

# Künstliche Intelligenz und Nachhaltigkeit

Klaus Mainzer<sup>1</sup>

**Abstract:** Die Informatik hat sich in den letzten Jahrzehnten zu einem der größten Treiber des gesellschaftlichen Wandels entwickelt. Bedingt durch den rasanten Fortschritt in der Informationstechnik finden Informatiksysteme eine rasante Verbreitung. Die Infrastrukturen des Internets und World Wide Webs schaffen völlig neue Formen der Interaktion und Kommunikation zwischen Menschen, Maschinen und Infrastrukturen (Internet der Dinge). Produkte und Dienstleistungen auf Basis von Softwaresystemen greifen um sich. Informatik verändert in vielen Anwendungsgebieten die Sicht auf die Welt. Damit steht die Informatik als Treiber des Wandels auf den ersten Blick in einem krassen Gegensatz zu einer statisch verstandenen Nachhaltigkeit.

**Keywords:** Nachhaltigkeit, Künstliche Intelligenz.

## 1 Zur Einführung: Informatik und Nachhaltigkeit

Nachhaltigkeit ist ein positiv besetzter Begriff – versteht man darunter doch historisch die Bewahrung von Werten im Sinne eines Wirtschaftens im Heute nicht zum Nachteil der Generationen von morgen. Vor dem Hintergrund des starken Wandels durch die Informatik scheinen Nachhaltigkeit und Informatik in einem strikten Gegensatz zu stehen.

Deutlich wird das bereits bei dem klassischen Anliegen der Nachhaltigkeit der Bewahrung der Umwelt. Informationstechnik ist einer der Energiefresser. Eine Initiative in Richtung eines schonenderen Umgangs mit den Ressourcen ist das Konzept der Green IT. Spannender aber als das durchaus wichtige Thema der Green IT ist die Frage, in welcher Weise Informatik und Informatiksysteme gestaltet werden können, dass sie eben nicht im Gegensatz zu einer umfassend verstandenen Nachhaltigkeit stehen. Das ist das Ziel nachhaltiger Innovationen, die dynamisch die soziale Welt verändern und dabei ökologische und ökonomische Ziele gleichermaßen beachten. Wichtig ist aber auch die kultur- und sozialwissenschaftliche Frage, was Menschen überhaupt wollen und welche Zukunft sie wünschen. Hier stellt sich die Frage nach der Macht von Software- und Hardwarekonzernen bei der Gestaltung einer zukünftigen Welt. Wie abhängig machen wir uns von deren Vorgaben?

Informatik ist die neue Ingenieurwissenschaft der Kultur- und Sozialwissenschaften. Sie verändert unsere Sicht auf die Welt, unser Denken. Steht das im Gegensatz zu Nachhaltigkeit im Sinne eines wertorientierten Handelns zur Bewahrung der Umwelt und Gestaltung der Zukunft? Hier findet sich eine Fülle interdisziplinärer Fragen, die zu einer Kooperation von Informatik mit Kultur- und Sozialwissenschaften führen muss, damit

nachhaltige Innovationen möglich werden.

## **2 Was kann Künstliche Intelligenz?**

Künstliche Intelligenz (KI) beherrscht längst unser Leben, ohne dass es vielen bewusst ist. Smartphones, die mit uns sprechen, Armbanduhren, die unsere Gesundheitsdaten aufzeichnen, Arbeitsabläufe, die sich automatisch organisieren, Autos, Flugzeuge und Drohnen, die sich selbst steuern, Verkehrs- und Energiesysteme mit autonomer Logistik oder Roboter, die ferne Planeten erkunden, sind technische Beispiele einer komplex vernetzten Welt intelligenter Systeme. Sie zeigen uns, wie unser Alltag von KI-Funktionen bestimmt ist. Um den Beitrag von KI zur Nachhaltigkeit zu untersuchen, muss zunächst geklärt werden, was KI ist und was sie kann (Mainzer 2019).

### **2.1 Symbolische KI: Logik und Deduktion**

In einer ersten Phase orientierte sich KI an formalen (symbolischen) Kalkülen der Logik, mit denen Problemlösungen regelbasiert abgeleitet werden können. Man spricht deshalb auch von symbolischer KI. Ein typisches Beispiel ist das automatische Beweisen mit logischen Deduktionen, die sich mit Computerprogrammen realisieren lassen. Automatisierung bedeutet bis zu einem bestimmten Grad auch Autonomie, da Computerprogramme die Beweistätigkeit eines Mathematikers übernehmen. Wissensbasierte Expertensysteme sind Computerprogramme, die Wissen über ein spezielles Gebiet speichern und ansammeln, aus dem Wissen automatisch Schlussfolgerungen ziehen, um zu konkreten Problemen des Gebietes Lösungen anzubieten. Im Unterschied zum menschlichen Experten ist das Wissen eines Expertensystems aber auf eine spezialisierte Informationsbasis beschränkt ohne allgemeines und strukturelles Wissen über die Welt (Puppe 1988; Mainzer 1990).

Um ein Expertensystem zu bauen, muss das Wissen des Experten in Regeln gefasst werden, in eine Programmiersprache übersetzt und mit einer Problemlösungsstrategie bearbeitet werden. Die Architektur eines Expertensystems besteht daher aus den folgenden Komponenten: Wissensbasis, Problemlösungskomponente (Ableitungssystem), Erklärungskomponente, Wissenserwerb, Dialogkomponente. In dieser Architektur werden zugleich die Grenzen symbolischer KI deutlich: Fähigkeiten, die nicht oder nur schwer symbolisch erfasst und regelbasiert simuliert werden können, bleiben der symbolischen KI verschlossen. Mit Blick auf Nachhaltigkeit können Expertensysteme eingesetzt werden, um notwendiges Spezialwissen aus unterschiedlichen Domänen

zusammenzustellen und auszuwerten. Beweis- und Kontrollverfahren tragen zur Sicherheit von Informatiksystemen bei.

## 2.2 Subsymbolische KI: Statistik und Induktion

Sensorische und motorische Fähigkeiten werden nicht aus Lehrbuchwissen logisch abgeleitet, sondern aus Beispielen erlernt, trainiert und eingeübt. So lernen wir, uns motorisch zu bewegen und in einer Vielzahl sensorischer Daten Muster und Zusammenhänge zu erkennen, an denen wir unser Handeln und Entscheiden orientieren können. Da diese Fähigkeiten nicht von ihrer symbolischen Repräsentation abhängen, spricht man auch von subsymbolischer KI. An die Stelle der formalen Schlüsse der Logik tritt nun die Statistik der Daten. Beim statistischen Lernen sollen allgemeine Abhängigkeiten und Zusammenhänge aus endlich vielen Beobachtungsdaten durch Algorithmen abgeleitet werden (Vapnik 1998). An die Stelle der Deduktion in der symbolischen KI tritt also in der subsymbolischen KI die Induktion. Dazu können wir uns ein naturwissenschaftliches Experiment vorstellen, bei dem in einer Serie von veränderten Bedingungen (Inputs) entsprechende Ergebnisse (Outputs) folgen. In der Medizin könnte es sich um einen Patienten handeln, der auf Medikamente in bestimmter Weise reagiert.

Dabei nehmen wir an, dass die entsprechenden Paare von Input- und Outputdaten unabhängig durch dasselbe Zufallsexperiment erzeugt werden. Statistisch sagt man deshalb, dass die endliche Folge von Beobachtungsdaten  $(x_1, y_1), \dots, (x_n, y_n)$  mit Inputs  $x_i$  und Outputs  $y_i$  ( $i = 1, \dots, n$ ) durch Zufallsvariablen  $(X_1, Y_1), \dots, (X_n, Y_n)$  realisiert wird, denen eine Wahrscheinlichkeitsverteilung  $P_{X,Y}$  zugrunde liegt. Algorithmen sollen nun Eigenschaften der Wahrscheinlichkeitsverteilung  $P_{X,Y}$  ableiten. Ein Beispiel wäre die Erwartungswahrscheinlichkeit, mit der für einen gegebenen Input ein entsprechender Output auftritt. Es kann sich aber auch um eine Klassifikationsaufgabe handeln: Eine Datenmenge soll auf zwei Klassen aufgeteilt werden. Mit welcher Wahrscheinlichkeit gehört ein Element der Datenmenge (Input) eher zu der einen oder anderen Klasse (Output)? Wir sprechen in diesem Fall auch von binärer Mustererkennung.

Die derzeitigen Erfolge des Machine Learning scheinen die These zu bestätigen, dass es auf möglichst große Datenmengen ankommt, die mit immer stärkerer Computerpower bearbeitet werden. Die erkannten Regularitäten hängen dann aber nur von der Wahrscheinlichkeitsverteilung der statistischen Daten ab:

Statistisches Lernen versucht, ein probabilistisches Modell aus endlich vielen Daten von Ergebnissen (z.B. Zufallsexperimente) und Beobachtungen abzuleiten.

Statistisches Schließen versucht umgekehrt, Eigenschaften von beobachteten Daten aus

einem angenommenen statistischen Modell abzuleiten.

In der Automatisierung statistischen Lernens nehmen neuronale Netze mit Lernalgorithmen eine Schlüsselrolle ein. Neuronale Netze sind vereinfachte Rechenmodelle nach dem Vorbild des menschlichen Gehirns, in denen Neuronen mit Synapsen verbunden sind. Die Intensität der neurochemischen Signale, die zwischen den Neuronen ausgesendet werden, sind im Modell durch Zahlengewichte repräsentiert. Probabilistische Netzwerke haben experimentell eine große Ähnlichkeit mit biologischen neuronalen Netzen. Werden Zellen entfernt oder einzelne Synapsengewichte um kleine Beträge verändert, erweisen sie sich als fehlertolerant gegenüber kleineren Störungen wie das menschliche Gehirn z.B. bei kleineren Unfallschäden. Das menschliche Gehirn arbeitet mit Schichten paralleler Signalverarbeitung. So sind z.B. zwischen einer sensorischen Inputschicht und einer motorischen Outputschicht interne Zwischenschritte neuronaler Signalverarbeitung geschaltet, die nicht mit der Außenwelt in Verbindung stehen.

Tatsächlich lässt sich auch in technischen neuronalen Netzen die Repräsentations- und Problemlösungskapazität steigern, indem verschiedene lernfähige Schichten mit möglichst vielen Neuronen zwischengeschaltet werden. Die erste Schicht erhält das Eingabemuster. Jedes Neuron dieser Schicht hat Verbindungen zu jedem Neuron der nächsten Schicht. Die Hintereinanderschaltung setzt sich fort, bis die letzte Schicht erreicht ist und ein Aktivitätsmuster abgibt (Hornik/ Stinchcombe/ White 1989).

Wir sprechen von überwachten Lernverfahren, wenn der zu lernende Prototyp (z.B. die Wiedererkennung eines Musters) bekannt ist und die jeweiligen Fehlerabweichungen daran gemessen werden können. Ein Lernalgorithmus muss die synaptischen Gewichte so lange verändern, bis ein Aktivitätsmuster in der Outputschicht herauskommt, das möglichst wenig vom Prototyp abweicht. Beim nicht-überwachten Lernen entdeckt ein Algorithmus selbstständig Ähnlichkeiten und Korrelationen von Daten, um die Datenmasse (Big Data) nach diesen Kriterien zu strukturieren. Deep Learning bezieht sich auf die Tiefe des Netzes, d.h. die Anzahl der Schichten in neuronalen Netzen, um so die Fähigkeiten zur Mustererkennung in großen Datenmassen zu steigern.

Ein effektives Verfahren besteht darin, für jedes Neuron der Outputschicht die Fehlerabweichung von tatsächlichem und gewünschtem Output zu berechnen und dann über die Schichten des Netzwerks zurückzuverfolgen. Wir sprechen dann von einem Backpropagation-Algorithmus. Die Absicht ist, durch genügend viele Lernschritte für ein Vorgabemuster den Fehler auf Null bzw. vernachlässigbar kleine Werte zu vermindern. Es bedarf keiner weiteren Erläuterung, dass die Digitalisierung der Umwelt mit einem gewaltigen Datenaufkommen verbunden ist, das durch statistische Lernverfahren zu bearbeiten ist, um Muster, Strukturen und Trends zu erkennen. Menschliche Gehirne

wären bei diesem Datenaufkommen überfordert, um z.B. Überwachungs- und Frühwarnsysteme einzurichten.

### 2.3 Vom statistischen zum kausalen Lernen

Statistisches Lernen und Schließen aus Daten reichen aber nicht aus. Wir müssen vielmehr die kausalen Zusammenhänge von Ursachen und Wirkungen hinter den Messdaten erkennen (Pearl 2009). Diese kausalen Zusammenhänge hängen von den Gesetzen der jeweiligen Anwendungsdomäne unserer Forschungsmethoden ab, also den Gesetzen der Physik, den Gesetzen der Biochemie, der Klimaforschung, der Life Sciences etc. Wäre es anders, könnten wir mit den Methoden des statistischen Lernens und Schließens bereits die Probleme dieser Welt lösen: Statistisches Lernen und Schließen ohne kausales Domänenwissen ist blind – bei noch so großer Datenmenge (Big Data) und Rechenpower!

Neben der Statistik der Daten bedarf es zusätzlicher Gesetzes- und Strukturannahmen der Anwendungsdomänen, die durch Experimente und Interventionen überprüft werden. Kausale Erklärungsmodelle (z.B. Klimamodelle oder Populationsmodelle) erfüllen die Gesetzes- und Strukturannahmen einer Theorie (z.B. Thermodynamik oder komplexe dynamische Systeme):

Beim kausalen Schließen werden Eigenschaften von Daten und Beobachtungen aus Kausalmodellen, d.h. Gesetzesannahmen von Ursachen und Wirkungen, abgeleitet. Kausales Schließen ermöglicht damit, die Wirkungen von Interventionen oder Datenveränderungen (z.B. durch Experimente und Interventionen) zu bestimmen.

Kausales Lernen versucht umgekehrt, ein Kausalmodell aus Beobachtungen, Messdaten und Interventionen (z.B. Experimente) abzuleiten, die zusätzliche Gesetzes- und Strukturannahmen voraussetzen.

Bei komplexen Systemen wie neuronalen Netzen mit z.B. Tausenden von Elementen und synaptischen Verbindungen erlauben zwar die Gesetze der statistischen Physik, globale Aussagen über Trend- und Konvergenzverhalten des gesamten Systems zu machen. Die Zahl der empirischen Parameter der einzelnen Elemente ist jedoch unter Umständen so groß, dass keine lokalen Ursachen ausgemacht werden können. Das neuronale Netz bleibt für uns eine „Black Box“. Vom ingenieurwissenschaftlichen Standpunkt aus sprechen Autoren daher von einem „dunklen Geheimnis“ im Zentrum der KI des Machine Learning: *“. . . even the engineers who designed [the machine learning-based system] may struggle to isolate the reason for any single action”* (Knight 2017).

Zwei verschiedene Ansätze im Software Engineering sind denkbar:

1. Testen zeigt nur (zufällig) gefundene Fehler, aber nicht alle anderen möglichen.
2. Zur grundsätzlichen Vermeidung müsste eine formale Verifikation des neuronalen Netzes und seiner zugrundeliegenden kausalen Abläufe durchgeführt werden.

Zusammengefasst folgt: Machine Learning mit neuronalen Netzen funktioniert, aber wir können die Abläufe in den neuronalen Netzen nicht im Einzelnen verstehen und kontrollieren. Heutige Techniken des Machine Learning beruhen meistens nur auf statistischem Lernen, aber das reicht nicht für sicherheitskritische Systeme, die nachhaltig sein sollen. Daher sollte Machine Learning mit Beweisassistenten und kausalem Lernen verbunden werden. Korrektes Verhalten wird dabei durch Metatheoreme in einem logischen Formalismus garantiert (Mainzer 2021; Mainzer/Schuster/Schwichtenberg 2021).

#### **2.4 Von der symbolischen und subsymbolischen KI zur hybriden KI**

Die Modelle subsymbolischer KI erinnern an die Organisation des Lernens im menschlichen Organismus: Verhalten und Reaktionen laufen dort ebenfalls weitgehend unbewusst ab. „Unbewusst“ heißt, dass wir uns der kausalen Abläufe des durch sensorielle und neuronale Signale gesteuerten Bewegungsapparats nicht bewusst sind. Das lässt sich mit Algorithmen des statistischen Lernens automatisieren. In kritischen Situationen reicht das aber nicht aus: Um mehr Sicherheit durch bessere Kontrolle im menschlichen Organismus zu erreichen, muss der Verstand mit kausaler Analyse und logischem Schließen eingreifen. Dieser Vorgang sollte im Machine Learning durch Algorithmen des kausalen Lernens und logischer Beweisassistenten automatisiert werden. Ziel ist daher eine hybride KI, in der analog zum menschlichen Organismus symbolische und subsymbolische KI verbunden werden.

### **3 Digitale Kreislaufwirtschaft als Beispiel für Nachhaltigkeit**

In den folgenden Empfehlungen werden die Potentiale der Digitalisierung und künstlichen Intelligenz für Kreislaufwirtschaft herausgestellt. In einer traditionellen linearen Wirtschaft werden Rohstoffe in Produkte für Konsum und Verbrauch umgewandelt, die Restmüll erzeugen. Linearität bedeutet, dass mehr Konsum mehr Rohstoffverbrauch erfordert und mehr Restmüll erzeugt. Es kommt darauf an, Verbrauch und Konsum in einen Kreislauf zurück zu koppeln (Recycling), um Rohstoffverbrauch und Umweltbelastung mit z.B. Restmüll zu minimieren. Verbrauchte Produkte und Restmüll sollten so weit als möglich wieder dem Kreislauf zugeführt werden. Die Natur selbst hat solche Kreislaufprozesse im Lauf der Evolution erfolgreich erprobt.

Kreislaufwirtschaft stellt daher einen wesentlichen Schritt für eine nachhaltige Wirtschaft dar. Bisher kann das Potential nur für bestimmte digitale Technologien in eingeschränkten Fallanalysen demonstriert werden. Um das Potential digitaler Technologien für geschlossene Ressourcenzyklen umfassend zu verstehen, müssen ihre Möglichkeiten und Wechselwirkungen mit soziotechnischen Anwendungen systematisch untersucht werden. Dabei darf allerdings nicht vergessen werden: Jeder soziotechnische Fortschritt muss mit geeigneten Kommunikationsstrategien begleitet werden, da diese Veränderungen und Eingriffe (i) durch die Gesellschaft akzeptiert und getragen und (ii) in Geschäftsmodelle umgesetzt werden müssen, um nachhaltig zu sein. Zur digitalen und KI-gestützten Kreislaufwirtschaft werden folgende Empfehlungen gegeben (TUM Senior Excellence Faculty 2021):

#### 4 Handlungsempfehlungen:

- 1) *Als Grundlage und Voraussetzung für eine nachhaltige Anwendung von KI-Tools benötigt Deutschland zunächst eine mächtige digitale Infrastruktur und Digitalisierung, die stärker ausgebaut und gefördert werden muss, besonders im öffentlichen Sektor und in der mittelständischen Industrie.*

Kreislaufwirtschaft als zentrales Beispiel der Nachhaltigkeit besteht aus sehr komplexen Prozessen mit hohem Datenaufkommen, die ein Ressourcenmanagement mit geschlossenen Rückkopplungsschleifen erfordern. Daher kann Kreislaufwirtschaft nur erfolgreich sein, wenn sie durch effektive digitale Infrastrukturen unterstützt wird. Diese Forderung ist eine notwendige Bedingung für die digitale Umsetzung einer Kreislaufwirtschaft.

- 2) *Neben konkreten Technologien und Infrastrukturen muss die Bedeutung von Standards und Normen berücksichtigt werden.*

Standards und Normen unterstützen die Effektivität von Netzwerken, da technische Lösungen durch Normung aufeinander abgestimmt werden und ihre Diversität minimiert wird. Gesetzliche und ethische Normen fördern Vertrauen und Akzeptanz einer vertrauenswürdigen IT und KI.

- 3) *Vor neuen kostspieligen Investitionen sollten die bereits existierenden digitalen Tools darauf getestet werden, wie weit sie bereits Ressourcenmanagement in der Kreislaufwirtschaft unterstützen und verbessern können.*

Digitalisierung bedeutet zunächst, digitale Tools von IT-Ausrüstung, IT-unterstützte Kommunikation und Kontrolle zu nutzen, die zur Zeit noch nicht hinreichend im öffentlichen Sektor und im Mittelstand zur Verfügung stehen.

- 4) *Kosten und Nutzen in Unternehmen und öffentlicher Verwaltung sollten klar und deutlich genannt werden.*

Die Digitalisierung der Kreislaufwirtschaft muss sich in Unternehmen und im öffentlichen Sektor rechnen, um als ökonomisch sinnvoll akzeptiert zu werden.

- 5) *Multilateraler Datenaustausch entlang den Versorgungs- und Lieferungsketten und den Lebenszyklen von Produkten ist notwendig.*

Kreislaufwirtschaft ermöglicht nachhaltiges Ressourcenmanagement, Abfallreduktion und Recycling von Ressourcen. Größere Transparenz von Produktentstehung trägt dazu bei, den Verbrauch zu reduzieren und Unternehmen zu bewegen, den Ressourcenerwerb zu verändern.

- 6) *Neben etablierten IT-Tools sollten neue vielversprechende Technologien wie Blockchain angewendet, getestet und entwickelt werden.*

Blockchain besteht aus seiner Kette von verschlüsselten Datenblöcken, die durch kryptographische Codes verbunden und erweitert werden können. Durch diese Ketten von Datenblöcken können z.B. Lieferungs-, Versorgungs- und Produktionsabläufe detailliert digital abgebildet werden, um zu jedem Zeitpunkt ihre Transparenz, Kontrolle und ihren Zugriff zu garantieren. Blockchain ist eine neue IT-Technologie, die alle Arten von Ressourcen mit Tokens kennzeichnen kann. Dadurch erhalten sie eindeutige digitale Identifikationen (ähnlich einer digitalen Münze), die alle Beteiligten verfolgen und nutzen können. Das macht den Wert der Ressourcen mehr ersichtlich, erleichtert ein neues System für die Bepreisung und den Handel von Ressourcen und setzt Anreize, um ein zirkuläres Verhalten zu übernehmen. Da viele Anwendungen von Blockchain noch in einer Testphase sind und breite Anwendung benötigen, sollte mehr Forschung und Entwicklung von Blockchain für nachhaltige Kreislaufwirtschaft betrieben werden.

- 7) *Neben etablierten IT-Tools sollten aber auch neue vielversprechende Technologien wie KI angewendet, getestet und entwickelt werden.*

KI öffnet neue Möglichkeiten für eine breite Palette der Nachhaltigkeit: In der Landwirtschaft können Drohnen oder sensorbasiertes Monitoring angewendet werden, um die Lebensgrundlagen von Pflanzen sowohl in ökonomischer als auch ökologischer Sicht besser einschätzen zu können. In der Produktion lässt sich der Energieverbrauch durch intelligente Netzwerke und Robotik reduzieren. Der Lebenszyklus von Produkten kann durch vorausschauende Wartung ausgeweitet werden. Im Recycling und Abfallmanagement kann KI die Identifikation und das Sortieren von Abfall verbessern. Für die Effizienz des Bauens und das Energiemanagement bietet KI verbesserte Systemkontrolle, Regulation des Heizens, Kühlens und der Ventilation. Kurz: Machine

learning sollte zur Beschleunigung und Optimierung von Versorgungsketten beitragen und die Zirkulation von Produkten, Komponenten und Materialien unterstützen.

- 8) *Eine Schlüsselforderung ist die Entwicklung nachhaltiger Geschäftsmodelle, die auf digitaler zirkulärer Ökonomie beruhen.*

Es gibt bereits vielversprechende Fallstudien zur Kreislaufwirtschaft durch Digitalisierung: Beispiele sind nachhaltige Hauswirtschaft (urban housing), nachhaltige Smart Cities, Metallrecycling und Plastikrecycling.

- 9) *Die ökologische, ökonomische und gesellschaftliche Balance von digitalen Tools und Infrastrukturen, d.h. ihre ökologische, ökonomische und gesellschaftliche Gesamtbilanz in der Kreislaufwirtschaft ist entscheidend.*

Beispielsweise muss die Effizienz digitaler Anwendungen und ihre ökonomischen und ökologischen Kosten des Energieverbrauchs ausgeglichen sein, um die Vorteile einer Kreislaufwirtschaft nutzen zu können.

## 5 Bibliography

- [HSW89] Hornik, Kurt / Stinchcombe, Maxwell / White, Halbert: Multilayer feedforward networks are universal approximators neural networks, in: Neural Networks 2 1989, 359-366.
- [Kw17] Knight, Will: The dark secret at the heart of AI, in: MIT Technology Review. April 11 2017, 1-22. 2000.
- [Mk90] Mainzer, Klaus: Knowledge-based systems. Remarks on the philosophy of technology and artificial intelligence, in: Journal for General Philosophy of Science 21 1990, 47-74.
- [Mk19] Mainzer, Klaus: Künstliche Intelligenz. Wann übernehmen die Maschinen? Berlin 2. Aufl. 2019.
- [Mk21] Mainzer, Klaus: Statistisches und kausales Lernen im Machine Learning, in: Philosophisches Handbuch der künstlichen Intelligenz (Hrsg. Klaus Mainzer). Berlin 2021
- [MSS21] Mainzer, Klaus; Schuster, Peter; Schwichtenberg, Helmut (Hrsg.): Proof and Computation. From Proof Theory and Univalent Mathematics to Program Extraction and Verification, World Scientific Singapore 2021.
- [Pj9] Pearl, Judea: Causality: Models, Reasoning, and Inference. Cambridge (Mass.) 2009.
- [Pf88] Puppe, Frank.: Einführung in Expertensysteme. Berlin 1988.
- [TUF21] TUM Senior Excellence Faculty (Hrsg.), TUM Forum Sustainability: Circular Economy, TUM (Technische Universität München) University Press: München 2021.

[Vv88] Vapnik, Vladimir N.: Statistical Learning Theory. New York 1998.