



University of Applied Sciences

APOLLON Hochschule
der Gesundheitswirtschaft

Big Data, Digitale Medizin und Smart Healthcare

DIGEH03



Das Studienheft und seine Teile sind urheberrechtlich geschützt. Jede Nutzung in anderen als den gesetzlich zugelassenen Fällen ist nicht erlaubt und bedarf der vorherigen schriftlichen Zustimmung des Rechteinhabers. Dies gilt insbesondere für das öffentliche Zugänglichmachen via Internet, die Vervielfältigung und Weitergabe. Zulässig ist das Speichern (und Ausdrucken) des Studienhefts für persönliche Zwecke.

Kurt Becker
Felix Hoffmann
Kirsten Libera
Harald H.H.W. Schmidt

Big Data, Digitale Medizin und Smart Healthcare

DIGEH03



Prof. Dr. med. Felix Hoffmann

Nach der Ausbildung zum Chemielaboranten studierte Felix Hoffmann von 2004 bis 2010 Medizin an der Heinrich-Heine-Universität in Düsseldorf. Es folgten die Weiterbildung zum Facharzt für Orthopädie und Unfallchirurgie und zum Notfallmediziner. Berufsbegleitend absolvierte Felix Hoffmann die Studiengänge Master of Health Management (MaHM) an der APOLLON Hochschule in Bremen, Medizinrecht (LL. M.) an der Westfälischen Wilhelms-Universität in Münster und eHealth and Communication (M. Sc.) an der Friedrich-Schiller-Universität Jena. Nach abgeschlossener Facharztweiterbildung folgten Tätigkeiten als Oberarzt und im Management verschiedener Krankenhäuser. Felix Hoffmann ist Professor für Digital Health an der APOLLON Hochschule Bremen.



Prof. Dr.-Ing. Kurt Becker

(geb. 1964) lehrt hauptberuflich als Professor und Studiengangsleiter für Gesundheitstechnologie-Management an der APOLLON Hochschule. Nebenberuflich ist er Gesellschafter/Geschäftsführer der preventionpartners GmbH in Aachen.

Er studierte Elektrotechnik und technische Informatik an der RWTH Aachen. Anschließend arbeitete er als wissenschaftlicher Mitarbeiter im Bereich der Medizintechnik und der medizinischen Informatik am Universitätsklinikum Aachen. 1996 promovierte er am Helmholtz-Institut für biomedizinische Technik über wissenschaftsbasierte Entscheidungsunterstützung in der Medizin.

Anschließend arbeitete er in leitenden Positionen in der Gesundheitswirtschaft, u. a. als Gesellschafter/Geschäftsführer von Beratungsunternehmen und Vorstand einer Aktiengesellschaft, bis er zunächst nebenberuflich einem Ruf an die Hochschule Niederrhein in Krefeld als Lehrbeauftragter für Gesundheitstelematik (Medizinische Informationstechnik) folgte. 2008 übernahm er an der APOLLON Hochschule die fachliche und inhaltliche Verantwortung für das Fach Gesundheitstechnologie. 2010 wurde er zum Professor für IT-Management in der Gesundheitswirtschaft berufen. Seit 2012 ist er Studiengangsleiter für den Studiengang „Medizin- und Gesundheitstechnologie-Management (B.A.)“ und seit 2020 Vizepräsident „Forschung“ an der APOLLON Hochschule.

Ehrenamtliche Tätigkeiten übt er als Vorsitzender der Landesvertretung NRW und Mitglied des erweiterten Vorstands des Berufsverbands Medizinischer Informatiker (BVMI), als stellvertretender Leiter der Arbeitsgruppe Medizinmanagement der Deutschen Gesellschaft für Medizinische Informatik, Biometrie und Epidemiologie e.V. (GMDS), als Ko-Sprecher des Fachausschusses Geschäftsmodelle intelligenter Assistenzsysteme (FA GIAS), als Beirat der Deutschen Gesellschaft für biomedizinische Technik (DGBMT) im Verband Elektrotechnik Elektronik Informationstechnik e.V. (VDE), als Geschäftsführer der Yoga Vidya Center Aachen UG und als Mitglied im Institute of Electrical and Electronics Engineers (IEEE) aus.

Die in unseren Studienheften verwendeten Personenbezeichnungen schließen ausdrücklich alle Geschlechtsidentitäten ein. Wir distanzieren uns ausdrücklich von jeglicher Diskriminierung hinsichtlich der geschlechtlichen Identität.

Falls wir in unseren Studienheften auf Seiten im Internet verweisen, haben wir diese nach sorgfältigen Erwägungen ausgewählt. Auf die zukünftige Gestaltung und den Inhalt der Seiten haben wir jedoch keinen Einfluss. Wir distanzieren uns daher ausdrücklich von diesen Seiten, soweit darin rechtswidrige, insbesondere jugendgefährdende oder verfassungsfeindliche Inhalte zutage treten sollten.

Überarbeitet von



Kirsten Libera

Nach dem Abitur studierte Kirsten Libera von 2007 bis 2010 an der Hochschule Fresenius den Studiengang „Health Care Management“. Hier wurde ihr Interesse für den Bereich der medizinischen Informatik geweckt, sodass sie von 2010 bis 2014 Informatik mit Anwendungsfach Medizin an der RWTH Aachen studierte. Nebenberuflich war sie an der Uniklinik Aachen als Data Managerin im Studienzentrum Viszeralmedizin tätig. Die Studiengänge ermöglichten ihr 2015 den beruflichen Einstieg im IT-Anwendungsmanagement der Vitos gGmbH (einem Verbund somatischer und psychiatrischer Kliniken mit 11.000 Mitarbeitenden) in Hessen. Nebenberuflich nahm sie das Studium zum

Master „Medizinische Informatik“ an der BHT in Berlin auf, das sie im Jahr 2017 erfolgreich abschloss.

Seit Anfang 2022 ist sie in leitender Position und mittlerweile als Abteilungsleitung Produktmanagement im Bereich medizinische Anwendungen der Vitos gGmbH tätig. Im Rahmen dieser Tätigkeit lenkt sie die Weiterentwicklung der im Einsatz befindlichen Krankenhausinformationssysteme, Praxisverwaltungssysteme und Heiminformationssysteme. Seit 2017 arbeitet sie zudem nebenberuflich als Online-Dozentin der APOLLON Hochschule Bremen.



Harald H.H.W. Schmidt

Als Arzt und Apotheker forscht Harald Schmidt in der Systemmedizin mit dem Ziel, das, was wir als „Krankheit“ bezeichnen, von einem deskriptiven, symptom- und organbasierten zu einem mechanismusbasierten Ansatz umzudefinieren. Er setzt hierzu Big Data, Multi-Target-Validierung, neue mechanismusbasierte Diagnostik und die Umwidmung zugelassener Arzneistoffe für neue klinische Anwendungen durch Netzwerkpharmakologie ein. Seine Forschung wird finanziert durch das H2020-Projekt REPO-TRIAL zur In-silico-Netzwerk-Pharmakologie und das Horizon Europe-Projekt REPO4EU zum Aufbau einer organagnostischen Repurposing-Plattform. Seine multinationale

Forschungserfahrung im akademischen Bereich (Deutschland, USA, Australien, Niederlande), in der Industrie (Abbott Labs) und in der Biotechnologie (Vasopharm) hat zu hochrangigen Veröffentlichungen (Hirsch-Index 102) und zahlreichen Patenten für Arzneimittel und Diagnostika geführt. Er ist zudem häufig eingeladener Keynote Speaker, Podcaster und Autor („Geheilt statt behandelt“ und „The End of Medicine as we know it“).

Big Data, Digitale Medizin und Smart Healthcare

Inhaltsverzeichnis

| | |
|--|----|
| Einleitung | 1 |
| 1 Big Data und künstliche Intelligenz | 3 |
| 1.1 Definition „Big Data“ | 3 |
| 1.2 Künstliche Intelligenz (KI) | 5 |
| 1.3 Funktionsweise von Big Data und KI | 8 |
| 1.3.1 Maschinelles Lernen | 8 |
| 1.3.2 Künstliche neuronale Netze | 12 |
| 1.4 Bildverarbeitung und Mustererkennung in der Medizin | 14 |
| 1.5 Einfluss von Big Data und KI auf die medizinische Forschung | 16 |
| 1.6 KI-Anwendungen in Medizin und Gesundheitswirtschaft | 17 |
| 1.6.1 Medizin- und Serviceroboter | 17 |
| 1.6.2 Assistenzsysteme: digitale Zwillinge/Avatare | 18 |
| 1.6.3 Modellierungsebenen digitaler Avatare | 19 |
| 1.6.4 Sprachmodelle | 21 |
| Zusammenfassung | 22 |
| Aufgaben zur Selbstüberprüfung | 24 |
| 2 Digitale Medizin | 25 |
| 2.1 Telemedizin | 25 |
| 2.1.1 Telemonitoring | 26 |
| 2.1.2 Telemedizin und Telemonitoring am Beispiel von Patienten mit chronischer Herzinsuffizienz | 27 |
| 2.1.3 Telemedizin und Telemonitoring am Beispiel von Patienten mit Diabetes | 30 |
| 2.1.4 Telemedizin und Telemonitoring am Beispiel von Patienten mit psychischen Erkrankungen | 31 |
| 2.2 Systemmedizin | 32 |
| 2.2.1 Warum brauchen wir eine Systemmedizin? | 32 |
| 2.2.2 Mit Interdisziplinarität zu Präzision und Prävention | 34 |
| 2.3 Apps und Smart Devices | 36 |
| 2.3.1 Medizin- und Gesundheits-Apps | 36 |
| 2.3.2 Sensorik und Wearables | 38 |
| 2.3.3 Einsatz im Gesundheitswesen | 42 |
| Zusammenfassung | 43 |
| Aufgaben zur Selbstüberprüfung | 44 |

| | | |
|----------|--|----|
| 3 | Smart Healthcare | 45 |
| 3.1 | Definition und Rahmenbedingungen | 45 |
| 3.2 | Konzept zur Erstellung einer Digital- und Transformationsstrategie | 47 |
| 3.3 | Praktische Umsetzung anhand konkreter Beispiele | 53 |
| 3.3.1 | Schritt 1: Purpose | 53 |
| 3.3.2 | Schritt 2 und 3: Ist-Zustand erfassen und Soll-Zustand konzipieren | 53 |
| 3.3.3 | Schritt 4: Maßnahmen umsetzen und digitalisieren | 54 |
| 3.3.4 | Schritt 5: Kontinuierliche Verbesserung | 55 |
| | Zusammenfassung | 55 |
| | Aufgaben zur Selbstüberprüfung | 56 |
| | Schlussbetrachtung | 57 |
| | Anhang | |
| A. | Bearbeitungshinweise zu den Übungen | 58 |
| B. | Lösungen der Aufgaben zur Selbstüberprüfung | 60 |
| C. | Glossar | 62 |
| D. | Literaturverzeichnis | 65 |
| E. | Abbildungsverzeichnis | 73 |
| F. | Tabellenverzeichnis | 74 |
| G. | Einsendeaufgabe | 75 |

Einleitung

Liebe Studierende,

moderne Informations- und Kommunikationstechnologien (IKT) nehmen seit einigen Jahrzehnten einen hohen Stellenwert in der Datenerhebung und Datenverarbeitung ein. Der Einsatz dieser Systeme soll u. a. die Datenqualität optimieren, die Kommunikation zwischen verschiedenen Akteuren durch eine konsequente Interoperabilität gewährleisten und verbessern sowie digitale Gesundheitsdienstleistungen ermöglichen.

Dieses Studienheft widmet sich den zugrunde liegenden Technologien der digitalen Transformation im Gesundheitswesen, deren Ziel die Aufrechterhaltung und Verbesserung der Gesundheitsversorgung ist.

Zunächst werden in Kapitel 1 die eng miteinander in Bezug stehenden Themen *Big Data* und *Künstliche Intelligenz* aufgegriffen, die sich mit der Automatisierung intelligenten Verhaltens und dem maschinellen Lernen befassen. Sie werden in Grundzügen die technische Funktionsweise und Anwendungsgebiete kennenlernen.

Durch die Corona-Pandemie und auch durch die Verankerung neuer Prozesse im Rahmen des Krankenhauszukunftsgesetzes (KHZG) haben einige Technologien einen regelrechten Aufschwung erhalten und sind bereits heute im Gesundheitswesen so stark verankert, dass sie nicht mehr wegzudenken sind. Die Veränderungen dienten also als Katalysatoren, beispielsweise bei der Inanspruchnahme von Videosprechstunden. Durch die Vielzahl an Anwendungsmöglichkeiten von IKT hat sich im Laufe der Jahre der Begriff „Electronic Health“ (E-Health) geprägt, hierunter fallen die Bereiche Telemedizin, mobile Gesundheitsanwendungen sowie computergestützte Bildungsangebote. Diese werden Ihnen in Kapitel 2 näher vorgestellt.

Schließlich werden Sie eine Strategie kennenlernen, wie ausgehend vom Purpose eines Unternehmens der Gesundheitswirtschaft eine Digitalisierungsstrategie erstellt werden kann, um den Wandel hin zum Smart Hospital strukturiert zu vollziehen. Dieses Kapitel 3 ist sehr interdisziplinär ausgerichtet und setzt Kenntnisse im Prozessmanagement voraus.

Viel Freude beim Lesen wünschen Ihnen

Kurt Becker, Felix Hoffmann, Kirsten Libera und Harald H.H.W. Schmidt

1 Big Data und künstliche Intelligenz

Nach dem Bearbeiten dieses Kapitels kennen Sie die technische Funktionsweise von Big Data, künstlicher Intelligenz und maschinellem Lernen. Sie wissen, auf welche Weise medizinische Daten mithilfe dieser Technologien erhoben, verarbeitet und ausgewertet werden können.

1.1 Definition „Big Data“

Der Begriff „Big Data“ bezeichnet große Datenmengen, die nicht mehr mit manuellen und herkömmlichen Methoden der Datenverarbeitung ausgewertet werden können. Im Folgenden wird zunächst eine umfassende Definition von Big Data erarbeitet; anschließend werden technologische Ansätze zur Bearbeitung von Big Data, die damit verbundenen Herausforderungen und Möglichkeiten sowie Anwendungsbeispiele vorgestellt (vgl. Rasche et al., 2015).

Der Ursprung und die erstmalige Verwendung des Begriffes „Big Data“ im aktuellen Kontext sind nicht ganz eindeutig und es werden unterschiedliche Quellen genannt, die den Begriff in der aktuellen Verwendung geprägt haben könnten. Bereits im Jahr 2011 wurde von McKinsey ein technischer Report zu „Big Data“ veröffentlicht, in dem eine „zeitlose“ Definition des Begriffs zu finden ist:

„Big Data bezieht sich auf Datensätze, deren Größe die Möglichkeiten typischer Datenbanksoftware-Tools zur Erfassung, Speicherung, Verwaltung und Analyse übersteigt. Diese Definition ist absichtlich subjektiv und beinhaltet eine bewegliche Definition, wie groß ein Datensatz sein muss, um als große Daten zu gelten – d. h. wir definieren große Daten nicht als größer als eine bestimmte Anzahl von Terabytes (Tausende von Gigabytes).

Wir gehen davon aus, dass mit dem technischen Fortschritt im Laufe der Zeit auch die Größe der Datensätze, die als große Daten gelten, zunehmen wird. Beachten Sie auch, dass die Definition je nach Sektor variieren kann, je nachdem, welche Art von Software-Tools allgemein verfügbar sind und welche Größen von Datensätzen in einer bestimmten Branche üblich sind. Mit diesen Vorbehalten werden große Daten in vielen Sektoren heute von einigen Dutzend Terabyte bis zu mehreren Petabyte (Tausende von Terabyte) reichen.“ (vgl. Manyika et al., 2011)

Eine weitere Definition von Big Data und vor allem deren Eigenschaften stammt von Gartner, ebenfalls aus dem Jahr 2011. Das von ihm verwendete 3-V-Modell geht auf einen Forschungsbericht des Analysten Doug Laney zurück, der die Herausforderungen des Datenwachstums als dreidimensional bezeichnet hat (vgl. Laney, 2001). Die drei Dimensionen beziehen sich auf ein ansteigendes Volumen (engl. volume) der Daten, auf eine ansteigende Geschwindigkeit (engl. velocity), mit der Daten erzeugt und verarbeitet werden, und auf eine steigende Vielfalt (engl. variety) der erzeugten Daten (vgl. Abb. 1.1).

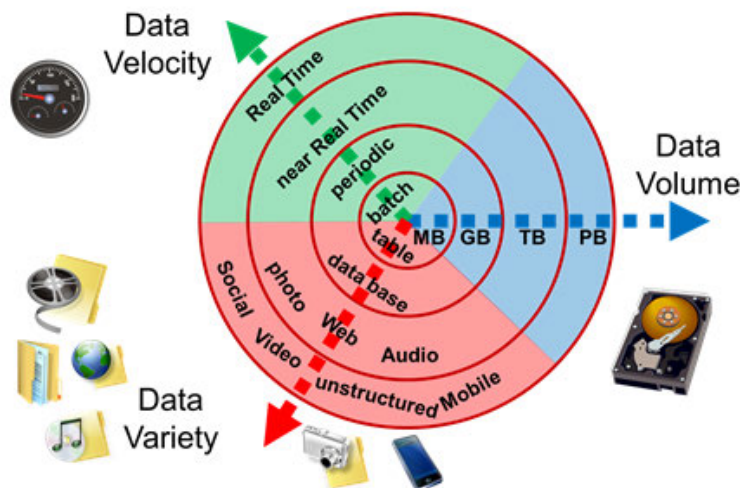


Abb. 1.1: Big-Data-3-V-Modell der Gartner Group (GI, 2013)

Abbildung 1.1 gibt einen Überblick über das 3-V-Modell der Gartner Group, das im Folgenden erklärt wird:

- Aufgabe von Big Data ist der Gewinn der Erkenntnis über den Umfang und den Wert der Daten (engl. *volume*).
- Mit Geschwindigkeit (engl. *velocity*) ist zum einen die enorme Rate gemeint, mit der die Daten in den unterschiedlichsten Anwendungsfeldern erzeugt werden. Zum anderen muss auf diese rasant wachsende Datenmenge schnellstmöglich reagiert werden. Dies gelingt nur durch eine zeitnahe Weiterverarbeitung der Daten, die im Sekunden- bis Minutenbereich liegt.
- Vielfalt (engl. *variety*) meint die Zusammenfassung der vorhandenen Daten, ob strukturiert oder nicht strukturiert, sowie deren Analyse.

Aus dieser Vielfalt entsteht ein Datenmix, der sich aus drei Kategorien zusammensetzt (vgl. Abb. 1.1):

1. Kategorie: unstrukturierte Daten (Mobile, Social, Video) aus der Kommunikation zwischen Personen, z. B. geteilte Bilder und Videos aus sozialen Netzwerken.
2. Kategorie: strukturierte Daten aus der Kommunikation zwischen Personen und Diensten oder Maschinen, z.B. Daten durch Geldautomatennutzung.
3. Kategorie: strukturierte Daten aus Datenbanken von Diensten oder Maschinen, z. B. Sensordaten, GPS-Informationen (vgl. GI, 2013).

Erst mit Big Data werden die Verarbeitung und die Analyse unstrukturierter Datenmengen ermöglicht (vgl. Davenport, 2014, S. 111). Big Data eröffnet dadurch viele neue Möglichkeiten und auch Kosteneinsparungen. Aufgrund von Big-Data-Technologien sind Speicher für enorme Datenmengen preiswerter geworden. Die Verarbeitungszeit wird durch die Aufteilung von Berechnungen auf mehreren Servern teilweise um das Hundertfache verringert. Eine weitere Möglichkeit ist die Gewinnung von Zeit durch die Verringerung der Laufzeit bei der Ausführung bestimmter Prozesse (vgl. Davenport, 2014, S. 61).

Durch Vorhersagemodelle kann es im Gesundheitswesen zudem zu Entscheidungsverbesserungen kommen, beispielsweise im Rahmen der Arzneimitteltherapiesicherheit (AMTS). Zusätzlich ermöglicht Big Data die Verbesserung von Produkten und Dienstleistungen, da die generierten Daten für die Entwicklung von neuen Produkten und Services genutzt werden können (vgl. Davenport, 2014, S. 62).

Einhergehend mit der Digitalisierung im Gesundheitswesen nimmt der Umfang der Daten und Informationen immer weiter zu. Das Gesundheitswesen ist gekennzeichnet durch eine Vielzahl komplexer Versorgungsfelder, in denen riesige Mengen von sowohl strukturierten als auch unstrukturierten Daten erzeugt werden. Um ein erfolgreiches Gesundheitswesen gestalten zu können, ist eine konsequente Erschließung dieser gesammelten Datensätze notwendig. Die Sammlung riesiger Datenmengen in Verbindung mit den neuen Analysewerkzeugen führt zu Vorteilen sowohl für die Gesundheitsdienstleister als auch für die Behandelten (vgl. Müller-Mielitz et al., 2017, S. 197). Die Erfassung, Konsolidierung und Verarbeitung solcher Gesundheitsdaten aus verschiedenen Datenquellen können auch zu einem besseren Verständnis von Krankheiten und deren Ursachen führen. Für den einzelnen Patienten kann z.B. ein optimierter Therapieplan erstellt werden, wobei es insgesamt zu einer Steigerung der Effizienz, Effektivität und Versorgungsqualität kommt, da die Gesundheitsdaten der Patienten durch jeden Gesundheitsdienstleister einsehbar sein können. Im Bereich der Pharmaindustrie können u. a. die Medikamente zielgerichteter entwickelt werden (vgl. Manns; Bähr, 2015, S. 67). Häufig werden die kombinierten Daten auch für die Unternehmenssteuerung oder im Rahmen von Reportings genutzt (vgl. Horváth; Michel, 2015, S. 30 f.).

Die dafür notwendigen Gesundheitsdaten kommen von den verschiedensten Quellen. Dazu gehören Wearables (vgl. Becker; Stammer 2017) genauso wie Biobanken, ePA, klinische Studien, Next Generation Sequencing sowie wissenschaftliche Journale. Biobanken ermöglichen die Gewinnung neuer Erkenntnisse über die Entstehung einer Krankheit und deren Verlauf, die die genetischen Informationen mit entsprechenden Hintergrunddaten verknüpfen (vgl. Manns; Bähr, 2015, S. 66). Eine große Rolle bezüglich der Herausforderungen des Themengebiets Big Data im Gesundheitswesen spielt der Datenschutz im Rahmen der Datenschutzgrundverordnung (DSGVO). Personenbezogene Daten sind sensibel und benötigen das Einverständnis der Weiterverarbeitung. Nicht alle bereits etablierten Mechanismen aus anderen Branchen sind also ohne Weiteres auf die medizinischen Daten übertragbar (vgl. Gadatsch; Landrock, 2018, S. 7).

Übung 1.1:

Nennen Sie drei Anwendungsbeispiele aus der Gesundheitswirtschaft, bei denen große Datenmengen erzeugt und ausgewertet werden.



1.2 Künstliche Intelligenz (KI)

Durch den zuvor beschriebenen Einsatz von Big Data entstehen Datenmengen, die von Menschen ohne technische Unterstützung nicht mehr ausgewertet werden können. Solange die Datenstrukturen genau bekannt sind, können die Daten noch mit „klassischen“ Datenmanagementwerkzeugen (Abfragen, Filter etc.) ausgewertet werden. Ist die Datenstruktur jedoch nicht bekannt, werden andere Werkzeuge benötigt. Hier setzt die

„künstliche Intelligenz“ (KI) an. KI bezeichnet ein Teilgebiet der Informatik, das sich mit der Automatisierung intelligenten Verhaltens und dem „maschinellen Lernen“ (ML, vgl. Kap. 1.3.1) befasst.

„Schwache KI“ befasst sich mit konkreten Anwendungsproblemen, wohingegen „starke KI“ auf die Erreichung intellektueller Fähigkeiten des menschlichen Gehirns wie beispielsweise logisches Denkvermögen und Entscheidungsfähigkeit abzielt.

Das Thema KI ist nicht neu, sondern beschäftigt die Menschheit schon seit Jahrzehnten. Spätestens seit der Entwicklung von elektronischen Taschenrechnern spielt die Verbindung zwischen Computern und menschlicher Intelligenz eine große Rolle. Im Allgemeinen versteht man unter Intelligenz jedoch die Fähigkeit, durch abstraktes, logisches Denken Probleme zu lösen und dementsprechend zweckmäßig zu handeln. Typischerweise wird der Begriff „Intelligenz“ auch mit Aspekten wie Kreativität, Lernfähigkeit und Innovationsfähigkeit verbunden. In der wissenschaftlichen Informatik wird versucht, diese Intelligenz nachzubilden, also einen Computer so zu konzipieren, dass dieser eigenständig, durch abstraktes, logisches Denken, Probleme lösen und zweckmäßig handeln kann (vgl. Jörg, 2018, S. 85 ff.).



Beispiel 1.1:

Als Alan Turing in seiner Arbeit „Computing Machinery and Intelligence“ im Jahr 1950 den sogenannten „Turing Test“ publizierte, war dieser das erste Messwerkzeug der künstlichen Intelligenz. Bei diesem Test kommuniziert ein Mensch über längere Zeit ohne Sicht- oder Hörkontakt parallel mit einem anderen Menschen und einer Maschine.

Kann der Tester nach der Unterhaltung nicht mit Bestimmtheit sagen, welcher Gesprächspartner Mensch und welcher Maschine ist, gilt der Test als bestanden und die Maschine als intelligent. Dennoch wurde in den meisten getesteten Fällen lediglich Wissen in die Maschine manuell einprogrammiert, tatsächlich intelligentes Verhalten lag hier noch nicht vor (vgl. Rueß; Krcmar, 2018, S. 7).

In den folgenden Jahrzehnten nach Turing wechselten sich im Wissenschaftsfeld der KI Phasen mit hohen und Phasen mit geringeren Forschungsaktivitäten und -investitionen (sogenannte „KI-Winter“) ab. Erst als sich die Forscher in den späten 1990er-Jahren mehr auf Subprobleme und die Anwendung der künstlichen Intelligenz auf reale Probleme wie Bilderkennung konzentrierten, konnten die Forschungserfolge wieder beschleunigt werden (vgl. Scherk et al., 2017, S. 11).

Gegenwärtig (Stand Ende 2023) befinden wir uns wieder in einer Welle des Fortschritts und der Popularität für künstliche Intelligenz. Als entscheidend hierfür gelten drei aufeinander aufbauende Faktoren:

1. Verfügbarkeit großer Datenmengen (Big Data)
2. verbesserte Algorithmen
3. gesteigerte Rechenleistung sowie -kapazität von Computern
4. Schaffung von Rahmenbedingungen und (europäischen) Standards

Aktuell wächst das globale Datenvolumen jährlich um mehr als 50 %, insbesondere auch durch die zunehmende Vernetzung verschiedener Geräte („Internet of Things“, IoT). Diese enorme Menge an verfügbaren Daten aus digitalen Quellen stellt das Roh-

material für die signifikant verbesserten maschinellen Lernansätze und Algorithmen dar. Die Entwicklung von Cloud Computing bietet zudem einen quasi unbegrenzten Zugang zu Rechenleistung, um die Daten zu verarbeiten (vgl. Bitkom, 2018, S. 15 ff.). Derzeit werden Kategorien, Klassifizierungen und Risikoklassen erarbeitet, die eine Einordnung von KI-Anwendungen ermöglichen sollen (vgl. Riegert, 2023).

KI an sich stellt keine eigene, einzeln zu betrachtende Technologie dar, sondern besteht aus einer ganzen Reihe von unterschiedlichen Technologien und Methoden. Um dieses intelligente Verhalten in Informatik-Anwendungen integrieren zu können, sind im Wesentlichen vier Kernfähigkeiten der KI notwendig:

- Wahrnehmen
- Verstehen
- Handeln
- Lernen

Diese Kernfähigkeiten werden im Folgenden beschrieben.

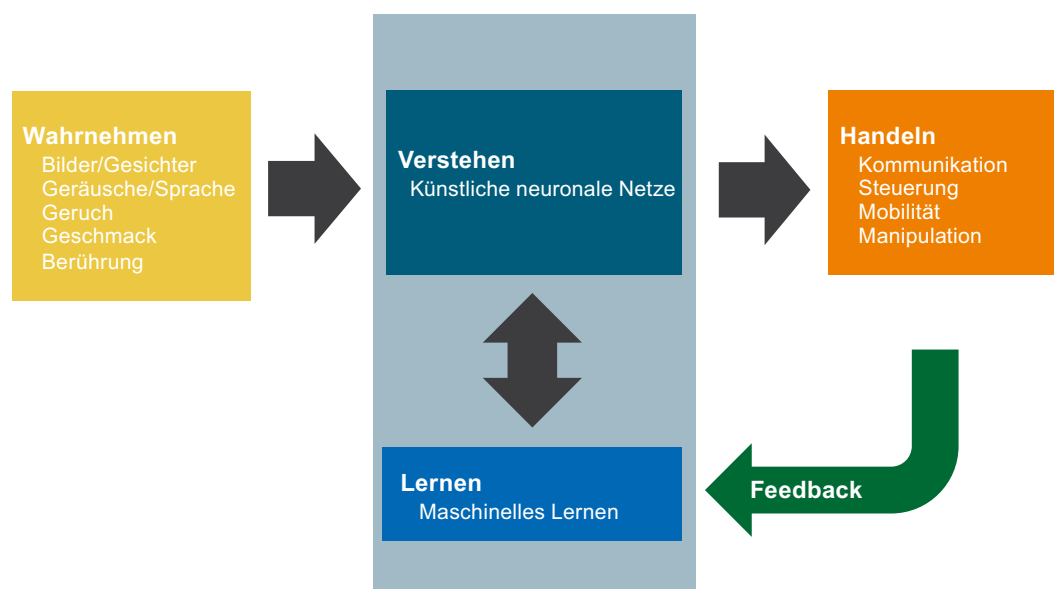


Abb. 1.2: Zentrale Komponenten einer KI

Wahrnehmen

Die erste Komponente jeder KI stellt die wahrnehmende Fähigkeit (engl. *sense*) dar. Das drastisch wachsende globale Datenvolumen sowie die Vielfalt der zu verarbeitenden Datenmengen sind Basis für das hohe Potenzial der KI.

So sind hier beispielsweise die „klassischen“ Wahrnehmungs- und Erfassungsinstrumente der künstlichen Intelligenz zu nennen: die Erkennung von Bildmaterialien, von Geräuschen wie Alarmen, die Spracherkennung sowie die Gesichtserkennung (vgl. Bitkom, 2017, S. 31 ff.).

Weitere denkbare Möglichkeiten, die die erste Komponente der künstlichen Intelligenz, die Fähigkeit wahrzunehmen, bedienen können, liegen z.B. in der Geruchserkennung sowie in der Erkennung von Berührungen und Fingerabdrücken (vgl. Purdy; Daugherty, 2016).

Verstehen

Die zweite Komponente eines jeden Systems, das KI anwendet, ist die Fähigkeit, Zusammenhänge zu verstehen (engl. *comprehend*). Dies kann beispielsweise der Inhalt eines Dokuments sein, die Klassifikation von Fotos oder auch das Auftreten einer Komplikation bei einem Patienten bzw. einer Patientin. Dazu können z.B. künstliche neuronale Netze eingesetzt werden (vgl. Kap. 1.3.2).

Handeln

Nachdem die KI-Anwendung nun Signale wahrgenommen und verstanden hat, folgt die dritte Kernfähigkeit: die Ausgabekomponente (act). Hierbei gibt es je nach System breit gefächerte Optionen, von der Ausführung des nächsten Schachzugs bis hin zur Komposition von Musikstücken. Es folgt die Ausführung der drei Hauptaspekte der handelnden Komponente von KI-Systemen: der Mobilität bzw. Manipulation, der Kommunikation sowie der Steuerung.

Lernen

Die vierte und letzte Komponente, die die erforderlichen Fähigkeiten für ein System, das als künstlich intelligent bezeichnet werden soll, komplettiert, stellt das Lernen (eng. *learn*) dar. Das Besondere an einer KI-Anwendung ist, dass diese sowohl während der Trainingsphase als auch im laufenden Betrieb lernt und sich stetig verbessert. Dieser Aspekt der künstlichen Intelligenz ist eng mit der Fähigkeit des Verstehens verbunden und soll hier noch einmal betont werden, da er das zentrale Merkmal der Intelligenz darstellt. Nicht-intelligente Systeme, die z.B. der klassischen Sprachsteuerung von Geräten dienen, verstehen zwar ihre Aufgabe, können jedoch nicht aus neuen Daten lernen. Um diesen Lernvorgang zu gewährleisten, greift die KI-Anwendung auf die Rückmeldung zu vorausgegangenen Handlungsaktionen zurück. Je nach Umfang des externen Feedbacks unterscheidet man dabei zwischen unterschiedlichen Lernformen.

1.3 Funktionsweise von Big Data und KI

Die wesentlichen Methoden, um die Systeme zur Erfüllung dieser Aufgaben zu trainieren, stellen das maschinelle Lernen (ML) sowie die künstlichen neuronalen Netze (KNN) und darauf aufbauend das Deep Learning dar. Diese werden im Folgenden näher beschrieben.

1.3.1 Maschinelles Lernen

Maschinelles Lernen gilt als Schlüsseltechnologie der künstlich intelligenten Systeme. Das Ziel dieser Technologie stellt die Generierung von „Wissen“ aus „Erfahrung“ dar, indem Lernalgorithmen aus Beispielen ein komplexes Modell entwickeln. Mithilfe dieses Modells können dann Prognosen getroffen oder Entscheidungen generiert werden.

Maschinelles Lernen (ML) bietet sich insbesondere in solchen Fällen an, in denen genügend Beispieldaten vorhanden sind, aber der zu untersuchende Prozess zu komplex ist, um ihn analytisch beschreiben zu können (vgl. Döbel et al., 2018, S. 8 ff.).

Der Algorithmus, also die Handlungsvorschrift zur Lösung eines Problems, durch den das ML-System bestimmt wird, benötigt eine Vielzahl von zuverlässigen Daten, um ein Muster in den Datenmengen erkennen zu können. Je mehr Daten in den Algorithmus einfließen, desto besser funktioniert die ML-Anwendung und desto einfacher können neue Funktionen hinzugefügt und Parameter angepasst werden (vgl. Kretschmer, 2018, S. 4).

Um eine ML-Anwendung konstruieren zu können, müssen zunächst alle verfügbaren Daten in drei Kategorien eingeteilt werden:

- Trainingsdaten
- Validierungsdaten
- Testdaten

Mithilfe der Trainingsdaten erstellt das KI-System das Modell, das alle relevanten Funktionen der Anwendung enthält. Um dieses Modell auf seine Richtigkeit prüfen zu können, werden die Validierungsdaten genutzt. Die Testdaten dienen dazu, die Performance und/oder Genauigkeit der ML-Anwendung zu kontrollieren und zu verbessern (vgl. Scherk et al., 2017, S. 14 ff.).

Tabelle 1.1 zeigt einen historischen Überblick zu ausgewählten Meilensteinen beim Einsatz maschinellen Lernens (vgl. Döbel, et al., 2018, S. 9).

Seit 2022 ist zudem der Chatbot ChatGPT (vgl. Kap. 1.6.4) zu erwähnen, der in der Lage ist, im Dialog mit Menschen, basierend auf textbasierten Nachrichten, zu kommunizieren (vgl. Luber, 2023).

Übung 1.2:

Suchen Sie im Netz nach Hinweisen zum Umgang mit KI-Tools. Wobei kann Sie ein KI-Tool unterstützen? Worauf ist zu achten?



Tab. 1.1: Überblick zu ausgewählten Meilensteinen im Einsatz von maschinellem Lernen (vgl. Döbel et al., 2018, S. 9, erweitert)

| | |
|------|--|
| 2023 | ChatGPT generiert und bearbeitet Texte, die allerdings inhaltlich fehlerhaft sein können. Es ist möglich, Gespräche mithilfe von KI auszuwerten, daraus Informationen zu entnehmen und diese standardisiert zu dokumentieren. |
|------|--|

| | |
|-----------|---|
| 2019 | <p>ML-basierte Systeme sind inzwischen in der Lage,</p> <ul style="list-style-type: none"> • radiologische Bilder so gut wie Mediziner zu analysieren • automatisch unklare Bilder zu vervollständigen • selbst KI-Software zu schreiben und zu trainieren • Börsengeschäfte anhand eigener Prognosen selbstständig durchzuführen • in komplexen Spielen wie Go und Poker gegen Menschen zu gewinnen • sich selbst Wissen, Spiele und Strategien beizubringen |
| 2017 | KI (Alpha Go) gewinnt im Go-Spiel gegen den „besten Spieler der Weltrangliste“ Ke Jie |
| 2011 | KI gewinnt im Quiz-Spiel (IBM Watson) |
| 2010er | Bedeutende Erfolge mit Deep Learning (v. a. in der Sprachverarbeitung, Objekterkennung, Mustererkennung, Bioinformatik) |
| 2000 | <p>Popularitätsgewinn des ML:</p> <p>Revival der neuronalen Netze (Big Data und schnelle Computer)</p> <p>Verbreitung der Kernel-Methoden des ML</p> |
| 1996 | KI gewinnt im Schach gegen den Weltmeister Kasparow (IBM Deep Blue) |
| 1990er | Durchbruch: Stützvektormaschinen (SVM) |
| 1985–1995 | Stagnation der Forschung und Entwicklung: Aufgabe der Expertensysteme (zu hohe Komplexität und langsame Computer) |
| 1980er | Praktische Anwendung der „Back Propagation“-Methode für ML und KNN; Forschung an Expertensystemen |
| 1980er | Boom der humanoiden Robotik (Japan) |
| 1974–1980 | Stagnation der FuE: Scheitern neuronaler Netze (zu langsame Computer) |
| 1960er | Entwicklung: Bayes'sche Netze, probabilistisches ML und semantische Netze |
| 1950er | <p>Pionierarbeit im maschinellen Lernen (ML)</p> <p>Begriffsprägung der künstlichen Intelligenz (KI)</p> |
| 1940er | Theorie der „ künstlichen neuronalen Netze “ (KNN) |

Das im Rahmen des maschinellen Lernens entwickelte Modell enthält eine Reihe möglicher Entscheidungsregeln sowie eine Vielzahl an Parametern, oftmals mehrere Millionen. Basierend auf vergangenen Ergebnissen, wird die intelligente Maschine bei ständigen Wiederholungen die Parameter fortwährend anpassen und somit bessere und richtigere Ergebnisse liefern.

Ziel ist es, das Modell so auszureifen, dass es sich verallgemeinern lässt und auch für zukünftige Fälle, die bisher noch nicht im Datensatz enthalten sind, zutreffende Ergebnisse liefern kann. Abb. 1.3 zeigt die Funktionsweise des maschinellen Lernens (vgl. Scherk et al., 2017, S. 15).

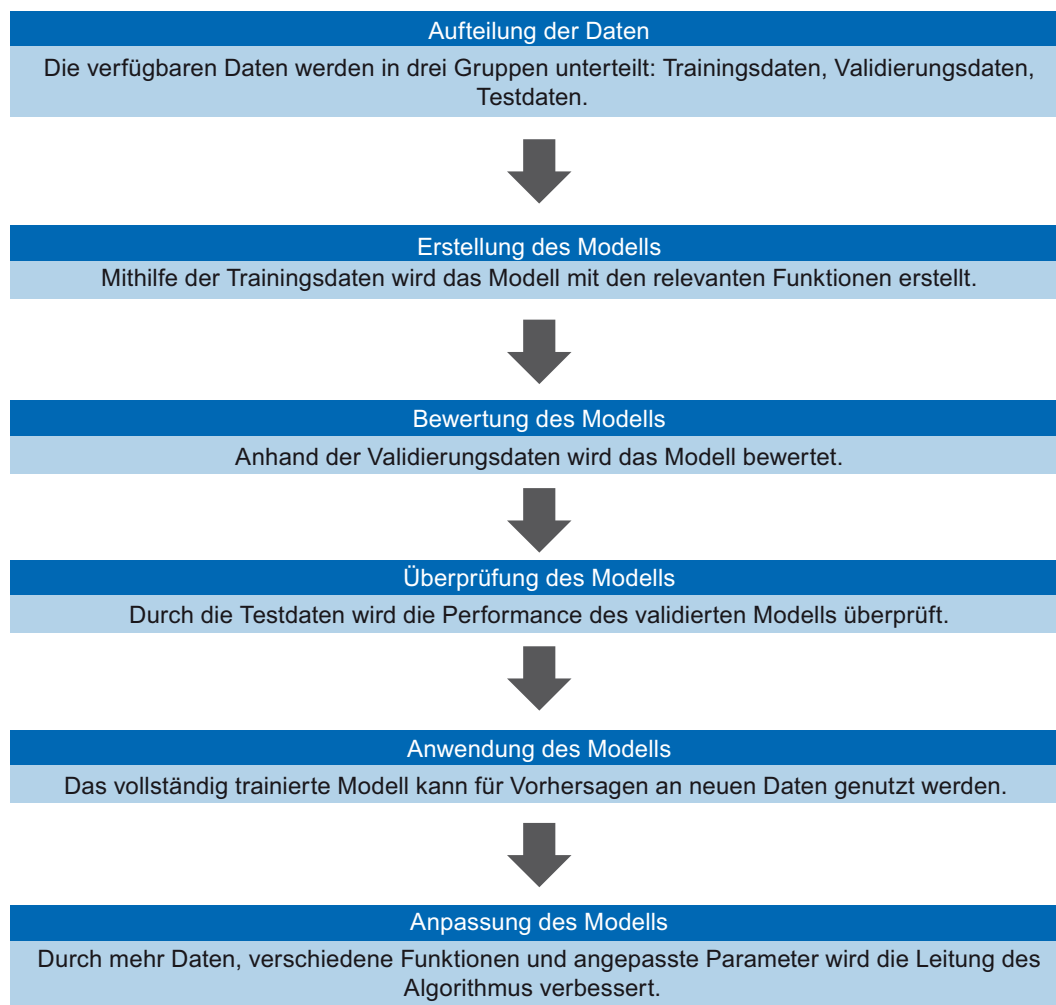


Abb. 1.3: Funktionsweise des maschinellen Lernens (vgl. Scherk et al., 2017, S. 15)

Die Konstruktion einer ML-Anwendung bedarf derzeit noch eines großen Aufwands und dennoch kann jeweils nur ein eingeschränkter Aufgabenbereich abgedeckt werden. Forschungsbemühungen in Zusammenhang mit maschinellem Lernen beschäftigen sich demnach neben der Verbesserung von Robustheit, Sicherheit und Transparenz vorrangig damit, den Trainingsaufwand der Systeme zu verringern und sie besser anpassbar für neue Aufgaben zu machen (vgl. Döbel et al., 2018, S. 8).



Zusätzlich sollte zukünftig im Fokus stehen, die Einsatzzwecke einzelner spezieller KI-Anwendungen sinnvoll zu kombinieren. Wichtig in diesem Kontext ist auch der gewissenhafte, sinnhafte Einsatz der KI-Anwendungen, da diese sowohl nutzen als auch schaden können. Es muss betrachtet werden, welche Beweggründe der KI zugrunde liegen, sodass zum Beispiel Informations-Kapitalismus ausgeschlossen werden kann (vgl. Simon, 2021, S. 21 f.).

1.3.2 Künstliche neuronale Netze

Bei komplexeren Fragestellungen, die sich nicht in einen Algorithmus fassen lassen, da sie von einer großen Menge subtiler Faktoren abhängen, bietet sich statt ML die Anwendung von künstlichen neuronalen Netzen (KNN) an. Die Grundidee der künstlichen Neuronen stützt sich dabei auf biologische Nervenzellen. Die passende Kombination vieler aneinandergereihter künstlicher Neuronen ergibt ein künstliches neuronales Netz. Bekommt ein künstliches Neuron einen Input in Form von bestimmten Datenbestandteilen, wie Pixeln, gewichtet es diese und gibt sie bei Überschreitung eines Schwellenwertes an das nächstgeschaltete Neuron weiter. Auf diese Art entsteht ein komplexes Netz, das auch sehr große Datenmengen analysieren und schwierige Probleme lösen kann (vgl. Faulmann et al., 2017, S. 8).

Der Abbildung 1.4 ist der vereinfachte Aufbau eines künstlichen neuronalen Netzes zu entnehmen. Erhält die Input-Ebene ein Signal von außen, schickt sie diese Information weiter an die nächsten Ebenen. Die Funktionsweise ist eine Feedback-Schleife, in der einer bestimmten Anzahl an Parametern Gewichte zugewiesen werden, die im Trainingsprozess durch Vergleichen der Ergebnisse mit den Soll-Werten schrittweise angepasst werden.

Da die Schichten zwischen der Ein- und Ausgabeschicht lediglich mit den jeweils angrenzenden Schichten interagieren, spricht man aus Sicht der Anwendenden von versteckten Schichten. Von diesen „Hidden Layers“, die in unterschiedlicher Anzahl vorliegen oder sogar ganz fehlen können, wird das Signal dann weiter an die Output-Ebene geleitet, die wiederum eine Reaktion auslösen kann. Gegebenenfalls kann der/die Anwendende die versteckten Schichten einsehen, jedoch bei mehrschichtigen Modellen mit einer hohen Zahl an Parametern häufig nicht erkennen, wie stark bestimmte Parameter das Eingabe-Ausgabe-Verhalten beeinflussen (vgl. Grohs, 2017).

Die Wahl des Modells hängt vom Hypothesenraum und seiner Dimensionalität ab, d. h. davon, welche Hypothesen für die Problemstellung relevant sind und wie viele Attribute einzubeziehen sind. Auch eine Kombination mehrerer KNN zu einem komplexeren KNN ist möglich. Diese Ensembles von Modellen erzielen oft eine bessere Leistung als ein einzelnes Modell (vgl. Russell; Norvig, 2012, S. 809 ff.).




Abb. 1.4: Schema eines künstlichen neuronalen Netzes (vgl. Grohs, 2017)

Nach der Konstruktion eines KNN muss dieses für seine Aufgaben trainiert werden. Hierbei gibt es verschiedene Möglichkeiten, die vom Löschen und Hinzufügen neuer Verbindungen und Neuronen bis zu einer Änderung der Schwellenwerte reichen.

Dabei wird unterschieden, ob das Lernen überwacht oder nicht überwacht wird, d.h., ob dem Algorithmus im Lernprozess Feedback durch den Anwender bereitgestellt wird oder nicht. Eine Unterscheidung zwischen überwachtem und nicht überwachtem Lernen ist in der Praxis oft schwierig und es wird eine Mischform genutzt, deren Funktion konsequenterweise als halb überwachtes Lernen bezeichnet wird. Dies ist dem Umstand geschuldet, dass für Trainingszwecke nutzbare Daten in realen Anwendungssituationen selten vollständig oder fehlerfrei sind. Oft stehen stattdessen nur wenige Trainingsbeispiele mit verlässlichem Feedback zur Verfügung, während die Mehrheit der Beispiele zufällige oder systematische Störungen aufweist. Das halb überwachte Lernen ist daher auf einen Kompromiss der hier genannten Haupttypen des Lernens ausgerichtet (vgl. Russell; Norvig, 2012, S. 811).

In den meisten Fällen erfolgt jedoch die Anpassung der Gewichte. Als intelligent gilt das KNN dabei, wenn es die Optimierung der Gewichte, Schwellenwerte usw. selbst durchführt. Auf diese Art wird die menschliche Intuition imitiert; das künstliche neuronale Netz lernt aus seinen Erfahrungen. Dieses Lernverhalten bezeichnet man als „tiefes Lernen“ (engl. *Deep Learning*; vgl. Faulmann et al., 2017).

Beim tiefen Lernen wird zwischen unterschiedlichen Lernmöglichkeiten unterschieden:

- So gibt es z.B. das *Backpropagation Learning*, bei dem eine Art externer „Lehrkraft“ (meist Algorithmen) dem KNN zu jedem Output die Differenz zur korrekten Lösung nennt und zusätzlich Gewichtsadjustierungen vorgibt.

- Beim *Supervised Learning* erhält das KNN lediglich eine Rückmeldung zur Differenz zur korrekten Lösung, optimiert die Lernregeln jedoch selbst.
- Im Rahmen des *Reinforcement Learning* wird dem System nur ein Feedback gegeben, ob die Lösung korrekt oder inkorrekt war. Es erhält jedoch keine Differenzangaben oder Korrekturanweisungen.
- Wird auf ein externes Feedback vollkommen verzichtet, spricht man vom *Unsupervised Learning*. Hierbei ordnet das KNN die Daten eigenständig ohne äußere Beeinflussung in Ähnlichkeitsklassen ein. Vorteil dieser Form ist, dass keine umfangreichen Trainingsdaten benötigt werden. Allerdings geht beim Unsupervised Learning der Überblick über den Lernvorgang des KNN verloren (vgl. Frölich, 2005).

Den Deep-Learning-Systemen, die das Unsupervised Learning beherrschen, wird derzeit das größte Potenzial in Zusammenhang mit künstlicher Intelligenz zugesprochen. Da keine Trainingsdaten und weniger Zeit für das Set-up des Systems benötigt werden, sinken auch die erforderlichen Investitionskosten, was die Anwendung wiederum zusätzlich alltagstauglich macht (vgl. Atos, 2016, S. 61).



Beispiel 1.2:

Ein Beispiel für ein Deep-Learning-System ist Alpha Zero. Dabei handelt es sich um ein autodidaktisches Computerprogramm, dessen Algorithmus mehrere komplexe Brettspiele (Schach, Go, Shogi) nur mittels der Spielregeln und intensiven Spielens gegen sich selbst erlernte. Es schlug andere Schach- bzw. Go-KIs mit Strategien, die es selbst entwickelt hatte. Dies ist ein sehr gutes Beispiel für die Abgrenzung von KI zu reinem ML (Alpha Go) und zeigt gleichzeitig auch mögliche Probleme der KI auf („unmenschliche“ Strategien: Der dänische Großmeister Peter Heine Nielsen sagte in einem Interview mit der BBC: „I always wondered how it would be if I get a superior species landed on earth and showed us how they played chess. Now I know.“)



Übung 1.3:

Ein Arzt-Kollege hat die Idee, den Augenhintergrund zu scannen und eine KI-Anwendung (Bildverarbeitung/Mustererkennung) zur SarsCoV2-Erkennung zu entwickeln. Wie würden Sie das KI-System in Bezug auf die Eingangs- und Ausgangsparameter gestalten?

Übung 1.4:

Wie kann beim Deep Learning sichergestellt werden, dass das System „das Richtige“ lernt?

1.4 Bildverarbeitung und Mustererkennung in der Medizin

Bei der bildgebenden Diagnostik werden Rohdaten, die beispielsweise mit MRT oder CT gewonnen werden, unter einem großen Informationsverlust für das menschliche Auge aufbereitet und dem Arzt als Bild zur Verfügung gestellt.

Das Prinzip der künstlichen Intelligenz in der bildgebenden Diagnostik besteht nicht in einer Verbesserung der Untersuchungstechnik an sich, sondern in der besseren und informationsverlustfreien Auswertung der gewonnenen Rohdaten, ohne dass Ausbildungsstand oder Tagesform hierbei eine Rolle spielen (vgl. Forsting, 2019, S. 73 f.).



Im Bereich der digitalisierten Medizin können drei Komponenten der KI unterschieden werden (vgl. Jörg, 2018, S. 87 f.):

- Die kognitive Intelligenz kann sich Situationen merken und kausale Folgen ableiten.
- Die soziale, emotionale Intelligenz analysiert Gesicht und Sprache der Menschen, um eine entsprechende Rolle einzunehmen.
- Mit der sensomotorischen Intelligenz ist es möglich, optische Eindrücke in Motorik umzusetzen, um z.B. einen Gegenstand zu greifen. Des Weiteren können akustische Befehle ausgeführt oder Fragen beantwortet werden.

Im gleichen Maße, wie große Datenmengen (Big Data) eine Chance für die Wissenschaft darstellen, sind sie für die Ärzteschaft in der Patientenversorgung eine große Herausforderung. Es wird immer schwieriger, alle relevanten Informationen (individuelle medizinische Befunde, Interaktionen von Medikamenten und Erkrankungen, aktuelle wissenschaftliche Erkenntnisse) bei der Behandlung eines Patienten/einer Patientin zu berücksichtigen. Künstliche Intelligenz kann dabei unterstützen, eine bestmögliche individuelle Therapieentscheidung für eine einzelne Person unter Berücksichtigung sämtlicher relevanter Informationen zu treffen (vgl. Wittpahl, 2019).

Insbesondere bei biomedizinischen Modellen stellt sich die Frage, wie sich bei hoher Themenkomplexität unscharfe Daten klassifizieren und semantisch verarbeiten lassen. Dabei stellt die Fuzzy-Logik eine Methode zur Verfügung, die Abstufungen unterschiedlicher Wahrheitswerte ermöglicht (vgl. Russell; Norvig, 2012, S. 645).

Die Fuzzy-Logik wurde im Jahr 1965 vom amerikanischen Wissenschaftler Lotfi A. Zadeh vorgestellt. Seine Idee war es, dem Computer das Arbeiten mit unscharfen Informationen zu ermöglichen. Auf dieser Logik basieren heute viele intelligente Haushaltsgeräte, z.B. Waschmaschine mit Schmutzerkennung oder Trockner mit Feuchtigkeitsmessung. Fuzzy-Logik kann aber auch dazu genutzt werden, Vitalparameter wie Blutdruck und Temperatur in für Mensch und Computer verständlichen Begriffen darzustellen (hoher Blutdruck, niedrige Temperatur etc.).

Das Potenzial zur Anwendung der Fuzzy-Logik-Methode im Bereich der Biomedizin wurde von Becker et al. aufgezeigt: Die Fuzzy-Logik und die darauf basierende Steuerung (Fuzzy-Control oder Fuzzy-Steuerung) nähern sich dem Problem über den Weg des Alltagsdenkens (Common Sense) an und können Objekte und Systeme unscharf beschreiben. Die Methode eignet sich daher für Problemstellungen, für die keine exakten mathematischen Modelle erstellt werden können (vgl. Becker et al., 1997, S. 35 ff.).

Bisher am weitesten ist die KI-Forschung in der medizinischen Diagnostik und hier insbesondere in der Radiologie. Dies liegt darin begründet, dass die Computer Aided Diagnosis (CAD) bereits seit den 1970er-Jahren etabliert und die Bildarchivierung hochgradig automatisiert ist. Vorteile neuerer KI-Systeme in der Radiologie liegen neben der Effizienz darin, dass auch Befunde, nach denen nicht explizit gesucht wird, in gleichen

Bildabschnitten erkannt werden können (z.B. eine Auffälligkeit der Aorta bei einem Röntgenbild der Wirbelsäule). Außerdem haben sich die Algorithmen in der Diagnostik von Krankheiten bereits als deutlich treffsicherer erwiesen als die Diagnostik durch erfahrene Radiologen (vgl. Höpner, 2019, S. 2).



Übung 1.5:

Betrachten Sie die Corona-Pandemie seit Beginn des Jahres 2020. Überlegen oder recherchieren Sie Anwendungsmöglichkeiten des maschinellen Lernens und der automatisierten Bildverarbeitung, die bei der Bewältigung dieser Pandemie oder folgender Pandemien hilfreich sein können.

1.5 Einfluss von Big Data und KI auf die medizinische Forschung

Nicht nur in der Bildverarbeitung fallen große Datenmengen an. Während des gesamten Behandlungsprozesses einer einzelnen Person werden riesige Datenmengen erhoben und gespeichert. Bis vor einigen Jahren war es nur unter großem Aufwand möglich, die Daten eines größeren Patientenkollektivs wissenschaftlich auszuwerten. Die hier vorgestellten innovativen Methoden der Datenauswertung ermöglichen die Auswertung riesiger Datenmengen mit einem verhältnismäßig geringen Aufwand; die Nutzung kollektiver Gesundheitsdaten wird möglich. Auf diese Weise ist es denkbar, dass retrospektive Analysen nicht nur an einer Stichprobe, sondern prinzipiell (die Verfügbarkeit der Daten vorausgesetzt) anhand der Gesamtpopulation durchgeführt werden können, was ein erhebliches Potenzial für die medizinische Forschung beinhaltet.

Im internationalen Vergleich nimmt Deutschland weiterhin eine starke Position ein. Vergleicht man die Anzahl der wissenschaftlichen Publikationen zum Thema künstliche Intelligenz im Jahr 2023, so lag Deutschland – gemeinsam mit den USA – hier an fünfter Stelle (vgl. AI-Index, 2023).

Die Forschung im Bereich künstlicher Intelligenz wurde in den letzten Jahren in fast allen Industrieländern intensiv ausgebaut. Insbesondere die chinesische sowie die US-amerikanische Forschung zu dieser Thematik zeigt sich hier im internationalen Vergleich als sehr dominant. Im **AI-Index-Report 2023** ist zudem auffällig, dass die KI-Entwicklung weltweit mittlerweile in zunehmendem Maß von einer kleinen Gruppe aus dem privaten Techniksektor vorangetrieben wird. Private Investitionen aus den USA und China machen mehr als die Hälfte aller weltweit getätigten privaten Investitionen aus. Öffentliche oder gesellschaftliche Akteure sind zunehmend weniger vertreten (vgl. Hahn, 2023).

Die Bundesregierung setzt sich zum Ziel, den Forschungsstandort Deutschland im Bereich der künstlichen Intelligenz weiter zu stärken, um einen Innovationsschub zu generieren, die Wettbewerbsfähigkeit der deutschen Industrie auszubauen sowie Deutschland zu einem führenden KI-Standort zu entwickeln. Hierzu wurde die KI-Strategie, die am 18.11.2018 durch das Bundeskabinett beschlossen wurde, aufgesetzt. Der Bund stellt bis 2025 insgesamt etwa 5 Mrd. Euro zur Verfügung. Ein Teilziel dieser Strategie stellt die Implementierung eines nationalen Netzwerks von zwölf Handlungsfeldern für die KI-Forschung dar. Es konnten bereits 100 KI-Professuren (durch Alexander-von-Humboldt-Professuren für KI, die Einrichtung von Professuren an den KI-Kompetenzzentren und weitere Initiativen) etabliert werden. Die Bereiche Robotik, Gesundheit, Bildung und KI-Startups (inklusive Nachwuchsförderung) stehen im Fokus. Im Gesundheitswe-

sen sind bereits einige Fördermittel verankert worden. Im Speziellen wurde beispielsweise die gemeinsame Datennutzung von Universitätskliniken seit 2021 mit 50 Millionen Euro gefördert; 19,5 Millionen Euro fließen seit 2022 in den Ausbau KI-basierter Assistenzsysteme zur Entlastung des Klinikpersonals, ebenso können seit 2019 ethische, rechtliche und soziale Aspekte dank der Fördermittel genauer betrachtet werden. Insgesamt wurden bereits (durch die Bundeshauhalte 2019, 2020 und 2021 sowie das Konjunktur- und Zukunftspaket) 3,5 Milliarden Euro ausgezahlt. Die KI-Strategie wurde 2020 sowie 2023 fortgeschrieben und aktualisiert (vgl. BMBF, 2023).

Übung 1.6:

Recherchieren Sie, ob es ähnliche Initiativen zur in Deutschland etablierten KI-Strategie in anderen (europäischen) Ländern gibt. Ähneln sich die Strategien oder weichen diese je nach Land stark voneinander ab?



1.6 KI-Anwendungen in Medizin und Gesundheitswirtschaft

Der demografische Wandel in Deutschland, ein akuter Fachkräftemangel an medizinischem Personal, Fortschritte in der Medizintechnik, die notwendige Vernetzung von Versorgungsstrukturen im ländlichen Raum sowie ein zunehmendes Gesundheitsbewusstsein der Bevölkerung sind Faktoren, die die Entwicklung der künstlichen Intelligenz im Gesundheitswesen maßgeblich beeinflussen. Bereits heute werden weltweit diverse KI-Systeme im Gesundheitswesen sowie in der Seniorenbetreuung konzipiert und erprobt. Einige davon werden in den folgenden Unterkapiteln vorgestellt.

1.6.1 Medizin- und Serviceroboter

Die Mobilität von KI-Anwendungen auf kleinerem Raum bezieht sich auf Mechanismen und Funktionen mobiler und greifender Roboter, die ihr Verhalten situativ anpassen. Diese Art von Robotern wird in der Industrie, insbesondere in der Automobilproduktion und der Elektrotechnik, bereits seit den 1970er-Jahren eingesetzt, wurde jedoch im Laufe der Zeit immer sicherer, selbstständiger und flexibler (vgl. Hecker et al., 2017, S. 12 ff.). Aus diesem Grund haben die KI-Roboter inzwischen auch Einzug in andere Bereiche gehalten, wie z.B. als Transportroboter in der Logistik, als mobile Feldroboter in der Landwirtschaft sowie als Exoskelette („Roboteranzüge“) oder Chirurgieroboter in der Medizintechnik (vgl. Bitkom, 2018, S. 80 ff.).

Bereits seit dem Jahr 2000 wird der chirurgische Roboter „Da Vinci“ in Kliniken eingesetzt, der präzise, mit vier Armen gleichzeitig, verschiedene Operationen durchführen kann. Derzeit werden Medizinroboter neuerer Generation entwickelt, die vor allem durch ein deutlich verbessertes haptisches Feedback an den Chirurgen überzeugen. Schien es vor einigen Jahren noch undenkbar, dass diese Roboter autark, also ohne menschliches Eingreifen, arbeiten können, so gab es im Jahr 2022 mit dem Roboter „Star“ in der Tierwelt bereits die ersten laparoskopischen, autonomen Operationen, nämlich zur Verbindung zweier Darmenden beim Schwein. Die Entwicklung ist hier also rasant (vgl. Klatt, 2022, S. 1).

Auch in der Pflege und Betreuung kranker und älterer Menschen werden KI-Serviceroboter konzipiert, die beispielsweise die Mobilisation ermöglichen oder anderweitig im Alltag behilflich sind. Bis diese Art von Robotern allerdings den Umzug von Senioren in ein Pflegeheim tatsächlich vermeiden kann, wird es noch einige Jahre dauern (vgl. Thommes et al., 2019, S. 21 f.).

Im privaten Raum hat sich überdies zunehmend der Gebrauch der Servicerobotik verbreitet. Diese KI-Anwendungen können bei alltäglichen Haushaltsaufgaben (z. B. Rasenmähen, Fensterreinigung) eingesetzt werden, als Security- und Überwachungssystem dienen oder Ältere und Pflegebedürftige im Alltag unterstützen. Prognosen gehen – nicht zuletzt auch wegen des demografischen Wandels und der damit einhergehenden steigenden Anzahl von Pflegebedürftigen – von einem hohen Wachstum der privaten Servicerobotik in den nächsten Jahren aus (vgl. Hecker et al., 2017, S. 17 ff.).

Interaktive Roboter

Eine weitere Möglichkeit, wie KI-Anwendungen im Rahmen der Ausgabekomponente agieren können, besteht in der interaktiven Kommunikation mit Menschen. Dieser Bereich überschneidet sich mit der oben angesprochenen Servicerobotik. Systeme, die mittels künstlicher Intelligenz mit dem Menschen interagieren, können beispielsweise zum Unterrichten, Begleiten oder Unterhalten genutzt werden. Tatsächlich stellen die sogenannten „Sozialen Roboter“ momentan den aktivsten Forschungsbereich innerhalb der Servicerobotik dar.

Neben der Kommunikation zwischen Mensch und Maschine, die außerhalb der beschriebenen sozialen Komponente beispielsweise auch im Kundenservice bei der automatischen Beantwortung von Kundenanfragen Einsatz findet, kann jedoch auch eine intelligente Kommunikation zwischen zwei Maschinen stattfinden. So können sich zwei KI-Anwendungen auch zu Zustandsdaten und Steuerbefehlen austauschen und auf diese Art miteinander interagieren (vgl. Bitkom, 2018, S. 84 ff.).

Soziale Roboter

Die Servicerobotik kann jedoch in einem weiteren Schritt sogar bis hin zu sogenannter sozialer Robotik führen. Beispiele hierfür sind die Robbe Paro von der japanischen Firma AIST, die auf emotionaler Ebene mit geistig eingeschränkten Patienten interagiert (vgl. Hecker et al., 2017, S. 17), oder der Care-O-Bot des Fraunhofer-Instituts für Produktionstechnik und Automatisierung, der von den Entwicklern als „zuvorkommend, freundlich und sympathisch“ beschrieben wird und seine aktuelle Stimmung über ein im Kopf integriertes Display anzeigen kann (vgl. Fraunhofer-IPA, 2019).

1.6.2 Assistenzsysteme: digitale Zwillinge/Avatare

Auch sogenannte „digitale Zwillinge“ werden bereits in der Medizin erprobt und bieten ein immenses Potenzial in der zukünftigen Gesundheitsversorgung. So wurden an der Stanford University mit Unterstützung von Siemens Healthineers 100 digitale 3D-Modelle von realen menschlichen Herzen erstellt, die anhand eines 2D-Ultraschall-Scans von Patienten mit Herzinsuffizienz angefertigt wurden. Diese personalisierten „Herz-

Zwillinge“ wurden durch ein KI-System auf Nebenwirkungen bei der Anwendung von verschiedenen Medikamenten überprüft. Außerdem konnte daran der Therapieverlauf prognostiziert werden (vgl. Kindler, 2019, S. 45).

Digitaler Zwilling steht synonym für „digitaler Avatar“. Solche personalisierten Gesundheitsavatare können z.B. im Bereich Diagnose- und Therapiemanagement (vgl. Becker, 2019a), im Diabetes-Management (vgl. Becker, 2017) oder auch im Bereich des Pflegemanagements (vgl. Becker, 2019b) eingesetzt werden. Bewegung und Aktivität spielen in der Pflege eine bedeutende Rolle. Die Pflegebedürftigen müssen mobilisiert und motiviert werden, um die Aktivitäten des täglichen Lebens (ATL) möglichst wieder selbstständig zu planen und auszuführen. Hier können digitale Avatare unterstützen.

Der digitale Gesundheitsavatar dient als Erklärungs- und Visualisierungskomponente und kann auch als multidimensionale Patientenakte eingesetzt werden. Solche Avatare wurden bereits in Forschungsprojekten evaluiert, wie das folgende Beispiel zeigt.

Beispiel 1.3:

Informationen zum Gesundheitsstatus von Patientinnen und Patienten liegen häufig nicht gebündelt, sondern stark fragmentiert vor. Ein vielversprechender Ansatz ist es, die verschiedenen Akteure zu vernetzen. In Thüringen ist durch diese Überlegung das Kompetenzcluster AVATAR entstanden, das aus 18 Bereichen – u. a. Medizintechnik, Diagnostik, Biotechnologie, IT, Datenwirtschaft, Wirtschaft, Recht, Forschungs- und Gesundheitseinrichtungen – besteht. Das Projekt wird vom Bundesministerium für Bildung und Forschung gefördert und läuft bis November 2025. Ziel ist es, unter Beachtung der gesetzlichen Rahmenbedingungen, digitale Avatare in Medizin und Pflege zu generieren. Diese sollen perspektivisch einen Beitrag zu Forschungsarbeiten leisten können sowie zur Evaluierung neuer Methoden und Medikamente eingesetzt werden. Diesbezüglich ist es notwendig, die unterschiedlichen Datenräume zusammenzuführen und zu anonymisieren. Hierbei wird u. a. der gängige Schnittstellen-Standard HL7 im Gesundheitswesen genutzt (vgl. Infectogenostics, 2023).



1.6.3 Modellierungsebenen digitaler Avatare

Der Ansatz des digitalen Avatars erfordert eine modellbasierte Wissensbasis auf der Grundlage verschiedener Modellierungsmethoden und Ebenen. Integriert werden die Submodelle zu einem Metamodell, dem personalisierten Gesundheitsavatar (vgl. Abb. 1.5), von dem aus wieder in die Submodelle referenziert werden kann:

- Aktivität
- Biomarker und Vitalparameter
- genomische Daten

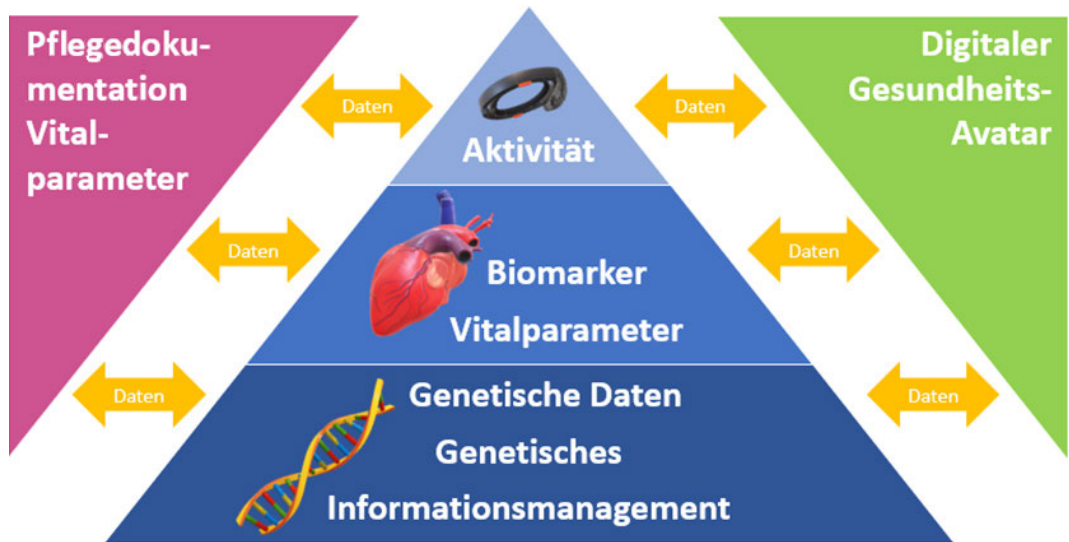


Abb. 1.5: Modellierungsebenen und Datenmanagement eines digitalen persönlichen Gesundheitsavatars (vgl. Becker, 2019b)

Im Folgenden werden die Modellierungsebenen kurz beschrieben:

Aktivität

Für die Modellierung der Aktivität können sogenannte „Wearables“ (vgl. Kap. 2.3.2) einen maßgeblichen Beitrag leisten. Mit preiswerter mobiler Messtechnik für spezifische Vital- und Bewegungsparameter, einem Smartphone und einer Verbindung mit dem Internet kann z. B. das Bewegungs- und Schlafverhalten der Pflegebedürftigen erfasst werden (vgl. Becker; Stammer, 2017).

Biomarker und Vitalparameter

Vitalparameter sind physiologische und biologische Parameter, die durch geeignete Messgeräte direkt am biologischen Organismus bzw. am Patienten erfasst werden können. Dies sind z. B. die Herzfrequenz, Blutdruckwerte oder der Blutzuckerspiegel. Schon lange nutzen Ärzte Biomarker für die Diagnose von Krankheiten. Die Biomarkers Definitions Working Group (BDWG) definiert Biomarker wie folgt:



„Ein Biomarker ist ein Charakteristikum, das als Indikator für normale biologische Prozesse, pathogene Prozesse oder pharmakologische Reaktionen auf eine therapeutische Intervention objektiv gemessen und bewertet wird.“ (BDWG, 2001)

Bei der Analytik mit Biomarkern unterscheidet man diagnostische, prognostische und prädiktive Biomarker (vgl. Bracht, 2009). Es werden Proben entnommen und Biomarker generiert, z. B. bei Blutzucker- und Blutlipidmessungen. Neuerdings spielen auch kontinuierliche Blutglukose- und Blutgerinnungsmessgeräte eine große Rolle. Auch für die Pflege spielen Biomarker eine große Rolle; so kann durch die Kombination bestimmter Parameter z. B. der Flüssigkeitshaushalt überwacht werden.

Nutzung genomischer Daten am Beispiel der Nutrigenomik

Nutrigenomik ist eine Forschungsrichtung, die die Interaktion eines Nährstoffs mit dem Genom und die daraus resultierenden Veränderungen der Stoffwechselwege untersucht. Die Regulation der Genexpression und die individuelle Antwort auf umweltbezogene Veränderungen (Nahrung) lassen sich in den Genen dann als interindividuelle Differenzen erfassen. Bereits sehr geringfügige Veränderungen können erhebliche Einflüsse auf den Stoffwechsel einzelner Nahrungsbestandteile und damit auf ihre Wirkung haben. Schon sehr geringe Veränderungen in den Genen sind für die Vielschichtigkeit der Stoffwechselantwort der Individuen auf ein und denselben Wirkstoff verantwortlich (vgl. Birschoff; Betz, 2010, S. 412).

Die Erkenntnisse aus der nutrigenomischen Forschung können z.B. in der individualisierten Ernährung der Pflege Anwendung finden und helfen, den Stoffwechsel wieder zum natürlichen Gleichgewicht zurückzuführen.

1.6.4 Sprachmodelle

Im Gesundheitswesen ist es essenziell, den Gesundheitsstatus der Patientinnen und Patienten auch schriftlich festzuhalten, sodass weitere Behandelnde und Akteure Zugang zu den relevanten Informationen haben. Täglich entstehen hier große Datenmengen, die – im Falle einer elektronischen Erfassung – ihren Weg in die entsprechende Applikation finden müssen. KI-Sprachmodelle sollen hier unterstützen, indem die gesprochene, natürliche Sprache durch Computermodelle automatisiert verarbeitet wird (vgl. BSI, 2023). Mittlerweile gibt es eine Vielzahl an unterschiedlichen KI-Sprachmodellen weltweit, deren Hersteller sich sowohl mit den Chancen der Sprachmodelle als auch mit deren IT-Sicherheitsrisiken beschäftigen. Nachfolgend erhalten Sie einen Einblick in die derzeit bekanntesten Sprachmodelle.

ChatGPT

Das öffentliche Bereitstellen des Prototyps ChatGPT (der auf den Grundprinzipien der neuronalen Netze basiert) Ende 2022 seitens der Firma OpenAI führte zu einer verstärkten Diskussion über Möglichkeiten und Grenzen der künstlichen Intelligenz – in Fachkreisen, aber auch unter Laien. Die Anwendungsmöglichkeiten im Gesundheitswesen scheinen vielfältig und reichen von Diagnose-Unterstützungssystemen über eine Begleitung bei der Entscheidungsfindung bezüglich der passenden Therapie bis hin zur Erstellung von Arztbriefen. Wichtig ist es, den Output von ChatGPT kritisch zu hinterfragen und die Zuverlässigkeit zu prüfen und daher ChatGPT den Patienten und Patientinnen nicht ohne Begleitung eines Experten in Gesundheitsfragen zur Verfügung zu stellen. Denn im Gegensatz zu Suchmaschinen, die verschiedene Quellen mit variierender Seriosität wiedergeben, gibt ChatGPT nur eine einzige Antwort aus, die schnell zu Verunsicherung und Fehlinterpretation führen kann. Ziel des Einsatzes sollte u. a. eine Verbesserung der Versorgungsstrukturen, auch im ländlichen Raum, sowie eine aktive Mitgestaltung der Entwicklung und des Einsatzes von ChatGPT durch die Gesundheitsakteure sein. Eine Kombination aus Applikationen wie ChatGPT und hinterfragenden, empathischen menschlichen Expertinnen und Experten scheint derzeit vielversprechend (vgl. Kurz et al., 2023).

Spracherkennungssoftware im Krankenhausinformationssystem (KIS)

Im Rahmen des Krankenhauszukunftsgesetzes (vgl. § 19 Abs. 1 Satz 1 Nr. 3 KHSFV) ist unter dem Fördertatbestand 3 die digitale Pflege- und Behandlungsdokumentation verankert. Ziel ist es, im verwendeten KIS effizienter und transparenter zu dokumentieren. Insbesondere wird die Einführung oder der Ausbau sprachbasierter Dokumentationssoftware unterstützt (vgl. BAS, 2023). Hierbei ist zu beachten, dass jeder Mensch und somit alle potenziellen Anwender/-innen ein eigenes Vokabular beim Einsprechen der Texte verwenden. Um den anfänglichen Schwierigkeiten in Bezug auf die Erkennungsraten der eingesprochenen Texte entgegenzuwirken, haben sich einige Softwarehersteller weiterentwickelt und setzen mittlerweile auf künstliche Intelligenz und insbesondere auf neuronale Netze. Diese kommen sowohl auf der Ebene des akustischen Modells (Phoneme oder kleinste gesprochenen Einheiten einer Sprache) als auch auf der Ebene des Sprachmodells (Häufigkeitserfassung von Wörtern) zum Einsatz (vgl. Nuance, 2019). Durch diese Neuerungen können nutzerspezifische Sprachmuster deutlich ausdifferenzierter etabliert werden. Auch hier sind natürlich das Trainieren und Korrigieren durch stetigen Input in das neuronale Netz essenziell (vgl. Lang, 2017).

Zusammenfassung

Der Begriff „Big Data“ bezeichnet große Datenmengen, die nicht mehr mit manuellen und herkömmlichen Methoden der Datenverarbeitung ausgewertet werden können. Eine oft zitierte Definition der Eigenschaften von Big Data stammt von Gartner und verwendet drei Dimensionen von Big Data:

- Volumen (engl. Volume) der Daten,
- Geschwindigkeit (engl. Velocity), mit der Daten erzeugt und verarbeitet werden,
- Vielfalt (engl. Variety) der erzeugten Daten.

Daraus entsteht ein Datenmix, der sich in drei Kategorien unterteilt:

1. Kategorie: Daten aus Kommunikation zwischen Personen, z.B. Daten, gewonnen aus sozialen Netzwerken,
2. Kategorie: Daten aus Kommunikation zwischen Personen und Diensten oder Maschinen, z.B. Daten durch Geldautomatennutzung,
3. Kategorie: Daten zwischen Diensten oder Maschinen, z.B. Sensordaten, GPS-Informationen.

Big Data bezeichnet zum einen die großen Datenmengen an sich und zum anderen Methoden, diese Datenmengen zu erfassen, zu speichern, zu bearbeiten und auszuwerten. Neuartige, schnelle Algorithmen ermöglichen die Verarbeitung großer Datenmengen, die nach Kombinationen von Merkmalen bzw. Korrelationen zwischen Mustern, die durch Zufall nicht richtig erklärt werden können, durchsucht werden. Big Data ermöglicht damit auch ein besseres Verständnis für Krankheiten im Allgemeinen.

Eine enge Verbindung besteht zwischen Big Data und den Methoden der künstlichen Intelligenz (KI), um diese großen Datenmengen auszuwerten. KI an sich stellt keine eigene einzeln zu betrachtende Technologie dar, sondern besteht aus einer ganzen Reihe von unterschiedlichen Technologien und Methoden. Um dieses intelligente Verhalten in Informatik-Anwendungen integrieren zu können, sind im Wesentlichen vier Kernfähig-

keiten notwendig: Wahrnehmen, Verstehen, Handeln und Lernen. Die wesentlichen Methoden, um KI-basierte Systeme zu trainieren, stellen das maschinelle Lernen (ML) sowie die künstlichen neuronalen Netze (KNN) und darauf aufbauend das Deep Learning dar. Lernen gilt als Schlüsseltechnologie der künstlich intelligenten Systeme. Das Ziel dieser Technologie ist die Generierung von „Wissen“ aus „Erfahrung“, indem Lernalgorithmen aus Beispielen ein komplexes Modell entwickeln. Mithilfe dieses Modells können dann Prognosen getroffen oder Entscheidungen generiert werden.

ML bietet sich insbesondere in solchen Fällen an, in denen genügend Beispieldaten vorhanden sind, aber der zu untersuchende Prozess zu komplex ist, um ihn analytisch beschreiben zu können. Um eine ML-Anwendung konstruieren zu können, müssen zunächst alle verfügbaren Daten in drei Kategorien eingeteilt werden: Trainingsdaten, Validierungsdaten und Testdaten.

Bei komplexeren Fragestellungen, die sich nicht in einen Algorithmus fassen lassen, da sie von einer großen Menge subtiler Faktoren abhängen, bietet sich die Anwendung von künstlichen neuronalen Netzen an. Die Grundidee der künstlichen Neuronen stützt sich dabei auf biologische Nervenzellen. Die passende Kombination vieler aneinandergereihter künstlicher Neuronen ergibt ein künstliches neuronales Netz. Bekommt ein künstliches Neuron einen Input in Form von bestimmten Datenbestandteilen, z. B. Pixeln, gewichtet es diese und gibt sie bei Überschreitung eines Schwellenwertes an das nächstgeschaltete Neuron weiter. Auf diese Art entsteht ein komplexes Netz, das auch sehr große Datenmengen analysieren und schwierige Probleme lösen kann.

Nach der Konstruktion eines KNN muss dieses für seine Aufgaben trainiert werden. Hierbei gibt es verschiedene Möglichkeiten, die vom Löschen und Hinzufügen neuer Verbindungen und Neuronen bis zu einer Änderung der Schwellenwerte reichen. Dabei wird unterschieden, ob das Lernen überwacht oder nicht überwacht wird, d. h. ob dem Algorithmus im Lernprozess Feedback durch den Anwender bereitgestellt wird oder nicht. Eine Unterscheidung zwischen überwachtem und nicht überwachtem Lernen ist in der Praxis oft schwierig und es wird eine Mischform genutzt, deren Funktion konsequenterweise als halb überwachtes Lernen bezeichnet wird.

Der Einsatz der künstlichen Intelligenz in der bildgebenden Diagnostik besteht in einer besseren und informationsverlustfreien Auswertung der gewonnenen Rohdaten, ohne dass Ausbildungsstand oder Tagesform des Untersuchers hierbei eine Rolle spielen.

Insbesondere bei biomedizinischen Modellen stellt sich die Frage, wie sich bei hoher Themenkomplexität unscharfe Daten klassifizieren und semantisch verarbeiten lassen. Dabei stellt die Fuzzy-Logik eine Methode zur Verfügung, die Abstufungen unterschiedlicher Wahrheitswerte ermöglicht. Die Fuzzy-Logik und die darauf basierende Steuerung (Fuzzy-Control oder Fuzzy-Steuerung) nähern sich dem Problem über den Weg des Alltagsdenkens (Common Sense) an und können Objekte und Systeme unscharf beschreiben.

Der demografische Wandel in Deutschland, ein akuter Fachkräftemangel an medizinischem Personal, Fortschritte in der Medizintechnik, die notwendige Vernetzung von Versorgungsstrukturen im ländlichen Raum sowie ein zunehmendes Gesundheitsbewusstsein der Bevölkerung sind Faktoren, die die Entwicklung der künstlichen Intelligenz im Gesundheitswesen maßgeblich beeinflussen. Bereits heute werden weltweit diverse KI-Systeme im Gesundheitswesen sowie in der Seniorenbetreuung konzipiert und erprobt.

Im privaten Raum hat sich überdies zunehmend der Gebrauch der Servicerobotik verbreitet. Diese KI-Anwendungen können bei alltäglichen Haushaltsaufgaben (z.B. Rasenmähen, Fensterreinigung) eingesetzt werden, als Security- und Überwachungssystem dienen oder Ältere und Pflegebedürftige im Alltag unterstützen. Die Servicerobotik kann zukünftig bis hin zu sogenannter sozialer Robotik führen. Beispiele hierfür sind die Robbe Paro oder der Care-O-Bot, die auf emotionaler Ebene mit geistig eingeschränkten Patienten kommunizieren sollen.

Auch sogenannte „digitale Zwillinge“ werden bereits in der Medizin erprobt und bieten ein immenses Potenzial in der zukünftigen Gesundheitsversorgung. Digitaler Zwilling steht synonym für digitaler Avatar. So können solche personalisierten Gesundheitsavatare z.B. im Bereich Diagnose- und Therapiemanagement, Diabetes-Management oder auch im Bereich des Pflegemanagements eingesetzt werden. Ein digitaler Gesundheitsavatar dient auch als Erklärungs- und Visualisierungskomponente und kann auch als multidimensionale Patientenakte eingesetzt werden. Sprachmodelle sind mittlerweile auch im Gesundheitswesen verstärkt zu finden. Eine Kombination aus Applikationen wie ChatGPT, Spracherkennungssoftware im KIS und der hinterfragenden, empathischen menschlichen Experten scheint derzeit vielversprechend. In den nächsten Jahren wird sich der Einsatz dieser noch prototypisch und im Rahmen von Forschungsprojekten eingesetzten Technologien in einem zunehmend digitalisierten Gesundheitswesen weiterverbreiten.

Aufgaben zur Selbstüberprüfung

- 1.1 Bitte beschreiben Sie die Parameter des 3-V-Modells.
- 1.2 Bitte beschreiben Sie das Grundprinzip von KI-Anwendungen in der bildgebenden Diagnostik.
- 1.3 Beschreiben Sie das Setting für die Erfassung der Lerndaten für das maschinelle Lernen für die KI-Anwendung aus Aufgabe 1.2.