrisiko vorherzusagen. Die Finanzverwaltung musste deshalb eine Strafe von 2,75 Millionen Euro zahlen und die Regierung unter der Führung von Mark Rutte trat 2021 wegen des Skandals um das Kinderbetreuungsgeld zu-

rück. Aber nach den folgenden Neuwahlen und zähen Koalitionsverhandlungen war er mit der gleichen Koalition wieder im Amt.⁴

Das Versprechen, dass ein höherer Grad an Automatisierung neben einer Effizienzsteigerung auch zu mehr Objektivität und damit Gerechtigkeit bei der Bearbeitung von Anträgen führt, wurde beim niederländischen Kinderbetreuungsgeld nicht eingelöst. Im Gegenteil: Bestehende Diskriminierung wurde verstärkt!

Man muss keine Absicht unterstellen, um zu erklären, wie das passieren kann. Es gilt das DIDO-Prinzip (zur Erinnerung: DIDO steht für ›discrimination in, discrimination out‹). Nehmen wir folgendes Beispiel: Eine große Firma will ihre Personalauswahl effizienter gestalten und deshalb automatisieren. Dazu analysiert sie über einen längeren Zeitraum, welche Merkmale einer Bewerbung am besten vorhersagen, ob jemand eingestellt wird. Wenn Frauen im bestehenden Bewerbungsprozess gegenüber Männern benachteiligt werden, wird der Algorithmus lernen, dass das Geschlecht für die Einstellung relevant ist. Vielleicht soll auch der spätere Erfolg im Unternehmen vorhergesagt werden, und wenn es in der Firma bisher hauptsächlich Männer auf der Führungsetage gab, dann wird der Algorithmus lernen, dass das Geschlecht Erfolg vorhersagt. Ein Empfehlungsalgorithmus, der basierend auf diesen Daten Bewerbungen vorsortiert, wird Männer bevorzugen.

Gibt es schon ohne Algorithmen bei der Personalauswahl Diskriminierung, verschwindet diese nicht, nur weil ein Computer den Prozess unterstützt und dadurch scheinbar objektiver macht. Daten bilden bestehende Diskriminierung ab und Algorithmen, die auf solchen Daten beruhen, reproduzieren diese Diskriminierung. Man kann versuchen, mehr Geschlechtergerechtigkeit dadurch zu erreichen, dass ein Algorithmus das Merkmal Geschlecht nicht nutzen kann. So macht man das inzwischen, auch wenn kein Algorithmus beteiligt ist, etwa beim Vorspielen für Stellen in renommierten Orchestern, wo das Geschlecht keine Rolle spielen sollte. Wichtig ist nur, wie gut eine Person ihr Musikinstrument beherrscht. In vielen Auswahlverfahren für Orchester sind Kandidatinnen und Kandidaten deshalb beim Vorspielen nicht zu sehen, sondern nur zu hören.⁵

4 Siehe nochmal Goujard & Manancourt (2022).

5 Basierend auf der Studie von Goldin & Rouse (2000).

Die Lösung ist nicht immer so einfach. In einer Bewerbung für eine Informatikstelle mag kein Geschlecht stehen, aber Lücken im Lebenslauf könnten trotzdem auf Babypausen hindeuten. Männer, die Informatik studieren, wählen vielleicht eher Maschinenbau als Nebenfach und Frauen eher Psychologie. In einem Lebenslauf finden sich viele solche Hinweise auf das Geschlecht und nicht alle sind so offensichtlich wie das Abiturzeugnis einer katholischen Mädchenschule. Ein Algorithmus, der das Geschlecht eines Bewerbers nicht kennt, kann all diese Hinweise trotzdem indirekt nutzen.⁶ Außerdem: Wenn einer Frau, weil sie eine Frau ist, in der Vergangenheit weniger Chancen gegeben wurden als einem Mann, ist sie in einem Bewerbungsverfahren selbst dann noch benachteiligt, wenn oberflächlich betrachtet, ihr Geschlecht bei der Auswahl gar keine Rolle spielt. Leider gibt es für diese Probleme keine einfachen, rein technischen Lösungen.⁷

Digital first, Bedenken second

Die FDP hat im Bundestagswahlkampf 2017 neben einem Schwarz-Weiß-Bild von Christian Lindner, der gebannt auf sein Handy schaut, ihren Wahlslogan in leuchtenden Farben und Großbuchstaben auf Plakate gedruckt: »DIGITAL FIRST. BEDENKEN SECOND.« Bei dem schleppenden Tempo der Digitalisierung in Deutschland ist nur allzu verständlich, dass manch einer ungeduldig wird. In der Softwareentwicklung, insbesondere bei Start-ups, gilt oft ein ähnliches Motto: »Move fast and break things.« Einfach mal machen, statt lange zu überlegen. Man kann sowieso nicht alles im Voraus planen. Dementsprechend löst man die Probleme am besten erst, sobald sie wirklich auftreten. Auf dem Softwaremarkt ist das eine ausgezeichnete Strategie, um schnell ein Produkt zu erstellen, das man in der Praxis erprobt und nach und nach anpasst. In der Forschung oder bei der Entwicklung von Prototypen führt dieser Ansatz dazu, dass man schnell lernt, was funktioniert und was nicht.

Bei der Entwicklung von Software ist es zu einem gewissen Grad akzeptabel geworden, dass das Produkt ausgeliefert wird und Prob-

⁶ Siehe nochmal Dastin (2018).

⁷ Buyl & De Bie (2024) geben einen Überblick darüber, warum es wesentlich schwieriger ist, als man denken könnte, Fairness technisch zu erreichen.

leme erst im laufenden Betrieb beim Kunden durch Updates behoben werden. Dass moderne Smart-TVs und Smartphones häufig Fehlermeldungen produzieren, regt nur noch Leute auf, die sich daran erinnern können, wie verlässlich analoge Fernseher und Telefone zuletzt waren. Alle anderen scheinen sich daran gewöhnt zu haben, dass Software im Alltag nicht immer so problemlos zu benutzen ist, wie man sich das wünschen könnte. Software hat oft Fehler, aber Probleme entstehen auch dadurch, dass Software umständlich zu bedienen ist oder nicht so funktioniert, wie die Nutzer es erwarten. Für das autonome Fahren wünscht man sich allerdings, dass vorhersehbare Probleme schon bei der Entwicklung behoben werden und Unvorhersehbares im Probebetrieb auffällt, bevor ein KI-System an den Kunden geliefert wird und dort womöglich Unfälle verursacht.⁸

Bei traditioneller Software gibt es lange etablierte Entwicklungs- und Prüfverfahren, um Fehler möglichst zu vermeiden. Bei sicherheitskritischer Software (anders als bei Smart-TVs) werden diese auch konsequent eingesetzt. Besonders wichtig ist dabei Eingaben und erwartetes Verhalten durch Standardisierung genau zu spezifizieren, damit man im Betrieb keine Überraschungen erlebt. KI soll aber immer genau in den Fällen helfen, die schwer zu spezifizieren sind und bisher noch menschliches Urteilsvermögen erfordern. Deshalb ist nicht leicht zu testen, ob die KI-Software auch wirklich das macht, was sie soll. Für KI-Systeme gibt es deshalb leider noch keine etablierten Standards.⁹ Während es in manchen Anwendungsfällen nur nervt, wenn eine Software sich nicht wie erwartet verhält, kann es in anderen Fällen ernste Folgen haben. Sind die Risiken größer, sollten auch die Bedenken größer sein. Mehr Bedenken hätten wahrscheinlich auch im niederländischen Finanzministerium Schlimmeres verhindert.

Als die ersten Probleme sichtbar wurden, hatten die Verantwortlichen in den Niederlanden zu Recht die Sorge, dass eine Umstellung der Verwaltung des Kinderbetreuungsgeldes große Änderungen in der IT erfordern würde. Große IT-Projekte gehen oft schief. Vom Drama um die Technik zur Mauterhebung auf der Autobahn bis zur elektro-

8 Das ist aber nicht immer der Fall. Tesla hat z.B. das Problem, dass sich Fahrer zu sehr auf den »Autopiloten« verlassen. Dieses Problem ist aber nicht leicht durch ein reines Softwareupdate zu fixen, ohne auch die Auswirkungen der Änderungen auf das menschliche Verhalten genau zu untersuchen (Duncan & Thadani, 2024; Krisher & The Associated Press, 2024).

9 Aber siehe DIN & DKE (2022).

nischen Patientenakte – die Medien berichten gerne und ausführlich darüber, wenn große IT-Projekte des Staates scheitern. Aber jeder, der einmal die Einführung einer neuen Software in einem Unternehmen mitbekommen hat, kann berichten, dass es auch in der Privatwirtschaft selten wirklich glattläuft. Laut einer einschlägigen Statistik sind IT-Projekte im Durchschnitt fast 75 Prozent teurer als geplant. Betrachtet man das schlechteste Fünftel aller IT-Projekte, waren diese im Durchschnitt sogar mehr als fünfmal so teuer. Offensichtlich wird bei vielen IT-Projekten nicht gut geplant. Fehlende Sorgfalt bei der Planung, übermäßig optimistische Schätzungen und unklare und widersprüchliche Ziele gehören zu den Problemen, die nicht nur IT-Projekte plagen, aber große IT-Projekte scheinen im Vergleich zu anderen Großprojekten besonders schlecht zu laufen. Die Erfahrung zeigt, dass am Ende viele Projekte ungleich komplizierter waren als ursprünglich gedacht.¹⁰ Da auch die Entwicklung und Einführung von KI-Software ein IT-Projekt ist, gibt es keinen Grund anzunehmen, dass es bei KI-Projekten besser laufen wird.

Die Einführung von neuer Software ist keine rein technische Aufgabe. Fast immer gehen damit Veränderungen in den Abläufen einer Organisation einher. Das gilt für Behörden genauso wie für Unternehmen. Probleme treten zum Beispiel auf, wenn Abläufe im Entwicklungsprozess missverstanden werden und nachträglich in der Software angepasst werden müssen. Andere Abläufe wurden vielleicht vergessen und besonders komplexe Abläufe aus Kostengründen zunächst nicht abgebildet. Einzelfälle, die nicht ins Raster passen, machen nach der Einführung der neuen Software noch mehr Probleme als vorher, weil bei der Entwicklung niemand an sie gedacht hat. Alte Daten müssen verfügbar bleiben und die Umstellung findet im laufenden Betrieb statt. Vielleicht haben sich auch rechtliche Rahmenbedingungen seit der Erteilung des Entwicklungsauftrages geändert. Es gibt viele Gründe, warum ein IT-Projekt scheitern kann. Viele Komplikationen entstehen aber dadurch, dass sich die Software in die Arbeitsprozesse der Menschen einpassen muss und die Menschen können oder wollen ihre Prozesse nicht immer an die Software anpassen.

Es gibt ohne Zweifel eine Vielzahl an langweiligen Aufgaben in Verwaltungen, die Sachbearbeiter und -bearbeiterinnen gerne automa-

10 Siehe Flyvbjerg & Gardner (2023). Die genannte Statistik findet sich auf S. 193 und die Inflation ist hierbei nicht mal eingerechnet.

tisieren würden. Deutschland ist nach wie vor ein Entwicklungsland, was die Digitalisierung der Behörden angeht. Ich kann aus erster Hand bestätigen, dass es an den Universitäten nur schleppend mit der Digitalisierung vorangeht und noch viele Papierakten gepflegt werden. Das liegt weniger daran, dass es zu viele Bedenkenräger gibt. Vielmehr fehlen teilweise noch wichtige rechtliche Grundlagen und da der Aufwand riesig ist, fehlen auch Zeit und Geld – oftmals auch Expertise. Bevor wir über den großflächigen Einsatz von KI in Behörden nachdenken, müssen wir in Deutschland erst bei der Digitalisierung der Verwaltung aufholen. Der aktuelle KI-Hype führt vielleicht dazu, dass es schneller vorangeht, aber wir sollten dabei darauf achten, dass nicht solche Katastrophen wie beim Kindergeldskandal in den Niederlanden passieren.

Auch in Deutschland ist die Versuchung groß, menschliches Urteilsvermögen im Namen der Effizienz durch Computer zu ersetzen. Es ist eine Sache, Verwaltungen durch den Einsatz von IT effizienter gestalten zu wollen, es ist aber eine gänzlich andere Sache, wenn Entscheidungen nicht mehr von Menschen, sondern von Computern getroffen werden. Was beim Fluggastrecht unproblematisch erscheinen mag, ist bei der Einstufung eines Antrags als Betrugsfall inakzeptabel. Moderne KI-Methoden können zwar noch nicht alle Einzelfälle, die in Verwaltungen anfallen, verlässlich automatisch bearbeiten, aber selbst wenn sie es könnten, besteht die große Gefahr, dass durch den Einsatz von KI bestehende Diskriminierung verstärkt wird. Wichtige Entscheidungen, die vielleicht große Auswirkungen auf die betroffenen Menschen haben können, dürfen nicht vollautomatisch von Maschinen getroffen werden. Sollen Computer aber menschliche Entscheidungen lediglich unterstützen, so wie die KI-Verordnung der EU es bei folgenreichen Entscheidungen vorsieht, dann stellt sich die Frage, wie genau Mensch und Maschine bei der Entscheidungsfindung zusammenarbeiten sollen. Auf diese Frage gibt noch keine befriedigende Antwort und sie wird wahrscheinlich für jede zukünftige KI-Anwendung in der Verwaltung separat beantwortet werden müssen.

Eine Zukunft ohne Arbeit

Wir befinden uns in einer Phase enormer Veränderungen, in der Digitalisierung, Big Data und Künstliche Intelligenz in viele Bereiche unseres Lebens vordringen. Während wir fasziniert auf sprechende Autos blicken und Science-Fiction-Filme und selbsternannte KI-Apostel vor der Singularität und der Machtübernahme der Roboter warnen, passiert die eigentliche Revolution in viel langweiligeren Bereichen wie der Finanzindustrie, dem Handel, dem Werbemarkt oder der Verwaltung. Dort sind verbesserte und automatisierte Analysen von immer größeren Datenmengen, die dank Digitalisierung leicht verfügbar sind, bares Geld wert. Die Industrie 4.0 verspricht enorme Produktivitätssteigerungen auch für andere Branchen. Zu einem großen Teil werden diese aus der Analyse von Daten kommen, zum Beispiel dadurch, dass sich die Wartung von Maschinen dank genauer Statistiken besser planen lässt. Für den Aufbau und den Betrieb der Infrastruktur zur Datensammlung und -analyse benötigt es allerdings viel mehr Data Scientists als dem Arbeitsmarkt zur Verfügung stehen. Seit ungefähr 2010 sind diese Jobs an der Schnittstelle zwischen Statistik und Informatik daher zu den sexiest Jobs überhaupt geworden.¹ Gut für alle, die sich dank ihrer Ausbildung mit Zahlen und Computern auskennen.

Alle anderen fragen sich sorgenvoll, ob ihre Stellen bald von Robotern und KI übernommen werden. Produktivitätssteigerungen bedeuten erfahrungsgemäß, dass menschliche Arbeit durch Automatisierung wegrationalisiert wird. Allgemeine Künstliche Intelligenz (AKI) ist zwar noch Science-Fiction, doch schon herkömmliche KI-Systeme übernehmen bereits immer mehr Aufgaben, die noch vor wenigen Jahren nicht automatisierbar gewesen wären. Durch Fortschritte im maschinellen Lernen können nun auch Mustererkennungsaufgaben,

1 Siehe Lohr (2009) für diese weitsichtige Einschätzung der Jobaussichten.

die auf implizitem Wissen beruhen, durch Computer erledigt werden. Sprachmodelle werden bald typische Call-Center-Aufgaben erledigen. Und wer braucht noch Übersetzerinnen und Übersetzer, wenn Google Translate und DeepL für viele Zwecke ausreichend sind? Lastwagen und Taxis fahren zukünftig autonom und der Roboter in der Fabrik ist ohnehin ein direkter Nachfahre der Webmaschine. Wie viele Berufe werden in der nahenden Revolution untergehen wie einst die Weber?

Die Arbeitslosigkeit droht

Eine Studie, die seit 2013 durch die Diskussion geistert, spricht davon, dass 47 Prozent aller Arbeitsplätze in den USA durch KI stark gefährdet sind. In Deutschland sind es mit seiner leicht anderen Berufsstruktur, in der es zum Beispiel mehr Handwerk gibt, immerhin noch 42 Prozent.² Bevor wir aber in Panik verfallen, gilt es, sich die Studie genauer anzuschauen:

Ausgangspunkt der Studie ist eine Liste aller Berufe, wie sie für statistische Erhebungen des amerikanischen Arbeitsmarktes genutzt wird. Darauf befinden sich knapp 700 Berufe. Zu der Liste gehört außerdem eine detaillierte Beschreibung, was die jeweiligen Tätigkeiten sind. Zudem werden die benötigten Fähigkeiten bewertet, zum Beispiel zu welchem Grad man feinmotorisch begabt sein sollte, oder wie viel Kreativität und Verhandlungsgeschick erforderlich sind.

Zusammen mit ein paar Kollegen aus der KI-Forschung sind die Autoren der Studie die ganze Liste der Berufe durchgegangen. Dabei haben sie die Berufsbeschreibungen kurz überflogen und sich gefragt, ob die Tätigkeiten in diesem Beruf, sofern man ausreichend Daten für maschinelles Lernen sammelte, sich mit der aktuellen Technologie (Stand 2013) automatisieren ließen. Bei den meisten der 700 Berufe waren sie sich unsicher, aber bei 70 Berufen waren sie sich sicher, ob das geht oder nicht geht. Der Meinung der Autoren nach muss sich zum Beispiel meine Zahnärztin keine Sorgen machen. Mit feinmotorischen Aufgaben, die sich nicht ganz genau wiederholen, sondern eine Anpassung an die individuelle Situation erfordern, sind Roboter derzeit noch überfordert. Ähnliches gilt für den Familientherapeuten, denn

2 Die Originalstudie ist von Frey & Osborne (2013) und sie wurde von Bonin, Gregory & Zierahn (2015) auf Deutschland übertragen.

wo soll die für den Beruf nötige soziale Intelligenz herkommen? Und die Modedesignerin kann auch nicht durch Computer ersetzt werden – zumindest nicht, solange KI noch nicht kreativ ist (die Studie wurde vor dem Aufstieg von generativer KI durchgeführt). Wer Taxi fährt, an der Kasse sitzt oder in einer technischen Redaktion arbeitet, kann hingegen gleich stempeln gehen.

Nachdem sie diese Einschätzungen vorgenommen hatten, ließen die Autoren einen statistischen Lernalgorithmus auf die Daten los (man kann ja nicht eine Vorhersage über den Einfluss von KI machen, ohne selbst dazu KI zu nutzen). Jeder Beruf ist bestimmt durch die Fähigkeiten, die für seine Ausübung wesentlich sind. Der Algorithmus identifiziert die Fähigkeiten, die am besten vorhersagen, ob die Autoren (mit ihrem impliziten Wissen) einen Beruf als gefährdet oder nicht gefährdet ansehen. Weil dem Algorithmus das für die 70 Berufe, bei denen sich die Autoren sicher waren, gelang, wurde er dann auf die restlichen Berufe angewandt. Das Resultat war, dass 47 Prozent der Menschen in den USA in Berufen arbeiten, die ähnliche Fähigkeiten erfordern, wie die Berufe, die die Autoren als ersetzbar einschätzten. Dazu gehören Köche, Buchhalter, Models und Schiedsrichter.

Das ist auch das erste Problem der Studie: Sie spiegelt nur die persönliche und nicht besonders systematisch erhobene Meinung einiger weniger KI-Experten wider. Die Autoren haben sich zwar bemüht, dabei auch die objektiven Tätigkeitsbeschreibungen der Berufe mit einzubeziehen, aber auch da haben sie sich auf ein paar wenige Aspekte beschränkt. In Wirklichkeit besteht jeder Beruf allerdings aus einer großen Anzahl an verschiedenen Tätigkeiten, die in dieser Studie nicht vollständig berücksichtigt wurden. So ist zu erklären, warum auch Models und Schiedsrichter auf der Liste der gefährdeten Berufe landeten, obwohl sie weit mehr machen, als nur Kleider zu tragen oder darauf zu achten, ob ein Ball eine Linie überquert. Die Autoren der Studie sind sich zwar sicher, dass Fahrer dank autonomer Fahrzeuge ersetzbar sind, ihre Studie vernachlässigt aber, dass beispielsweise ein Fahrer für Essen auf Rädern nicht nur das Auto fährt. Er trägt das Essen auch in den vierten Stock und plaudert mit seinen Kunden, die vielleicht nicht viel aus der Wohnung kommen. Statt einen ganzen Beruf vorschnell als automatisierbar abzutun, sollte man sich die einzelnen Tätigkeiten genau ansehen. Nur Berufe, bei denen sich fast alle Tätigkeiten automatisieren lassen, können ohne weiteres von Maschinen erledigt werden. Bei präziserer Analyse der Tätigkeitsstrukturen der einzelnen Berufe

bleiben statt 42 Prozent der Arbeitsplätze in Deutschland, die direkt gefährdet sein könnten, nur 12 Prozent übrig.³

Doch selbst diese Zahl ist noch mit Vorsicht zu genießen. Letztendlich handelt es sich nur um eine stark subjektive Einschätzung, die mit recht groben Methoden auf den Arbeitsmarkt hochgerechnet wurde. Das kann man den Autoren der Studie nicht vorwerfen. Sie wollten gar nicht mehr als eine erste, grobe Abschätzung geben.

Tätigkeiten werden automatisiert

Neuere Studien aus dem Jahr 2017 zeichnen ein differenzierteres Bild. Statt ganzer Berufe werden in diesen Studien grundlegende Tätigkeiten hinsichtlich ihrer Automatisierbarkeit eingeschätzt. In der amerikanischen Berufsklassifikation gibt es über 2000 solcher Tätigkeiten, wie das Führen von Verhandlungen oder der feinmotorisch anspruchsvolle Zusammenbau von kleinen Einzelteilen, die in unterschiedlicher Ausprägung in verschiedenen Berufen auftauchen. Ein Beruf ist zu dem Grad automatisierbar, zu dem die Tätigkeiten in dem Beruf automatisierbar sind. Damit man sich nicht blind auf das Urteil einiger weniger Expertinnen und Experten verlassen muss, wurde zunächst ein ganzer Kriterienkatalog entwickelt, der transparent macht, wann genau eine Tätigkeit für maschinelles Lernen geeignet ist. Dazu wurden keine Vorhersagen über zukünftige technologische Entwicklungen herangezogen, vielmehr sollte der Kriterienkatalog lediglich abbilden, was zu diesem Zeitpunkt schon möglich war (Stand 2017). Nachdem Sie die vorherigen Kapitel in diesem Buch gelesen haben, werden Sie die Hauptkriterien nicht weiter überraschen:⁴

1. Die Tätigkeit hat klar definierte Eingaben und Ausgaben, die in einem statistischen Zusammenhang miteinander stehen.
2. Es gibt bereits große Mengen an relevanten Daten in digitaler Form oder man kann solche Daten mit vertretbarem Aufwand sammeln.

3 Abschnitt 3.2 in Bonin et al. (2015).

4 Die Kriterien finden sich fast genau so bei Brynjolfsson & Mitchell (2017). Ich fokussiere mich aber nur auf die positiven Eigenschaften von maschinellem Lernen und habe die Liste der Beschränkungen zur Vereinfachung der Diskussion weggelassen.

3. Die Ziele der Aufgabe lassen sich eindeutig bestimmen und deren Erfüllung messen.

Hinzu kommen weitere Kriterien, die teilweise auf technologische Beschränkungen außerhalb der KI-Forschung zurückzuführen sind. Zum Beispiel sind viele handwerkliche Tätigkeiten durch die Mechanik von Robotern beschränkt. Keine Roboterhand kann momentan auch nur annähernd so flexibel und schnell beliebige Objekte in Kisten packen wie Menschen (obwohl natürlich an diesem Problem gearbeitet wird).

Bewertet man nun statt ganzen Berufen einzelne Tätigkeiten anhand dieser nachvollziehbaren Kriterien, stellt man fest, dass jeder Beruf Tätigkeitsanteile hat, die geeignet sind, durch maschinelles Lernen automatisiert zu werden. Aber man findet auch, dass kein Beruf vollständig automatisierbar ist. Außerdem gibt es keine Korrelation zwischen Bezahlung und Automatisierbarkeit. Anwältinnen sind genauso betroffen wie Lagerarbeiter.⁵

Manche der Beschränkungen von maschinellern Lernen sind inzwischen durch die Fortschritte bei Sprachmodellen gefallen. Ohne Sprachmodelle konnten Aufgaben, die ein breites Allgemeinwissen, den gesunden Menschenverstand oder gute sprachliche Fähigkeiten brauchten, nicht leicht durch KI-Systeme erledigt werden. Daher hat eine Folgestudie untersucht, welche beruflichen Tätigkeiten sich durch Sprachmodelle automatisieren lassen (Stand 2024).⁶ Wieder stellt man fest, dass fast alle Berufe betroffen sind. Die Autorinnen und Autoren schätzen, dass 80 Prozent der Angestellten in den Vereinigten Staaten in Berufen arbeiten, in denen sich mindestens 10 Prozent der Tätigkeiten durch Sprachmodelle automatisieren lassen. Für knapp 20 Prozent der Angestellten könnten das vielleicht sogar 50 Prozent ihrer Tätigkeiten sein. Anders als bei der vorherigen Studie sind davon besonders die gut bezahlten Berufe betroffen, die eine lange Ausbildung benötigen. Die Fliesenlegerin hat weniger zu befürchten als der Apotheker. Am meisten betroffen sind Menschen, die in der Wissenschaft oder der Softwareentwicklung arbeiten. Und der Job des Data Scientists sieht jetzt vielleicht doch nicht mehr so sexy aus.

Man darf aber bei all diesen Studien nicht vergessen, dass sie nur Einschätzungen darüber abgeben, welche Tätigkeiten sich im Prinzip

5 Siehe Brynjolfsson, Mitchell & Rock (2018).

6 Siehe Eloundou, Manning, Mishkin & Rock (2024).

mit heutiger Technologie automatisieren lassen könnten. Nur weil etwas technologisch machbar ist, wird es nicht unbedingt auch gemacht. Erstens muss es sich wirtschaftlich rechnen, die passende KI-Anwendung zu entwickeln und zu betreiben. Zweitens gibt es soziale und rechtliche Gründe, die einer Anwendung im Weg stehen können. Sollten zum Beispiel Roboter die Betreuung von Demenzzkranken übernehmen, um Pflegekosten zu sparen? Bevor Pflegeroboter in Altenheimen eingesetzt werden, muss es dafür eine gesellschaftliche Akzeptanz geben. Wer haftet, wenn ein autonomes Fahrzeug einen Unfall baut? Bevor autonome Fahrzeuge jemanden arbeitslos machen, müssen rechtliche Rahmenbedingungen geschaffen werden.

Es stimmt zwar, dass die technologische Entwicklung in der KI rasant ist, aber wie schnell diese Entwicklungen in der Arbeitswelt ankommen, ist keine rein technologische Frage. Neben der gesellschaftlichen Akzeptanz und der Gesetzgebung entwickeln sich insbesondere die Strukturen in großen Organisationen – seien es Unternehmen oder Behörden – nur langsam weiter. Können einzelne Arbeitsplätze nur teilweise automatisiert werden, ist es auch nicht so leicht, diese Arbeitsplätze einfach so durch Maschinen zu ersetzen. Dass es nicht damit getan ist, eine neue Maschine zu kaufen, um die Produktivität zu erhöhen, hat sich bei der Einführung von Computern gezeigt. Weil Mitarbeiter weitergebildet und Arbeits- und Geschäftsprozesse mit viel Aufwand umorganisiert werden mussten, zeigten Statistiken echte Produktivitätssteigerungen erst 20 Jahre später. Erst wenn man organisatorisch alle Tätigkeiten, die automatisiert werden können, von den Tätigkeiten getrennt hat, die nicht automatisiert werden können, hat man einen Arbeitsplatz überflüssig gemacht. Durch solche Umstrukturierungen werden sich die Anforderungen an die Arbeitnehmer ändern. Sicher wird es daher Verschiebungen auf dem Arbeitsmarkt mit Gewinnern und Verlierern geben – selbst ohne KI passiert das durch die Digitalisierung jetzt schon –, aber diese Änderungen werden vermutlich nicht über Nacht geschehen.⁷

Ob auf längere Sicht insgesamt mehr oder weniger Arbeit zu tun ist, hängt von vielen technologischen, gesellschaftlichen und wirtschaft-

7 Dass die Einführung von Computern zunächst keine Produktivitätssteigerung brachte, wird von Ökonomen auch als ›Produktivitätsparadox‹ bezeichnet. Der Grund dafür wird in der nötigen Umstrukturierung gesehen. Siehe Kapitel 7 und S. 137-138 in Brynjolfsson & McAfee (2016).

lichen Faktoren ab. Wenn zum Beispiel ein Produkt dank Teilautomatisierung (egal ob durch Dampfkraft, Elektrizität, Computer oder KI angetrieben) billiger hergestellt werden kann, kaufen vielleicht auch mehr Kunden das Produkt. Dann stellt die Fabrik mehr her und so entsteht auch mehr Arbeit, die nicht von Maschinen übernommen werden kann. Daraufhin müssen vielleicht sogar zusätzliche Leute eingestellt werden. Gleichzeitig sparen die Kunden, die das Produkt eh gekauft hätten, Geld und erwerben damit andere Dinge, die sie sich sonst nicht geleistet hätten. Auch an diesen Produkten hängen Arbeitsplätze. Aufgrund solcher komplexen Zusammenhänge ist der Einfluss von KI auf den gesamten Arbeitsmarkt nur schwer vorherzusagen. Soviel kann man allerdings sagen: Bei früheren Automatisierungswellen kam es zu großen Veränderungen auf dem Arbeitsmarkt, die Arbeit als solche ist uns insgesamt aber noch nie ausgegangen.⁸

Hilfe, die Roboter kommen!

Dass bei der Automatisierung durch KI trotzdem alles anders kommen könnte, zeigt folgendes Gedankenexperiment: Stellen Sie sich Androiden vor, die alle Tätigkeiten genauso gut erledigen wie Menschen. Diese Androiden ersetzen Menschen an jedem Arbeitsplatz. Insbesondere können sie andere Androiden herstellen. Je mehr Androiden es gibt, desto wertloser wird menschliche Arbeit. Wer Androiden besitzt, der kann diese unternehmerisch einsetzen, um Dinge herzustellen oder Dienstleistungen anzubieten, die andere konsumieren können, und so Geld verdienen. Was aber, wenn man außer seiner eigenen Arbeitskraft nichts anbieten kann und damit nicht genug verdient? Dann wird der Traum von einer Welt, in der niemand arbeiten muss, zu einem kapitalistischen Albtraum, in dem sorgenfrei lebende Androidenbesitzer einer Heerschar von Ausgebeuteten und Arbeitslosen gegenüberstehen.⁹

8 Siehe Kapitel 11 in Brynjolfsson & McAfee (2016), das einen guten Überblick über die Debatte gibt, ob Technologie uns eines Tages alle arbeitslos machen könnte. Interessant sind in diesem Zusammenhang auch die Vorhersagen und Analysen, die zu Beginn früherer Automatisierungswellen gemacht wurden, etwa von Pollock (1964).

9 Das Androiden-Gedankenexperiment ist auch aus Kapitel 11 in Brynjolfsson & McAfee (2016).

Das Wort ›Roboter‹ wurde vor mehr als hundert Jahren durch ein Theaterstück des tschechischen Autors Karel Čapek populär gemacht.¹⁰ Es leitet sich von dem tschechischen Wort für Fronarbeit ab. Der Titel bezieht sich auf den Namen der Firma, die in dem Stück androide Sklaven herstellt: *W.U.R., Werstands Universal Robots*. Diese Roboter sehen aus wie Menschen und sind universell einsetzbar. Sie können Menschen an jedem Arbeitsplatz ersetzen. Literarisches Vorbild für die Roboter war der Golem. Anders als der Golem und anders als heutige Androiden sind die Roboter in Čapeks Stück wie Frankensteins Monster aus Fleisch und Blut gefertigt. Mit heutigen Robotern haben sie gemein, dass sie keine Gefühle haben. Die biblischen Bezüge in dem Stück sind nicht zu übersehen. Werstand, der Erfinder der Roboter, will Gott ebenbürtig werden, indem er die Roboter nach dem Ebenbild des Menschen erschafft. Auch in seiner Kapitalismuskritik ist das Stück nicht gerade subtil. Werstands Sohn erkannte das große wirtschaftliche Potenzial und als Abermillionen von solchen Robotern produziert waren, fand sich die Welt nicht im Paradies, sondern in genau dem kapitalistischen Albtraum wieder, der auch heute von manchen befürchtet wird.

Es kommt aber noch schlimmer. Die Roboter lehnen sich dagegen auf, dass sie von den Menschen nicht menschlich behandelt werden, und löschen die Menschheit deshalb aus. Als das passiert, sagt Alquist, der einzige Mensch, der überleben wird:

Ich klage die Wissenschaft an! Ich klage die Technik an! [...] Mich selbst! Uns alle! Wir, wir sind schuldig! Um unseres Größenwahns, um irgendwelcher Gewinne, um ich weiß nicht welcher großartigen Sache willen haben wir die Menschheit getötet!¹¹

Das Stück ist eine beißende Gesellschaftskritik, die den Verlust an Menschlichkeit beklagt. Naive Technikgläubigkeit und ungezügelter Kapitalismus führen zu Kontrollverlust und dem Ende der Menschheit. Kommt Ihnen diese Erzählung bekannt vor? Es ist noch so eine Ironie der Geschichte, dass *W.U.R.* uns das Wort ›Roboter‹ geschenkt hat, die Gesellschaftskritik, die mit dem Wort so offensichtlich verbunden ist, aber nicht seine beabsichtigte Wirkung entfaltet hat. Stattdessen wird

¹⁰ Siehe Jordan (2016).

¹¹ Čapek (1922), S. 89.

die im Theaterstück metaphorische Auslöschung der Menschheit durch die Roboter heutzutage wörtlich genommen.

Im Stück ist die Entwicklung von Maschinen, die Menschen in allen Bereichen ersetzen, eng mit der Logik eines kapitalistischen Wirtschaftssystems verbunden. Dass menschenähnlichen Robotern aber aus wirtschaftlichen Gründen die Zukunft gehört, ist noch nicht ausgemacht – auch, wenn einige Firmen zurzeit an spektakulären Androiden arbeiten. Die Hoffnung dieser Unternehmen ist, dass Androiden in einer Welt, in der der Mensch das Maß aller Dinge ist, tatsächlich universell eingesetzt werden können. Ein Waschroboter, der die Wäsche mit der Hand über ein Waschbrett reibt, ist aber nicht die beste Lösung für das leidige Wäschewaschen. Und Gott sei Dank haben die Erfinder der Waschmaschine nicht auf die Entwicklung von Androiden gesetzt. Bisher bauten Ingenieurinnen und Ingenieure immer Spezialmaschinen, die ganz anders als Menschen sind und ihre Aufgaben gerade deshalb besser als der Mensch erledigen. Die allermeisten Roboter, die bisher entwickelt wurden, sehen überhaupt nicht wie Menschen aus. Ihre Konstruktion ist an spezielle Aufgaben angepasst. Denken Sie an Industrieroboter oder Staubsaugerroboter. Ob sich die Entwicklung von Androiden wirklich lohnt, wird davon abhängen, ob es neben Wäsche zusammenlegen, Pakete tragen und nuklearen Müll aufräumen genügend Aufgaben für diese Roboter gibt, die ihren hohen Preis rechtfertigen und nicht anders billiger und besser erledigt werden können.

Oft nehmen uns Spezialmaschinen keine Arbeit weg, sondern sie entlasten uns bei mühseligen Aufgaben und helfen uns so, die nötige Arbeit besser und schneller zu erledigen. Welche Statikerin möchte heute noch ohne Computer die Statik eines Hochhauses berechnen und welcher Bauarbeiter möchte das Hochhaus ohne Betonmischer und Kran bauen? Eine Architektin könnte Angst haben, dass in Zukunft KI-Programme Häuser automatisch nach den Vorgaben des Kunden entwerfen. Aber vielleicht gibt sie auch einige kleinteilige Planungsaufgaben gerne an eine KI-Software ab, um mehr Zeit für kreative Tätigkeiten und Gespräche mit dem Kunden zu haben. Würden wir uns in Diskussionen über KI weniger auf Utopien und Dystopien fokussieren, sondern darauf, wie KI-Systeme Menschen bei konkreten Aufgaben unterstützen könnten, dann gäbe es vielleicht weniger Aufregung.

Mächtige Denkwerkzeuge

Die Menschheit hat inzwischen über 70 Jahre Erfahrung mit dem Einsatz von elektronischen Computern und KI. Computer sind unersetzliche Werkzeuge geworden, um komplexe Probleme zu lösen. Ein Buch zur Geschichte der Computer nennt sie deshalb schon im Titel *Tools for Thought*.¹ Ganz wie andere Software auch hilft nützliche KI-Software Menschen dabei, konkrete Probleme zu lösen.

Computerprogramme haben in der Vergangenheit natürlich einigen Menschen Arbeit weggenommen, indem sie geistige Tätigkeiten – insbesondere das Rechnen und Verarbeiten von Daten – automatisiert haben. Das wird vermutlich durch den Fortschritt in Informatik und KI so weitergehen. Aber erst die schnelle und einfache Verfügbarkeit von Berechnungen und Daten erlaubt es Architekten, spektakuläre Gebäude zu entwerfen, Ärztinnen dreidimensionale Bilder des Inneren eines Patienten aufzunehmen oder Meteorologen immer bessere Wettervorhersagen zu machen. Wenn Computer nicht schneller und besser rechneten als Menschen, gäbe es all diese Fortschritte nicht. Wir haben bisher keine Computerprogramme entwickelt, die Architekten, Ärztinnen oder Meteorologen ersetzen. Wir haben Computerprogramme entwickelt, die ihre kognitiven Fähigkeiten verstärken. Viele dieser Programme enthalten heute schon klassische KI-Algorithmen, ohne dass wir bisher deshalb viel Aufheben darum gemacht hätten. Statt von KI spreche ich in solchen Fällen daher lieber von kognitiven Werkzeugen.

1 Siehe Rheingold (2000).

Die Kepler'sche Vermutung

Als 1998 Thomas Hales ankündigte, er habe die Kepler'sche Vermutung bewiesen, war das eine mathematische Sensation. Die Vermutung besagte, dass man Kugeln am platzsparendsten so packt, wie der Obsthändler Orangen an seinem Marktstand stapelt. Wie denn sonst, könnte man einwenden, aber seitdem der Astronom Johannes Kepler 1611 diese Vermutung niederschrieb, haben sich unzählige Mathematikerinnen und Mathematiker ihre Zähne an einem Beweis ausgebissen. Hales hatte einen unfairen Vorteil gegenüber seinen Vorgängern. Er nutzte einen Computer, der ihm knechtische Rechenarbeiten abnahm. Er konnte das Problem auf ein paar tausend mögliche Fälle reduzieren und statt alle diese Fälle selber zu überprüfen, schrieb er ein Computerprogramm, das diese Aufgabe für ihn übernahm.

Seine Kolleginnen und Kollegen blieben skeptisch, denn woher weiß man, dass das Computerprogramm richtig funktioniert? Selbst wenn Hales keinen Programmierfehler gemacht hat, vielleicht haben die Entwickler der Software, auf die er aufgebaut hat, einen Fehler gemacht, oder es gab einen Bug in der Architektur des Prozessors (der Intel Pentium lässt grüßen). Moderne Computer und moderne Software sind so komplex, dass niemand alle Teile überblicken kann. Wie räumt man dann die Zweifel an einem Computerbeweis aus? Ein paar mutige und pflichtbewusste Mathematiker versuchten, den ganzen Beweis, inklusive der computergeprüften Teile, nachzuvollziehen. Sie gaben nach ein paar Jahren auf. Hales war mit den Restzweifeln extrem unzufrieden. Diese Restzweifeln ließen sich nur durch einen noch aggressiveren Computereinsatz weiter verringern. Also startete er ein Projekt, die Kepler'sche Vermutung nicht nur in Teilen, sondern vollständig mit der Unterstützung eines KI-Programmes zu beweisen, das selber beweisbar richtig ist. Das dauerte bis 2017. Ohne KI-Einsatz hätte der Beweis nie geführt werden können. Aber die KI war nur das Werkzeug, das dem Menschen bei langweiligen Details geholfen hat.²

Aus dem gleichen Grund greifen Sie beim Führen Ihres Haushaltsbuches zum Taschenrechner. (Sie führen doch ein Haushaltsbuch,

2 Siehe Hales et al. (2017). Das KI-Programm, das genutzt wurde, ist ein sogenannter automatischer Theorembeweiser. Das allererste KI-Programm überhaupt war übrigens auch ein automatischer Theorembeweiser: Der Logic Theorist von Newell & Simon (1956).

oder?) Übernimmt der Taschenrechner das Rechnen, haben Sie den Kopf für die eigentlichen Fragen frei. Haben Sie auch wirklich alle Ausgaben berücksichtigt? Ist die Zeitersparnis im Vergleich zum ÖPNV die Mehrkosten des eigenen Autos wert? Ohne Kopfrechnen geht es schneller – und wir machen weniger Fehler. Bei der Einführung von Taschenrechnern in der Schule gab es große Vorbehalte, die Kinder könnten das Kopfrechnen nicht mehr lernen. Kinder brauchen gewisse Grundkompetenzen beim Rechnen, um den Taschenrechner richtig benutzen zu können, aber sie müssen nicht mehr so viele Rechentricks kennen wie früher. Ist das schlimm?

Kompetenzen erodieren

In seiner Kurzgeschichte *Das Gefühl der Macht* beschreibt Isaac Asimov eine hoch entwickelte Zukunft, in der niemand mehr rechnen kann.³ Die Kunst des Rechnens per Hand – oder gar im Kopf – wurde vollständig vergessen. Nichts in dieser Zukunft geht mehr ohne Computer. Aber niemand versteht, wie diese Dinge funktionieren. Bis ein einfacher Techniker zufällig herausfindet, wie man Zahlen mit Papier und Bleistift multiplizieren kann. Ganz ohne Computer. Dass Menschen mit Papier und Bleistift alles können, was ein Computer kann, ist eine wissenschaftliche Sensation. In Asimovs Kurzgeschichte befreit diese Entdeckung die Menschen aus ihrer Abhängigkeit von Computern. Sie gewinnen die Fähigkeit zum selbständigen Denken zurück – und ein Gefühl der Macht (die sie natürlich sofort zu Kriegszwecken nutzen).

Wenn Computer uns immer mehr Aufgaben abnehmen, ist es auch wahrscheinlich, dass immer weniger Menschen diese Aufgaben ohne Computerunterstützung werden ausführen können. Die Gefahr besteht, dass Wissen und Fähigkeiten verloren gehen. Mit Abakus und Rechenschieber umgehen zu können, ist nur eines von vielen Beispielen. Dank GPS können weniger Menschen Karten lesen. Und wenn Autos autonom fahren, braucht niemand mehr fahren zu lernen. Aber ist die Automatisierung von solchen kognitiven Fertigkeiten anders als die Automatisierung von handwerklichen Fertigkeiten? Industrielle Backmischungen machen es doch auch immer schwieriger, einen Bäcker zu finden, der sein Handwerk noch versteht. Und nur wenige Men-

3 Die Kurzgeschichte findet sich in der Sammlung von Asimov (1986).

schen können heute noch spinnen, köhlern oder böttchern. Nochmal gefragt: Ist das schlimm? Die Antwort ist natürlich, dass man von Fall zu Fall entscheiden muss. Manchmal ist es okay, dass die Menschheit Fähigkeiten verlernt, und manchmal wünscht man sich, dass das nicht passiert wäre, zum Beispiel, wenn man eine Bäckerei sucht, bei der die Brezeln noch wie früher schmecken.

In den späten 1980er Jahren hatten wir in Deutschland schon einmal einen KI-Hype (und das war auch nicht der erste).⁴ Damals wurde das Deutsche Forschungszentrum für Künstliche Intelligenz (DFKI) gegründet. Die KI-Methoden waren andere, die Versprechen dieselben. Der Bundestag hat damals eine Enquete-Kommission beauftragt, die Chancen und Risiken des Einsatzes von KI in Produktion und Medizin zu bewerten.⁵ Der Bericht ist auch deshalb heute noch äußerst lesenswert, weil er eine schleichende Kompetenzerosion als eine der größten Gefahren identifiziert. Der Einsatz von KI könnte die Fähigkeit von Expertinnen und Experten, Entscheidungen kompetent und verantwortungsvoll zu treffen, systematisch untergraben.

Diese Sorge lässt sich gut am Beispiel eines Autopiloten im Flugzeug veranschaulichen. Der Autopilot soll Pilotinnen und Piloten entlasten und damit die Flugsicherheit erhöhen. Das tut er auch, aber es gibt Nebenwirkungen, an die man vielleicht nicht sofort denkt. Denn obwohl moderne Autopiloten ein Wunder der Automatisierung sind, sitzen immer noch zwei Piloten im Cockpit. Warum eigentlich? Es gibt immer noch Handgriffe, die der Computer noch nicht alleine erledigen kann. Vor allem tragen die Piloten aber die Verantwortung. Sie sagen dem Autopiloten, wo er hinfliegen soll, und sie kontrollieren, dass der Autopilot keinen Fehler macht. Und falls doch mal etwas schiefgehen sollte, ist es ihre Aufgabe einzugreifen. Piloten, die nur mit Autopilot fliegen, haben allerdings wenig Übung, das Flugzeug ohne Autopilot zu beherrschen. Gleichzeitig sollen sie aber in besonders brenzligen

4 Zu der Zeit lief in Japan das sogenannte ›Fifth Generation Computer Systems‹ Projekt, das damals ein Wettrennen zwischen Japan und den USA ausgelöst hat. Beim Lesen des Buches von Feigenbaum & McCorduck (1983) über das Projekt kann man das eine oder andere Déjà-vu erleben. In Europa lief zur gleichen Zeit das ESPRIT-Programm (›European Strategic Programme on Research in Information Technology‹). Wer sich dafür interessiert, wie die allerersten KI-Systeme (damals meist noch als kybernetische Systeme bezeichnet) in der BRD rezipiert worden sind, kann bei Pollock (1964) oder Steinbuch (1965) einen ersten Eindruck bekommen.

5 Siehe Enquete-Kommission (1990).

Situationen, in denen der Autopilot versagt, eingreifen und die Verantwortung übernehmen. Das passt nicht zusammen. Deswegen kann die Automatisierung, die die Flugsicherheit in vielen Situationen erhöht, das Fliegen in anderen Situationen unsicherer machen. Fachleute für Mensch-Maschine-Interaktion sprechen in solchen Fällen deshalb von den ›Ironien der Automatisierung‹.⁶

Während es im Cockpit schon lange einen Autopiloten gibt, ist für viele Ärztinnen und Ärzte die Zusammenarbeit mit KI-Systemen noch weitgehend Neuland. Die Probleme sind allerdings ähnlich. Weder Radiologen noch KI-Systeme erkennen Brustkrebs auf Röntgenbildern, ohne dabei Fehler zu machen. Ärzte sind aber teuer und arbeiten im Vergleich zu Computern sehr langsam. Sobald sich in klinischen Studien nachweisen lässt, dass KI-Systeme Brustkrebs besser erkennen als Radiologen, müsste man doch auf die Ärzte verzichten können, oder? Aber wer übernimmt dann die Verantwortung? Die Hersteller der KI-Software wahrscheinlich nicht. Also wird auf absehbare Zeit weiterhin ein Arzt die Diagnosen der Software überprüfen müssen. Merkt er nach einiger Zeit, dass die Software gut funktioniert, schaut er vielleicht nicht mehr so genau hin, oder die Aufgabe wird ihm einfach lästig. Es wird dadurch wahrscheinlicher, dass ihm die Fehldiagnosen des Computers, die er früher noch entdeckt hätte, durchrutschen. Seine Fähigkeiten verbessert er auch nicht mehr. Junge Ärztinnen und Ärzte, die zukünftig nicht mehr ohne KI-Software arbeiten, lernen vielleicht nie, Röntgenbilder richtig zu lesen. Kompetenz und Verantwortung gehören aber zusammen.

Viele andere Berufe stehen vor ähnlichen Herausforderungen. Neben medizinischen Tätigkeiten werden auch Aufgaben in den Bereichen Wissenschaft, Recht und Verwaltung von zunehmender Automatisierung betroffen sein. Wenn wir Kompetenz und Verantwortung zusammenhalten wollen, setzen wir uns am besten gar nicht erst das Ziel, all die Menschen in diesen Bereichen vollständig durch KI-Systeme zu ersetzen. Stattdessen sollten wir sie ins Zentrum der technologischen Entwicklung stellen. Statt zu versuchen, ihre Tätigkeiten vollständig zu automatisieren, sollten wir kognitive Werkzeuge entwickeln, die Expertinnen und Experten bestmöglich darin unterstützen, kompetente und verantwortungsvolle Entscheidungen zu treffen. Diese Werkzeuge

6 Der Begriff stammt von Bainbridge (1983).

nutzen KI-Methoden, aber nicht, um menschliche Intelligenz zu ersetzen, sondern um sie zu verstärken.

Fühle die Macht

Als der Schachweltmeister Garri Kasparow sich IBMs Deep Blue geschlagen geben musste, fragte er sich vielleicht, ob seine besonderen Fertigkeiten, die er sein Leben lang weiterentwickelt hat, jetzt überflüssig geworden sind. Doch Kasparow hängt seinen Beruf nicht an den Nagel, sondern nahm stattdessen an gemischten Turnieren teil, in denen Schachspieler mit Unterstützung von Computerprogrammen gegeneinander antreten. Der Mensch entscheidet, welche Züge gemacht werden, kann sich aber verschiedene Szenarien von einem Schachprogramm durchrechnen lassen. Diese Spiele haben eine andere Dynamik als klassische Schachspiele. Flüchtigkeitsfehler sind ausgeschlossen und Strategie wird wichtiger. Mensch und Maschine ergänzen sich mit ihren Fähigkeiten. Und das Spielniveau steigt. Wie übrigens auch das Niveau in klassischen Turnieren seit Kasparows Niederlage gestiegen ist, da die Vorbereitung und das Training sich durch Computerunterstützung für viele Spieler deutlich verbessert haben. Der Einsatz von KI führt also nicht zwingend zu einer Kompetenzerosion, er kann auch zur Kompetenzentwicklung beitragen.⁷

Eine der ersten profitablen Anwendungen für Sprachmodelle könnten Programmierassistenten sein. Es gibt Berichte, dass Programmierinnen und Programmierer, die von KI unterstützt werden, bis zu 50 Prozent schneller sind.⁸ Sollte das wirklich stimmen, werden Programmierer mit die ersten sein, die die Auswirkungen von KI in ihrem Arbeitsalltag bemerken werden. Da Programmiersprachen auch Sprachen sind und es im Internet neben natürlichsprachlichem Text auch sehr viel Programmcode gibt, haben Sprachmodelle neben Englisch und Spanisch auch die Computersprachen Python und Java gelernt. Wird das dazu führen, dass wir in Zukunft keine professionellen Programmierer mehr brauchen werden, die ihr Handwerk erst über viele

7 Siehe Kasparow (2017). Er nennt Turniere, bei denen in gemischten Teams gespielt wird, »Advanced Chess«.

8 Peng, Kalliamvakou, Cihon & Demirel (2023) berichten dies, arbeiten allerdings für einen Hersteller eines solchen Assistenten.

Jahre lernen müssen? Oder werden KI-Assistenten dazu führen, dass Programmierer, ähnlich wie Schachspieler, durch KI-Unterstützung besser werden?

Eine der ersten Studien, die sorgfältig untersucht hat, wie genau sich Programmierer von Sprachmodellen Unterstützung lassen, erkannte zwei Gruppen von Nutzern. Die erste Gruppe beschreibt dem Sprachmodell ihr Problem und akzeptiert den Vorschlag des Sprachmodells relativ unkritisch, frei nach dem Motto: Wird schon stimmen. Diese Gruppe war entsprechend schnell in der Bearbeitung der Programmieraufgaben, die ihnen die Studienleiter gegeben haben. Die andere Gruppe wollte den Vorschlag des Sprachmodells verstehen, bevor sie ihn akzeptiert. Bei einfachen Programmen war das kein Problem, aber sobald die Aufgabe etwas komplizierter wurde, gaben die Programmierer oft auf, weil die Lösung, die das Sprachmodell vorschlug, unverständlich war. In diesen Fällen entschieden diese Programmierer sich, den Code besser selber zu schreiben, als der KI blind zu trauen. Diese Versuchsteilnehmer brauchten durch den Einsatz von KI daher oftmals länger.⁹ Die Geschwindigkeit, mit der Code produziert wird, ist offensichtlich kein gutes Maß dafür, ob der Code auch etwas taugt. Im Internet gibt es viel schlechten Code, der Fehler und Sicherheitslücken enthält. Aus solchen Beispielen lernen Sprachmodelle programmieren. Daher ist es nicht überraschend, dass der Code, den Sprachmodelle produzieren, oft fehlerhaft und unsicher ist.¹⁰ Das ist das bekannte Bullshit-Problem von Sprachmodellen.

Aber natürlich gibt es auch beim Programmieren viele Teilaufgaben, die repetitiv und langweilig sind und durch KI beschleunigt werden können. Viele Programmieraufgaben sind nicht so anspruchsvoll, als dass man dafür einen erfahrenen Experten bräuchte. Solche Aufgaben können auch Anfänger mit KI-Unterstützung übernehmen. Wie beim Schreiben von Texten ist auch beim Schreiben von Code das Produzieren von Zeichenketten nicht unbedingt das, was am längsten dauert oder am mühseligsten ist. Jemand, der schneller tippen kann, ist nicht automatisch schneller oder besser im Denken. Bei komplexen Aufgaben ist der Flaschenhals im Produktionsprozess das Verständnis des Programmierers. Dieses stellt sich oftmals erst durch den Schreibprozess ein. Wie bei Piloten und Radiologen kann es kontraproduktiv

⁹ Siehe Vaithilingam, Zhang & Glassman (2022).

¹⁰ Siehe Pearce, Ahmad, Tan, Dolan-Gavitt & Karri (2022).

sein, die Arbeit von Programmierern vollständig zu automatisieren. Eine anstrengende Tätigkeit, die ein verantwortungsbewusster Programmierer leider nicht an eine KI abgeben kann, ist: eigenständiges Denken.

Wir können aber versuchen, KI-basierte Werkzeuge zu entwickeln, die Menschen beim Denken unterstützen. Diese kognitiven Werkzeuge sollten nicht zum Ziel haben, den Menschen das Denken vollständig abzunehmen, sondern die Menschen dabei unterstützen, ihre Kompetenzen stetig weiterzuentwickeln. Im besten Fall führt der Einsatz von Programmierassistenten dazu, dass Programmiererinnen und Programmierer mehr und nicht weniger über ihren Code nachdenken. Nur so können sie immer besseren Code produzieren. Insbesondere Anfängern würde es helfen, wenn der Programmierassistent wie ein Tutor ihren Lernprozess durch passendes Feedback fördert.¹¹ Bauen wir aber Programmierassistenten stattdessen so, dass sie dem Programmierer das Denken ganz abnehmen und er deshalb nichts dazulernt, führt das im schlechtesten Fall zu einer weitreichenden Kompetenzerosion. Software verliert dann an Qualität. Ob das eine oder andere Szenario eintritt, hängt davon ab, ob das Entwicklungsziel für KI ist, Programmierer zu ersetzen oder zu unterstützen.

Welche Kompetenzen weiterentwickelt werden sollten und auf welche Kompetenzen wir in Zukunft verzichten können, dazu gibt es unterschiedliche Meinungen. Das ist eine der zentralen Debatten, die wir über den Einsatz von KI führen müssen. Seit Jahrzehnten ist zum Beispiel die Rede davon, dass Programmieren genauso wie Lesen, Schreiben und Rechnen in einer digitalen Gesellschaft zu den Grundkompetenzen zählt und entsprechend schon in der Grundschule auf den Lehrplan gehört. Aber seitdem Computer durch Sprachmodelle jetzt scheinbar natürliche Sprache verstehen, gibt es laute Stimmen, die behaupten, dass es bald überflüssig sein wird, programmieren zu lernen.¹²

Programmieren schult allerdings mathematisches Denken und das wird auch zukünftig noch nützlich sein. Wir haben nicht aufgehört,

11 Es gibt verschiedene Projekte, intelligente Tutoresysteme, die auf Sprachmodellen beruhen, zu entwickeln. Eines der bekanntesten ist der Code Tutor Khanmigo von Khan Academy. Dabei sind intelligente Tutoresysteme natürlich nicht auf das Fach Informatik beschränkt. Genauso gibt es intelligente Tutoresysteme für Mathematik, Physik, Biologie oder zum Sprachenlernen.

12 Siehe Kreienbrink (2024).

den Kindern in der Schule Zählen und Rechnen beizubringen, weil es billige Taschenrechner gab. Die Menschheit hat bisher nicht verlernt zu rechnen und Asimovs Kurzgeschichte bleibt in dieser Hinsicht Science-Fiction. Wir entscheiden, welche Fertigkeiten wir unsere Kinder lehren wollen. Und nur weil eine Maschine eine Aufgabe übernehmen kann, werden wir die entsprechenden Kompetenzen nicht gleich aus dem Lehrplan streichen. Es wäre absurd, Schreiben in der Schule nicht mehr zu unterrichten, weil es jetzt generative KI gibt. Klares Kommunizieren, überzeugendes Argumentieren und logisches Denken sind weiterhin wichtig und sollten nach wie vor durch Schreiben gefördert werden. Kinder und Jugendliche müssen diese Fähigkeiten entwickeln, damit sie sich in unserer hoch technisierten und immer komplexer werdenden Welt zurechtfinden. Eigenständiges Denken lässt sich nicht an eine KI outsourcen. Unsere Kinder sollen auch in Zukunft die Macht des eigenständigen Denkens fühlen.

Nachwort

Maschinen übernehmen immer mehr Aufgaben, die bisher nur Menschen aufgrund ihrer Intelligenz erledigen konnten. Es gibt enorme Fortschritte in der Anwendung von Künstlicher Intelligenz. Anders als bei Wolfgang von Kempelens berühmtem Schachautomaten aus dem 18. Jahrhundert versteckt sich heute kein Mensch mehr in der Maschine. Aber es findet sich auch kein Geist in der Maschine.

Algorithmen finden Problemlösungen, indem sie systematisch oder zufällig viele verschiedene Lösungen ausprobieren. Sprachmodelle nutzen die statistischen Regelmäßigkeiten in Sprache aus, um Texte zu verarbeiten. Lernalgorithmen passen sich an statistische Regelmäßigkeiten in Daten an, brauchen dafür aber riesige Datenmengen. Deshalb tauchen die Schlagwörter maschinelles Lernen und Big Data so häufig zusammen auf. Zwar sind manche dieser Lernalgorithmen von frühen psychologischen Lerntheorien inspiriert, sie lernen jedoch ganz anders als Menschen. In lernender Künstlicher Intelligenz spiegelt sich bislang vor allem die Intelligenz ihrer Entwickler, die die Systeme so lange trainiert haben, bis die Programme eng bestimmte Probleme selbständig lösen konnten. KI-Forscher träumen zwar davon, Programmierer in der Zukunft durch KI-Systeme zu ersetzen, doch die bisher existierenden KI-Systeme zum Programmieren gehen ganz anders vor als menschliche Problemlöser. Weil wir Menschen oft in Worten denken, ist die aktuelle Aufregung um Sprachmodelle durchaus gerechtfertigt. Von Allgemeiner Künstlicher Intelligenz (AKI) sind wir aber noch weit entfernt.

Das Mantra dieses Buches war: Wir sind es, die den Maschinen vor-schnell eine menschenähnliche Intelligenz zuschreiben. Dabei haben wir weder eine genaue Vorstellung davon, was menschliche Intelligenz eigentlich auszeichnet, noch verstehen wir im Detail, wie genau KI funktioniert. Diese Täuschung über die wahre Natur der Maschinen verstellt uns den Blick auf die Zukunft.

Aller Wahrscheinlichkeit nach wird es wohl keine große Revolte geben und KI-Technologie wird nicht grundsätzlich verboten werden (anders als in Frank Herberts Roman *Dune*). Daher ist zu erwarten, dass unser Alltag künftig noch mehr von Computern bestimmt sein wird als er das heute ohnehin schon ist. Wenn wir uns nicht machtlos gegenüber dieser neuen Automatisierungswelle fühlen wollen, müssen wir als Gesellschaft verstehen, was sich hinter KI wirklich verbirgt. Nur dann können wir zukünftige KI-Systeme in unserem Sinne gestalten und regulieren. Einer breiten gesellschaftlichen Diskussion über KI steht aber im Weg, dass es zwei verschiedene Auffassungen von KI gibt, die nicht immer klar auseinandergehalten werden:¹

1. KI als Ingenieursdisziplin
2. KI als Kognitionswissenschaft

Der größte Teil der aktuellen KI-Forschung fällt in die erste Kategorie und ist eine konsequente Fortsetzung früherer Bestrebungen zur Automatisierung. Dabei werden großartige Ingenieursleistungen vollbracht, die echte Probleme lösen. KI-Automaten übernehmen zwar Aufgaben, die sonst Menschen erledigen, der Anspruch ist aber nicht, dass sie das genauso tun wie Menschen. Im Gegenteil, oft ist der Anspruch, dass sie die Aufgaben besser und schneller und deshalb anders als Menschen erledigen. Es wäre besser gewesen, hätte sich statt KI der Begriff »Automatenbau« für diese Ingenieursdisziplin durchgesetzt. Wenn wir von »künstlicher« Intelligenz sprechen, suggeriert das nämlich, dass es darum geht, »natürliche« Intelligenz zu imitieren, was aber in den allermeisten Fällen gar nicht das Ziel ist.

Computer zu nutzen, um natürliche Intelligenz zu verstehen, ist aber durchaus ein Ziel, das die frühe KI-Forschung in der kognitionswissenschaftlichen Tradition verfolgte. Indem man Computermodelle von psychologischen Prozessen entwickelt und das Verhalten dieser

1 Hier übernehme ich grob die Unterscheidung zwischen »AI-as-engineering« und »AI-as-psychology«, die Rooij et al. (2024) machen. In diesem Artikel werden noch weitere Differenzierungen vorgenommen, die ich hier auslasse. Eine ähnliche Einteilung findet sich auch bei Lighthill (1973), der zwischen KI Typ A (für »Advanced Automation«) und Typ C (für »Computer-based Central Nervous System«) unterscheidet. Beiden Arten von KI bescheinigt er, dass sie Fortschritte seit dem Beginn der KI-Forschung gemacht haben. Skeptisch ist er aber beim Typ B (für »Bridge«), der versucht, die beiden anderen Arten zu verbinden und damit viel Verwirrung stiftet.

Modelle mit dem Verhalten von Menschen (oder Tieren) vergleicht, kann man die Grundlagen von Intelligenz untersuchen. Statt von KI spricht man in diesem Fall heute von »kognitiver Modellierung«, die ein Teilgebiet der Kognitionswissenschaft ist. Im Gegensatz zu der Befürchtung, dass die Maschinen schon bald die Intelligenz des Menschen übertrumpfen werden, ist der Fortschritt bei kognitiven Modellen erschreckend langsam. Menschen sind verdammt komplizierte Wesen und Psychologinnen und Psychologen müssen ihre Modelle erst in vielen Experimenten überprüfen, bevor sie ernsthaft behaupten können, dass ein Computerprogramm ein Problem ähnlich wie ein Mensch löst. Dabei sind sie extrem vorsichtig, dass sie den Maschinen nicht leichtfertig menschliche Intelligenz zuschreiben – schon alleine, weil niemand genau versteht, was menschliche Intelligenz eigentlich ist. Der andere Teil der KI-Forschung, der keine kognitiven Modelle entwickelt, ist oftmals mit seinen Zuschreibungen von Intelligenz nicht ganz so vorsichtig.²

Genauso wie Flugzeuge und Vögel beide das physikalische Prinzip des Auftriebs zum Fliegen nutzen, nutzen Computer und Menschen beide die Prinzipien der Informationsverarbeitung, um sich intelligent zu verhalten. Deshalb sind die zwei Arten von KI, der Automatenbau und die kognitive Modellierung, eng miteinander verwandt. Aber sie haben andere Ziele. Manche Flugzeugentwürfe sind zwar vom Vogelflug inspiriert, aber es erscheint lächerlich, dass jemand versuchen könnte, ein Passagierflugzeug zu bauen, das genauso mit den Flügeln schlägt wie ein Vogel. Natürlich könnte man künstliche Federn herstellen und auf die Flügel kleben, die genaue Form des Skelettes nachbauen und künstliche Muskeln entwickeln, die das Skelett bewegen. Möchte man im Detail verstehen, wie Vögel fliegen, dann ist so ein Modell eines Vogels extrem hilfreich. Für Passagierflugzeuge, die viel größer als jeder Vogel sind und schneller fliegen, taugen Vögel allerdings nur bedingt als Vorbild.³

Im Fall von KI spukt trotzdem ständig die Science-Fiction-Vorstellung von menschenähnlichen Robotern durch die Diskussion. Dabei wird ganz selbstverständlich angenommen, dass die Maschinen eine

2 Mitchell (2023) und Odouard & Mitchell (2022) kritisieren das.

3 Die Analogie zwischen Kognition und KI auf der einen Seite und Vogelflug und Flugzeug auf der anderen ist in der Kognitionswissenschaft sehr beliebt und geht auf Marr (1982) zurück.

menschenähnliche Intelligenz entwickeln werden. Ich verstehe nur zu gut, welche Faszination die Idee ausübt, dass wir menschliche Intelligenz im Computer nachbilden können, schließlich habe ich selbst deswegen die kognitive Modellierung zu meinem Beruf gemacht. Ich kann mir gut vorstellen, dass wir theoretisch immer kompliziertere Computermodele bauen könnten, die das menschliche Denken immer besser in seiner Gesamtheit simulieren. Aber nur weil ich es theoretisch für möglich halte, heißt das nicht, dass ich es praktisch für machbar halte.⁴

Außerdem halte ich es nicht für sinnvoll. Warum sollte das Ziel von KI als Ingenieursdisziplin das Nachahmen von menschlicher Intelligenz sein? Wenn KI-Systeme in manchen Anwendungen Menschen ersetzen sollen, sollten sie die Aufgaben besser erledigen, als der Mensch es tut. Das wird in den meisten Fällen bedeuten, dass sie es anders machen. Statt einer menschenähnlichen KI brauchen wir dann eine menschenunähnliche KI. In anderen Anwendungen sollen KI-Systeme Menschen nicht ersetzen, sondern unterstützen. Dafür müssen sie die Fähigkeiten des Menschen ergänzen, statt sie nachzubilden. Statt einer menschenähnlichen KI brauchen wir in diesen Fällen eine menschenzentrierte KI.⁵ Wie Menschen und KI-Systeme in Zukunft zusammenarbeiten werden, ist dabei noch nicht ausgemacht. Wir müssen uns entscheiden, welche Tätigkeiten wir an KI-Systeme abgeben und bei welchen sie uns lediglich unterstützen sollen. Dabei müssen wir in jedem Einzelfall sorgfältig darauf achten, ob wir die mit einer Aufgabe einhergehende Verantwortung wirklich an eine Maschine abgeben können.

KI ist keine Naturgewalt, die plötzlich und unerwartet über uns hereinbricht. Natürlich gibt es wirtschaftliche und geopolitische Interessen, die wie bei vergangenen Automatisierungswellen die Entwicklung von neuen Technologien antreiben und die international nur schwer zu kontrollieren sind. Aber wir sind als Gesellschaft diesen Entwicklungen nur dann machtlos ausgeliefert, solange wir sie nicht verstehen und nicht politisch mitgestalten. Mit der KI-Verordnung der Europäischen Union ist ein Anfang gemacht.

4 Siehe nochmal Rooij et al. (2024), die auch darauf hinweisen, dass aus der theoretischen Möglichkeit nicht die praktische Machbarkeit folgt. Sie haben sogar gute theoretische Argumente, warum es praktisch nicht geht.

5 Siehe Shneiderman (2022) für eine Einführung in menschenzentrierte KI.

Diskussionen über KI drehen sich aber leider immer noch zu häufig darum, ob KI-Systeme denken können, inwiefern Menschen nur biologische Maschinen sind oder superintelligente Killerroboter die Welt-herrschaft übernehmen werden. Das sind spannende philosophische Fragen. Es ist auch aufregend, sich die ferne Zukunft vorzustellen. Wir sollten uns aber deshalb nicht von den eigentlichen Fragen ablenken lassen, die sich heute stellen: Welche gesellschaftlichen Auswirkungen haben Digitalisierung, Big Data und KI? Und wie genau sollen Menschen und Maschinen zusammenarbeiten, damit wir die Kontrolle und die Verantwortung behalten? Wenn wir diese Fragen beantworten wollen, dürfen wir uns nicht über die Fähigkeiten von KI täuschen und künstliche mit menschlicher Intelligenz verwechseln.

Danksagungen

Das Buchprojekt nahm seinen Anfang damit, dass ich 2019 am Sachbuchseminar der Bayerischen Akademie des Schreibens am Literaturhaus München teilnehmen durfte. Ich danke Katrin Lange sowie Hanna Schuler und Wolfgang Büscher, ohne deren Starthilfe ich mit dem Schreiben nicht begonnen hätte. Ich danke auch den anderen Teilnehmerinnen und Teilnehmern für die lebhaften Diskussionen.

Über die Jahre haben so viele Menschen mit mir über die verschiedenen Inhalte des Buches diskutiert, dass es leider unmöglich ist, ihnen allen einzeln dafür zu danken. Einige von ihnen hatten einen besonders starken Einfluss auf mich, haben mich besonders unterstützt oder haben sich sogar die Zeit genommen, das Manuskript genau zu lesen. In vielen Punkten werden sie immer noch nicht mit mir übereinstimmen, aber ihr zum Teil ausführliches und detailliertes Feedback hat das Buch auf jeden Fall besser gemacht: Dirk Balfanz, Petra Grell, Bianca Jäkel, Hartmut Jäkel, Roswitha Jäkel, Thorsten Jäkel, Pablo León-Vilagrà, Marianne Maertens, Kristof Meding, Claire Ott, Vildan Salikutluk, Vera Shuman, Maik Stüttgen, Iris van Rooij, Constantin Rothkopf, Anselm Spindler, Matthias Thönnissen, Susanne Trick, Tomer Ullman, Felix Wichmann und Carlos Zednik. Vielen Dank Euch allen!

Mein besonderer Dank gilt der Familie Shuman und der Familie Ullman, die mir Asyl gewährt haben, als ich vor meinen anderen Aufgaben flüchten musste, um das Buch fertig zu schreiben.

Literaturverzeichnis

- Adam, A. (1998). *Artificial Knowing: Gender and the Thinking Machine*. London: Routledge.
- Adam, D. (2024). Lethal AI weapons are here: How can we control them? *Nature*, 629, 521-523.
- Algorithm Watch (2024). AI Act: Nachbessern beim Schutz vor Massenüberwachung im öffentlichen Raum. Zugriff am 7.7.2024. Verfügbar unter: <https://algorithmwatch.org/de/ai-act-nachbessern-schutz-vor-massenuberwachung/>
- Allyn, B. (2024). The music industry is coming for AI. NPR. Zugriff am 27.8.2024. Verfügbar unter: <https://www.npr.org/2024/07/12/nx-s1-5034324/the-music-industry-is-coming-for-ai>
- Aly, G. & Roth, K. H. (2000). *Die restlose Erfassung: Volkszählen, Identifizieren, Aussondern im Nationalsozialismus*. Frankfurt a.M.: Fischer Taschenbuch.
- Andreessen, M. (2023). The Techno-Optimist Manifesto. Zugriff am 17.7.2024. Verfügbar unter: <https://a16z.com/the-techno-optimist-manifesto>
- Anguiano, D. & Beckett, L. (2023). How Hollywood writers triumphed over AI – and why it matters. *The Guardian*. Zugriff am 5.10.2024. Verfügbar unter: <https://www.theguardian.com/culture/2023/oct/01/hollywood-writers-strike-artificial-intelligence>
- Asimov, I. (1986). *Robot Dreams*. London: Orion Publishing Group.
- Associated Press (2017). Putin: Leader in artificial intelligence will rule world. Zugriff am 20.7.2024. Verfügbar unter: <https://apnews.com/article/bb5628f2a7424a10b3e38b07f4eb90d4>
- Bainbridge, L. (1983). Ironies of automation. *Automatica*, 6, 775-779.
- Bayerisches Staatsministerium der Justiz (2024). Zugriff am 30.12.2024. Verfügbar unter: <https://www.justiz.bayern.de/presse-und-medien/pressemitteilungen/archiv/2024/116.php>

- Bearne, S. (2023). New AI systems collide with copyright law. *BBC*. Zugriff am 27.8.2024. Verfügbar unter: <https://www.bbc.com/news/business-66231268>
- Bengio, Y., Hinton, G., Yao, A., Song, D., Abbeel, P., Darrell, T. et al. (2024). Managing extreme AI risks amid rapid progress. *Science*, 384 (6698), 842-845.
- Bhuyian, J. (2021). LAPD ended predictive policing programs amid public outcry. *The Guardian*. Zugriff am 9.7.2024. Verfügbar unter: <https://www.theguardian.com/us-news/2021/nov/07/lapd-predictive-policing-surveillance-reform>
- Birhane, A., Prabhu, V. U. & Kahembwe, W. (2021). *Multimodal Datasets: Misogyny, Pornography, and Malignant Stereotypes*. No. 2110.01963v. arXiv.
- Bohannon, M. (2023). Lawyer used ChatGPT in court – and cited fake cases. *Forbes*. Zugriff am 19.6.2024. Verfügbar unter: <https://www.forbes.com/sites/mollybohannon/2023/06/08/lawyer-used-chatgpt-in-court-and-cited-fake-cases-a-judge-is-considering-sanctions/>
- Bonin, H., Gregory, T. & Zierahn, U. (2015). *Übertragung der Studie von Frey/Osborne (2013) auf Deutschland*. Kurzexptise No. 57. Mannheim: Zentrum für Europäische Wirtschaftsforschung GmbH.
- Booth, R. (2014). Facebook reveals news feed experiment to control emotions. *The Guardian*. Zugriff am 13.9.2019. Verfügbar unter: <https://www.theguardian.com/technology/2014/jun/29/facebook-users-emotions-news-feeds>
- Borchard, R. (2025). Wie »Stargate« in Trumps Pläne passt. *Tagesschau*. Zugriff am 10.2.2025. Verfügbar unter: <https://www.tagesschau.de/ausland/amerika/ki-stargate-trump-100.html>
- Bostrom, N. (2014). *Superintelligence: Paths, Dangers, Strategies*. Oxford: Oxford University Press.
- Braitenberg, V. (1984). *Vehicles: Experiments in Synthetic Psychology*. Cambridge, MA: MIT Press.
- Bräutigam, F. (2021). Ein Signal für die junge Generation. *Tagesschau*. Zugriff am 18.7.2024. Verfügbar unter: <https://www.tagesschau.de/inland/klimaschutz-beschluss-analyse-101.html>
- Brayne, S. (2021). *Predict and Surveil: Data, Discretion, and the Future of Policing*. New York, NY: Oxford University Press.
- Brown, N. & Sandholm, T. (2018). Superhuman AI for heads-up no-limit poker: Libratus beats top professionals. *Science*, 359, 418-424.

- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P. et al. (2020). Language models are few-shot learners. In H. Larochelle, M. Ranzato, R. Hadsell, M.-F. Balcan & H.-T. Lin (Hg.), *Advances in Neural Information Processing Systems* (Band 33). Redhook, NY: Curran Associates, Inc.
- Bruner, J. R., Goodnow, J. J. & Austin, G. A. (1956). *A Study of Thinking*. New York, NY: Wiley.
- Brynjolfsson, E., Li, D. & Raymond, L. R. (2023). *Generative AI at Work*. No. 31161. Cambridge, MA: National Bureau of Economic Research.
- Brynjolfsson, E. & McAfee, A. (2016). *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. New York, NY: W. W. Norton & Company, Inc.
- Brynjolfsson, E. & Mitchell, T. (2017). What can machine learning do? Workforce implications. *Science*, 358 (6370), 1530-1534.
- Brynjolfsson, E., Mitchell, T. & Rock, D. (2018). What can machines learn and what does it mean for occupations and the economy? *AEA Papers and Proceedings* (Band 108, S. 43-47).
- Buranyi, S. (2017). Rise of the racist robots – how AI is learning all our worst impulses. *The Guardian*. Zugriff am 5.7.2024. Verfügbar unter: <https://www.theguardian.com/inequality/2017/aug/08/rise-of-the-racist-robots-how-ai-is-learning-all-our-worst-impulses>
- Buyl, M. & De Bie, T. (2024). Inherent limitations of AI fairness. *Communications of the ACM*, 67 (2), 48-55. New York, NY: ACM.
- Cadwalladr, C. (2019). Facebook's role in Brexit – and the threat to democracy. *TED Talk*. Zugriff am 16.5.2024. Verfügbar unter: https://www.ted.com/talks/carole_cadwalladr_facebook_s_role_in_brexit_and_the_threat_to_democracy
- Cadwalladr, C., Graham-Harrison, E. & Townsend, M. (2018). Revealed: Brexit insider claims Vote Leave team may have breached spending limits. *The Guardian*. Zugriff am 14.9.2019. Verfügbar unter: <https://www.theguardian.com/politics/2018/mar/24/brexit-whistleblower-cambridge-analytica-beleave-vote-leave-shahmir-sanni>
- Campitelli, G. & Gobet, F. (2004). Adaptive expert decision making: Skilled chess players search more and deeper. *ICGA Journal*, 27 (4), 209-216.
- Čapek, K. (1922). *W.U.R. – Werstands Universal Robots*. Prag und Leipzig: Orbis Druck, Verlags,- und Zeitungs-A.-G.

- Charness, N. (1981). Search in chess: Age and skill differences. *Journal of Experimental Psychology: Human Perception and Performance*, 7 (2), 467-476.
- Chase, W. G. & Simon, H. A. (1973). Perception in chess. *Cognitive Psychology*, 4 (55-81).
- Chow, A. R. (2023). Kelly McKernan. *Time Magazine*. Zugriff am 27.8.2024. Verfügbar unter: <https://time.com/collection/time100-ai/6309445/kelly-mckernan>
- Christl, W. (2019). Microtargeting. *Aus Politik und Zeitgeschichte*. Zugriff am 3.1.2025. Verfügbar unter: <https://www.bpb.de/shop/zeitschriften/apuz/292349/microtargeting/>
- Coerper, A. & Klauser, F. (2023). Digitale Söldner Uncovered – Das Geschäft mit den Wahlen. *ZDF Frontal*. Zugriff am 16.5.2024. Verfügbar unter: <https://www.zdf.de/politik/frontal/desinformation-wahlmanipulation-israel-digital-soeldner-investigativ-recherche-youtube-100.html>
- Cooney, C. (2024). Creating sexually explicit deepfakes to become a criminal offence. *BBC*. Zugriff am 30.12.2024. Verfügbar unter: <https://www.bbc.com/news/uk-68823042>
- Dachwitz, I. (2024). Parteien wollen weiter zielgerichtete Social-Media-Werbung schalten. *Netzpolitik.org*. Zugriff am 25.2.2025. Verfügbar unter: <https://netzpolitik.org/2024/trotz-appell-der-datenschutz-beauftragten-parteien-wollen-weiter-zielgerichtete-social-media-werbung-schalten/>
- Dastin, J. (2018). Amazon scraps secret AI recruiting tool that showed bias against women. *Reuters*. Zugriff am 16.7.2024. Verfügbar unter: <https://www.reuters.com/article/world/insight-amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MKOAG>
- Dell'Acqua, F., McFowland III, E., Ethan Mollick, E., Lifshitz-Assaf, H., Kellogg, K. C., Rajendran, S. et al. (2023). *Navigating the Jagged Technological Frontier: Field Experimental Evidence of the Effects of AI on Knowledge Worker Productivity and Quality*. Cambridge, MA: Harvard Business School.
- Deng, J., Dong, W., Socher, R., Li, L., Kai Li & Li Fei-Fei. (2009). ImageNet: A large-scale hierarchical image database. *IEEE Conference on Computer Vision and Pattern Recognition* (S. 248-255).
- Descartes, R. (2011). *Discours de la Méthode: Französisch – Deutsch*. (C. Wohlers, Hg.). Hamburg: Felix Meiner Verlag.

- Deutscher Verkehrsgerichtstag (2023). Empfehlungen des 61. Verkehrsgerichtstages: AK III. Zugriff am 8.5.2024. Verfügbar unter: <https://deutscher-verkehrsgerichtstag.de/pages/dokumentation/themen-empfehlungen.php>
- Dewdney, A. K. (1989). *The Turing Omnibus*. Rockville, MD: Computer Science Press.
- DIN & DKE (2022). Deutsche Normungsroadmap Künstliche Intelligenz (Ausgabe 2). Zugriff am 5.7.2024. Verfügbar unter: <http://www.din.de/go/normungsroadmapki>
- Duffy, C. (2024). Elon Musk drops lawsuit after OpenAI published his emails. *CNN*. Zugriff am 29.7.2024. Verfügbar unter: <https://edition.cnn.com/2024/06/11/tech/elon-musk-drops-openai-lawsuit/index.html>
- Duhigg, C. (2012). How companies learn your secrets. *The New York Times Magazine*. Zugriff am 12.9.2019. Verfügbar unter: <https://www.nytimes.com/2012/02/19/magazine/shopping-habits.html>
- Duncan, I. & Thadani, T. (2024). Tesla's Autopilot linked to more crashes even after massive recall. *The Washington Post*. Zugriff am 16.7.2024. Verfügbar unter: <https://www.washingtonpost.com/business/2024/04/26/tesla-nhtsa-autopilot-recall-investigation>
- Dursun, M. & Stradinger, A. (2022). Überlastete Gerichte: Klagewelle bei Flugverspätungen lähmt Justiz. *Report Mainz*. Zugriff am 19.6.2023. Verfügbar unter: <https://www.daserste.de/information/politik-weltgeschehen/report-mainz/sendung/ueberlastete-gerichte-klagewelle-bei-flugverspaetungen-laehmt-justiz-100.html>
- Dzieza, J. (2023). AI is a lot of work. *The Verge*. Zugriff am 28.8.2024. Verfügbar unter: <https://www.theverge.com/features/23764584/artificial-intelligence-data-notation-labor-scale-surge-remotasks-openai-chatbots>
- Eckstein, M. P., Koehler, K., Welbourne, L. E. & Akbas, E. (2017). Humans, but not deep neural networks, often miss giant targets in scenes. *Current Biology*, 27, 2827-2832.
- Eisenhart Rothe, Y. von. (2018). Dieses Bild hat eine künstliche Intelligenz gemalt, jetzt ist es Hunderttausende Dollar wert. *Bento*. Zugriff am 1.12.2024. Verfügbar unter: <https://www.spiegel.de/kultur/von-kuenstlicher-intelligenz-gemaltes-bild-wurde-erst-mals-versteigert-a-bd8c6f8d-9d4f-410e-b4cd-992e30209>

- Eloundou, T., Manning, S., Mishkin, P. & Rock, D. (2024). GPTs are GPTs: Labor market impact potential of LLMs. *Science*, 384 (6702), 1306-1308.
- Enquete-Kommission (1990). *Chancen und Risiken des Einsatzes von Expertensystemen in Produktion und Medizin*. Drucksache No. 11/7990. Berlin: Deutscher Bundestag.
- Erickson, P., Klein, J. L., Daston, L., Lemov, R., Sturm, T. & Gordin, M. D. (2013). *How Reason Almost Lost Its Mind*. Chicago, IL: The University of Chicago Press.
- Ericsson, K. A. & Pool, R. (2016). *Peak: Secrets from the New Science of Expertise*. Boston, MA: Houghton Mifflin Harcourt.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115-118.
- Europäische Kommission (2024). Tinder verpflichtet sich zu klaren Verbraucherinformationen über personalisierte Preise. Zugriff am 16.5.2024. Verfügbar unter: https://ec.europa.eu/commission/presscorner/detail/de/ip_24_1344
- Evans, J. S. B. T., Barston, J. L. & Pollard, P. (1983). On the conflict between logic and belief in syllogistic reasoning. *Memory & Cognition*, 11, 295-306.
- Feigenbaum, E. A. & McCorduck, P. (1983). *The Fifth Generation: Artificial Intelligence and Japan's Computer Challenge to the World*. Reading, MA: Addison-Wesley.
- Ferrucci, D., Brown, E., Chu-Carroll, J., Fan, J., Gondek, D., Kalyanpur, A. A. et al. (2010). Building Watson: An overview of the DeepQA project. *AI Magazine*, 31 (3), 59-79.
- Flyvbjerg, B. & Gardner, D. (2023). *How Big Things Get Done*. London: Macmillan Business.
- Franke, U. & Söderström, J. (2023). Star tech enterprise: Emerging technologies in Russia's war on Ukraine. *European Council on Foreign Relations (ECFR)*. Zugriff am 8.5.2024. Verfügbar unter: <https://ecfr.eu/publication/star-tech-enterprise-emerging-technologies-in-russias-war-on-ukraine/>
- Frey, C. B. & Osborne, M. A. (2013). The future of employment: how susceptible are jobs to computerisation? Zugriff am 23.9.2019. Verfügbar unter: https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf

- Geirhos, R., Temme, C. R. M., Rauber, J., Schütt, H. H., Bethge, M. & Wichmann, F. A. (2018). Generalisation in humans and deep neural networks. In S. Bengio, H. Wallach, H. Larochelle, K. Grauman, Cesa-Bianchi N. & R. Garnett (Hg.), *Advances in Neural Information Processing Systems* (Band 31, S. 7549-7561). Redhook, NY: Curran Associates, Inc.
- Geist, E. & Lohn, A. J. (2018). *How Might Artificial Intelligence Affect the Risk of Nuclear War?* Santa Monica, CA: RAND Corporation. Verfügbar unter: <https://www.rand.org/pubs/perspectives/PE296.html>.
- Gibbs, S. (2014). Elon Musk: Artificial intelligence is our biggest existential threat. *The Guardian*. Zugriff am 29.7.2024. Verfügbar unter: <https://www.theguardian.com/technology/2014/oct/27/elon-musk-artificial-intelligence-ai-biggest-existential-threat>
- Gobet, F. & Simon, H. A. (1996a). The roles of recognition processes and look-ahead search in time-constrained expert problem solving: Evidence from grand-master-level chess. *Psychological Science*, 7 (1), 52-55.
- Gobet, F. & Simon, H. A. (1996b). Recall of rapidly presented random chess positions is a function of skill. *Psychonomic Bulletin & Review*, 3, 159-163.
- Goldin, C. & Rouse, C. (2000). Orchestrating impartiality: The impact of »blind« auditions on female musicians. *American Economic Review*, 90 (4), 715-741. American Economic Association.
- Gomez-Uribe, C. A. & Hunt, N. (2015). The Netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 6 (4), 13:1-19.
- Goujard, C. & Manancourt, V. (2022). Dutch scandal serves as a warning for Europe over risks of using algorithms. *Politico*. Zugriff am 17.6.2024. Verfügbar unter: <https://www.politico.eu/article/dutch-scandal-serves-as-a-warning-for-europe-over-risks-of-using-algorithms/>
- Goujard, C. & Scott, M. (2023). EU hits Meta with record €1.2B privacy fine. *Politico*. Zugriff am 18.6.2024. Verfügbar unter: <https://www.politico.eu/article/eu-hits-meta-with-record-e1-2b-privacy-fine/>
- Grace, K., Salvatier, J., Dafoe, B., A. an Zhang & Evans, O. (2018). When will AI exceed human performance? Evidence from AI experts. *Journal of Artificial Intelligence Research*, 62, 729-754.

- Grace, K., Stewart, H., Sandkühler, J. F., Thomas, S., Weinstein-Raun, B. & Brauner, J. (2024). *Thousands of AI Authors on the Future of AI*. No. 2401.02843. arXiv.
- Graff, B. (2016). Rassistischer Chat-Roboter: Mit falschen Werten bombardiert. *Süddeutsche Zeitung*. Zugriff am 28.8.2024. Verfügbar unter: <https://www.sueddeutsche.de/wirtschaft/microsoft-programm-tay-rassistischer-chat-roboter-mit-falschen-werten-bombardiert-1.2928421>
- Graves, A., Wayne, G., Reynolds, M., Harley, T., Danihelka, I., Grabska-Barwinska, A. et al. (2016). Hybrid computing using a neural network with dynamic external memory. *Nature*, 538, 471-476.
- Greaves, H. & MacAskill, W. (2021). The case for strong longtermism. Zugriff am 18.7.2024. Verfügbar unter: <https://globalprioritiesinstitute.org/hilary-greaves-william-macaskill-the-case-for-strong-longtermism-2>
- Gross, C. G. (2002). Genealogy of the »Grandmother Cell«. *The Neuroscientist*, 8 (5), 512-518.
- Gutmann, M., Rathgeber, B. & Syed, T. (2013). Autonomie. In A. Stephan & S. Walter (Hg.), *Handbuch Kognitionswissenschaft* (S. 230-239). Heidelberg: Metzler.
- Gwynne, D. T. & Rentz, D. C. F. (1983). Beetles on the bottle: Male Burprestids mistake stubbies for females (Coleoptera). *Australian Journal of Entomology*, 22 (1), 79-80.
- Hagey, K. & Fitch, A. (2024). Sam Altman seeks trillions of dollars to reshape business of chips and AI. *The Wall Street Journal*. Zugriff am 29.7.2024. Verfügbar unter: <https://www.wsj.com/tech/ai/sam-altman-seeks-trillions-of-dollars-to-reshape-business-of-chips-and-ai-89ab3dbo>
- Hales, T., Adams, M., Bauer, G., Dang, T. D., Harrison, J., Hoang, L. T. et al. (2017). A formal proof of the Kepler Conjecture. *Forum of Mathematics, Pi*, 5 (e2), 1-29.
- Harlan, E. & Brunner, K. (2023). Der Rohstoff der KI sind wir. BR24. Zugriff am 27.8.2024. Verfügbar unter: <https://interaktiv.br.de/ki-trainingsdaten>
- Hart, P., Nilsson, N. J. & Raphael, B. (1968). A formal basis for the heuristic determination of minimum costs. *IEEE Transactions of Systems Science and Cybernetics*, (2), 100-107.
- Haskins, C. (2020). Scars, tattoos, and license plates: This is what Palantir and the LAPD know about you. *BuzzFeed*. Zugriff am 9.7.2024.

- Verfügbar unter: <https://www.buzzfeednews.com/article/caroline-haskins1/training-documents-palantir-lapd>
- Hawking, S., Tegmark, M. & Russell, S. (2014). Transcending complacency on superintelligent machines. *The Huffington Post*. Verfügbar unter: https://www.huffpost.com/entry/artificial-intelligence_b_5174265
- Heaven, W. D. (2023). How existential risk became the biggest meme in AI. *MIT Technology Review*. Verfügbar unter: <https://www.technologyreview.com/2023/06/19/1075140/how-existential-risk-became-biggest-meme-in-ai>
- Hebb, D. O. (1949). *The Organization of Behavior: A Neuropsychological Theory*. New York, NY: Wiley-Interscience.
- Heider, F. & Simmel, M. (1944). An experimental study of apparent behavior. *The American Journal of Psychology*, 57, 243-259.
- Henshall, W. (2023). The billion-dollar price tag of building AI. *Time Magazine*. Zugriff am 1.10.2024. Verfügbar unter: <https://time.com/6984292/cost-artificial-intelligence-compute-epoch-report>
- Hern, A. (2014). Elon Musk says he invested in DeepMind over Terminator fears. *The Guardian*. Zugriff am 29.7.2024. Verfügbar unter: <https://www.theguardian.com/technology/2014/jun/18/elon-musk-deepmind-ai-tesla-motors>
- Hernández-Orallo, J. (2017). *The Measure of All Minds: Evaluating Natural and Artificial Intelligence*. Cambridge: Cambridge University Press.
- Hernández-Orallo, J., Martínez-Plumed, F., Schmid, U., Siebers, M. & Dowe, D. L. (2016). Computer models solving intelligence test problems: Progress and implications. *Artificial Intelligence*, 230, 74-107.
- Hicks, M. (2018). *Programmed Inequality: How Britain Discarded Women Technologists and Lost Its Edge in Computing*. Cambridge, MA: MIT Press.
- Hicks, M. T., Humphries, J. & Slater, J. (2024). ChatGPT is bullshit. *Ethics and Information Technology*, 26 (2), 1-10.
- Hiltscher, L.-M. (2025). DeepSeek, der Schrecken der US-Techgiganten. *Tagesschau*. Zugriff am 18.2.2025. Verfügbar unter: <https://www.tagesschau.de/wirtschaft/unternehmen/deepseek-ki-start-up-china-100.html>
- Ho, K. K. (2024). Artwork Made by Humanoid Robot Ai-Da Using AI Algorithms Sells for \$1 M. at Sotheby's. *ARTnews*. Zugriff am 1.12.2024. Verfügbar unter: <https://www.artnews.com/art-news/news/artwork-humanoid-robot-ai-da-artificial-intelligence-algorithms-sothebys-alan-turing-1234723391/>

- Hoffman, D. D. (2009). The interface theory of perception: Natural selection drives true perception to swift extinction. In S. Dickinson, M. Tarr, A. Leonardis & B. Schiele (Hg.), *Object Recognition: Computer and Human Vision Perspectives* (S. 148-265). Cambridge: Cambridge University Press.
- Hollings, C., Martin, U. & Rice, A. (2020). How Ada Lovelace's notes on the Analytical Engine created the first computer program. *BBC Science Focus*. Zugriff am 7.12.2024. Verfügbar unter: <https://www.sciencefocus.com/future-technology/how-ada-lovelaces-notes-on-the-analytical-engine-created-the-first-computer-program>
- Honsel, G. (2006). Die Hype-Zyklen neuer Technologien. *Spiegel Netzwelt*. Zugriff am 18.2.2025. Verfügbar unter: <https://www.spiegel.de/netzwelt/tech/aufmerksamkeits-kurven-die-hype-zyklen-neuer-technologien-a-443717.html>
- Horkheimer, M. (1947). *Eclipse of Reason*. New York, NY: Oxford University Press.
- Hubel, D. H. & Wiesel, T. N. (1979). Brain mechanisms of vision. *Scientific American*, 241 (3), 150-162.
- Hughes, J. (2024). Can Hollywood's new SAG-AFTRA contract hold AI at bay? *Los Angeles Times*. Zugriff am 5.10.2024. Verfügbar unter: <https://www.latimes.com/opinion/story/2023-11-30/ai-hollywood-sag-aftra-strike-streaming-residuals-digital-replacement>
- Hurtz, S. (2019). Sprachassistenten verlieren ihre menschlichen Ohren. *Süddeutsche Zeitung*. Zugriff am 14.9.2019. Verfügbar unter: <https://www.sueddeutsche.de/digital/alexa-siri-google-daten-schutz-1.4552480>
- Hvistendahl, M. (2021). How the LAPD and Palantir use data to justify racist policing. *The Intercept*. Zugriff am 9.7.2024. Verfügbar unter: <https://theintercept.com/2021/01/30/lapd-palantir-data-driven-policing>
- Jaffri, A. (2024). Jenseits der GenAI – der Hype Cycle 2024 für künstliche Intelligenz. *Gartner*. Zugriff am 18.2.2025. Verfügbar unter: <https://www.gartner.de/de/artikel/hype-cycle-fuer-kuenstliche-intelligenz>
- Jannai, D., Meron, A., Lenz, B., Levine, Y. & Shoham, Y. (2023). *Human or Not? A Gamified Approach to the Turing Test*. No. 2305.20010. arXiv.
- Jordan, J. M. (2016). The Czech play that gave us the word »robot«. *The MIT Press Reader*. Zugriff am 9.10.2024. Verfügbar unter: <https://thereader.mitpress.mit.edu/origin-word-robot-rur>

- Kang, C. (2023). OpenAI's Sam Altman urges A.I. regulation in senate hearing. *The New York Times*. Zugriff am 29.7.2024. Verfügbar unter: <https://www.nytimes.com/2023/05/16/technology/openai-altman-artificial-intelligence-regulation.html>
- Kannan, P. (2023). Another warning letter from A.I. researchers and executives. *The New Yorker*. Zugriff am 19.7.2024. Verfügbar unter: <https://www.newyorker.com/humor/daily-shouts/another-warning-letter-from-ai-researchers-and-executives>
- Kasparow, G. (2017). *Deep Thinking*. London: John Murray.
- Katz, Y. (2020). *Artificial Whiteness: Politics and Ideology in Artificial Intelligence*. New York, NY: Columbia University Press.
- Kempfle, R. (2023). Überlastung der Zivilgerichte durch Massenverfahren – Lösungsvorschläge des Deutschen Richterbundes. *AnwBl Online*. Zugriff am 19.6.2023. Verfügbar unter: <https://anwaltsblatt.anwaltsverein.de/files/anwaltsblatt.de/anwaltsblatt-online/2023-079.pdf>
- Kleene, S. C. (1951). *Representation of Events in Nerve Nets and Finite Automata*. No. RM-704. Santa Monica, CA: The RAND Corporation.
- Knight, H. (2024). San Francisco moves to lead fight against deepfake nudes. *New York Times*. Zugriff am 5.10.2024. Verfügbar unter: <https://www.nytimes.com/2024/08/15/us/deepfake-pornography-lawsuit-san-francisco.html>
- Köhler, W. (1921). *Intelligenzprüfungen an Menschenaffen*. Berlin: Verlag von Julius Springer.
- Korf, R. E. & Schultze, P. (2005). Large-scale parallel breadth-first search. *Proceedings of the AAAI Conference on Artificial Intelligence* (Band 20, S. 1380-1385). Washington, DC: Association for the Advancement of Artificial Intelligence.
- Kramer, A. D. I., Guillory, J. E. & Hancock, J. T. (2014). Experimental evidence of massive-scale emotional contagion through social networks. *Proceedings of the National Academy of Sciences USA*, 111 (24), 8788-8790.
- Kreienbrink, M. (2024). Nvidia-CEO: Programmieren lernen lohnt gar nicht mehr – das sagen Entwickler dazu. *t3n*. Zugriff am 24.10.2024. Verfügbar unter: <https://t3n.de/news/nvidia-ceo-programmieren-lernen-programmierer-reaktionen-1610911/>
- Krisher, T. & The Associated Press. (2024). U.S. investigators ask Tesla why there have been 20 crashes since carmaker supposedly fixed Autopilot flaws. *Fortune*. Zugriff am 16.7.2024. Verfügbar unter:

- <https://fortune.com/2024/05/07/tesla-autopilot-recall-crash-investigation-nhtsa>
- Kurzweil, R. (2005). *The Singularity is Near: When Humans Transcend Biology*. London: Penguin Books.
- Lake, B. M., Ullman, T. D., Tenenbaum, J. B. & Gershman, S. J. (2017). Building machines that learn and think like people. *Behavioral and Brain Sciences*, 40, e253.
- Lampinen, A. K., Dasgupta, I., Chan, S. C. Y., Sheahan, H. R., Creswell, A., Kumaran, D. et al. (2024). Language models, like humans, show content effects on reasoning tasks. *PNAS nexus*, 3 (7), pgae233.
- Landeshauptstadt München (2024). MUCGPT: KI-Sprachassistentz für städtische Beschäftigte gelauncht. *Rathaus Umschau*. Zugriff am 5.10.2024. Verfügbar unter: <https://ru.muenchen.de/2024/42/MUCGPT-KI-Sprachassistentz-fuer-staedtische-Beschaefigte-gelauncht-111559>
- Le, Q. V., Ranzato, M. A., Monga, R., Devin, M., Chen, K., Corrado, G. S. et al. (2012). Building high-level features using large scale unsupervised learning. *Proceedings of the 29th International Conference on Machine Learning* (S. 507-514).
- Lemoine, B. (2022). Is LaMDA Sentient? – an Interview. *Medium*. Zugriff am 6.5.2024. Verfügbar unter: <https://cajundiscordian.medium.com/is-lamda-sentient-an-interview-ea64d916d917>
- Lenat, D., Prakash, M. & Shepherd, M. (1985). CYC: Using common sense knowledge to overcome brittleness and knowledge acquisition bottlenecks. *AI Magazine*, 6 (4), 65-85.
- Lettvin, J. Y., Maturana, H. R., McCulloch, W. S. & Pitts, W. H. (1959). What the frog's eye tells the frog's brain. *Proceedings of the IRE* (Band 47, S. 1940-51).
- Levy, S. (2017). What Deep Blue tells us about AI in 2017. *WIRED*. Zugriff am 14.9.2019. Verfügbar unter: <https://www.wired.com/2017/05/what-deep-blue-tells-us-about-ai-in-2017/>
- Light, J. S. (1999). When computers were women. *Technology and Culture*, 40 (3), 455-483.
- Lighthill, J. (1973). *Artificial Intelligence: A Paper Symposium*. Zugriff am 16.7.2024. Verfügbar unter: http://www.chilton-computing.org.uk/inf/literature/reports/lighthill_report/contents.htm
- Lohr, S. (2009). For today's graduate, just one word: statistics. *The New York Times*. Zugriff am 23.9.2019. Verfügbar unter: <https://www.nytimes.com/2009/08/06/technology/06stats.html>

- Lomas, N. (2023). Meta ordered to suspend Facebook EU data flows as it's hit with record €1.2BN privacy fine under GDPR. *TechCrunch*. Zugriff am 18.6.2024. Verfügbar unter: <https://techcrunch.com/2023/05/22/facebook-eu-us-data-flows-decision/>
- Marr, D. (1982). *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information*. New York, NY: W. H. Freeman.
- McCarthy, J. (2007). What is artificial intelligence? Zugriff am 9.5.2024. Verfügbar unter: <http://jmc.stanford.edu/articles/whatisai/whatisai.pdf>
- McCulloch, W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Mathematical Biophysics*, 5, 115-133.
- McCurdock, P. (1979). *Machines Who Think*. W. H. Freeman.
- Meckel, M. (2023). Silicon Scientology: Wenn KI zur Ideologie wird. *Handelsblatt*. Zugriff am 2.1.2025. Verfügbar unter: <https://www.handelsblatt.com/meinung/kolumnen/kolumne-kreative-zerstoerung-silicon-scientology-wenn-ki-zur-ideologie-wird/29462864.html>
- Metz, C. (2016). The sadness and beauty of watching Google's AI play Go. *WIRED*. Zugriff am 6.11.2024. Verfügbar unter: <https://www.wired.com/2016/03/sadness-beauty-watching-googles-ai-play-go>
- Metz, C., Kang, C., Frenkel, S., Thompson, S. A. & Grant, N. (2024). How tech giants cut corners to harvest data for A.I. *New York Times*. Zugriff am 27.8.2024. Verfügbar unter: <https://www.nytimes.com/2024/04/06/technology/tech-giants-harvest-data-artificial-intelligence.html>
- Meyer-Fünffinger, A., Streule, J., Zierer, M., Kartheuser, B. & Schöfel, R. (2024). Palantir-Software: Bayerisches LKA soll Testbetrieb stoppen. *BR24*. Zugriff am 9.7.2024. Verfügbar unter: <https://www.br.de/nachrichten/bayern/palantir-software-bayerisches-lka-soll-testbetrieb-stoppen>
- Michel, L. (2012). The grandmaster hoax. *The Paris Review*. Zugriff am 14.9.2019. Verfügbar unter: <https://www.theparisreview.org/blog/2012/03/28/the-grandmaster-hoax/>
- Mirowski, P., Mathewson, K. W., Pittman, J. & Evans, R. (2022). *Co-writing Screenplays and Theatre Scripts Alongside Language Models Using Dramatron*. No. 2209.14958. arXiv.
- Mitchell, M. (2023). How do we know how smart AI systems are? *Science*, 381, eadj5957.

- Moore, T. E. (1982). Subliminal advertising: What you see is what you get. *Journal of Marketing*, 46, 38-47.
- Neumann, J. von. (1993). First draft of a report on the EDVAC. *IEEE Annals of the History of Computing*, 15 (4), 29-43.
- Newell, A. & Simon, H. A. (1956). *The Logic Theory Machine: A Complex Information Processing System*. No. P-868. Santa Monica, CA: The RAND Corporation.
- Newell, A. & Simon, H. A. (1972). *Human Problem Solving*. Englewood Cliffs, NJ: Prentice-Hall.
- Noy, S. & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381 (6654), 187-192.
- Odouard, V. V. & Mitchell, M. (2022). Evaluating understanding on conceptual abstraction benchmarks. In J. Hernández-Orallo, L. Cheke, J. Tenenbaum, T. Ullman, F. Martínez-Plumed, D. Rutar et al. (Hg.), *EBE'M'22: AI Evaluation Beyond Metrics*. Aachen: CEUR Workshop Proceedings.
- Pearce, H., Ahmad, B., Tan, B., Dolan-Gavitt, B. & Karri, R. (2022). Asleep at the keyboard? Assessing the security of GitHub Copilot's code contributions. *Proceedings of the 43rd IEEE Symposium on Security and Privacy* (S. 754-768). New York, NY: Institute of Electrical and Electronics Engineers.
- Peeters, R. & Widlak, A. C. (2023). Administrative exclusion in the infrastructure-level bureaucracy: The case of the Dutch daycare benefit scandal. *Public Administration Review*, 83, 863-877.
- Peng, S., Kalliamvakou, E., Cihon, P. & Demirer, M. (2023). *The Impact of AI on Developer Productivity: Evidence from GitHub Copilot*. No. 2302.06590v1. arXiv.
- Perrigo, B. (2023). OpenAI Used Kenyan workers on less than \$2 per hour to make ChatGPT less toxic. *Time Magazine*. Zugriff am 28.8.2024. Verfügbar unter: <https://time.com/6247678/openai-chatgpt-kenya-workers>
- Piccinini, G. (2004). The first computational theory of mind and brain: A close look at McCulloch and Pitts's »Logical calculus of ideas immanent in nervous activity«. *Synthese*, 141, 175-215.
- Poe, E. A. (1836). Maelzel's chess-player. *Southern Literary Messenger*, (2), 318-326.
- Pollock, F. (1964). *Automation*. Frankfurt a.M.: Europäische Verlagsanstalt.

- Poser, H. (2016). *Leibniz' Philosophie: Über die Einheit von Metaphysik und Wissenschaft*. Hamburg: Felix Meiner Verlag.
- Quian Quiroga, R., Reddy, L., Kreiman, G., Koch, C. & Fried, I. (2005). Invariant visual representation by single neurons in the human brain. *Nature*, 435 (7045), 1102-1107.
- Quinn, P. C., Eimas, P. D. & Rosenkrantz, S. L. (1993). Evidence for representations of perceptually similar natural categories by 3-month-old and 4-month-old infants. *Perception*, 22 (4), 463-475.
- Reed, B. (2022). Google fires software engineer who claims AI chatbot is sentient. *The Guardian*. Zugriff am 6.5.2024. Verfügbar unter: <https://www.theguardian.com/technology/2022/jul/23/google-fires-software-engineer-who-claims-ai-chatbot-is-sentient>
- Reinsel, D., Gantz, J. & Rydning, J. (2018). *Data Age 2025 – The Digitization of the World: From Edge to Core*. IDC White Paper No. US44413318. IDC. Verfügbar unter: <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>
- Rheingold, H. (2000). *Tools for Thought: The History and Future of Mind-Expanding Technology*. Cambridge, MA: MIT Press.
- Robertson, K. (2024). 8 daily newspapers sue OpenAI and Microsoft over A.I. *New York Times*. Zugriff am 27.8.2024. Verfügbar unter: <https://www.nytimes.com/2024/04/30/business/media/newspapers-sued-microsoft-openai.html>
- Robertz, E. & Eßlinger, L. (2023). Speicherzeit und Score: Was folgt aus dem Schufa-Urteil? *Capital*. Zugriff am 5.16.2024. Verfügbar unter: <https://www.capital.de/geld-versicherungen/schufa-urteil-des-eugh--was-darf-die-auskunft-ei-nun-und-was-nicht--34267306.html>
- Rolnick, D., Donti, P. L., Kaack, L. H., Kochanski, K., Lacoste, A., Sankaran, K. et al. (2019). *Tackling Climate Change with Machine Learning*. No. 1906.05433. arXiv.
- Romermann, S. (2020). Ein »verschlimmbesserter« Erfolg. *Deutschlandfunk*. Zugriff am 18.7.2024. Verfügbar unter: <https://www.deutschlandfunk.de/oekonomin-zu-20-jahre-eeg-ein-verschlimmbesserter-erfolg-100.html>
- Rooij, I. van, Guest, O., Adolfs, F., Haan, R. de, Kolokova, A. & Rich, P. (2024). Reclaiming AI as a theoretical tool for cognitive science. *Computational Brain & Behavior*, 7, 616-636.

- Rosenblatt, F. (1958). The Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, 386-408.
- Russell, S. (2019). *Human Compatible: Artificial Intelligence and the Problem of Control*. New York, NY: Viking.
- Russell, S. (2023). Written statement for the United States Senate AI Forum on »Risk, Alignment, & Guarding Against Doomsday Scenarios«. Verfügbar unter: <https://people.eecs.berkeley.edu/~russell/papers/russell-senate23b-statement.pdf>
- Russell, S. & Norvig, P. (2009). *Artificial Intelligence: A Modern Approach* (3. Auflage). Upper Saddle River, NJ: Prentice Hall.
- Samuel, S. (2021). What we owe to future generations. *Vox*. Verfügbar unter: <https://www.vox.com/future-perfect/22552963/how-to-be-a-good-ancestor-longtermism-climate-change>
- Samuel, S. (2022). Effective altruism's most controversial idea. *Vox*. Zugriff am 18.7.2024. Verfügbar unter: <https://www.vox.com/future-perfect/23298870/effective-altruism-longtermism-will-macaskill-future>
- Sauer, F. (2018). Künstliche Intelligenz in den Streitkräften: Zum Handlungsbedarf bei Autonomie in Waffensystemen. *Arbeitspapiere der Bundesakademie für Sicherheitspolitik*. Zugriff am 8.5.2024. Verfügbar unter: <https://www.baks.bund.de/de/arbeitspapiere/2018/kuenstliche-intelligenz-in-den-streitkraeften-zum-handlungsbedarf-bei-autonomie>
- Scheld, C. (2023). Analyse-Programm verfassungswidrig: Warum die Polizei-Software »HessenData« von Palantir so problematisch ist. *Hessenschau*. Zugriff am 9.7.2024. Verfügbar unter: <https://www.hessenschau.de/politik/warum-die-polizei-software-hessendata-von-palantir-so-problematisch-ist-v2,urteil-bundesverfassungsgericht-hessendata-100.html>
- Schreiber, M. (2023). Schufa-Score entscheidet über Strom- und Gasverträge. *Süddeutsche Zeitung*. Zugriff am 5.7.2024. Verfügbar unter: <https://www.sueddeutsche.de/wirtschaft/schufa-score-daten-schutz-eugh-kunden-strompreis-1.6313888>
- Scott, M., Volpicelli, G., Chatterjee, M., Manancourt, V., Goujard, C. & Bordelon, B. (2024). Inside the shadowy global battle to tame the world's most dangerous technology. *Politico*. Zugriff am 18.6.2024. Verfügbar unter: <https://www.politico.eu/article/ai-control-kamala-harris-nick-clegg-meta-big-tech-social-media/>

- Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences*, 3 (3), 417-457.
- Shannon, C. E. (1950). Programming a computer for playing chess. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 41 (314), 256-275.
- Shannon, C. E. & McCarthy, J. (Hg.). (1956). *Automata Studies*. Princeton, NJ: Princeton University Press.
- Shannon, C. & Weaver, W. (1949). *The Mathematical Theory of Communication*. Champaign, IL: The University of Illinois Press.
- Shneiderman, B. (2022). *Human-Centered AI*. Oxford: Oxford University Press.
- Siebert, H. (2001). *Der Kobra-Effekt: Wie man Irrwege der Wirtschaftspolitik vermeidet*. Stuttgart: Deutsche Verlags-Anstalt.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Driessche, G. van den et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529, 484-489.
- Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Lanctot, M. et al. (2018). A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play. *Science*, 362, 1140-1140.
- Staatsministerium Baden-Württemberg (2023). Pressemitteilung: Künstliche Intelligenz in der Verwaltung. Zugriff am 5.10.2024. Verfügbar unter: <https://stm.baden-wuerttemberg.de/de/service/presse/meldung/pid/kuenstliche-intelligenz-in-der-verwaltung>
- Standage, T. (2002). *The Turk: The Life and Times of the Famous Eighteenth-Century Chess-Playing Machine*. Walker & Company.
- Steinbuch, K. (1965). *Automat und Mensch – Kybernetische Tatsachen und Hypothesen*. Berlin/Heidelberg: Springer-Verlag.
- Sutton, R. S. & Barto, A. G. (2018). *Reinforcement Learning* (2. Auflage). Cambridge, MA: MIT Press.
- Telford, T., Tiku, N. & De Vynck, G. (2024). Musk wanted control over OpenAI, emails released by the company allege. *The Washington Post*. Zugriff am 29.7.2024. Verfügbar unter: <https://www.washingtonpost.com/business/2024/03/06/open-ai-musk-lawsuit-agi-profit-emails>
- Tesauro, G. (1992). Practical issues in temporal difference learning. *Machine Learning*, 8, 257-277.

- The Guardian (2018). The Cambridge Analytica Files. Zugriff am 16.5.2024. Verfügbar unter: <https://www.theguardian.com/news/series/cambridge-analytica-files>
- Thorndike, E. L. (1898). Animal intelligence: An experimental study of the associative processes in animals: Series of Monograph Supplements. *Psychological Review*, II (4, 8), 1-109.
- Timberg, C. (2017). Russian propaganda may have been shared hundreds of millions of times, new research says. *The Washington Post*. Zugriff am 14.9.2019. Verfügbar unter: <https://www.washingtonpost.com/news/the-switch/wp/2017/10/05/russian-propaganda-may-have-been-shared-hundreds-of-millions-of-times-new-research-says/>
- Tolman, E. C. (1948). Cognitive maps in rats and men. *Psychological Review*, 55 (4), 189-208.
- Tong, A. & Sriram, A. (2025). Musk's lawsuit against OpenAI may go to trial in part, judge says. *Reuters*. Zugriff am 2.3.2025. Verfügbar unter: <https://www.reuters.com/legal/elon-musk-openai-head-court-spar-over-nonprofit-conversion-2025-02-04/>
- Toole, B. A. (1998). *Ada: The Enchantress of Numbers – Prophet of the Computer Age*. Mill Valley, CA: Strawberry Press.
- Tromp, J. & Farnebäck, G. (2016). Combinatorics of Go. Zugriff am 23.5.2024. Verfügbar unter: <https://tromp.github.io/go/gostate.pdf>
- Turing, A. M. (1937). On computable functions with an application to the Entscheidungsproblem. *Proceedings of the London Mathematical Society*, 42, 230-265.
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59, 433-460.
- Vaithilingam, P., Zhang, T. & Glassman, E. L. (2022). Expectation vs. experience: Evaluating the usability of code generation tools powered by large language models. *Extended Abstracts of the 2022 CHI Conference on Human Factors in Computing Systems* (S. 332:1-7). New York, NY: Association for Computing Machinery.
- Vance, A. (2017). Google and Facebook's idealistic futures are built on ads. *Bloomberg*. Zugriff am 16.5.2024. Verfügbar unter: <https://www.bloomberg.com/news/articles/2017-05-04/google-and-facebook-s-idealistic-futures-are-built-on-ads>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N. et al. (2017). Attention is all you need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan et al. (Hg.),

- Advances in Neural Information Processing Systems* (Band 30). Redhook, NY: Curran Associates, Inc.
- Villalobos, P., Ho, A., Sevilla, J., Besiroglu, T., Heim, L. & Hobbhahn, M. (2024). Position: Will we run out of data? Limits of LLM scaling based on human-generated data. In R. Salakhutdinov, Z. Kolter, K. Heller, A. Weller, N. Oliver, J. Scarlett et al. (Hg.), *Proceedings of the 41st International Conference on Machine Learning* (Band 235, S. 49523-49544). Cambridge: ML Research Press.
- Vinyals, O., Babuschkin, I., Czarnecki, W. M., Mathieu, M., Dudzik, A., Chung, J. et al. (2019). Grandmaster level in StarCraft II using multi-agent reinforcement learning. *Nature*, 575 (7782), 350-354.
- Watkins, C. (1989). *Learning from Delayed Rewards*. London: King's College.
- Watkins, C. & Dayan, P. (1992). Q-learning. *Machine Learning*, 8 (3-4), 279-292.
- Wattles, J. (2024). SpaceX put a Tesla sportscar into space five years ago. Where is it now? *CNN*. Zugriff am 30.7.2024. Verfügbar unter: <https://edition.cnn.com/2023/02/06/world/spacex-elon-musk-tesla-roadster-five-years-scen/index.html>
- Weibel, L. (2024). It's not all doom and gloom: 8 experts on their reasons to be optimistic in 2024. *World Economic Forum*. Zugriff am 31.7.2024. Verfügbar unter: <https://www.weforum.org/agenda/preview/eddf2248-2cdo-43dd-8d34-52a3680a29bb>
- Weizenbaum, J. (1966). ELIZA – A computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9 (1), 36-45.
- Weizenbaum, J. (1976). *Computer Power and Human Reason: From Judgment To Calculation*. San Francisco, CA: W. H. Freeman.
- Williams, C. (2015). AI guru Ng: Fearing a rise of killer robots is like worrying about overpopulation on Mars. *The Register*. Zugriff am 31.7.2024. Verfügbar unter: https://www.theregister.com/2015/03/19/andrew_ng_baidu_ai/
- Yao, S., Yu, D., Zhao, J., Shafran, I., Griffiths, T. L., Cao, Y. et al. (2023). *Tree of Thoughts: Deliberate Problem Solving with Large Language Models*. No. 2305.10601. arXiv.
- Zimmermann, N. (2024). Präsidentenwahl in Rumänien muss wiederholt werden. *Frankfurter Allgemeine Zeitung*. Zugriff am 7.12.2024. Verfügbar unter: <https://www.faz.net/aktuell/politik/ausland/gericht-ent->

scheidet-praesidentenwahl-in-rumaenien-muss-wiederholt-werden-110158684.html

Zuboff, S. (2019). Surveillance Capitalism – Überwachungskapitalismus – Essay. *Aus Politik und Zeitgeschichte*. Zugriff am 1.12.2024. Verfügbar unter: <https://www.bpb.de/shop/zeitschriften/apuz/292337/surveillance-capitalism-ueberwachungskapitalismus-essay>