

Design und künstliche Intelligenz

Design und künstliche Intelligenz

Theoretische und praktische Grundlagen der
Gestaltung mit maschinell lernenden Systemen

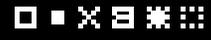
Marc Engenhardt

Sebastian Löwe

Birkhäuser
Basel

Für Kristin

Für Laura



Inhaltsverzeichnis

□	10	1. Künstliche Intelligenz als Designproblem – eine Einführung
<hr/>		
■	15	2. Grundfragen künstlich-intelligenter Systeme
<hr/>		
	16	2.1 Zur Notwendigkeit für Designer:innen, sich mit künstlicher Intelligenz zu befassen
	18	2.2 Aus Daten lernen
	20	2.3 Arten des Lernens und Problemlösens
	22	2.4 Arten der Prognose
	23	2.5 Einige wichtige Klassen des statistischen Lernens
	23	2.5.1 Lineare Regression
	25	2.5.2 Entscheidungsbäume
	27	2.5.3 Clustering und Ähnlichkeit
	30	2.5.4 Neuronale Netze
	30	Künstliche neuronale Netze
	38	Convolutional Neural Networks
	43	Recurrent Neural Networks
	45	Generative Adversarial Networks
	47	2.6 Prognosemaschinen – ein Zwischenfazit
	47	2.7 Die Frage der Intelligenz optimierender Systeme
	50	2.8 Zur Frage der (Un-)Voreingenommenheit und Ethik diskriminierender Systeme
	53	2.9 Eine Technologie für die Leistungs- und Wachstumsgesellschaft
	54	2.10 Konsequenzen für das Design
<hr/>		
✕	56	3. Gestaltung mit und für intelligente Systeme
<hr/>		
	57	3.1 Einleitung
	58	3.2 Gestaltung mit intelligenten Systemen: Ko-Kreation von Designer:in und Maschine
	60	3.2.1 Systeme für Strategie und Needfinding
	62	3.2.2 Systeme für Ideation und Inspiration
	64	3.2.3 Systeme für Suche und Generierung
	70	3.2.4 Systeme für Low-Fidelity-Prototyping
	75	3.2.5 Systeme für Designoptimierung und -automatisierung
	82	3.2.6 Resultate
	84	3.3 Gestaltung für intelligente Systeme: Intelligence Experience
	85	3.3.1 Vorhersage und Personalisierung als zentrale Eigenschaften von Intelligence Experience
	88	3.3.2 Intelligente User Interfaces
	94	3.3.3 Faktoren und Modi der Intelligence Experience
	96	3.3.4 Designprinzipien für Intelligence Experience
	108	3.3.5 Resultate
	109	3.4 Auswirkungen auf Gestaltung und Gestalter:innen
	109	3.4.1 Ein neues Verständnis von Kreativität, Autorschaft und Design in Zeiten intelligenter Gestaltung?
	113	3.4.2 Neue Herausforderungen und Fähigkeiten für Designer:innen
	118	3.4.3 Neue Bereiche in der Designausbildung
	119	3.4.4 Neue rechtliche und ethische Fragen
	121	3.4.5 Neue Wertschöpfung mit und Strategien für intelligente Produkte
<hr/>		
≡	124	4. Anwendungsfälle intelligenter Systeme im Designprozess
<hr/>		
	125	4.1 Einleitung
	127	4.2 Kommunikationsdesign: DHL Layout Creator von Strichpunkt
	133	4.3 Medienkunst: Neural Zoo und Artificial Remnants von Sofia Crespo
	141	4.4 Interface-Design: Einstein Designer von Salesforce
	149	4.5 Modedesign: Pangolin Dress von Anouk Wipprecht

- 154 4.6 Architectural Design: Spacemaker von Autodesk
 - 161 4.7 Interaktionsdesign: Archive Dreaming von Refik Anadol
-

168 **5. Mit intelligenten Systemen gestalten – ein praktischer Einstieg**

- 169 5.1 Einleitung
 - 170 5.2 Needs: Was Designer:innen tatsächlich möchten
 - 171 5.3 Storys: Erste Gedankenexperimente für intelligente Systeme
 - 172 5.4 Tools: Praktische Werkzeuge und ihre Anwendungsgebiete
 - 172 5.4.1 Tools 1: Experimentelle Werkzeuge
 - 173 5.4.2 Tools 2: Professionelle Werkzeuge und Stand-alone-Lösungen
 - 174 5.4.3 Tools 3: Anwendungen ohne Coding-Kenntnisse gestalten
 - 176 5.4.4 Tools 4: Intelligente Anwendungen selbst programmieren
 - 177 5.4.5 Tools 5: Intelligente Anwendungen interdisziplinär erarbeiten
 - 178 5.5 Floom: Ein visuelles, interaktives Innovation Framework für nutzer:innenzentriertes Machine Learning in interdisziplinären Teams
-

182 **Literaturverzeichnis**

201 **Abbildungsverzeichnis**

- 206 Danksagung
 - 207 Die Autoren
-

- 208 Impressum
-



1.
Künstliche Intelligenz als Designproblem –
eine Einführung

Wer noch vor einigen Jahren Bilder anschaute, die mit künstlicher Intelligenz, kurz KI, hergestellt wurden, sah selbst als ungeübte:r Betrachter:in sofort, dass es sich nicht um Fotografien handeln konnte. Man staunte zwar, dass solche Bilder überhaupt existierten, und malte sich aus, welche Art von informatischer Magie diese Artefakte hergestellt haben mag. Doch man war sich sicher, dass diese Bilder so schnell ihren eingezäunten Bereich der KI-Labore nicht verlassen und als Massenware niemanden täuschen oder schädigen werden.

Ihre Unschuld haben diese Bilder längst verloren. Unter dem Namen „Deep Fake“ sind sie zu einem kulturellen Massenphänomen geworden. Websites wie „This Person Does Not Exist“¹ erlauben auf Knopfdruck, Porträts von Menschen zu erzeugen, die es erstens nicht gibt und die zweitens mit dem bloßen Auge nicht mehr von einer Porträtfotografie zu unterscheiden sind. Adobes Photoshop bietet neuronale Filter, die es erlauben, porträtierte Menschen zum Lächeln zu bringen, auch wenn die Personen vorher auf den Bildern gar nicht gelächelt haben. Strafverfolgungsbehörden nutzen Deep Fakes, um Bilder pädophiler Straftaten zu generieren und Täter anzulocken.² Deep Fakes von Prominenten wie Bruce Willis werden erfolgreich in der Werbung eingesetzt. Dabei kommt nicht die aktuelle Version von Willis zum Einsatz, sondern der junge Bruce Willis.³ Deep Fakes werden aber auch in Filmdokumentationen eingesetzt, etwa um Menschen in Ländern zu schützen, wo sie wegen ihrer sexuellen Orientierung verfolgt werden. Ihre wahren Gesichter müssen dann nicht mehr verpixelt werden, sondern werden durch Deep Fake zu einem ganz anderen Gesicht.⁴ Schnell wird

deutlich, dass sich die Bilder durch KI von ihrem Original abgelöst haben und durch das rasante Tempo des Fortschritts der KI-Techniken selbstständig geworden sind.

Das Phänomen Deep Fake ist allerdings nur ein Beispiel aus einer Vielzahl von Technologien und Methoden, die sich hinter dem Schlagwort KI verbergen. Künstliche Intelligenz ist nicht nur auf Bilder beschränkt, sie erkennt auch Stimmen, Sprache, Töne, Gesten und Emotionen und kann diese entsprechend verarbeiten und selbst erschaffen. Seit einiger Zeit werden sogar Bilder durch Sprache generiert und KI, die zur Spracherkennung entwickelt wurde, erkennt Bildelemente. Künstliche Intelligenz kann zudem in riesigen Mengen von Daten Muster erkennen und so helfen, Kaufentscheidungen zu verstehen oder erfolgreiche Designfeatures auszumachen.

Für die Welt der Gestaltung und der Gestaltenden in ihr hat künstliche Intelligenz, wie man unschwer erkennen kann, weitreichende Konsequenzen. Wenn KI Einzug in die Designwerkzeuge erhält, werden zentrale Fragen für die Gestaltung aufgeworfen:

- Welche Wirkung hat KI auf das Design und den Designprozess?
- Wie verändert KI die Aufgabenbereiche und Arbeitsweisen von Designer:innen?
- Welche Möglichkeiten ergeben sich durch KI-Designwerkzeuge?
- Wie sind diese Werkzeuge in den Gestaltungsprozess eingebunden?
- Entstehen durch KI neue Gestaltungsmethoden und -prozesse?

1 This Person Does Not Exist: „Random Face Generator“, <https://this-person-does-not-exist.com/en> (19.4.2022).

2 Truscheit, Karin: „Durch Tauschen zum Täter“, *Frankfurter Allgemeine Zeitung*, 8.3.2021, S. 7.

3 Foster, George: „That’s Not Bruce Willis In A Russian Phone Commercial, That’s Another Deepfake“, <https://www.thegamer.com/bruce-willis-deepfake> (20.4.2022).

4 Rothkopf, Joshua: „Deepfake Technology Enters the Documentary World“, <https://www.nytimes.com/2020/07/01/movies/deepfakes-documentary-welcome-to-chechnya.html> (20.4.2022).

Neben diesen unmittelbar designspezifischen Fragen werden aber auch ethische und rechtliche Fragen aufgeworfen, etwa:

- Wem gehören die Bilder?
- Welche ethischen Implikationen hat KI?

Nicht nur wird KI in den Gestaltungswerkzeugen selbst verwendet, sie wird auch in digitalen Produkten eingebaut, die Designer:innen konzipieren und umsetzen. Designer:innen nutzen hier KI als Designmaterial und gestalten neue „User Experiences“ für intelligente Produkte und Medien. Hier stellen sich Fragen, wie:

- Wie verändert KI das Erlebnis digitaler Produkte?
- Welche Möglichkeiten ergeben sich durch KI für die Nutzenden?
- Welche Prinzipien guter Gestaltung ergeben sich daraus?

Auch an diese inhärent designerischen Fragen schließt die zentrale ethische Frage an:

- Wie schütze ich Nutzer:innen vor einer diskriminierenden KI?

Auf der Ebene der Designstrategie stellen sich zentrale Fragen, wie:

- Welche neuen Geschäftsmodelle ergeben sich mit KI?
- Wie schafft KI Differenzierung im Markt?
- Welche Folgen hat KI für das Markenerlebnis?
- Wie strukturiert und steuert man Innovationsprozesse für KI-basierte Produkte?

Abschließend hat künstliche Intelligenz auch Wirkungen auf die Design- und Kreativitätstheorie sowie

auf das Rollenverständnis der Designer:innen. Hier sind folgende Fragen zentral:

- Wie verändert sich das Verständnis von Kreativität und Gestaltung durch KI?
- Welche neuen Fähigkeiten brauchen Designer:innen im Umgang mit KI?

Obwohl künstliche Intelligenz kein neues Phänomen und bereits weitreichend in digitale Produkte integriert ist, sind die meisten der oben aufgeworfenen Fragen noch keinesfalls beantwortet. In vielen Fällen fehlt überhaupt eine belastbare Basis der akademischen Auseinandersetzung mit der KI-Technologie in der Gestaltung. Die Fragen des Designs mit KI sind überraschenderweise also weder systematisch beantwortet noch in eine theoretische Ordnung überführt oder aus der Sicht des Designs umfassend wissenschaftlich diskutiert und ausgewertet. Im Ganzen sind die meisten der oben aufgeworfenen Fragen noch ein Desiderat der Designforschung und ihre systematische Beantwortung ein erstes wichtiges Anliegen des hier vorliegenden Buches.

Da künstliche Intelligenz als universale Technologie ein inhärent interdisziplinäres Phänomen ist, ist es auch nicht nur auf eine Disziplin beschränkt. Vielmehr entstanden viele wichtige Beiträge in Disziplinen, die an das Design angrenzen, wie etwa der Human-Computer-Interaction-Forschung, die eher dem Bereich der Informatik zugeordnet wird. Einige aus Gestaltungssicht relevante akademische Beiträge stammen auch aus der Psychologie oder den Ingenieurwissenschaften. Hier sind die Disziplinengrenzen oft ein Hindernis für eine informierte Debatte und Schnittstellenwissen wäre von zentraler Bedeutung. Ziel des Buches ist es daher genauso, die vielen Stränge und Wissensstände aus den unterschiedlichsten Disziplinen zusammenzuführen und für Gestalter:in-

nen in verständlicher Weise zugänglich zu machen. Dazu soll zunächst einmal – in Kapitel 2 – geklärt werden, was sich hinter der Chiffre künstliche Intelligenz überhaupt verbirgt, wieso KI-Technologie auf so große Mengen von Daten angewiesen ist und um welche Art von Intelligenz es sich bei KI überhaupt handelt. Es sollen zentrale Verfahren der KI vorgestellt werden, welche Probleme sie lösen und welche Anwendungsgebiete, aber auch welche ethischen, ökonomischen und designerischen Implikationen sich daraus ergeben.

Im dritten Kapitel wird systematisch erklärt, welche Auswirkung KI auf den Gestaltungsprozess hat und wie KI-Werkzeuge in den Designprozess integriert sind. Das Buch macht zum ersten Mal in der deutschsprachigen Designforschung den Versuch, anhand von fünf Systemebenen ein kohärentes Ordnungsprinzip der KI-Technologie für das Design abzuleiten. Ergänzt wird das Kapitel durch die systematische Untersuchung der KI als Designmaterial für digitale Produkte und Produkterlebnisse. Untersucht wird die für KI zentrale Anpassung an Nutzer:innenwünsche durch Personalisierung, von der aus dann Prinzipien guter Gestaltung mit KI entwickelt werden. Das Kapitel schließt mit einer Diskussion darüber, wie sich das Designverständnis und die Fähigkeiten von Designer:innen durch KI erweitern müssen, aber auch wie sich designstrategische Überlegungen anpassen müssen.

Im vierten Kapitel illustriert das Buch anhand einschlägiger Fallbeispiele in ausgesuchten Designdisziplinen, wie KI-Werkzeuge eingesetzt werden können, sodass eine gelungene Gestaltung und ein gutes Designerlebnis daraus resultieren. Insgesamt sechs Designer:innen, Designagenturen und -studios sowie Beratungsunternehmen geben Einblicke in ihre Arbeitsschritte und die Überlegungen, die letztlich zu ihrem intelligenten Design führten.

Auch die Fragen, wie man als Designer:in die neuen KI-Werkzeuge praktisch nutzt und neue KI-Anwendungen im Team generiert, beantwortet das Buch. Im abschließenden fünften Kapitel möchte das Buch praktische Hilfestellungen für Designer:innen leisten und zeigen, wie ein leichter Einstieg in die Arbeit mit KI-Werkzeugen gelingen kann. Für den Unternehmens- und Beratungskontext stellt das Buch erstmals ein umfängliches visuelles interaktives Innovation Framework vor, mit dem Designer:innen im Team KI-Produkte entwickeln können.

Obwohl sich das Buch als Grundlagenwerk versteht, kann es unmöglich alle Aspekte der KI-Technologie oder der Gestaltung mit und für KI abdecken. Die Einführung in die Grundlagen der KI setzt ausgewählte Schwerpunkte auf solche Verfahren, die die Prinzipien der Technologie am schlüssigsten illustrieren und häufig verwendet werden. Es ist nicht Absicht des Buches, sich grundlegend mathematisch oder informatisch mit dem Thema auseinanderzusetzen. Dafür sind bereits viele Grundlagenwerke zum Thema KI erschienen. Das Buch soll vielmehr einerseits KI-Schnittstellenwissen für Designer:innen erarbeiten. Zum anderen fokussiert es vor allem auf die visuelle Gestaltung. Der große Bereich der Spracherkennung und -verarbeitung und ihre Anwendung in den Sprachassistenten soll hier nur am Rande behandelt werden und nur dort, wo sie für visuelle Gestaltung relevant ist.

Die Publikation ist eine Einführung in das Thema Design und künstliche Intelligenz und richtet sich vornehmlich an Theoretiker:innen und Praktiker:innen aus den Bereichen Design, Designmanagement und angrenzenden Gebieten, wie der Human-Computer-Interaction, der Medienkunst oder dem Projektmanagement. Es wurde bewusst darauf geachtet, dass auf keine spezifische Designdisziplin fokussiert wird

und die meisten Bereiche, in denen Designer:innen heute arbeiten, gleichberechtigt repräsentiert sind. Das Buch ist aber sicher auch für Leser:innen interessant, die nicht im Design arbeiten, sich aber dennoch zu Grundfragen der Gestaltung mit dieser schillernden Technologie ein erstes umfassendes Bild machen möchten.



2. Grundfragen künstlich-intelligenter Systeme

Um die Wirkung und das Potenzial künstlicher Intelligenz ranken sich viele eher überzogene Vorstellungen. So trifft man häufiger auf die Überzeugung, dass KI als Vorstufe einer umfassenden, menschengleichen Intelligenz zu begreifen wäre. Ebenfalls wird häufig wiederholt, dass Designer:innen bald durch intelligente Maschinen ersetzt werden. Solche Ansichten gehen am Wesen der künstlichen Intelligenz vorbei. Gemeinhin werden unter dem Begriff „künstliche Intelligenz“ Verfahren der Informatik gefasst, die in der Lage sind, für bestimmte eingegrenzte Problembereiche selbstständig Lösungen zu generieren. Es sind computergestützte Verfahren, die das Moment der Optimierung ihrer Ergebnisse von Grund auf eingebaut haben, denn sie lernen, ihre eigenen Fehler zu korrigieren. Weil diese Verfahren entfernt an menschliche Intelligenz erinnern, nutzt man den Begriff „künstliche Intelligenz“. Allerdings ist der Begriff fragwürdig, denn er betont zu stark die wenig vorhandenen Gemeinsamkeiten mit menschlicher Intelligenz. Prüft man genauer, was die Technologien tatsächlich vermögen, die als intelligent gefasst werden, merkt man schnell, dass sie mit einer menschlichen Intelligenz noch sehr wenig teilen.

Das folgende Kapitel soll klären, was eigentlich das Intelligente an künstlich-intelligenten Systemen ist oder mit anderen Worten, wie intelligente Systeme lernen. Der Oberbegriff für alle Verfahren der künstlichen Intelligenz und des maschinellen Lernens in diesem Kapitel ist das statistische Lernen. Das Kapitel hat zum Ziel, zentrale Verfahren des statistischen Lernens zu erklären, ohne informatische oder mathematische Kenntnisse vorauszusetzen. Gezeigt werden soll, worin das Moment des Lernens besteht und welche Konsequenzen es für die Lösung welcher Probleme hat. Damit soll der Grundstein für ein besseres Verständnis darüber gelegt werden, wie diese

Verfahren im Designprozess als intelligente Werkzeuge und in den Designanwendungen als Designmaterial verwendet werden. Abschließend reflektiert das Kapitel kritisch die ethischen und ökonomischen Implikationen des statistischen Lernens.

Zunächst soll jedoch die Frage beantwortet werden, wieso sich Designer:innen überhaupt mit Verfahren statistischen Lernens auseinandersetzen sollten.

2.1 Zur Notwendigkeit für Designer:innen, sich mit künstlicher Intelligenz zu befassen

Design nutzt immer Gestaltungswerkzeuge, egal ob sie Jahrtausende alt sind oder erst kürzlich entwickelt wurden. Diese Werkzeuge helfen nicht nur, Gestaltung dem Zweck ihrer Nutzung gemäß zu planen und zu implementieren. Sie sind auch Mittel, um schneller, effektiver und präziser zu gestalten. Es ist kein Geheimnis, dass digitale Werkzeuge ihren analogen Gegenständen in puncto Verarbeitung und Anwendung vielfach überlegen sind. Oft sind Stift und Papier gute Werkzeuge für Ideenfindung und Prototyping, aber wenn es um die Umsetzung geht, müssen gestalterische Werkzeuge mittlerweile komplexe Aufgaben bewältigen können, die nur digitale Systeme zufriedenstellend ausführen.

Digitale Werkzeuge, darin unterscheiden sie sich nicht von den analogen, haben ihre je eigenen Notwendigkeiten, Funktionsweisen, Potenziale und Grenzen. Die intelligenten Gestaltungswerkzeuge sind in dieser Hinsicht keine Ausnahme. So arbeiten intelligente Systeme nur in ihrem jeweils definierten Bereich und das auch nur, wenn sie eine genügend gute Basis haben.

In einer anderen Hinsicht jedoch sind intelligente Werkzeuge tatsächlich von allen anderen zu unterscheiden. Mit statistischen Lernverfahren ist es möglich, auf der Grundlage von mehr oder weniger genauen *Vorhersagen* zu gestalten, sowohl was die digitalen Erlebnisse von Nutzer:innen angeht als auch die Mittel der Gestaltung. Damit ändert sich die Qualität der Werkzeuge für Gestaltung ein ganzes Stück weit und schafft neue, kreativere oder effektivere Möglichkeiten zu gestalten. Für Designer:innen bedeutet dies, dass sie ohne ein grundlegendes Verständnis der Funktionsweise von statistischem Lernen in Zukunft nicht mehr die vollen Potenziale von Gestaltungswerkzeugen werden ausschöpfen können. Wenn sie die Logik und Funktionsweise ihrer Werkzeuge nicht verstehen, können sie sie schlicht nicht effektiv einsetzen.

Aber nicht nur die Technologie hat sich in den letzten Jahren rasant fortentwickelt. Auch die Arbeitsbereiche der Designer:innen haben sich immer mehr erweitert. Gestalter:innen sind heute nicht mehr nur die Schönheitsbeauftragten, die fertige Produkte aufhübschen, sondern mittlerweile in agile Innovations- und Produktentwicklungsprozesse von Beginn an einbezogen. Sie forschen dort an nutzer:innenzentrierten Lösungen für tatsächlich vorhandene Bedürfnisse. Dabei fällt ihnen die Aufgabe zu, solche Bedürfnisse mittels technologischer Möglichkeiten in komplexe digitale Lösungen und User Experiences zu überführen. Mit intelligenten Systemen ändern sich auch Nutzer:innenerfahrungen grundlegend, denn sie können Präferenzen, Vorlieben und Handlungen von Nutzer:innen antizipieren und das Produkt daran anpassen. Um diese Erfahrungen mit intelligenten Produkten bestmöglich gestalten zu können, benötigen Designer:innen ein grundlegendes Verständnis von der Wirkungsweise und den Anwen-

dungsmöglichkeiten zentraler Verfahren statistischen Lernens. Neben den Bedürfnissen der Nutzenden müssen sie nun auch die Datenbedürfnisse der intelligenten Systeme kennen.

Vielfach sind Gestalter:innen heute in interdisziplinäre Entwicklungsteams eingebunden. Mit Data Scientists oder Developer:innen in interdisziplinären Teams zusammenzuarbeiten, ohne ein Verständnis des gemeinsamen Gegenstandes zu haben, ist schwierig und unproduktiv. Gerade in Teams, die keinen homogenen fachlichen Background besitzen, ist es für Gestaltende wichtig, ein Grundverständnis zu entwickeln, wie intelligente Systeme funktionieren, um sich mit Kolleg:innen austauschen und gemeinsam neue Ideen entwickeln und umsetzen zu können. Wie gut Innovationspotenziale ausgeschöpft werden, ist daher auch eine Frage des gelingenden Austauschs zwischen den Teammitgliedern.

In einigen Firmen haben es sich Designer:innen daher zur Aufgabe gemacht, eine gestalterische Grundlage für die gemeinsame Arbeit zu schaffen. Bei Airbnb haben Designer:innen und Designmanager:innen beispielsweise ein Framework mit dem Namen „Invisible Design“ entwickelt, das ihnen ermöglicht, eine gemeinsame Verständigung mit Data Scientists und Entwickler:innen herzustellen, indem sie die Wirkungsweise eines für Airbnb zentralen Verfahrens statistischen Lernens, die lineare Regression, visualisierten.⁵ In dem interdisziplinären Entwicklungsteam wurde ein gemeinsames Verständnis entwickelt, wie lineare Regression funktioniert, indem man die mathematische Formel, die den Designer:innen nicht zugänglich war, grafisch übertrug. So wurde die Wirkungsweise des Lernverfahrens visuell verdeutlicht. Dies wiederum lieferte dann die gemeinsame Grundlage, um erfolgreich Services, wie

⁵ Cartwright, Amber: „Invisible Design: Co-designing with machines“, <https://medium.com/swlh/invisible-design-co-designing-with-machines-aea62a1e0f6d> (20.4.2022).

die automatische Preisempfehlung für Airbnb-Gastgeber:innen umzusetzen. Gestaltende verantworten nicht mehr nur Nutzer:innenerlebnisse, sie spielen auch eine zentrale Rolle dabei, die technologische Grundlage dieser Erlebnisse zu kommunizieren und in eine User Experience zu übersetzen.

Alle hier angesprochenen Aspekte müssen Designer:innen, die mit intelligenten Systemen gestalten, nachvollziehen und beherrschen, um zu nützlichen Lösungen zu gelangen. Gestalter:innen sollten deshalb eine grundlegende Vorstellung haben, was zentrale Verfahren statistischen Lernens sind, was sie für die Nutzer:innen leisten können und worin ihre wesentlichen Unterschiede und Anwendungsgebiete bestehen.

Allen Anwendungen statistischen Lernens ist ein Moment wesentlich zu eigen: Einem Nutzer:innenbedürfnis kann nur so gut gedient werden, wie es die Funktionsweise des Lernverfahrens erlaubt. Dessen Qualität der Vorhersagen ist entscheidend abhängig von den Trainingsdaten. Damit wird eine zentrale Frage aufgeworfen: Was bedeutet es eigentlich, wenn ein Algorithmus aus Daten lernen kann, und wieso sind Daten so wichtig für statistisches Lernen?

2.2 Aus Daten lernen

Alle Problemlösungen, die den Computer als Hilfsmittel verwenden, benötigen konkrete Handlungsanweisungen, sogenannte Algorithmen. Diese Algorithmen sind für Computer verständlich formulierte, zeitlich begrenzte Schritte, die er nacheinander abarbeiten muss, um ein bestimmtes Problem zu lösen. Algorithmen bekommen bestimmte Daten als Eingabedaten vorgegeben und liefern dann durch ihre Ausführung bestimmte Ausgabedaten; das nennt

man fest kodierte, regelbasierte Programmierung. Beispielsweise bekommt ein Sortierungsalgorithmus eine unsortierte Liste von Zahlen. Er prüft dann, ob die Eingabedaten überhaupt eine Liste von Zahlen sind, schaut jede Zahl in der Liste an, vergleicht sie mit der vorhergehenden und ändert dann auf Basis dieses Vergleichs die Platzierung dieser Zahl in der Liste. Sind alle Schritte der Handlungsanweisung ausgeführt, sind also alle Zahlen einmal angeschaut und platziert worden, ist der Algorithmus fertig und die Nutzenden erhalten eine fertig sortierte Liste. Egal welche Zahlen das Programm bekommt und wie viele es sind, es führt immer nur das aus, was vorher als seine Handlungsanweisung eindeutig definiert wurde, es sortiert immer nur Zahlen.

Nun sind aber manche Probleme mit solchen vordefinierten Handlungsanweisungen nicht lösbar, auch nicht mit sehr detailliert beschriebenen Handlungsschritten. So etwas wie die Prognose, ob eine bestimmte Kundin ein bestimmtes Produkt kaufen wird, scheitert daran, dass es schlicht zu viele Möglichkeiten gibt, die ein Algorithmus zu beachten hätte. Programmierer:innen müssten alle möglichen Kaufentscheidungen und vor allem deren jeweilige psychologische, ökonomische, soziale und ästhetische Faktoren kennen, um sie in eine funktionale Handlungsanweisung zu überführen. Es ist schlicht unmöglich, in der Logik einzeln definierter Regeln dieses Verhalten für viele Millionen Kund:innen abzubilden; abgesehen davon, dass das auch viel zu teuer wäre. Das Prinzip der fest kodierten, regelbasierten Programmierung scheitert hier.

Trotzdem können manche Algorithmen solche Kaufentscheidungen recht gut bestimmen. Nicht indem sie jeden Schritt streng vordefiniert bekommen, sondern indem man sie ermächtigt, aus Millionen

von Einzeldaten logische Schlüsse zu ziehen. Dieses Vorgehen ist der Kern des statistischen Lernens. Es umfasst Verfahren, die aus einer großen Menge von Daten lernen, ob und wie ein bestimmter statistischer Zusammenhang in ihnen vorhanden ist. Verfahren des statistischen Lernens können aber auch ganz und gar selbstständig aus den Daten statistische Muster ermitteln, die dem Menschen gar nicht zugänglich sind, und ihre Vorgehensweise darauf anpassen.⁶

Voraussetzung und Grundlage dieser Lernprozesse sind große Mengen an Daten, weshalb man dieses Phänomen auch Big Data getauft hat. Der selbstlernende Algorithmus hat im Unterschied zu vorher streng definierten Handlungsanweisungen einstellbare Parameter, die er im Laufe seines Lernprozesses anpasst, indem er sie optimiert.⁷ Lernenden Algorithmen gibt man also ein *Optimierungsproblem*, das sie mittels ihres Aufbaus und der verfügbaren Daten sukzessive lösen können. Wie das im Einzelnen geschieht, welche Arten und Strategien des Optimierens es gibt, ist Gegenstand der folgenden Unterkapitel.

Grundsätzlich hat man es also beim statistischen Lernen mit Verfahren zu tun, die durch sukzessives Training und fortlaufende Optimierung besser werden. Dabei ist erstens wesentlich, dass sie aus den vielen einzelnen Daten einen statistisch signifikanten, also allgemeinen Zusammenhang erschließen können. Mit anderen Worten: dass sie in der Lage sind zu generalisieren, also von vielen konkreten Daten auf ein übergeordnetes, in den Daten verborgenes Wirkungsverhältnis oder Prinzip zu schließen.⁸ Man nennt diese Algorithmen auch Modelle, weil sie ein Abbild der Wirklichkeit geben in Form von aus Daten gelernten Annäherungen.

Die Algorithmen sind nun zweitens in der Lage, nur auf der Basis des gelernten Prinzips neue, unbekannte Daten mit hoher Wahrscheinlichkeit richtig zu bestimmen. Manchmal müssen Anwender:innen diese Prinzipien und Zusammenhänge noch nicht einmal vollständig verstehen und die Algorithmen decken diese Prinzipien selbstständig auf. Das macht diese Arten von Algorithmen so wirkungsvoll und attraktiv. All das hat nichts mit Magie oder einer quasimenschlichen Fähigkeit zu tun, sondern vielmehr mit informatischen Strategien der Optimierung.

Ein Anwendungsbeispiel soll dies erhellen: So möchte Airbnb den optimalen Übernachtungspreis kennen, den ein Apartment zu einem bestimmten Zeitpunkt an einem bestimmten Ort und mit bestimmter Ausstattung erzielen kann. Kennt das Unternehmen diesen Preis, hat das enorme Auswirkungen auf die User Experience von Airbnb. Vermieter:innen müssen nicht mehr Preise intuitiv bestimmen und Mieter:innen bekommen immer den für sie besten Preis. Gesucht ist also ein Preis, der das Maximum für die Vermieter:innen herausholt, ohne für potenzielle Gäste zu teuer zu werden. Airbnb nutzt lineare Regression⁹, um den idealen Preis zu ermitteln. Da es einen linearen Zusammenhang gibt zwischen dem Ort des Apartments, seiner Verkehrsanbindung und Ausstattung sowie dem Preis, kann man mit dem Verfahren diesen Zusammenhang erlernen. Hat der Algorithmus, der das Verfahren nutzt, diesen Zusammenhang erst einmal ermittelt, kann er ohne Probleme für das kommende Wochenende den optimalen Preis für ein Apartment vorhersagen. Den Preis kann Airbnb dann seinen Gastgeber:innen als Optimum für jedes einzelne Apartment vorschlagen und so die Bedürfnisse von Nutzer:in und Gastgeber:in befriedigen.

6 Alpaydin, Ethem: *Machine Learning*, Cambridge: MIT Press 2016, S. 16.

7 Alpaydin: *Machine Learning*, S. 24.

8 Daumé, Hal: *A Course in Machine Learning*, Eigenpublikation 2017, S. 9, <http://ciml.info> (20.4.2022).

9 Im Kapitel „Lineare Regression“ wird die Funktionsweise des Verfahrens genauer erklärt. An dieser Stelle reicht der Gedanke, dass dieses Verfahren einen linearen Zusammenhang zwischen Preis und Wohnungseigenschaften erkennt.

Die Preisermittlung behält immer die Qualität einer Prognose, weil sie eine statistische Annäherung an die Wirklichkeit ist; sie bleibt also Spekulation, wenn auch statistisch abgesicherte Spekulation. Man kann schon an dieser Stelle festhalten, dass Verfahren statistischen Lernens informierte Spekulation betreiben, die auf vorher gelernten Zusammenhängen basiert. Diese Verfahren antizipieren damit ein Stück weit zukünftige Wirklichkeit. Dass diese Natur der informierten Spekulation interessante Auswirkungen auf die Gestaltung hat, wird sich im Weiteren zeigen.

2.3 Arten des Lernens und Problemlösens

Zunächst kann man lernfähige Algorithmen anhand der drei Strategien unterscheiden, mit und durch die sie lernen und Probleme lösen. Das ist erstens das sogenannte *Supervised Learning*, zweitens das *Unsupervised Learning* und drittens das *Reinforcement Learning*.

Am weitesten verbreitet ist derzeit *Supervised Learning*, das man mit „beaufsichtigtes Lernen“ oder „überwachtes Lernen“ übersetzen kann. Die Überwachung besteht darin, Modelle mit Daten zu trainieren, deren korrektes Ergebnis vor dem Lernprozess bereits bekannt ist. Beispielsweise kann so ein Modell trainiert werden, dass es Hunde- von Katzenbildern unterscheiden kann. Die Trainingsdaten hierfür sind Bilder, die jeweils individuell als Hunde- oder Katzenbilder gekennzeichnet sind. Zu jedem Bild ist also die Angabe hinterlegt, ob es sich um ein Bild von einem Hund oder einer Katze handelt. Dies nennt man in der Fachsprache Label. In der überwachten Lernphase gleicht der Algorithmus seine aktuelle Prognose mit dem Label ab und erfährt, ob er bereits richtig liegt oder weiter optimieren muss. Das Modell gleicht also immer wieder zwischen seinem jeweils

prognostizierten und dem korrekten Ergebnis ab und lernt anhand des Labels, wie es optimieren muss. So klassifiziert beispielsweise der Bilderkennungsalgorithmus in den ersten Optimierungsdurchläufen das Foto einer Katze noch als Hund, weil er die wesentlichen Unterschiede noch nicht erkannt und auf sie hin optimiert hat. Er bekommt beim überwachten Lernen nach jedem Durchlauf das Feedback anhand des Labels, ob seine bisherige Klassifikation stimmt oder nicht, denn mit dem Label ist eindeutig vermerkt, ob es sich um eine Katze oder einen Hund handelt. Solange der Algorithmus Fehler macht, ist klar, dass er weiter optimieren muss; so lange, bis er das Ergebnis richtig prognostiziert. Ist der Bilderkennungsalgorithmus, der zwischen Hunden und Katzen unterscheiden kann, fertig trainiert, kann er auch unbekannte – also nicht gelabelte – Daten richtig bestimmen. Dies ist das Ziel des Trainings, denn man möchte einen Algorithmus, der ungelabelte Daten richtig klassifiziert. Ein typisches Verfahren für überwachtes Lernen ist das künstliche neuronale Netz, das später ausführlicher erklärt wird.

Beim *Unsupervised Learning*, dem unbeaufsichtigten oder nicht überwachten Lernen ist das Modell in der Lage, ohne Rückbezug auf ein Label innerhalb einer Menge von Daten Zusammenhänge selbstständig auszumachen. So wird beispielsweise bei der Warenkorbanalyse das Einkaufsverhalten vieler Tausend Supermarktkund:innen ausgewertet und ermittelt, welche Einkäufe häufig zusammen getätigt werden. Mit dem unüberwachten Lernen können statistische Zusammenhänge in Daten ausfindig gemacht werden, die vorher unbekannt oder wegen der zu großen Datenmenge für menschliche Wahrnehmung nicht auffindbar waren. Mit der Warenkorbanalyse hat man beispielsweise herausgefunden, dass Kund:innen, die Milch und Käse kaufen, mit 70-prozentiger Wahr-

scheinlichkeit auch gleich noch Brot kaufen.¹⁰ Mit diesem Wissen kann das Management des Supermarkts dann Schlüsse auf den Grundriss des Marktes ziehen, den Architekt:innen, Planer:innen oder Interiordesigner:innen dann umsetzen. Legt man die Milchprodukte näher an die Bäckerei, schafft man Bequemlichkeit für die Kundschaft. Legt man sie weiter auseinander, garantiert man, dass Kund:innen an anderen Produkten vorbeigehen, und erhöht damit Impulskäufe. Verfahren für unüberwachtes Lernen sind die später ausgeführten Entscheidungsäume und das Clustering.

Zwischen Supervised und Unsupervised Learning bestehen Mischformen, die unter dem Begriff Semi-supervised Learning zusammengefasst werden. Eines der wichtigsten Verfahren, die in diese Kategorie fallen, ist das *Self-supervised Learning*.¹¹ Denn mit diesem Verfahren kann einer der großen Nachteile von Supervised Learning behoben werden, und zwar die großen Mengen an gelabelten Daten, die benötigt werden. Das Verfahren heißt selbstüberwacht, weil es die Signale für das unüberwachte Lernen selbstständig ermittelt. Damit ist dieses Verfahren eine Art Vortraining auf Basis eines Unsupervised Learnings, das subtile Muster in großen Datenmengen selbstständig erkennt und als Hinweis für das weitere überwachte Lernen versteht. In der überwachten Lernphase lernt ein System dann anhand von nur wenigen Daten die relevanten Zusammenhänge und kann somit auch aus kleinen Datenmengen erfolgreich Prinzipien ableiten. Anwendungsgebiete hierfür sind beispielsweise Algorithmen, die Schwarz-Weiß-Bilder kolorieren oder fehlerhafte Bilder retuschieren können.

Die letzte Gruppe der Lernverfahren, die hier beleuchtet werden soll, ist das *Reinforcement Learning* oder bestärkende Lernen. Bei diesem Verfahren werden keine richtigen Lösungen vorgegeben, sondern Lösungswege honoriert, indem es einen Score für richtige Lösungen gibt. Einzelne Schritte auf dem Weg zur richtigen Lösung werden belohnt oder bestraft und ergeben dann den Gesamtscore. Der Algorithmus lernt also, welche Handlungen stärker belohnt werden, und optimiert dadurch sein Verhalten. Beispielsweise kann ein Staubsaugerroboter die Aufgabe bekommen, den optimalen, das heißt schnellsten Weg durch eine Wohnung zu finden, um alle Räume zu reinigen. Der Algorithmus, der den Roboter steuert, arbeitet mit Reinforcement Learning, das sowohl den aktuellen Status des Roboters kennt, in diesem Fall den Raum, in dem sich der Roboter befindet, als auch mögliche Aktionen, die er ausführen kann. In diesem Fall soll der Algorithmus nur entscheiden, wie er am schnellsten durch die gesamte Wohnung gelangt; alle anderen Reinigungsaktionen automatisiert ein anderer Algorithmus. Manche der möglichen Aktionen sind nachteilig, weil der Roboter in Räume gelangt, die er schon gesaugt hat oder die ihn auf einen Umweg führen. Andere Aktionen sind vorteilhaft, weil sie schneller zum Ziel, einer sauberen Wohnung, führen. Mit dem Reinforcement Learning wird ohne Vorwissen gelernt, welche der je nach Status verschiedenen Aktionen vorteilhaft ist und welche nachteilhaft. Jede einzelne Aktion wird zunächst mit einem vorläufigen Score versehen. Je höher der Score, umso besser ist die Aktion und umso höher ist der Gesamtscore am Ende des Lerndurchgangs.¹² Auf diese Weise findet der Roboter nach dem Training den besten Weg zum Staubsaugen.

10 Bramer, Max: *Principles of Data Mining*, London: Springer-Verlag 2016, S. 8.

11 LeCun, Yann/Misra, Ishan: „Self-supervised learning: The dark matter of intelligence“, <https://ai.facebook.com/blog/self-supervised-learning-the-dark-matter-of-intelligence> (9.2.2022).

12 Breuer, Klaus: *Computerspiele programmieren. Künstliche Intelligenz für künstliche Gehirne*, München: Oldenbourg 2012, S. 85.