



Die digitale Vermessung der Zukunft

Welche Rolle spielt Künstliche Intelligenz in Foresight zur Gestaltung von Nachhaltigkeitstransformationen?

Autor*innen:

Steffen Bauer
Ingo Kollosche
André Uhl
Gerard de Melo
Kerstin Fritzsche

Kurz gesagt

Nachhaltigkeitstransformationen sind komplex und von erheblichen Unsicherheiten gezeichnet. Die Zukunftsforschung zielt darauf ab, Trends, Faktoren und Wirkungsketten besser zu erkennen und so einen Beitrag zu erfolgsversprechenden Transformationspfaden zu leisten. Können Künstliche Intelligenz und Co. dabei helfen? Welche Fallstricke gibt es bei ihrer Anwendung?

Inhaltsverzeichnis

1. Nachhaltige Zukünfte erkunden	3
2. Die Debatte um die Digitalisierung der Zukunftsforschung.....	6
3. Methoden der Zukunftsforschung	8
4. Textmining für die Zukunftsforschung	11
4.1. Was ist Textmining?	11
4.2. Textmining als Methode der Zukunftsforschung.....	13
5. Garbage In, Garbage Out – Herausforderungen datengetriebener Ansätze ...	19
5.1. Datenerhebung	19
5.2. Datenauswertung	20
5.3. Datennutzung	21
6. Kann Künstliche Intelligenz Projektionen liefern?	24
7. Fazit	27
8. Literatur.....	29
9. Über die Autor*innen	32

1. Nachhaltige Zukünfte erkunden

Um den Klimawandel zu bremsen und die natürlichen Lebensgrundlagen zu erhalten, braucht es in zentralen gesellschaftlichen und wirtschaftlichen Bereichen – wie etwa Mobilität, Energieversorgung, Wohnen, Konsum oder Produktion – eine konsequente Transformation hin zu mehr Nachhaltigkeit und Gemeinwohl. Ob, wie und mit welchem Erfolg sich derart umfassende Wandlungsprozesse vollziehen, ist jedoch von einer Vielzahl und Vielfalt an Einflussfaktoren abhängig: Der gesellschaftliche Rückhalt kann schwinden oder zunehmen, das Erreichen ökologischer Kippunkte kann beschleunigtes Handeln erfordern, technologische Entwicklungen können neue Lösungen bieten, aber auch neue Herausforderungen mit sich bringen. Damit sind Nachhaltigkeitstransformationen erheblichen *Zukunftsrisiken* ausgesetzt. Diese Zukunftsrisiken besser zu verstehen, potenzielle Einflussfaktoren möglichst gut abzuschätzen und Wege zum Erreichen der Transformationsziele aufzuzeigen, sind zentrale Aufgaben der Zukunftsforschung.

„Der Zweck von Zukunftsstudien ist es, mögliche, wahrscheinliche und wünschenswerte Zukünfte zu entdecken oder zu erfinden, zu untersuchen, zu bewerten und vorzuschlagen.“

(Bell 2009), eigene Übersetzung

Zukunftsforschung beabsichtigt durch die Betrachtung möglicher Zukünfte einen Perspektivwechsel auf die Gegenwart und eine kreative Konstruktion alternativer Entwicklungsmöglichkeiten. Der Fokus auf wahrscheinlichste Zukünfte schränkt dabei den Möglichkeitsraum ein und erlaubt es so, unter Berücksichtigung spezifischer Faktoren, Bedingungen und Zeithorizonte konkretere Zukunftsbilder – beispielsweise für nachhaltigere Lebens- und Wirtschaftsweisen – zu entwerfen. Analysen wünschbarer Zukünfte gehen hingegen auf normative Absichten, Vorstellungen und Vorentscheidungen von Akteur*innen und Betroffenen ein. Die wissenschaftliche Zukunftsforschung sagt also nicht die Zukunft voraus. Vielmehr versteht und beforscht sie die gezeichneten Zukunftsbilder als gegenwärtige Reflexionen über die Zukunft. Damit hat die Zukunftsforschung zum Ziel, Orientierungswissen (*Denken über Zukunft ermöglichen*) und Handlungswissen (*Gestalten von Zukunft vorbereiten*) als Entscheidungsgrundlage in der jeweiligen Gegenwart zu schaffen.

Die Bedingungen für eine systematische Vorausschau und die Entwicklung und Analyse von Zukunftsbildern im Rahmen der Zukunftsforschung sind von Turbulenzen, Unsicherheiten, Unwägbarkeiten, Mehrdeutigkeiten sowie einer hohen Komplexität und neuartigen Mensch-Technologie-Konstellationen (Ramírez und Wilkinson 2016) gekennzeichnet. Vor diesem Hintergrund braucht es Methoden und Instrumente, die eine systematische Exploration relevanter Entwicklungen und Phänomene ermöglichen und es erlauben, Muster und Wirkungsbeziehungen zwischen einer Vielfalt von Faktoren zu erkennen. Auch in der Zukunftsforschung kommen daher zunehmend digitale Tools zum Einsatz, um große Datenmengen zu systematisieren und zu analysieren. Mithilfe von Text-Mining-Verfahren und Social-Media-Datenanalysen kann bspw. eine große Anzahl an Quellen automatisiert ausgewertet werden, um thematische Zukunftstrends zu identifizieren. Allerdings fehlt bislang ein Überblick über die Anwendungsmöglichkeiten digitaler Tools für die Zukunftsforschung und eine Betrachtung ihrer Herausforderungen und Chancen.

Dieses Positionspapier leistet einen Beitrag, um diese Lücke zu schließen. Es skizziert dafür den Stand der Debatte und erklärt, welche Rolle Künstliche Intelligenz (KI, siehe Box 1) und Daten für die Zukunftsforschung bereits heute spielen und ggf. in Zukunft spielen können. Insbesondere geht es darauf ein, inwiefern digitale Tools helfen können, komplexe Nachhaltigkeits-transformationen besser zu verstehen, und wo ihre Grenzen liegen. Damit soll das Papier helfen, KI und andere digitale Ansätze als Werkzeuge zur Erkundung und Gestaltung nachhaltiger Zukünfte besser zu verstehen und möglichst effektiv einzusetzen.

Box 1: Was ist Künstliche Intelligenz?

Künstliche Intelligenz (KI) ist ein breites Fachgebiet der Informatik, dessen Ziel die Entwicklung von Programmen ist, die menschliche Intelligenz nachahmen können. Das Forschungsfeld KI ist seit Mitte der 1950er Jahre etabliert und besteht inzwischen aus einer Vielzahl sehr unterschiedlicher und quasi-eigenständiger Subdisziplinen. Es bestehen zudem enge interdisziplinäre Bezüge zur Robotik, Logik, Data Science, Statistik, Kognitionswissenschaft, Psychologie, Linguistik, Philosophie und den Neurowissenschaften.

Maschinelles Lernen (ML) ist ein Teilbereich der KI-Forschung. Während bei der traditionellen Softwareentwicklung die Arbeitsschritte eines Programms vom Menschen vorgegeben werden, erlaubt das Maschinelle Lernen ein automatisiertes Erlernen von Verhalten anhand von Daten mit Hilfe komplexer statistischer Verfahren. Dabei wird mit Hilfe eines Lernalgorithmus ein Modell trainiert, das dann im Laufe des Prozesses eine jeweils festgelegte Aufgabe immer besser erfüllt.

Überwachtes Lernen ist die häufigste Form des Maschinellen Lernens. Hier wird die zu erfüllende Aufgabe, etwa eine Prognosefragestellung, anhand konkreter Beispiele aus der Vergangenheit erlernt. Oft werden die Werte einer konkreten Zielgröße mit Hilfe anderer Größen (sog. Einflussgrößen) vorhergesagt. Aus den historischen Beispieldaten wird dann ein Modell für den Zusammenhang zwischen den beiden Größen erstellt, mit dem anschließend Prognosen für neue Daten getroffen werden können. Das Überwachte Lernen kann eingeteilt werden in Fragestellungen der Regression, bei denen quantitative Werte prognostiziert werden sollen, und in solche der Klassifikation, bei denen es um qualitative Werte geht (wie bspw. kreditwürdig: Ja/Nein).

Deep Learning ist eine spezifische Familie von Methoden innerhalb des Maschinellen Lernens. Es verwendet vom Gehirn inspirierte Künstliche Neuronen, die zusammen ein Netz bilden und in Schichten angeordnet sind. Das „Deep“ im Namen des Forschungsansatzes bezieht sich dabei auf eine große Anzahl an Schichten, so dass die künstlichen Neuronen durch eine Verkettung von Operationen noch komplexere Zusammenhänge erlernen können.

2. Die Debatte um die Digitalisierung der Zukunftsforschung

Die Zukunftsforschung beschäftigt sich überwiegend mit langfristigen Zeiträumen und komplexen gesellschaftlichen Phänomenen und verfolgt ein tendenziell qualitatives Vorgehen. Darin unterscheidet sie sich von Algorithmen-gestützten Forecasting-Modellen, die sehr spezifische Phänomene auf eher kurzfristigen Zeiträumen betrachten. Daher überrascht es nicht, dass der Diskurs in der Community der Zukunftsforscher*innen zum Einsatz von Datenanalyse und KI tendenziell von einer skeptischen Haltung geprägt ist. So betonen viele Expert*innen, dass auch im digitalen Zeitalter die Interpretation von Informationen menschliche Arbeit bleiben wird. Ein Vertreter ist hier beispielsweise der niederländische Zukunftsforscher Rudy van Belkom in einer Reflexion über den möglichen Einfluss von KI auf seine Arbeit (van Belkom 2020). Er betont, dass heutige KI letzten Endes nur eine fortgeschrittene Form von Statistik sei und darauf basiere, dass die Zukunft wie die Vergangenheit sei.

Als ergänzendes Hilfsmittel werden die Vorteile digitaler Technologien aber durchgehend anerkannt. In der deutschen Diskussion äußerten sich in diesem Sinne u.a. Axel Zweck und Matthias Braun. Danach seien technische Hilfsmittel für die Vorselektion und Analyse der kontinuierlich ansteigenden Informationsmenge unabdingbar. Zugleich aber betonen sie, dass trotz aller Fortschritte in der Entwicklung intelligenterer Computertechnologie noch keinerlei Aussicht besteht, strategische Vorausschau vollständig oder auch nur näherungsweise durch Algorithmen ersetzen zu können (Zweck und Braun 2021).

Im Gegensatz dazu steht der besonders optimistische Beitrag von Anne Boysen, der in Folge zu einer der am meisten zitierten Veröffentlichungen in diesem Themenfeld wurde (Boysen 2020). Die Autorin prophezeit, dass Big Data und KI die Entdeckung von Trends und Datenmustern ermöglichen werden, die ansonsten völlig übersehen würden. Boysen setzt zudem große Hoffnung in technische Lösungen, um die Voreingenommenheit (Bias) von Algorithmen zu reduzieren oder zu vermeiden. Als Fazit kommt sie zu dem Ergebnis, dass Methoden des Datamining und des Maschinellen Lernens unparteilichere Analysen erlauben als menschlichen Expert*innen möglich ist. Ein Überblicksbericht, der Veröffentlichungen zur Suche nach schwachen Signalen im Rahmen der Unternehmens-Foresight auswertete, kam zu ähnlichen Ergebnissen. Danach stelle die menschliche Voreingenommenheit ein Hauptproblem dar, das nur durch stärkere Investition in Suchstrategien, in die

Datenqualität und insbesondere in die Automatisierung reduziert werden könne (Mühlroth und Grottke 2018).

Ansonsten stammen die optimistischsten Stimmen meist nicht aus der eigentlichen Zukunftsforschung und Foresight-Community, sondern von Vertreter*innen quantitativ orientierter Fächer, die ein persönliches Interesse an komplexerer Vorausschau entwickelt haben. Ein Beispiel ist der iranische Energie-Experte Reza Hafezi, der für die Kombination von qualitativen und quantitativen Modellen eintritt und bei bestimmten Anwendungsfällen aus dem Energiebereich zeigte, dass solch eine Kombination bessere Ergebnisse liefert als ein rein qualitatives oder quantitatives Vorgehen (Hafezi 2020).

Wie relevant das Thema KI in der Zukunftsforschung inzwischen ist, zeigte ein im März 2021 stattgefundenes virtuelles Arbeitsgruppentreffen des Netzwerks Zukunftsforschung, das sich dem Thema „Kann KI Zukunftsforschung?“ widmete. Es wurde vom Masterstudiengang Zukunftsforschung (FU Berlin) und dessen Alumni Club mitorganisiert und von vielen Foresight-Praktiker*innen besucht. Dabei aufgeworfene Fragen waren unter anderem: Stellt KI eher eine Konkurrenz oder eine Unterstützung der Zukunftsforschung dar? Werden neue (unerfüllbare) Erwartungen an Foresight geweckt? Und wird die Nutzung KI-gestützter Foresight zum Privileg weniger oder kann sie auch eine eher demokratisierende Wirkung entfalten?

Box 2: Ein digitaler Zwilling der Erde als Prognosestool?

Ein aufwendiges Vorhaben einer rein quantitativen Modellbildung, das zur Entwicklung von Zukunftsszenarien im Kontext des Klimawandels beitragen kann, ist das von der Europäischen Union Anfang 2021 gestartete Projekt Destination Earth (DestinE). Innerhalb einer Dekade soll ein möglichst umfassender und detaillierter Digital Twin der Erde, d.h. eine auf Echtzeitdaten basierende Simulation, erstellt werden.

Zentrale Teilprojekte für die nächsten drei Jahre sind die Erstellung eines Digital Twins für extreme Naturereignisse, sowie eines Twins, der die menschliche Anpassung an den Klimawandel darstellt. Ziel von DestinE ist es unter anderem, damit die Auswirkungen und die Effizienz von europäischen Regulierungsinitiativen frühzeitig simulieren zu können (Bauer et al. 2021).

3. Methoden der Zukunftsforschung

Die Zukunftsforschung schaut über den Tellerrand einzelner Disziplinen hinaus und bedient sich eines breiten Fächers unterschiedlicher Verfahren: Klassische Methoden der Zukunftsforschung wie Szenario-Prozesse, Zukunftswerkstätten oder Delphi-Befragungen gehören ebenso dazu wie partizipative Verfahren wie etwa Design Fiction, die einen kreativen Ansatz der Wissensgenerierung verfolgen. Einen guten Überblick über die unterschiedlichen Ansätze der Zukunftsforschung bietet Rafael Poppers vielfach zitierter „Foresight Diamond“ (Popper 2008). In diesem diamantförmigen Schaubild sind insgesamt 44 methodische Ansätze zusammengetragen. Diese sind nach vier Ausprägungen bezüglich ihrer jeweils primär genutzten Wissensquellen (Kreativität, Kompetenz, Interaktion und Evidenz) sowie in einem Spektrum von qualitativ, über semi-quantitativ bis quantitativ (unter der Verwendung jeweils unterschiedlicher Schriftarten für die Ansätze) verortet.

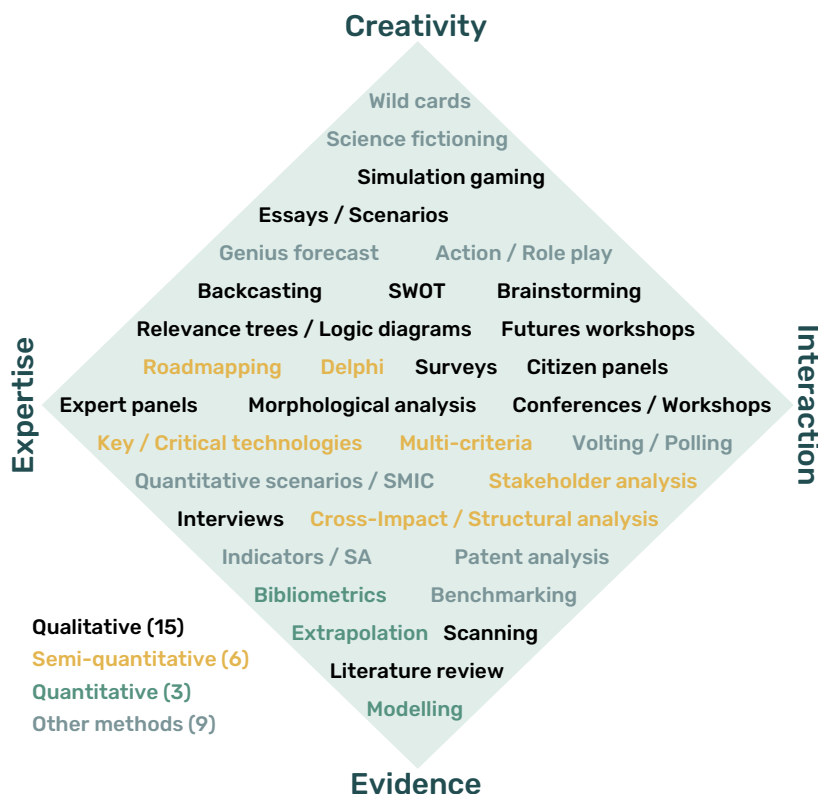


Abbildung 1: Diamant der Foresight Methoden

(Quelle: Popper, Rafael (2008): Foresight Methodology. In: L. Georghiou, J. Cassingena, M. Keenan, I. Miles und R. Popper (Hg.): The Handbook of Technology Foresight: Concepts and Practice. Cheltenham: Edward Elgar Publishing. Seite 44-88.)

Während kreativitätsbasierte Methoden originelles und phantasievolles Denken erfordern, wird anhand von evidenzbasierten Methoden versucht, ein bestimmtes Phänomen mit Hilfe zuverlässiger wissenschaftlicher Quellen zu erklären. Bei kompetenzbasierten Methoden kommt es auf die Implementation der Fachexpertise und des fachspezifischen Erfahrungswissens von Expert*innen zu einem bestimmten Thema an. Interaktionsbasierte Methoden hingegen beinhalten partizipative und integrative Elemente, zu denen durchaus auch Laien beitragen können.

Natürlich gibt es methodische Mischformen, die sich nicht eindeutig in dieser Art und Weise klassifizieren lassen. Eine strikte Unterscheidung zwischen z.B. Expertise und Interaktion als Wissensquellen ist in der praktischen Anwendung einzelner Methoden und vor dem Hintergrund ihrer Zielstellungen nicht immer sinnvoll. Als ein Beispiel sei hier die Delphi-Methode genannt, die – gerade in ihrer modernen Form als Real-Time-Delphi – sowohl ein hohes Maß an Expertise als auch an Interaktion erfordert. Auch könnte auf weitere Methoden zurückgegriffen werden, welche im Diamanten nicht enthalten sind (z.B. Zukunftswerkstatt, Design Fiction oder Social-Media-Datenanalyse). Dennoch ermöglicht Poppers Konzept einen hilfreichen ersten Zugang, um sich mit den methodischen Ansätzen der Zukunftsforschung vertraut zu machen. Digitale Tools können in diesem methodischen Spektrum insbesondere dann eingesetzt werden, wenn es darum geht, eine Evidenzbasis für Annahmen über die Zukunft zu schaffen. Folgende Beispiele können dafür genannt werden:

- Digitale Tools können das Wissensmanagement unterstützen, etwa die Organisation von Rohdaten und bereits vorhandenen Wissensbeständen.
- Textminingverfahren, aber auch ausgefeilte Möglichkeiten für die Datenvisualisierung, können dabei helfen, große Datenmengen in einem schnelleren Zeitraum zu erfassen und besser auszuwerten. Besonders relevant für die Zukunftsforschung ist dabei, dass dadurch bestimmte kurzfristige Trends, sog. Mikrotrends oder allgemein kurzzeitig und massenhaft auftretende Phänomene leichter aufdecken lassen und unter Umständen auch besser eingeschätzt werden können.
- Damit verbunden erlauben KI-Tools und datengestützte Verfahren, bisher wenig beachtete Datensätze für die Zukunftsforschung besser oder überhaupt erstmals dienstbar zu machen. Das betrifft etwa Bilder, Videos oder Metadaten, die durch intelligente digitale Verfahren in den Analyse-prozess integriert werden können. Auch durch das viel beschworene Netz der Dinge („Internet of Things“, IoT) werden

Unmengen an Daten aus unterschiedlichsten Bereichen generiert, die durch den Einsatz von KI für die Zukunftsforschung aufbereitet werden könnten.

- Gegebenenfalls werden zudem in der Zukunft Tools möglich, die Bewertungen vornehmen können und so die automatisierte Auswertung großer Informationsmengen unterstützen. Dies gilt insbesondere für die automatische Bewertung der Vertrauenswürdigkeit von (Text-)Quellen und für die algorithmische Identifikation von Experte*innen.

All diese Verfahren sind stark von ihrer zugrundeliegenden Datenbasis abhängig. Kapitel 5 geht daher auf Fallstricke und Herausforderungen der Nutzung von KI und großen Datenmengen (Big Data, siehe Box 3) für die Zukunftsforschung ein. Im Folgenden wird zunächst der Einsatz von Textmining für ausgewählte Methoden der Zukunftsforschung genauer betrachtet.

Box 3: Was ist Big Data?

Der Begriff Big Data steht für die Möglichkeit der Auswertung einer sehr großen Menge heterogener, meist nur schwach strukturierter Daten aus verschiedenen Quellen in einem schnellen Datenstrom. Um dies technisch zu ermöglichen, mussten neue Methoden der, insbesondere parallelen und verteilten Datenverarbeitung entwickelt werden. In einem umgangssprachlichen Sinne, steht Big Data als Schlagwort außerdem auch für das Sammeln und Auswerten von Datenmengen und sich daraus ergebenden gesellschaftlichen Konsequenzen.

4. Textmining für die Zukunftsforschung

4.1. Was ist Textmining?

Der Begriff Textmining ist nicht scharf definiert und kann heutzutage als ein Teilgebiet des Natural Language Processing (NLP) angesehen werden. NLP ist ein KI-Gebiet mit älterer Tradition, das sich mit der automatisierten Sprachverarbeitung allgemein beschäftigt. Es umfasst damit auch außerhalb des Textmining liegende Themen, wie beispielsweise das automatische Übersetzen.

Unter Textmining, manchmal auch Text Data Mining genannt, versteht man digitale Techniken, mit denen der jeweils als relevant betrachtete Informationsgehalt von un- oder schwachstrukturierten Textdaten modelliert und extrahiert werden kann. Im Rahmen der Anwendung in der Wirtschaft (bspw. im Marketing) wird dafür international häufig auch der Begriff Text Analytics verwendet. Eine entsprechende algorithmische Analyse erkennt beispielsweise die verwendeten Eigennamen oder die den Texten zugrunde liegende emotionale Stimmung. Textmining-Programme können auch Dokumente nach bestimmten Kriterien klassifizieren oder nach Ähnlichkeit gruppieren. Zu den beforschten Gebieten gehört auch die automatische Zusammenfassung des Inhalts eines längeren Textes. Der Begriff Textmining umfasst in der Praxis ein weites Feld von sehr einfach funktionierenden Softwaretools bis hin zu theoretisch denkbaren zukünftigen Systemen, die komplizierte Texte wie Fachbücher „verstehen“ können.

Man kann die bestehenden Text-Mining-Ansätze vereinfacht in drei Teile gliedern:

- Beim *Information Retrieval* werden statistische Messwerte genutzt, um Textdokumente zu charakterisieren, z.B. über die Anzahl bestimmter Wörter.
- Bei der Nutzung von *Natural Language Processing* werden dagegen auch tieferliegende linguistische Strukturen einbezogen. Typische Techniken sind die Zerlegung eines Satzes in seine grammatikalischen Bestandteile und die Zuordnung von Wörtern eines Textes zu Wortarten. In einem normalen Text kommen häufig sogenannte Koreferenzen vor, d.h. zwei oder mehrere unterschiedliche sprachliche Ausdrücke bezeichnen dasselbe. Damit eine automatische Verarbeitung möglich ist, müssen diese zuvor aufgelöst werden, was mit Techniken des NLP möglich wird.

- Als dritter Ansatz kann die *Knowledge Extraction* angesehen werden. Hier werden Methoden entwickelt, die ein automatisiertes semantisches Verständnis von Texten erlauben und den Inhalt des Textes darstellen können.

Die Fortschritte im Textmining in den letzten zwei Jahrzehnten werden auf die Anwendung von Techniken des Maschinellen Lernen zurückgeführt. Allgemein hat das letzte Jahrzehnt dank Deep Learning zu besonders großen Verbesserungen in der automatischen Sprachverarbeitung geführt. Zuletzt wurden dabei Künstliche Neuronale Netze mit Milliarden von Parametern entwickelt. Entsprechend aufwändig sind auch die Trainingsprozesse und die damit verbundenen Rechenkosten, die inzwischen Millionenbeträge erfordern (Benaich und Hogarth 2020). Unter Nachhaltigkeitsaspekten stellt der Energieverbrauch beim Training von Modellen des Maschinellen Lernens ein Problem dar (siehe dazu Box 4).

Allerdings wird dabei auch das weiterhin unzulängliche Welt- und Kontextwissen deutlich. Die Frage wie man Weltwissen geeignet lernt, repräsentiert und diesbezüglich schlussfolgert, stellt weiterhin eine der größten Herausforderungen für die KI-Forschung dar. Dies führt dazu, dass entsprechende Systeme trotz der technischen Weiterentwicklungen weiterhin Fehler machen, die ein Mensch so kaum begehen würde. Fortschritte im Text Mining, die zu Algorithmen führen, die ihre Aufgaben akkurater erledigen, werden allgemein erwartet.

Box 4: Maschinelles Lernen verbraucht erhebliche Energiemengen

Die Erfolge des Maschinellen Lernens und des Deep Learning beruhen zu einem großen Teil auf der Nutzung vermehrt zur Verfügung stehender Rechenleistung. Der damit verbundene Energieverbrauch und CO₂-Fußabdruck ist in den letzten Jahren zunehmend in den Blick geraten. Einer Schätzung zufolge kann das Training eines Sprachmodells in Form eines Künstlichen Neuronales Netzes in besonderen Extremfällen sogar 300.000 kg CO₂ produzieren (Strubell et al. 2019). Dies entspricht dem CO₂-Fußabdruck von ca. 140 Hin- und Rückflügen zwischen Frankfurt und New York. Dazu kommt ein Trend zu immer größeren Sprachmodellen sowie noch größeren multimodalen Modellen (Benaich und Hogarth 2020). Zu den Faktoren, die den sich daraus ergebenden CO₂-Fußabdruck beeinflussen, gehört die Lage des benutzten Servers, der verwendete Strommix, die Dauer des Trainings und die verwendete Hardware (Dhar 2020).

4.2. Textmining als Methode der Zukunftsforschung

Horizon Scanning:

Zu den wichtigsten Instrumenten der strategischen Früherkennung von Veränderungen, gehört das sogenannte Horizon Scanning. Neben dem Monitoring bekannter Trends geht es hierbei um die Identifikation neuer, relevanter Entwicklungen innerhalb eines festgelegten Scanfeldes. Die frühzeitige Erkennung von Mikrotrends, häufig auch schwache Signale genannt, soll dabei die Vorbereitung auf die nahe Zukunft erleichtern, z.B. eine Diskussion von Chancen wie Risiken neuer Entwicklungen und dadurch bessere Entscheidungen ermöglichen. Angestrebt wird mit dem Horizon Scanning damit sowohl eine „Kartierung der Umfeldler“ wie auch eine „Radarfunktion“ (Behrendt et al. 2015). Ein Horizon Scanning ist ein sehr ressourcenintensiver Prozess und wird daher meist nicht kontinuierlicher durchgeführt.

Verwendete digitale Hilfsmittel für solch ein Horizon Scanning sind eine eigene Datenbank, Suchmaschinen, Umfrage-Tools, Web-basierte Quellendokumentation und bei Teamarbeit ein gemeinsames Dokumentenmanagement bzw. eine entsprechende Kollaborationsplattform. Besonders relevante Quellen sind typischerweise Zukunftsstudien, Wissenschaftsredaktionen, Web-Portale, Verbände sowie Trend- und Newsletter. In der Unternehmens-Foresight kommen allerdings zunehmend auch elaboriertere, datengestützte Methoden beim Horizon Scanning zum Einsatz. Dies gilt auch für verwandte Einsatzgebiete wie das Technologie-Scouting (Bovenschoolte et al. 2021).

Die Scoping-Phase dient im ersten Schritt der Präzisierung des Informationsbedarfs und der grundlegenden Auswahl des Untersuchungsgegenstandes. Im zweiten Schritt wird das Scanfeld genauer bestimmt und die thematische Bandbreite festgelegt, wie auch die auszuwertenden Sprachräume und die relevante zeitliche Perspektive. Dazu gehört auch die Festlegung, ob das Scanning explorativ breit oder themenorientiert angelegt sein soll. In der Scoping-Phase müssen menschliche Projektverantwortliche Entscheidungen treffen, die ihnen keine Maschine oder Algorithmus erleichtern oder abnehmen kann. Die nun folgende Scanning-Phase legt in ihrem ersten Teil (Schritt 3 in Abb. 2) die relevanten Methoden fest (Web-Recherche, Interviews, Umfragen etc.), wie auch die auszuwertenden Quellensorten und die Art der Dokumentation der Ergebnisse. Auch hier sind wieder menschliche

Entscheidungen erforderlich, die die Ausrichtung des Horizon Scanning Projektes betreffen.

Grafik 2 stellt den Workflow eines Horizon Scanning Prozesses dar und wurde in dieser Form für die Etablierung eines umweltforschungs- und umwelpolitikbezogenen Scanning System beschrieben. Welche der drei Phasen, bzw. sieben Einzelschritte, können durch das Textmining und ggf. weitere KI-Tools unterstützt werden?

Hauptanwendungsgebiet von Textmining ist nun die anschließende eigentliche Recherche von Themen unter Berücksichtigung des Scanfilter (der markierte Schritt Nr. 4). Mittels Textmining könnten sehr große unstrukturiert vorliegende Informationsbestände nach Begriffen und Begriffsbeziehungen durchsucht und statistisch ausgewertet werden. Eine (teil-)automatisierte Erfassung ist dabei in der Lage, eine deutlich größere Menge solcher Textquellen zu berücksichtigen, und dies in kürzerer Zeit. Die Auswahl erfolgt nach Neuheit sowie einer Bewertung der Relevanz. Letztere entweder in Form eines human-in-the-loop Ansatzes oder bei zukünftigen vollautomatischen Systemen in Form einer quantitativen Bewertungsmöglichkeit. Die Ergebnisse könnten automatisch in einer Datenbank abgelegt und nach festgelegten Kategorien dokumentiert werden. Der menschliche Analyst muss allerdings weiterhin für die Umsetzung der in der Scoping-Phase festgelegten Ziele und Leitfragen Sorge tragen und das Textmining-Assistenzsystems entsprechend steuern.

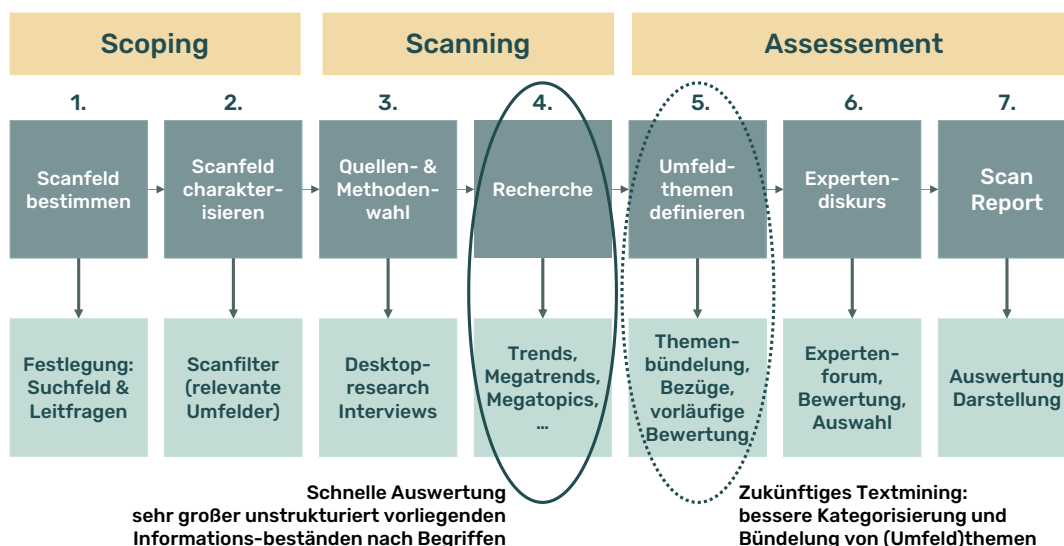


Abbildung 2: Einsatz von Textmining im Horizon Scanning

(Quelle: Behrendt, Siegfried; Scharp, Michael; Zieschank, Roland; van Nouhuys, Jo (2015): „Horizon Scanning“ und Trendmonitoring als ein Instrument in der Umweltpolitik zur strategischen Früherkennung und effizienten Politikberatung. Konzeptstudie. Hg. v. Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit. Berlin. Seite 59).

Für den englischsprachigen Raum gibt es bereits jetzt erste auf Textmining basierende Unterstützungstools für Zukunftsforscher*innen, wie z.B. die Software „Shaping Tomorrow“. Diese kann prognostische Sätze, die eine bestimmte Form haben, nämlich „In der Zukunft wird A der Fall sein“ sehr schnell und großflächig aus dem Internet extrahieren und in einer entsprechenden Datenbank für eine (teil)automatische Verwertung zugänglich machen (Kehl et al. 2020).

Semantische Technologien spielen bei der Suche im Web zunehmend eine Rolle, siehe z.B. Google Knowledge Graph, und werden es künftig ermöglichen, nicht nur bekannte Suchbegriffe zu verwenden, sondern ggf. auch Bedeutungsbeziehungen zu verwandten und gegebenenfalls noch nicht bekannten Suchbegriffen in die Recherche einzubeziehen (Behrendt et al. 2015). Auch Ambiguitätstoleranz ist bei Verfahren des Natural Language Processing zunehmend möglich.

Weitere Fortschritte bei der automatisierten Bewertung von Quellen könnten die Möglichkeiten der Nutzung in die Recherchephase weiter erhöhen. Im Rahmen von KI-basierten Unterstützungstools für das journalistische Faktenchecken finden dafür relevante Entwicklungen statt. Derzeitiger Stand ist der erfolgreiche Umgang mit einfachen deklarativen Sätzen, während komplexere Sätze oder implizite Behauptungen Schwierigkeiten bereiten (Funke 2019)

Besteht Interesse an fremdsprachigen Quellen, können diese mittels Maschinellen Übersetzens ebenfalls berücksichtigt werden. Weitere KI-Techniken können zunehmend auch eine multimodale Auswertung ermöglichen. Somit könnten auch andere Quelltypen für eine Auswertung berücksichtigt werden, wie etwa Audioaufnahmen (z.B. Podcasts) und Videos. Eine solche Teilautomatisierung kann damit relevante Informationen nutzen, die ansonsten unter der Publikations- und Datenflut verborgen blieben.

Das Ergebnis einer solchen Scanning-Phase ist eine erste Sammlung von möglicherweise relevanten Einzelthemen, die dann in der letzten Phase, dem Assessment, ausgewertet und validiert werden. Im ersten Teil dieser Assessmentphase (Schritt 5 in Abb. 2) muss die Vielzahl der gesammelten Themen gebündelt werden. Die Auswahl der Themen, welche zu einem sogenannten Umfeldthema zusammengefasst werden, ist dabei heutzutage noch eine menschlich-kreative Leistung durch die Teammitglieder. Die gebündelten Themen werden dazu üblicherweise in verschiedene Kategorien eingeordnet. Häufig wird dabei zwischen den Kategorien Trend, Megatrend,

Emerging Issue, Schwachen Signalen und Wild Card, also einem unerwarteten, folgenreichen Ereignis, unterschieden.

Zukünftige Textmining-Systeme, die eine tiefergehende semantische Analyse als bisherige Tools erlauben, könnten zu einer besseren, beispielsweise schnelleren, Identifizierung, Bündelung und Kategorisierung von Umfeldthemen führen. Um darauf hinzuweisen, dass solche Systeme in der Praxis noch nicht umsetzbar sind, wurde in Abb. 2 der Einsatz von Textmining mit der gestrichelten Linie als hypothetisch markiert.

Im 6. Schritt geht es um die Validierung der Ergebnisse, meistens in Form von Interviews oder Workshops mit Expert*innen. Hier könnten zukünftige KI-Systeme, die über Textmining hinausgehen, durch entsprechende Bewertungen bei der Auswahl der Teilnehmer helfen. Gegenwärtig und in der vorhersehbaren Zukunft kann die Interpretation des Menschen bei diesen kritischen Kernaufgaben jedoch nicht ersetzt werden, da dort Fragen der Interpretation, der Bewertung und Kontextualisierung im Fokus stehen (Bosse et al. 2018).

Zusammengefasst kann durch KI in einem Horizon Scanning-Prozess das Analyse-Team bisher lediglich von Routinetätigkeiten entlastet werden, so dass im Idealfall für die menschliche Kreativität und das kritische Denken – beide zentral für die Zukunftsforschung – mehr Zeit bleibt.

Szenario-Entwicklung:

Eine zentrale Methodik der Zukunftsforschung ist die Szenariotechnik. Dabei wird eine hochgradig unsichere Zukunft durch verschiedene mögliche Weltverläufe beschrieben. Es gibt dabei eine Vielzahl verschiedener Methoden der Entwicklung von Szenarien. Ziel ist es dabei, den Status quo in Frage zu stellen.

Avancierte Textmining-Tools, aber auch quantitative Datenanalysen können im Grunde schon jetzt den Szenariementwurf auf eine breitere Datenlage stellen und damit empirisch besser fundieren. Multiperspektivität kann durch die Nutzung verschiedener Datenquellen und Untermengen derartiger Quellen sowie durch den Einsatz mehrerer Algorithmen erreicht werden. Ohne eine etablierte und standardisierte methodische Vorgehensweise ist ein semiautomatisierter Prozess allerdings meist zu aufwendig, um außerhalb von Forschungsprojekten für die Anwendung praktikabel zu sein.

Noch spekulativ sind Hoffnungen, eines Tages mit Hilfe von KI und neuen methodischen Ansätze, die Konsistenz der entworfenen Szenarien relativ zu vorgegebenen Argumente und Fakten quantitativ bewerten zu können. Ein noch anspruchsvollerer Schritt wäre die automatisierte Generierung von Szenarien durch entsprechend leistungsfähige Sprachmodelle und universale Modelle mit vielfältigen Fähigkeiten. Davon ist man allerdings aufgrund der Schwierigkeiten im kausalen Verständnis und Weltwissen von KI-Systemen noch weit entfernt.

Zusammenfassend lässt sich festhalten, dass viele Phasen der Szenariotechnik in der Praxis heutzutage nicht automatisierbar sind. Hierzu zählen: die Beschreibung des aktuellen Kontextes; die Auswahl der geeigneten Variante der Szenariomethode; die Benennung und Kurzbeschreibung jedes Szenarios anhand von Hauptmerkmalen sowie die mit den jeweiligen Szenarien verknüpften strategischen Empfehlungen.

Dieses Kapitel betrachtete Textmining als eine der wichtigsten Möglichkeiten, die Datengrundlage für die Zukunftsforschung zu verbessern. Im nächsten Kapitel werden die bei datengetriebener KI-Ansätze, daher dem Maschinellen Lernen, bestehenden grundsätzlichen Herausforderungen zusammengefasst. Diese betreffen die Bereiche Datenerhebung, Datenauswertung und Datennutzung.

Box 5: Exkurs in die Wirtschaft – KI & Big Data als Prognosetools

Künstliche Intelligenz und die Techniken der Data Science werden heutzutage bereits in verschiedenen Kontexten für Vorhersagen eingesetzt. Haupteinsatzgebiet ist dabei gegenwärtig die Wirtschaft. Die dort adressierten Fragestellungen unterscheiden sich jedoch wesentlich von denen, die die Zukunftsforschung behandelt. Typischerweise geht es im Bereich der Wirtschaft anders als in der Zukunftsforschung um Vorhersagen in deutlich abgegrenzten und überschaubaren Bereichen mit einer begrenzten Anzahl von Variablen. Häufig liegt der Fokus dabei auf der nahen Zukunft. Der erwartete Nutzen ist zudem üblicherweise direkt quantifizierbar (Agrawal et al. 2018).

Ein Beispiel aus der Wirtschaft sind die von Onlineshops und digitalen Plattformen eingesetzten Empfehlungsdienste. Diese lernen auf Grund der vorliegenden Nutzerdaten, immer besser die Interessen der Benutzer an einem Onlineinhalt vorherzusagen und können so personalisierte Empfehlungen abgeben. Der Erfolg lässt sich dabei auf relativ einfache Art messen, beispielsweise in Form von verkauften Produkteinheiten, Webseiten-Clicks oder entsprechenden Verweilzeiten. Weiterhin lassen sich durch Ansätze des Maschinellen Lernens die zukünftige Entwicklung von Zeitreihen prognostizieren. So kann zum Beispiel der Zeitpunkt abgeschätzt werden, ab dem eine Maschine voraussichtlich versagt. So kann rechtzeitig eine Wartung erfolgen und ein Ausfall der Maschine vermieden werden (*Predictive maintenance*).

Datenanalyse für Unternehmen wird zudem unter dem Schlagwort *Predictive analytics* zu Unterstützung von Managemententscheidungen genutzt. Unternehmen verwenden *Predictive analytics* beispielsweise an, um Kundenabwanderungen zu verhindern oder Störungen der Lieferkette frühzeitig zu antizipieren. Die schon begonnene Einführung von digitalen Zwillingen entlang der Wertschöpfungskette eines Unternehmens verspricht dabei weitere Verbesserungen bei den Vorhersagemöglichkeiten durch die Nutzung von Echtzeitdaten in Simulationen, wobei auch KI-Techniken zum Einsatz kommen (Mohn et al. 2020). Der Markt zur Analyse von Geschäftsdaten wird gegenwärtig nur von einer Handvoll global agierender, meist US-amerikanischer IT-Konzerne dominiert.

5. Garbage In, Garbage Out – Herausforderungen datengetriebener Ansätze

5.1. Datenerhebung

Ansätze des Maschinellen Lernen sind abhängig vom Zugang zu meist großen Mengen¹ qualitativ guter Daten. Zwar stehen quantitativ eine immer größere Anzahl von Daten zur Verfügung, doch die Qualität ist häufig fraglich. Oft wird bei der Umsetzung eines entsprechenden Projektes unterschätzt, welcher hohen Aufwand die der eigentlichen Analyse-Ebene vorgelagerten Stufen von Datensammlung, -speicherung und -aufbereitung einnehmen. Dies ist ein wichtiger Grund, warum entsprechende Projekte des Öfteren enttäuschende Resultate erbrachten. Visuell wird die Bedeutung der vorgelagerten Phasen gut mit der folgenden Infografik (Grafik 3) vermittelt.

Die Data Science- Bedürfnispyramide

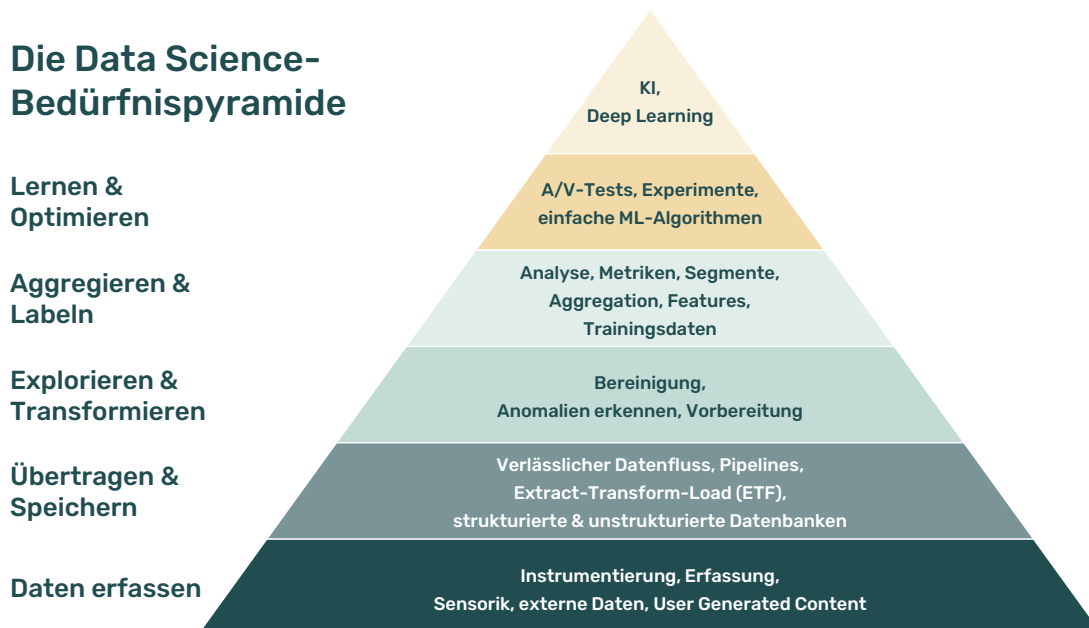


Abbildung 3: Die Data Science Bedürfnispyramide

(Quelle: Rogati, Monica (2017): The AI Hierarchy of Needs. Online verfügbar unter <https://medium.com/hackernoon/the-ai-hierarchy-of-needs-18f111fcc007>, zuletzt geprüft am 12.10.2021.)

¹ Eine Ausnahme ist das Forschungsfeld des *Few-shot learning* (FSL). Dort werden Verfahren entwickelt, die auch mit sehr wenigen Beispieldaten ein Erlernen von Verhalten ermöglichen. Ziel ist es trotz beschränkter Informationen akkurate Modelle zu gewinnen. In der Praxis erfolgt dies in der Regel durch Rückgriff auf besonders große Mengen extrinsischer Daten. Momentan ist dies Grundlagenforschung, bei entsprechenden Fortschritten könnte FSL aber durchaus praxisrelevant für Bereichen werden wo keine problemspezifischen Big Data vorliegen.

Die Abfolge eines solchen Projekts, von manchen auch die Data Science Pipeline genannt, besteht aus Erfassung, Extraktion, Bereinigung, Speicherung, Suche, Verbreitung, Anfragen, Analyse und Visualisierung (Naumann 2020). Für jeden dieser einzelnen Schritte gibt es dabei eigene etablierte Forschungsbereiche, bzw. entsprechende Produkte. Mit der Abfolge von der „Erfassung“ bis zur „Verbreitung“ befasst sich das Data Engineering und die letzten drei Stufen entsprechen der Data Science im engeren Sinne. Dabei ist es Ziel der Extraktion, nur die relevanten Daten zu erhalten. In der Bereinigungsphase werden fehlerhafte, unvollständige, irrelevante, duplizierte oder falsch formatierte Daten aussortiert oder angepasst. Zudem muss der Umgang mit fehlenden Werten, sogenannten Nullwerten, geregelt sein.

Für eine datengetriebene Zukunftsforschung, die die Gestaltung der Nachhaltigkeitstransformation unterstützen möchte, sind daher Fragen nach dem Zugang zu den dafür benötigten Daten zentral.

5.2. Datenauswertung

Ein großes Problem, gleichzeitig aber auch eine Stärke der Datenanalyse mittels Maschinellen Lernens ist die relativ atheoretische Vorgehensweise. Mit den entsprechenden statistischen Verfahren kann aus einer Datenmenge ein prädiktives, d.h. der Vorhersage dienendes Modell abgeleitet werden. Zwar liegen jedem Lernalgorithmus gewisse Annahmen zugrunde, aber es müssen keine expliziten theoretischen Annahmen über relevante kausale Beziehungen getroffen werden. Für den Einsatz in der Praxis ist dies häufig nützlich. So können mittels *Predictive Analytics* in einem geschäftlichen Kontext recht schnell Vorhersagemodelle gebildet werden. Klassische wissenschaftliche Verfahren, die erst die kausalen Faktoren für ein darauf basierendes Modell finden müssten, wären in einem solchen dynamischen Umfeld unpraktikabel.

Allerdings ist dies auch eine Fehlerquelle, denn ohne ein Verständnis von Ursachen können völlig fehlerhafte Modelle und entsprechend falsche Vorhersagen entstehen. Grundsätzlich gilt, dass aus einem korrelierten Zusammenhang noch kein kausaler und daher realer folgt.² In der Grundlagenforschung wird deshalb an Ansätzen gearbeitet, die das kausale Schließen von KI-Systemen zu verbessern versuchen. Allerdings ist nicht absehbar, ab wann

² Korrelation kann ein Hinweis auf Kausalität sein. Ist aber weder notwendige noch hinreichende Bedingung für das Vorliegen von Kausalität.

solche Versuche auch praxisrelevant werden. Menschliche Expert*innen sind für die kritische Einordnung und Überprüfung der Ergebnisse grundsätzlich unverzichtbar.

Zu den besonderen Herausforderungen bei der Datenauswertung mit Maschinellen Lernverfahren gehören das *Overfitting* und das *Underfitting*. Beim *Overfitting* erstellt der Algorithmus ein Modell, das auf Grund zu vieler erklärender Variablen zu genau die existierenden Daten abbildet. Solch ein überangepasstes Modell mag zwar die Trainingsdaten, bzw. die Daten der Stichprobe korrekt wiedergeben, da es sie sozusagen „auswendig gelernt“ hat. Eine Generalisierungsleistung ist dann allerdings nur bedingt möglich, was wiederum zu fehlerhaften Prognosen führt. Das „Gedächtnis“ eines solchen zu stark spezifizierten Modells ist also zu groß. Es hat nicht genug Regeln gelernt, die dann auch auf andere Fälle angewendet werden können. Solch ein *Overfitting* lässt sich u.a. dadurch umgehen, indem Modelle mit wenigen Freiheitsgraden verwendet werden. Das *Underfitting* ist das umgekehrte Problem. Ein Modell wird dann aufgrund gewisser Annahmen der realen Komplexität der Daten nicht gerecht, was ebenfalls zu fehlerhaften Prognosen führt.

Insbesondere beim für Prognosefragestellungen relevanten Überwachten Lernen spielt zudem das sogenannte Verzerrung-Varianz-Dilemma (*Bias-variance tradeoff*) eine wichtige Rolle. Dies beschreibt das Problem, dass eine gleichzeitige Minimierung der Fehlerquelle „Verzerrung“ (Bias) und der Fehlerquelle „Varianz“ in der Regel unmöglich ist. Mit der Fehlerquelle „Verzerrung“ ist der Unterschied zwischen dem korrekten Wert und der erwarteten Vorhersage gemeint. Mit der Fehlerquelle „Varianz“ ist die Variabilität der Modelvorhersage für einen gegebenen Datenpunkt gemeint, bei vorgestellter mehrfacher Wiederholung des Modellbildungsprozesses. Beide Fehlerquellen sind allerdings gleichermaßen problematisch und müssen je nach Anwendungskontext von menschlichen Expert*innen angepasst werden. Lernalgorithmen haben üblicherweise einige Parameter, um die Verzerrung sowie Varianz zu steuern.

5.3. Datennutzung

Vertrauen ist für eine erfolgreiche Kollaboration zwischen Menschen und KI-Systemen zentral (Glikson und Woolley 2020). Dabei stellt sowohl ein zu großes wie ein zu geringes Vertrauen ein Problem dar. Die Abfolge der Schritte eines Algorithmus in einer klassischen Programmierung ist zumindest prinzipiell

transparent. Wir können nachvollziehen, warum z. B. ein entsprechendes Programm eine Person in eine bestimmte Kategorie einsortiert hat. Systeme des Maschinellen Lernens erlernen dagegen komplexe statistische Zusammenhänge aus Trainingsdaten, ohne dass dafür notwendigerweise transparente Entscheidungsschritte angegeben werden können. Sie sind damit in vielen Fällen auch für Expert*innen nicht mehr nachvollziehbar. Es wird deswegen auch oft von Black-Box-Systemen gesprochen (Shrestha et al. 2019). Dies bringt für den Einsatz als Assistenzsystem in der Zukunftsforschung Nachteile. So sind in Black-Box-Systemen die Fehlerquellen nicht transparent und damit nur schwer aufzudecken. Es ist zudem bekannt, dass Maschinelles Lernen etwa aufgrund der eingesetzten Daten, Annahmen oder Evaluierungsmethoden leicht zu Modellen führen kann, die sozial ungewünschte (bspw. rassistische) Fehlschlüsse produzieren.

Doch gibt es wissenschaftlich-technische Möglichkeiten, um eine bessere Nachvollziehbarkeit der Ergebnisse solcher datengetriebener KI zu erreichen? Hierzu hat sich das Forschungsfeld der *Explainable AI* (abgekürzt XAI) etabliert. XAI versucht Methoden bereitzustellen, die es einem entsprechenden Programm ermöglichen, für den Menschen nachvollziehbare Erklärungen für seine Vorhersagen zu generieren. Inzwischen sind zumindest für die Erklärung von Einzelentscheidungen zusätzliche Erklärungswerkzeuge einsetzbar mit denen nachträglich die Nachvollziehbarkeit verbessert werden kann. Die etabliertesten dieser Werkzeuge und Methoden richten sich allerdings an Fachleute mit entsprechendem Wissen. Für einen breiteren Anwenderkreis nutzbare Methoden liegen dagegen bisher nur eingeschränkt vor (Kraus et al. 2021).

Zudem belegen psychologische Experimente, dass menschliche Expert*innen eine deutliche kognitive Verzerrung gegenüber Maschinen zeigen. Selbst wenn ihnen bekannt ist, dass ein maschinelles System in einem konkreten Kontext nachweisbar bessere Prognosen als Menschen liefert, vertrauen sie bei einer Abweichung häufig eher der eigenen Einschätzung (Abeliuk et al. 2020). Die ermöglichten Korrekturen eigener Fehleinschätzungen durch weiter fortgeschrittene KI-Systeme würden damit ungenutzt bleiben. Aber auch umgekehrt besteht die Gefahr, dass bei einer naiven Nutzung mit zu großer Technikgläubigkeit den KI-Systemen ein falscher Grad an Objektivität zugeschrieben wird. Während gegenüber menschlichen Expert*innen ganz selbstverständlich davon ausgegangen wird, dass diese eine eigene Perspektive mitbringen, wird dies bei technischen Systemen öfters vergessen. Zudem könnten Kund*innen eines Foresight-Prozesses der Nutzung datengetriebener

KI-Ansätze einen viel höheren Wert zusprechen als dieser sachlich verdient. Die Nutzung von KI droht dann schnell zu einer Marketing-Masche zu verkommen, die viel mehr verspricht als diese Technologie tatsächlich beiträgt.

Box 6: Interview mit Prof. Dr. Gerard de Melo, Hasso-Plattner-Institut

Prof. de Melo leitet seit 2020 das Fachgebiet „Artificial Intelligence and Intelligent Systems“ am Hasso-Plattner-Institut / Universität Potsdam.

In welchen konkreten Anwendungsfällen hilft KI heute schon dabei Aussagen über die Zukunft zu treffen?

In der KI spricht man generell von der „Vorhersage“ eines Modells, wenn dieses zu einer Frage eine Einschätzung liefert, z.B. ob jemand sich für ein YouTube-Video oder Produkt interessieren wird. In manchen Fällen haben die Prognosen einen zeitlich größeren Horizont, etwa wenn die verbleibende Lebensdauer einer Maschine geschätzt wird.

Im Bereich Predictive Analytics und Forecasting wird versucht, numerische Zeitreihen wie z.B. Passagieraufkommen oder Absatzzahlen weiter fortzuführen. Aber auch hier ist der betrachtete Zeithorizont sehr begrenzt, da neue Unwägbarkeiten oder auch Umweltkatastrophen erheblichen Einfluss auf die Entwicklung nehmen können.

Welche Erwartungen kann KI erfüllen im Sinne einer langfristigen Vorausschau komplexer Systeme?

KI ist insbesondere dann gut einsetzbar, wenn ein reicher Erfahrungsschatz an Daten aus der Vergangenheit vorliegt, so dass das Modell nach Regularitäten suchen und eine Prognose treffen kann. Bei einer langfristigen Vorausschau geht es aber oft gerade darum, ganz neuartige Entwicklungen zu antizipieren, ohne dass vergleichbare Beispiele aus der Vergangenheit heranziehbar wären. Hier stoßen die meisten KI-Methoden an ihre Grenzen.

Stattdessen können in diesem Fall spezialisierte Techniken zum Einsatz gelangen, die in menschlichen Daten nach Signalen suchen, welche auf eine gewisse Entwicklung hindeuten könnten. In Frage kommt da insbesondere Textmining in sozialen Medien, Patentanmeldungen, Nachrichten-Feeds sowie wissenschaftlichen Veröffentlichungen. Daneben können KI-Methoden versuchen zu einzelnen Sachfragen relevante Hintergrundinformationen zu liefern sowie die von verschiedenen menschlichen Expert*innen gelieferten Einschätzungen zu aggregieren um eine Gesamteinschätzung zu liefern.

Wie sieht eine gute Praxis für den Einsatz von KI zu Foresight-Zwecken aus?

Oft assoziiert man mit algorithmischen Lösungen eine gewisse Objektivität, da es allein auf die nackten Zahlen ankommt. Jedem KI-System sind aber gewisse Grundannahmen inhärent und die Ergebnisse hängen wesentlich von den zugrundeliegenden Daten ab, welche in der Praxis selten ausreichend hochwertig und repräsentativ sind. Somit kann es recht leicht zu vielfältigen Formen von Fehlschlüssen und Voreingenommenheiten kommen und es ist unabdingbar, die Vorhersagen eines Systems und im besten Fall auch die einzelnen Arbeitsschritte kritisch zu hinterfragen.

Was glauben Sie, ist von der Entwicklung von KI in den nächsten 10 bis 20 Jahren zu erwarten? Welche Potenziale zeichnen sich bereits ab?

Vor 10-20 Jahren haben selbst wir KI-Expert*innen kaum geglaubt, dass die KI so rasant voranschreitet und wir etwa selbstfahrende Autos in der Großstadt haben oder Sprachmodelle, die anspruchsvolle Geschichten verfassen. In Zukunft werden immer größere Datenmengen unterschiedlichster Art (Web-Inhalte, YouTube-Videos, Unternehmensdatenbanken, u.v.m.) verknüpft, um außerordentlich große Universalmodelle zu trainieren, anstelle von auf einzelnen Aufgaben spezialisierte. Dazu kommt ein Trend zu virtuellen Welten und digitalen Zwillingen, in denen Simulationen ablaufen können, mit denen eine KI millionenfach schneller als in der realen Welt üben kann. Auch wenn KI den Mensch nicht ersetzen kann, wird es immer mehr Aufgaben geben, die eine KI besser erledigen kann als ein einzelner Mensch.

6. Kann Künstliche Intelligenz Projektionen liefern?

In den vorherigen Kapiteln wurden Ansatzpunkte, aber auch potenzielle Schwächen von KI als Hilfsmittel für quantitative Methoden der Zukunftsforschung diskutiert. Dieses Kapitel erörtert, inwiefern KI einen Beitrag zu den eher auf Expertise und Kreativität fußenden methodischen Ansätzen der Zukunftsforschung liefern kann.

Das vorausschauende Denken in Projektionen ist ein Kern von Projekten und Studien im Bereich der Zukunftsforschung. Hier ist nach dem heutigen Stand das Potential von KI noch erheblich eingeschränkt und ihre Defizite werden hinsichtlich des Prozessierens sachlicher, zeitlicher und sozialer Komplexität deutlich. In dieser Phase von Foresight-Prozessen geht es um die Aufgabe,

Annahmen (Projektionen) zu definieren und zu begründen, die in längerfristige zeitliche Horizonte reichen. Sie unterliegen ungewissen, sich stetig wandelnden Bedingungen, die allein auf der Basis vergangener Daten nicht extrapoliert werden können. Neben der Formulierung dieser Annahmen müssen diese zu konsistenten und zugleich komplexen Konstruktionen verknüpft werden. Allein da versagen heute noch die KI-Anwendungen (Kehlmann 2021). Dennoch ist ein großes Versprechen der KI-basierten Ansätze, die prognostischen Potentiale zu stärken, indem Willkürlichkeit in Foresight-Prozessen eingeschränkt wird, die genutzte Datenbasis umfangreicher und relevanter wird und die Möglichkeit daraus Schlussfolgerungen zu ziehen verbessert wird.

Prognosen und Vorhersagen decken allein nicht die gesamten Aufgaben und Ziele der Zukunftsforschung ab. Im Kontext projektiver Arbeit geht es immer auch um die Generierung und Begründung von Annahmen und Hypothesen, wie sich Dinge in der Zukunft entwickeln und welche Konsequenzen sie für gesellschaftliche (Teil-)Systeme haben werden. Dazu bedarf es neben Daten auch an Theorien und Erfahrungen. Bisher ist noch keine KI entwickelt worden, die diese Eigenschaften in sich vereint und solch eine Hypothesenbildung automatisiert. Foresight-Annahmen beruhen auf einem Mix aus qualitativen und quantitativen Daten und Methoden.

Auf das Potential zur Unterstützung der quantitativen Datenerhebung und -auswertung der KI wurde eingegangen. Aber wie mit dem Klassiker der empirischen Sozialforschung umgegangen wird – dem Verhältnis qualitativer und quantitativer Ansätze – ist bzgl. des KI-Einsatzes noch nicht methodisch geklärt.

Eine weitere Herausforderung für KI-Ansätze ist der Umgang mit Komplexität. Die klassische systemtheoretische Definition von Komplexität lautet, dass mit Komplexität etwas bezeichnet wird, das immer mehr Möglichkeiten hat, als aktualisiert werden kann. „Ein System ist dann komplex, wenn man mehrere Beschreibungen für es braucht.“ (Bolz 2012: 35). Die wesentliche Aufgabe der Zukunftsforschung ist es gerade, mehrere Möglichkeiten oder Alternativen aufzuzeigen und nicht ein Zustand zu prognostizieren, und exakt zu bestimmen, was kommt.

Sämtliche vorausschauenden Anwendungsbereiche der KI (wie *Predictive Analytics*, *Predictive Policing* oder *Predictive Maintenance*) operieren auf der Basis von Vergangenheitsdaten und mit Wahrscheinlichkeiten. Ereignisse mit geringer sozialer und zeitlicher Komplexität können durch KI-Anwendungen

bereits durchaus gut prognostiziert werden (Kaufentscheidungen, geographische soziale Brennpunkte, Ausfallwahrscheinlichkeit eines mechanischen Systems). Wer bisher alle Bücher eines Autors online gekauft hat, wird dies wahrscheinlich auch in Zukunft tun und genau das kann vorausgesagt werden.

Entwickelt man nun Projektionen zukünftiger gesellschaftlicher Szenarios mittels Techniken der *Predictive Analytics* und von Zeitreihenanalyse wird damit ggf. nur die Business-as-usual Entwicklung fortgeschrieben. Wie die historische Erfahrung zeigt, ist dies bei langfristigen Entwicklungen ein eher unwahrscheinlicher Fall. Denn ein solch stark deterministisches Vorgehen negiert die Möglichkeit unerwarteter und disruptiver Ereignisse wie auch die gesellschaftliche Kreativität bei der Veränderung der eigenen Entwicklung. Die klassische Zukunftsforschung versucht, dies auf verschiedenen Weisen zu adressieren und nutzt dazu u.a. den Begriff Wild Cards³ und spricht von Zukünften im Plural.

Allgemein gilt, je weiter der zeitliche Horizont aufgespannt wird, umso problematischer werden Vorhersagen. Die Gestaltungsbereiche der Zukunftsforschung sind offen und sehr komplexe Systeme, d.h. über die Zeit verändern sich die Bedingungen und neue Komplexitätszustände treten auf. Diese Kreativitäts- und Rechenleistung vermag heute und in nächster Zukunft noch keine KI übernehmen. Entsprechende Entwicklungen sind durch extern nicht zu überwachende innere Prozesse und gerade auch durch menschliche Wahlhandlungen geformt.

³ Darunter werden zukünftige Entwicklungen oder Ereignisse verstanden, die sich durch eine relativ geringe Eintrittswahrscheinlichkeit und potenziell weit reichende Wirkungen auszeichnen (Steinmüller und Steinmüller 2003).

7. Fazit

Die meisten Expert*innen gehen davon, dass auch in naher Zukunft KI noch weit davon entfernt sein wird, einfach *auf Knopfdruck* Antworten auf komplexe Fragestellung liefern zu können. Es sind vor allem erkenntnistheoretische Grenzen der KI, die ihr Potential für alternative Projektionsentwicklungen auf systemischem Niveau limitieren. Damit fehlt die Fähigkeit, wirklich über Bestehendes hinaus zu denken und das Korsett von Erfahrungen und Status Quo-Annahmen durch mentales Experimentieren abzustreifen.

Legt man einen komplexen Begriff von Wissenschaft der Zukunftsforschung zu Grunde, dann wird die zentrale Rolle des Menschen, die durch kein technisches System ersetzt werden kann, offensichtlich: Wissenschaft kann als die „methodisch-argumentativ und reflektierte Gewinnung, Tradierung, Sicherung und Darstellung von intersubjektiv nachvollziehbaren Erkenntnissen in Bezug auf einen Gegenstandsbereich im Sinne komplexer, mit adäquaten Erklärungen als wahr gerechtfertigte Aussagensysteme in einem historisch-sozialen Kontext“ (Gabriel 2013) definiert werden. Intersubjektivität, Erklärungen und Reflexivität in der KI müssen jedoch erst noch definiert und dargestellt werden.

Datengetriebene Technologien ermöglichen aber teilweise schon jetzt mächtige und damit auch nützliche Assistenzsysteme. Im Idealfall kommt es dadurch zu einer Entlastung des Analyse-Teams von Routinetätigkeiten, so dass mehr zeitliche Ressourcen für die in der Zukunftsforschung wichtigen Fähigkeiten der Kreativität und des kritischen Denkens in Systemzusammenhängen zur Verfügung stehen kann. Die Betonung liegt dabei auf der zentralen Aufgabe der Zukunftsforschung: die Kritik bestehender Zukunftsbilder und Zukunftserwartungen und die Auseinandersetzung mit Interessen und Machtkonstellationen, die diese Zukunftsbilder motivieren und generieren. Gerade mit Blick auf Nachhaltigkeitstransformationen bleibt es die zentrale Rolle des Menschen, Zielbilder und normative Leitplanken für diese zu entwickeln.

Ein moderner Workflow in der Zukunftsforschung könnte daher aus einer Kombination von manuell-menschlichen und automatischen Datenerhebungs- und Auswertungsschritten bestehen. Auf der Ebene der Methoden der Zukunftsforschung kann diese in der klassischen Situationsanalyse, der Trendentwicklung und der empirischen Fundierung von einer KI-Nutzung profitieren. Bei der Szenariokonstruktion wird es schon deutlich schwieriger.

In quantitativen Szenarioprozessen werden KI-Anwendungen eine Hilfe sein, durch ihr enormes Potential der Datenprozessierung. Wo es allerdings auf qualitative Daten, implizites Wissen und kreative Denkanstrengungen ankommt, wird die KI noch lange das Nachsehen haben. Aber gerade diese Quellen projektiven und prädiktiven Arbeitens sind in der Zukunftsforschung unverzichtbar. Auch zukünftig wird es auf Erklärungen für Projektionen und Annahmen über die Zukunft ankommen. Diese Erklärungen können gegenwärtig noch nicht von KI-Anwendungen generiert und reflexiv bearbeitet werden.

Der Mehrwert der Nutzung datengetriebener Ansätze und von KI-Assistenzsystemen für die Zukunftsforschung wurde in diesem Positionspapier beschrieben. Um dieses Potential auch in der Praxis konkret zu verwirklichen, sind weitere Investitionen und Maßnahmen notwendig. Dazu könnte u.a. ein Forschungsprogramm gehören, das detailliert ergründet, wo genau Foresight und der jeweilige KI-Entwicklungsstand zusammentreffen, was damit jeweils möglich ist und das hierfür neue Instrumente und Prozesse entwickelt. Ein wichtiger Strang sollte sich dabei der Etablierung von Standards zur Integration von KI-Verfahren mit Methoden der qualitativen Datenanalyse widmen.

Zudem braucht es eines Förderprogramms zur systematischen Wissensvermittlung der schon vorliegenden Forschungsergebnisse und bestehenden Tools an die Foresight-Praktiker. Es gilt hier das disziplinär verstreute Wissen (z.B. aus der computergestützten Sozialforschung und der Informationswissenschaft etc.) zu bündeln und in der Praxis leicht zugänglich zu machen. Beispielsweise in Form einer institutionell gut abgesicherten Web-Plattform, die Best-Practice-Beispiele bereithält und Informationen zu in Frage kommenden Tools sowie den wichtigsten Veröffentlichungen bietet. Es wäre zudem erstrebenswert, wenn die Community der Foresight-Praktiker eigene Weiterbildungsangebote organisiert.

Für eine sozial-ökologische Transformation sind immense gesellschaftliche und wirtschaftliche Aufgaben zu bewältigen. Eine leistungsfähige Zukunftsforschung, welche die menschliche Reflexionsfähigkeit mit Methoden der KI erweitert, kann einen zielgenaueren Beitrag zu der dafür notwendigen Foresight leisten und so Zukunftsrisiken mindern. Hierfür bedarf es insbesondere bei Praktikern aus Forschung, Politik und Wirtschaft eines besseren Verständnisses von KI-Technologien, um die Erwartungen an die Synthese menschlicher und künstlicher Intelligenz realistisch zu antizipieren.

Die Autoren bedanken sich bei Prof. Dr. Katharina Hölzle (HPI, Potsdam) und Dr. Robert Rose (HPI, Potsdam) für ihre Ideen, Anmerkungen und Feedback.

8. Literatur

- Abeliuk, Andrés; Benjamin, Daniel M.; Morstatter, Fred; Galstyan, Aram (2020): Quantifying machine influence over human forecasters. In: *Scientific reports* 10 (1), S. 15940. DOI: 10.1038/s41598-020-72690-4.
- Agrawal, Ajay; Gans, Joshua; Goldfarb, Avi (2018): *Prediction Machines. The Simple Economics of Artificial Intelligence*. Boston, Massachusetts: Harvard Business Review Press.
- Bauer, Peter; Stevens, Bjorn; Hazeleger, Wilco (2021): A digital twin of Earth for the green transition. In: *Nat. Clim. Chang.* 11 (2), S. 80–83. DOI: 10.1038/s41558-021-00986-y.
- Behrendt, Siegfried; Scharp, Michael; Zieschank, Roland; van Nouhuys, Jo (2015): „Horizon Scanning“ und Trendmonitoring als ein Instrument in der Umweltpolitik zur strategischen Früherkennung und effizienten Politikberatung. Konzeptstudie. Hg. v. Bundesministerium für Umwelt, Naturschutz, Bau und Reaktorsicherheit. Berlin.
- Bell, Wendell (2009): *Foundations of Future Studies. History, Purposes and Knowledge*. Volume 1. 5. Auflage. New Jersey: Transaction Publishers.
- Benaich, Nathan; Hogarth, Ian (2020): *State of AI Report 2020*. Online verfügbar unter <https://www.stateof.ai/2020>, zuletzt geprüft am 12.10.2021.
- Bolz, Norbert (2012): *Ratten im Labyrinth. Niklas Luhmann und die Grenzen der Aufklärung*. München: Fink.
- Bosse, Christian; Hoffmann, J.; van Elst, L. (2018): Potenzialeinschätzung von Big Data Mining als methodischer Zugang für Foresight. In: *Aktuelle Veröffentlichungen*. Online verfügbar unter urn:nbn:de:0009-32-46723, zuletzt geprüft am 21.09.2021.
- Bovenschulte, Marc; Ehrenberg-Sillies; Goluchowicz, Kerstin; Bogenstahl, Christoph (2021): *Regierungs-Foresight - Stand und Perspektiven*. Institut für Innovation und Technik (iit-perspektive, 59). Online verfügbar unter https://www.iit-berlin.de/wp-content/uploads/2021/06/2021_06_10_iit-perspektive_Nr-59_Regierungs-Foresight.pdf, zuletzt geprüft am 07.10.2021.
- Boysen, Anne (2020): Mine the Gap: Augmenting Foresight Methodologies with Data Analytics. In: *World Futures Review* 12 (2), S. 239–248. DOI: 10.1177/1946756720905639.
- Dhar, Payal (2020): The carbon impact of artificial intelligence. In: *Nat Mach Intell* 2 (8), S. 423–425. DOI: 10.1038/s42256-020-0219-9.

- Funke, Daniel (2019): These fact-checkers won \$2 million to implement AI in their newsrooms. Hg. v. poynter.org. Online verfügbar unter <https://www.poynter.org/fact-checking/2019/these-fact-checkers-won-2-million-to-implement-ai-in-their-newsrooms/>, zuletzt geprüft am 01.11.2021.
- Gabriel, Johannes (2013): Der wissenschaftliche Umgang mit Zukunft. Eine Ideologiekritik am Beispiel von Zukunftsstudien über China. Trier, Univ., Diss, 2012. Wiesbaden: Springer Fachmedien Wiesbaden. Online verfügbar unter <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10687705>.
- Glikson, Ella; Woolley, Anita Williams (2020): Human Trust in Artificial Intelligence: Review of Empirical Research. In: ANNALS 14 (2), S. 627–660. DOI: 10.5465/annals.2018.0057.
- Hafezi, Reza (2020): How Artificial Intelligence Can Improve Understanding in Challenging Chaotic Environments. In: World Futures Review 12 (2), S. 219–228. DOI: 10.1177/1946756719880539.
- Kehl, Walter; Jackson, Mike; Fergnani, Alessandro (2020): Natural Language Processing and Futures Studies. In: World Futures Review 12 (2), S. 181–197. DOI: 10.1177/1946756719882414.
- Kehlmann, Daniel (2021): Mein Algorithmus und ich. Stuttgarter Zukunftsrede. Stuttgart: Klett-Cotta Verlag.
- Kraus, Tom; Ganschow, Lene; Eisenträger, Marlene; Wischmann, Steffen (2021): Erklärbare KI. Anforderungen, Anwendungsfälle und Lösungen. Hg. v. Technologieprogramm KI-Innovationswettbewerb des Bundesministeriums für Wirtschaft und Energie. iit-Institut für Innovation und Technik in der VDI/VDE Innovation + Technik GmbH. Online verfügbar unter https://www.digitale-technologien.de/DT/Redaktion/DE/Downloads/Publikation/KI-Inno/2021/Studie_Erklaerbare_KI.pdf;jsessionid=C94CE1AF540F11B6D64E3EB19A61A2AF?__blob=publicationFile&v=9, zuletzt geprüft am 21.09.2021.
- Mohn, Christine; Kolarsch, Christian; Chen, Yin; Grassmann, Roman; Gatzka, Cord (2020): Digital Twin – Zwischen den Welten. Potential, Reifegrad und Einsatzgebiete Digitaler Zwillinge für die DB. Digital.Trend.Studie. Hg. v. DB System GmbH. Online verfügbar unter https://www.dbsystem.de/resource/blob/5654212/b0c1fa2596dc441d8525c6f53e3ff856/200930_Digital-Trend-Studie_Digital-Twin_FINAL-data.pdf, zuletzt geprüft am 12.10.2021.
- Mühlroth, Christian; Grottke, Michael (2018): A systematic literature review of mining weak signals and trends for corporate foresight. In: J Bus Econ 88 (5), S. 643–687. DOI: 10.1007/s11573-018-0898-4.
- Naumann, Felix (2020): Data Engineering und Data Science – Klarheit in den Schlagwort-Dschungel. MOOC: openHPI, zuletzt geprüft am 07.09.2021.

- Popper, Rafael (2008): Foresight Methodology. In: L. Georghiou, J. Cassingena, M. Keenan, I. Miles und R. Popper (Hg.): The Handbook of Technology Foresight: Concepts and Practice. Cheltenham: Edward Elgar Publishing.
- Ramírez, Rafael; Wilkinson, Angela (2016): Strategic Reframing. The Oxford scenario planning approach. First edition. Oxford, United Kingdom: Oxford University Press.
- Shrestha, Yash Raj; Ben-Menahem, Shiko M.; Krogh, Georg von (2019): Organizational Decision-Making Structures in the Age of Artificial Intelligence. In: California Management Review 61 (4), S. 66–83. DOI: 10.1177/0008125619862257.
- Steinmüller, Angela; Steinmüller, Karlheinz (2003): Ungezähmte Zukunft. Wild Cards und die Grenzen der Berechenbarkeit. München: Gerling Akademie Verlag.
- Strubell, Emma; Ganesh, Ananya; McCallum, Andrew (2019): Energy and Policy Considerations for Deep Learning in NLP. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Stroudsburg, PA, USA: Association for Computational Linguistics.
- van Belkom, Rudy (2020): The Impact of Artificial Intelligence on the Activities of a Futurist. In: World Futures Review 12 (2), S. 156–168. DOI: 10.1177/1946756719875720.
- Zweck, Axel; Braun, Matthias (2021): Predictive Analytics: Sind Zukunftsforscher*innen ein Auslaufmodell? Hg. v. VDI Technologiezentrum GmbH. Düsseldorf.

9. Über die Autor*innen

Steffen Bauer

IZT – Institut für Zukunftsstudien und Technologiebewertung

Steffen Bauer ist wissenschaftlicher Mitarbeiter am Institut für Zukunftsstudien und Technologiebewertung (IZT). Er arbeitet zu den Chancen und Risiken neuer digitaler Technologien und deren Regulierung. Ein Fokus liegt dabei auf KI-Systemen. Steffen Bauer arbeitet unter anderem an Forschungsprojekten für das Bundesministerium für Umwelt, Naturschutz u. nukleare Sicherheit und die Kreditanstalt für Wiederaufbau.

Ingo Kollosche

IZT – Institut für Zukunftsstudien und Technologiebewertung

Dipl.-Soz. Ingo Kollosche ist Leiter des Forschungsbereiches "Zukunftsforschung und Transformation" am Institut für Zukunftsstudien und Technologiebewertung (IZT). Zu seinen Arbeitsschwerpunkten zählen gesellschaftlicher Wandel, Wertewandel und Lebensstile, Methoden der innovationsorientierten und partizipativen Zukunftsforschung, Szenario-Technik, Trendentwicklung sowie Großgruppenverfahren. Er ist Lehrbeauftragter für Zukunftsforschung am Fachgebiet Integrierte Verkehrsplanung (IVP) der TU Berlin.

André Uhl

IZT – Institut für Zukunftsstudien und Technologiebewertung

André Uhl ist Zukunftsforscher und wissenschaftlicher Mitarbeiter am IZT – Institut für Zukunftsstudien und Technologiebewertung in Berlin. Er befasst sich vor allem mit Methoden der Zukunftsforschung und Technikfolgenabschätzung und der Kommunikation wissenschaftlicher Erkenntnisse. André Uhl arbeitet unter anderem an Forschungsprojekten für die Europäische Kommission, das Bundesministerium für Bildung und Forschung und den Deutschen Bundestag und ist Mitherausgeber des Buches „Einblicke, Ausblicke, Weitblicke. Aktuelle Perspektiven in der Zukunftsforschung“.

Gerard de Melo**Hasso-Plattner-Institut**

Gerard de Melo ist Professor und Leiter des Fachgebiets Artificial Intelligence and Intelligent Systems am Hasso-Plattner-Institut und an der Universität Potsdam. Zuvor war er Assistenzprofessor an der Rutgers University in den USA und an der Tsinghua-Universität in Peking. Sein Team verfolgt das Ziel, KI-Systeme zu entwickeln, mit denen verschiedene Formen von Daten besser verstanden und strukturiert werden können. Weitere Details finden sich unter gerard.demelo.org.

Kerstin Fritzsche**IZT – Institut für Zukunftsstudien und Technologiebewertung**

Kerstin Fritzsche ist Politikwissenschaftlerin und arbeitet zu den Chancen und Herausforderungen digitaler Technologien für den sozio-ökologischen Wandel. Bis Oktober 2021 leitete sie den Forschungsbereich Digitalisierung am Institut für Zukunftsstudien und Technologiebewertung (IZT) in Berlin und arbeitet nun im öffentlichen Dienst zu digitalpolitischen Themen im Land Brandenburg

Über CO:DINA

Das Verbundvorhaben CO:DINA – Transformationsroadmap Digitalisierung und Nachhaltigkeit vernetzt Wissenschaft, Politik, Zivilgesellschaft und Wirtschaft, um neue strategische Stoßrichtungen für eine sozial-ökologische Digitalisierung zu identifizieren. Vielfalt in Denkweisen, Perspektiven und Erfahrungen ist die Voraussetzung, um die Komplexität der Digitalisierung besser zu verstehen und grundlegenden Fragen insbesondere zur Künstlichen Intelligenz mit tragfähigen Lösungsansätzen zu begegnen. Dabei entstehen Netzwerke zwischen Akteursgruppen, die bislang unzureichend verbunden waren. So wird die politische und gesellschaftliche Handlungsfähigkeit für einen sozial-ökologisch-digitalen Wandel gestärkt.

Das Vorhaben wird vom Bundesministerium für Umwelt, Naturschutz und nukleare Sicherheit (BMU) im Rahmen der KI-Leuchtturminitiative gefördert und gemeinsam vom IZT – Institut für Zukunftsstudien und Technologiebewertung und dem Wuppertal Institut für Klima, Umwelt, Energie umgesetzt.

Impressum



IZT – Institut für Zukunftsstudien und
Technologiebewertung gemeinnützige GmbH
Schopenhauerstr. 26, 14129 Berlin
Tel.: +49 (0) 30 803088-0
Fax: +49 (0) 30 803088-88
E-Mail: info@izt.de
Internet: www.izt.de




Wuppertal Institut für Klima, Umwelt, Energie GmbH
Döppersberg 19, 42103 Wuppertal
Tel.: +49 (0) 202-2492-101
Fax: +49 (0) 202-2492-108
E-Mail: info@wupperinst.org
Internet: www.wupperinst.org



Weitere Veröffentlichungen unter
www.codina-transformation.de

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages