

Fabian Anicker

Sozialisierte Maschinen. Zur gesellschaftlichen Funktion von Künstlicher Intelligenz

Zusammenfassung: Das beispiellose Entwicklungs- und Verbreitungstempo von Künstlicher Intelligenz deutet auf eine Transformation von grundsätzlicher gesellschaftlicher Bedeutung hin. Bisher ist es der Soziologie jedoch noch nicht gelungen, diese Strukturtransformation überzeugend auf den Begriff zu bringen; wohl auch, weil kein dezidiert soziologischer Begriff von KI vorliegt. Der in diesem Aufsatz unterbreitete Vorschlag lautet, künstlich intelligente Systeme als sozialisierte Maschinen zu begreifen, die funktionsnotwendiges implizites Wissen inkorporieren und ersetzen können. Diese Perspektive eröffnet Einsichten bezüglich der Funktion von KI in der Gesellschaft und zeigt, welche Verschiebungen gesellschaftlicher Kontroll- und Machtverhältnisse zu erwarten sind.

Schlüsselworte: Künstliche Intelligenz; KI; Soziologie; machine learning; Gesellschaftstheorie; Theorie multipler Differenzierung; implizites Wissen; Differenzierung

Socialized Machines: The Societal Function of Artificial Intelligence

Abstract: The unprecedented pace of development and diffusion of artificial intelligence seems to mark a transformation of fundamental social importance. So far, sociology has not succeeded in convincingly conceptualizing this structural transformation; probably because there is no decidedly sociological concept of AI. The proposal made in this paper is to conceive of artificially intelligent systems as socialized machines that can incorporate and replace functionally necessary tacit knowledge. This perspective opens up insights regarding the function of AI in society and shows which shifts in societal control and power relations can be expected.

Key words: artificial intelligence; AI; sociology; theory of society; machine learning; multiple differentiation theory; tacit knowledge; social differentiation

»Die einzige Alternative zur strukturellen Kopplung Bewußtsein/Kommunikation, die sich gegenwärtig bereits andeutet, aber unschätzbare Folgen haben würde, ist der Computer.« (Luhmann 1997, S. 117)

Es dürfte kaum einen kontemporären gesellschaftlichen Strukturwandel geben, der sich selbst im Rahmen der normalisierten Hypertrophie der Moderne mit höherem Tempo und größerer Breitenwirkung vollzieht, als die Transition zu Künstlicher Intelligenz (KI). Im Bereich der Informatik und des Internets ist man zwar an scheinbar unbegrenztes exponentielles Wachstum gewöhnt, aber die Entwicklung der KI-Technologien lässt sich auch hier nur als Explosion beschreiben. Die Leistung von KI-Systemen verdoppelt sich

seit 2012, anders als die Rechenleistung von Prozessoren, *nicht* alle zwei Jahre, sondern im atemberaubenden Verdopplungstempo von 3,4 Monaten (Perrault et al. 2019). Während ein Prozessor im Jahr 2020 nach *Moore's Law* (Leiserson et al. 2020; Tegmark 2017) etwa 16 Mal so leistungsfähig ist, wie ein gleichteurer Prozessor aus dem Jahr 2012, ist die KI schon im Jahr 2019 mehr als 16 *Millionen* mal effektiver als ihr Pendant aus dem Jahr 2012. Exponentiell wächst auch die Zahl der publizierten Papiere, der PhDs, der industriellen Anwendungen und der politischen Aufmerksamkeit für das Thema (Zhang et al. 2021), so dass das Wachstum von KI-Forschung und Anwendungen jenes der übrigen Informationstechnologien deutlich übertrifft. Und spätestens seitdem ChatGPT binnen weniger Monate die Weltöffentlichkeit eroberte, ist es auch für Laien nicht mehr zu übersehen, dass KI zu tiefgreifenden Veränderungen in der Gesellschaft führen wird.¹

Allerdings sind die sozialen Ursachen der digitalen Transformation, insbesondere ihre gesellschaftstheoretisch zu bestimmenden Bedingungen, bisher noch nicht klar. Wieso und zu welchem Ende erzeugt und verbreitet die Gesellschaft eine Technologie, die sich anders als konventionelle Technik nicht durch Transparenz, sondern durch Intransparenz der Funktionsweise bei gleichzeitiger Brauchbarkeit der Outputs auszeichnet? Auch wenn es interessante Spekulationen gibt, fehlen Beiträge, die die digitale Transformation sowohl feinkörnig untersuchen als auch an gesellschaftstheoretische Fragen rückbinden. Eine solche Theorie müsste bei einer Analyse des *Ineinandergreifens* von technischen und sozialen Prozessen ansetzen und beide sowohl in ihren Eigenlogiken als auch in ihrem Zusammenhang untersuchen.

Dies ist im Rahmen eines Zeitschriftenaufsatzes nicht zu leisten. Möglich ist es aber, das soziologische Problem genauer zu markieren und die Perspektive zu umreißen, aus der die gesellschaftstheoretische Relevanz von KI durchsichtig werden kann. Dafür wird zunächst auf Basis einer theoretisch enthaltsamen Phänomenbeschreibung eine provisorische Funktionsbestimmung von KI vorgenommen (Kapitel 1). Diese erste Problembebestimmung wird vertieft und verlagert, indem das Problem aus der Perspektive der Theorie multipler Differenzierung analysiert wird. Es wird sich zeigen, dass KI sich nicht nur als *sozialisierte Technik* beschreiben lässt, sondern auch an einer ähnlichen Stelle funktional relevant für die Reproduktion sozialer Strukturen wird wie Sozialisation (Kapitel 2). Im dritten Kapitel werden mögliche Implikationen der Technisierbarkeit von Sozialisation für soziale Strukturen diskutiert.

1 In den Monaten seit der Veröffentlichung von ChatGPT im November 2022 hat sich die Anzahl der Medienberichte zu KI in Deutschland gegenüber dem Vorjahresniveau etwa verdoppelt (Quelle: Meinungsmonitor:KI, Längsschnitterhebung der Berichterstattung zu KI in den 33 größten Print- und Onlinemedien, für vorläufige Ergebnisse siehe <https://www.cais-research.de/forschung/memoki/memoki-medienanalyse/>), bereits Ende Januar hatten über 10 % der deutschen Bevölkerung das Programm bereits genutzt und sich überwiegend von dessen Fähigkeiten beeindruckt gezeigt (Flaßhoff et al. 2023).

1 Protozoologischer Vorspann: KI als Lösung für Digitalisierungsprobleme

Es lohnt sich, abstrakte Überlegungen zur Strukturelevanz von Künstlicher Intelligenz ausgehend von einer relativ einfachen und theoretisch wenig vorbelasteten Phänomenbeschreibung anzustellen. Die Transition zu KI ist, wenn man einer hilfreichen Unterscheidung von Brennen und Kreiss (2016) folgt, ein Teilprozess innerhalb der Digitalisierung. Ihr auf Technizität enggeführter Begriff der Digitalisierung begreift diese als Zusammenhang von Datafizierung und Informationsverarbeitung. Die Funktion der Datafizierung besteht darin, soziale und nicht-soziale Sachverhalte in ein Sinnformat zu übersetzen, das Maschinen verarbeiten können, also die Umwandlung von Sachverhalten in Daten und Zahlen. Datafizierung ist die Voraussetzung von Datenverarbeitung, der Verwendung von Daten als Informationen durch Menschen und Maschinen. Wenn man verstehen will, was Digitalisierung ist, muss man vor allem verstehen, warum die Gesellschaft Bedarfe danach entwickelt, Phänomene und Sachverhalte zu datafizieren (und damit maschinenlesbar zu machen) und wie und wozu diese digitalen Informationen verarbeitet werden.

Gesellschaftstheoretisch naheliegend ist in diesem Kontext eine Komplexitätstheoretische Betrachtungsweise. Gesellschaftliche Systeme sind in eine Umwelt eingebettet, die nicht in ihrer Gesamtheit in den Systemen berücksichtigt werden kann. Um überhaupt agieren und entscheiden zu können – Waren zu kaufen, Recht zu sprechen, Liebesbeziehungen einzugehen, Personal einzustellen usw. –, ist es für die Systeme erforderlich, Komplexität zu reduzieren, das meiste zu ignorieren und nur einige wenige Daten in Informationen zu übersetzen. Diese keineswegs nur der soziologischen Systemtheorie vorbehaltene Einsicht gilt allgemein für alle Systeme in allen zeitlichen und räumlichen Umwelten. Eine umfassende Datafizierung sozialer Prozesse durch Tracking, Sensoring, Tracing, Skalierung, Ordinalisierung usw. (Fourcade 2016; Fourcade/Johns 2020; Holton/Boyd 2021) ändert daran zunächst nichts Wesentliches. Neben die analoge tritt eine digitale Umwelt, die in ihrer Komplexität in Kommunikation unmöglich abgebildet werden kann. Datafizierung verschafft nicht per se mehr Übersicht oder Transparenz. Allerdings ändert sich in einer digitalisierten Umwelt die *Art der Umweltkomplexität*. Potenziell relevante Daten werden nicht durch Kommunikation oder Wahrnehmung aufgenommen, sondern in großen Datenbanken *technisch vorgehalten* – die Datenbank wird zur dominanten symbolischen Form der digitalen Weltrepräsentation (Manovich 1999). Digitalisierte Daten sind für soziale Systeme leichter verfügbar, aber die unfassbaren Datenmengen lassen das Problem der Umweltkomplexität für die Systeme selbst erst sinnfällig werden. Die umfassende Datafizierung verwandelt die prinzipielle Ungewissheit der Umwelt in *zurechenbares* Nicht-Wissen; d. h. ein Nicht-Wissen, von dem man weiß, dass man es haben könnte oder hätte haben können. Mit der richtigen Kompression von Daten in verarbeitbare Informationen hätte man den Umsatz steigern, den Anschlag verhindern oder die richtigen Aktien kaufen können (aus einfachem Nichtwissen wird »intentionales Nichtwissen«, vgl. Böschen et al. 2006; siehe auch Wehling 2009). Das prinzipielle Problem der Komplexität erscheint deshalb

auch in der Selbstbeschreibung sozialer Systeme zunehmend als *Kapazitätsproblem* von Kanal (Channel) und Empfänger.

Als Flaschenhals sozialer Steuerungsprozesse erscheint dabei zunehmend weder das Datenvolumen noch die Rechenleistung von Computern, sondern die menschliche Aufmerksamkeit. Während die menschliche Fähigkeit, Informationen zu verarbeiten, durch die mehr oder weniger konstante Kapazität für serielle Prozessierung von Gedanken im Bewusstsein begrenzt ist und nichttechnische soziale Systeme mindestens mittelbar an diese Kapazitätsgrenze gebunden sind, wächst die Rechenleistung von Computern seit geraumer Zeit exponentiell. Von dieser technischen Sicht des Problems her sind daher solche Technologien besonders strukturell relevant, die menschliche Aufmerksamkeit effizienter einsetzen, z. B. indem sie diese durch Filterung entlasten und durch Selektion steuern – oder aber den Prozess der Reproduktion von sozialen Strukturen in einigen Bereichen von menschlicher Aufmerksamkeit entkoppeln. Die soziologische Forschung hat sich in diesem Kontext u. a. für Algorithmen interessiert, die Relevanzen vorfiltern oder Schnittstellen zwischen menschlichem Bewusstsein und maschineller Informationsverarbeitung optimieren (Fuller 1998; Galloway 2012; Hookway 2014; Knorr-Cetina/Bruegger 2002; Lipp/Dickel 2022). Hier spielen unterschiedliche Algorithmen eine Rolle, die Relevanzen vorselegieren, z. B. indem sie Datenverkehr auf Internetseiten, die Reputation in sozialen Netzwerken oder die Autorität von Quellen über ihre Position im Netzwerk der Hyperlinks messen und dadurch die Verteilung der knappen Ressource menschlicher Aufmerksamkeit auf die unüberschaubare Menge an Informationen optimieren (Cardon 2017; Gillespie 2014).² Die radikalere und wegen ihrer Vermeidung der Einführung auf menschliche Aufmerksamkeit effizientere technische Lösung des Problems der Datenvermehrung besteht freilich darin, *den Beitrag, den menschliche Aufmerksamkeit zur sozialen Strukturreproduktion leistet, möglichst vollständig zu ersetzen*. Damit hätten wir eine erste Vermutung zur gesellschaftlichen Funktion von Künstlicher Intelligenz: Sie ermöglicht eine partielle Entkopplung der Reproduktion sozialer Systeme von strukturwichtigen Bewusstseinsleistungen. Bereits diese einfache Vorüberlegung ermöglicht es, eine genuin soziologische Perspektive auf KI einzunehmen und die vieldiskutierte Frage danach, ob KI-Systeme *wirklich* intelligent sind, analytisch zu dezentrieren: Es kommt aus soziologischer Sicht nicht darauf an, ob Computer ähnlich denken können wie Menschen, sondern darauf, wie sie sich in strukturell relevante soziale Prozesse einklinken und welche gesellschaftlichen Transformationen dadurch wahrscheinlich werden. Ihr volles Potenzial entfaltet eine soziologische Perspektive auf KI aber erst, wenn gesellschaftstheoretische Annahmen zur Art sozialer Strukturen und den Bedingungen ihrer Reproduktion hinzugezogen werden.

2 Laut Schätzungen betrug das weltweite Datenvolumen im Jahr 2018 35 Zettabyte (ein Zettabyte entspricht etwas mehr als einer Billion Gigabyte), für das Jahr 2025 rechnet man mit einer Verfünfachung auf 175 Zettabyte (Reinsel et al. 2018).

2 Differenzierungstheoretische Erwägungen: Von der sozialen zur digitalen Übersetzung der Gesellschaft?

Niklas Luhmann hatte früh gesehen, dass es einen möglichen Weg der Reduktion von Komplexität für soziale Systeme gibt, der der sinnhaften Differenzierung von Sonderkontexten der Problemdefinition und -bearbeitung (Funktionssysteme, Organisationen) und ihrer Kopplung mit menschlichen Bewusstseinsleistungen noch überlegen sein könnte: die weitgehende Übertragung der Rationalisierung auf Maschinen, deren mögliche Auswirkungen für den Luhmann der 1970er Jahre »selbst mit ungemilderter Spekulation nicht erfassbar« sind (Luhmann 1999 [1973]: 256). Auch in »Die Gesellschaft der Gesellschaft« wird der Computer für soziale Systeme als mögliches funktionales Äquivalent des Bewusstseins ins Spiel gebracht; auch hier spricht Luhmann von »unschätzbaren Folgen« (1997: 117). Man kann angesichts der frühen Diagnosen die Hellsichtigkeit Luhmanns bezüglich der Strukturwichtigkeit technisierter Informationsverarbeitung bewundern. Andererseits ist es aber auch einigen systemtheoretischen Grundentscheidungen geschuldet, dass die Möglichkeit der Ersetzung von Bewusstseins- durch Rechenleistungen bei ihrem Schöpfer eher andächtiges Erschauern auslöst als detaillierte Analysen. Insbesondere drei Problembereiche der systemtheoretisch angeleiteten Differenzierungstheorie sind zu nennen: Erstens verhindert ein unnötig auf die Kopplung von Sozialem und menschlichem Bewusstsein enggeführter Kommunikationsbegriff ein tieferes Verständnis der Beziehung zwischen sozialen Systemen und (digitaler) Technik (Esposito 2017; zur Kritik Harth/Lorenz 2017; eine bemerkenswerte Ausnahme bildet der *Zettelkasten*, vgl. Luhmann 1981; Pröschold 2019). Zweitens ist die systemtheoretische Entgegensetzung von Bewusstsein bzw. psychischem System und sozialen Systemen wenig hilfreich, um die Rolle, die nicht nur Gedanken, sondern auch die körpergebundene, praktische menschliche Handlungskompetenz für soziale Systeme und für die Differenzierungsform der Gesellschaft spielen, zu verstehen. Wenn es aber theoretisch keine differenzierten Thesen zur Funktion menschlicher Kompetenzen für soziale Prozesse gibt, fehlt auch der Ausgangspunkt, um zu erwägen, inwiefern Maschinen tatsächlich menschliche Leistungen für Sozialität ersetzen können und was daraus für die Gesellschaft folgen würde. Drittens ist das notorische Problem der Intersystembeziehungen zu benennen: Unterschiedliche Systemtypen – konventionell werden Interaktion, Organisation und Gesellschaft unterschieden (Luhmann 1984: 16, 2005) – werden in ihrem Verhältnis zueinander nicht befriedigend analysiert. Wie genau sind abstrakte soziale Systeme auf Organisationen, wie diese wiederum auf Interaktionen angewiesen (und umgekehrt) – und wie könnte davon ausgehend der Einfluss der Digitalisierung auf Intersystemverhältnisse und die Differenzierungsform der Gesellschaft eruiert werden? Man kann nicht erwarten, dass solche Fragen in den verhältnismäßig kurzen Skizzen beantwortet werden, die Luhmann zu den Systemtypen und ihren wechselseitigen Beziehungen geliefert hat, aber auch nachfolgende Forschung hat den grundsätzlichen Unklarheiten bezüglich Intersystembeziehungen nicht abhelfen können (vgl. die Beiträge in Heintz/Tyrell 2016; siehe auch Hellmann 2016; Renn 2006: 97 ff.). Gerade ein Thema wie Digitalisierung, das wie kaum ein anderes dazu einlädt, die Rekonfiguration der Kommunikationsver-

hältnisse durch vermeintlich intelligente Maschinen und digitale Medien, die Verschiebung in Intersystemverhältnissen und die Rolle der Menschen in der Gesellschaft neu zu überdenken, ist deshalb bei der konventionellen Systemtheorie weniger gut aufgehoben als man zunächst meinen könnte (so auch Heintz 2021: 157 f.). Es fehlen Bezugspunkte für funktionale Analysen, die erlauben würden, die von Luhmann nur angedeutete Umstellung der strukturellen Kopplung von Bewusstsein/Kommunikation auf Komputation/Kommunikation theoretisch zu fassen. Der Aufstieg der Digitaltechnologien führt zu einer unausdenkbaren, mit den Mitteln der Theorie nicht mehr bestimmbar Gesellschaftstransformation. Diese Limitationen gelten auch für neuere Entwürfe, die die Bedeutung von Digitalisierung und KI auf systemtheoretischer Basis behandeln. Dirk Baecker bleibt zwar nicht der Systemtheorie, wohl aber dem Luhmann'schen Impetus treu, wenn er, statt die Transformation vor dem Hintergrund der Theorie funktionaler Differenzierung zu analysieren, mit einer Medienrevolution rechnet und entsprechend die Ankunft einer »nächsten«, in ihrer Differenzierungsform völlig anders gebauten Gesellschaft erwartet (Baecker 2018). Armin Nassehi geht den umgekehrten, theoretisch konservativen Weg, Digitalisierung als immer schon in die Strukturbedingungen funktionaler Differenzierung eingebaut zu beschreiben, so dass man an der Theorie gar nicht mehr so viel ändern muss (Nassehi 2019). Beides läuft darauf hinaus, *Digitalisierung als Prozess der Strukturtransformation theoretisch aus dem Blick zu verlieren*; im ersten Fall, weil der Wandel vermeintlich so radikal ist, dass klassische gesellschaftstheoretische Schemata nicht mehr greifen, im zweiten, weil er im Theorem funktionaler Differenzierung »immer schon« berücksichtigt war.

Diese Defizite der konventionellen Systemtheorie könnten vielleicht durch interne Revisionen bearbeitet werden und die Möglichkeit, dies zu tun, soll hier gar nicht in Abrede gestellt werden (siehe Dickel 2022). In der Summe sind jedoch so grundlegende Änderungen nötig, dass es sinnvoll scheint, sich nach Alternativen umzuschauen. Für unsere Zwecke soll bei der vor allem von Joachim Renn ausgearbeiteten pragmatistischen Differenzierungstheorie, der Theorie multipler Differenzierung (TMD), angesetzt werden (siehe auch Mölders 2019; Nell 2020; Renn 2006, 2014, 2016, 2021a). Die TMD legt ihre differenzierungstheoretischen Schwerpunkte gerade auf jene Bereiche, die in der Luhmann'schen Systemtheorie zu kurz kommen: Die Ko-Konstitution von Intentionalität und Sozialität, die Verhältnisse zwischen verschiedenen Systemtypen, und die Angewiesenheit sozialer Systeme auf pragmatische, verkörperte Wissensbestände der an ihnen mitwirkenden Menschen. Die Theorie soll hier nicht vollständig rekonstruiert werden, sondern in ihrer heuristischen Funktion für die Analyse der Digitalisierung selektiv in Anspruch genommen werden.

Eine zentrale Annahme der TMD ist, dass sozial abstrakte, mit höherer Reichweite und Durchsetzungsfähigkeit ausgestattete Einheiten wie Organisationen und Funktionssysteme auf einer anderen Form der Integration beruhen, für die *Sprache* konstitutiv ist. Im Unterschied zur einfachen Verknüpfung praktischer, symbolvermittelter Handlungen ermöglichen Sprachen mit propositionaler Struktur einen anderen Modus der Selbstreferenz und damit eine andere Form der sozialen Integration. Die TMD unterscheidet sich von klassischen differenzierungstheoretischen Entwürfen, die ebenfalls die besondere Rolle der Spra-

che für die Ausbildung von Systemen (Habermas, Parsons), autonomen Feldern (Bourdieu) oder Erfolgsmedien (Luhmann) betonen, durch eine pragmatistische Sprachtheorie im Anschluss an Wittgenstein, die die pragmatische Fundierung aller Kommunikation in Lebensformen betont. Auch abstrakte Zeichensysteme sind in bestimmten Handlungszusammenhängen fundiert, die Wittgenstein »Sprachspiele« nennt (Wittgenstein 2003) und die in der praktischen Gemeinsamkeit einer geteilten Lebensform verwurzelt sind. Diese Festlegung auf die Komplementärbegriffe von Sprachspiel/Lebensform als basale sozialtheoretische Einheiten hat weitreichende Folgen für die Differenzierungstheorie. Die vielleicht wichtigste ist die, dass abstrakte, reichweitenstarke soziale Einheiten nicht als selbstgenügsam, d. h. nicht als autopoietisch im Luhmann'schen Sinne gedacht werden können. Gemäß der Wittgenstein'schen Einsicht, dass Regeln nicht ihre eigene Anwendung vorschreiben können, funktionieren Abstraktionen und darauf aufbauende Systemtypen nur, weil sie andernorts Kontexte der Applikation voraussetzen können, die eine verlässliche und einigermaßen antizipierbare Regelanwendung garantieren. Auch hochabstrakte Systeme wie die Weltwirtschaft oder die moderne Wissenschaft sind so letztendlich auf nicht mehr systemintern zu garantierende pragmatische Leistungen angewiesen, d. h. auf Organisationen, Trägermilieus und letztlich Personen, die Geld investieren statt zu horten, wissenschaftlich korrekt urteilen, Recht konsistent anwenden, oder eine Religion angemessen ausüben. Abstrakte Systemlogiken müssen in konkrete Handlungszusammenhänge übersetzt werden. Es handelt sich dabei nicht um ein bloßes Nebeneinanderher-Operieren, von pragmatisch integrierten Lebensformen und ausdifferenzierten Systemen, sondern um Übersetzung, weil die pragmatische Konkretion sich an der *richtigen* Umsetzung von abstrakten Regeln orientiert und auch umgekehrt, bei der Gestaltung abstrakter Vorgaben in Organisationen und Funktionssystemen die Nichtkontrollierbarkeit der praktischen Anwendung in Rechnung gestellt werden muss. »Richtigkeit« hat hier den Sinn der »Angemessenheit«, sie meint eine praktische und implizite Normativität des korrekten, sozial anschlussfähigen Vollzugs, der durch explizite Normen niemals erschöpfend reguliert werden kann (Brandom 1979, 1994; Renn 2021b).³ Reichweitenstarke soziale Systeme entstehen zwar, indem

- 3 Sowohl die Fähigkeiten zur Abstraktion von Regeln aus der Praxis als auch die spezifizierende Durchsetzung abstrakter Regeln in die Praxis können nicht selbst durch abstrakte Regeln determiniert werden. Beide Punkte werden in ihrer theoretischen Bedeutung vom späten Wittgenstein gesehen: Aus jeder Handlungspraxis lässt sich eine Vielzahl von Regeln über die »richtige« Fortsetzung der Praxis ableiten (»Gerrymandering Problem«), und zu jeder Regel gibt es eine Vielzahl möglicher Praktiken, die man als »Anwendung« der Regel beschreiben könnte (Regelfolgeproblem) (vgl. Brandom 1994). Die empirische Relevanz der relativen Unabhängigkeit der Regelanwendung gegenüber ihrer Formulierung kann man sich an den Befunden der Organisationsforschung klarmachen, die die Prägestärke des »Street level« (Lipsky) bei der Implementation organisationaler Programme verdeutlichen. Wie Marc Mölders am Beispiel des Investigativjournalismus gezeigt hat (2019), gilt der Übersetzungszwang nicht nur »Top-Down«, sondern auch »Bottom-Up«: Die Irritation abstrakter Systemtypen – letztlich also die Beeinflussung von Gesellschaftsstrukturen durch lokale Praktiken – erfordert die Übersetzung lokaler Störungen in explizite Problemformulierungen, die an die Problembearbeitungskapazitäten abstrakterer Systeme anschlussfähig sein müssen. Es ist das Verdienst seiner Studie, zu zeigen, wie stark praktisches Wissen um die Irritabilität abstrakterer Systeme in lokale, organisational eingebettete Praktiken eingeschrieben ist.

sie von lokalen Kontexten abstrahieren, aber ohne sich von diesen komplett zu lösen.⁴ Um sich zu reproduzieren und in ihrer Umwelt zu behaupten, sind auch hochabstrakte, transsituativ operierende Systeme darauf angewiesen, in konkreten Handlungszusammenhängen durch den kollektiven Habitus einer eingespielten Praxis der Regelanwendung re-spezifiziert zu werden. Im Vergleich zur konventionellen Differenzierungstheorie hebt die TMD die pragmatische Einbettung funktionaler Differenzierung und die Angewiesenheit abstrakter Systeme auf praktisch verkörpertes, implizites Wissen besonders hervor: Keine Abstraktion ohne anschließende Konkretion. Organisationen und Systeme bleiben auch nach ihrer Ausdifferenzierung auf nicht restlos explizierbare pragmatische Leistungen angewiesen. Das implizite Wissen bleibt auch für abstraktere Systemtypen notwendige »Resource flexibler Umweltbeziehungen« (Renn 2021c: 189). Die sukzessive »Kleinarbeitung« abstrakter Systemprobleme in konkrete pragmatische Entscheidungen über die Stufen von Organisation, Milieu und Person nennt Renn eine »Übersetzungskaskade«. Es handelt sich bei einer konkretisierenden Top-Down-Kaskade nicht einfach um eine kybernetische Steuerungshierarchie, weil verschiedenartige Systeme auch verschiedene, miteinander inkompatible Medien (performative Handlungsabstimmung, explizite Semantik, Entscheidungen im Rahmen formaler Beziehungen) für ihre Reproduktion in Anspruch nehmen und ein Durchgriff von oben nach unten nicht möglich ist. Der Witz der derart gesellschaftstheoretisch gewendeten wittgensteinianischen Perspektive besteht in der Hilflosigkeit der Abstraktion gegenüber den sich allerorten ergebenden Spezifikationsbedarfen. Es reicht nicht, zu wissen, dass es in der Wirtschaft um Profite geht, um eine rentable Firma zu gründen; es reicht nicht, formale Hierarchien einzurichten, um die Firma erfolgreich zu führen; es reicht nicht, ein geselliger Mensch zu sein, um eine gute Chefin abzugeben. Die Organisationsforschung kennt viele Fälle, in denen explizite Organisationsziele und implizite Organisationskultur in Spannung geraten oder sogar zu einer Pervertierung der offiziellen Organisationszwecke führen (Gouldner 1965; Lipsky 1980; vgl. klassisch Luhmann 1962).⁵ Die Grenzen zwischen verschiedenen Sozialformen lassen sich nicht aufheben, sondern

- 4 In der Luhmann'schen Systemtheorie wird davon ausgegangen, dass Systeme das Verankerungsproblem lösen, indem sie Teile Ihrer Programmanwendung »konditionieren«, z. B. indem Motive generalisiert und stereotype Handlungsweisen erwartet werden können (z. B. mehr Geld zu haben, ist per se gut und Tauschbereitschaft von Waren gegen Geld kann in allen Wirtschaftseinrichtungen vorausgesetzt werden). Aber mit dem Konzept der Konditionierung unterschätzt man (ähnlich wie Bourdieu mit seinem Dispositionsbegriff) die tatsächliche Flexibilität und Kreativität bei der praktischen Regelauslegung (Joas 1992).
- 5 Allerdings gibt es breite Variationskorridore, innerhalb derer Systeme pragmatisch realisiert werden können. Abstrakte Strukturen werden – wie am eindrucklichsten wohl Garfinkel gezeigt hat – nicht dadurch reproduziert, dass in der Praxis eine starre Normkonformität eingeübt wird, sondern dadurch, dass es multiple Realisationsmöglichkeiten für strukturreproduzierende Handlungen gibt: Man reproduziert das Wirtschaftssystem, ganz gleich, wofür man sein Geld ausgibt; auch schlechte Lehrer kontinuierieren das Erziehungssystem, auch falsche Theorien die Wissenschaft usw. Gleichwohl gibt es Möglichkeiten, Strukturen pragmatisch zu unterlaufen, etwa, indem sich gegenüber dem Wirtschaftssystem Praktiken der Subsistenzwirtschaft, gegenüber dem Erziehungssystem Praktiken der Heimerziehung oder gegenüber der Wissenschaft Praktiken des »bullshitting« (H. Frankfurt) ausbilden.

können nur indirekt, im Modus der Übersetzung, von den sozialen Systemen selbst berücksichtigt, unter Inkaufnahme von Sinnbrüchen transzendiert, und dadurch immer auch aufrechterhalten werden. In diesem Sinne wird die Differenzierungstheorie handlungstheoretisch fundiert. Nicht alles ist Handlung, denn die Logik der systemischen Integration ist eine andere als die implizite Logik des Alltagshandelns, aber ohne Handlungen und praktisches Wissen ist alles nichts.

2.1 Sozialisation und Erziehung von Menschen und Maschinen

Wo soziale Strukturen auf Bewusstseinsleistungen angewiesen sind, sind sie an die begrenzte Aufnahmefähigkeit, die Serialität und die relativ langsame Verarbeitungsgeschwindigkeit menschlicher Kognition gebunden. Aus der Perspektive der TMD lässt sich dieses Verhältnis nun genauer analysieren, weil die Funktion menschlicher Kompetenzen nicht auf Kognition enggeführt wird (vgl. Luhmann 1991), sondern die gesamte Breite praktischer, körperlich-leiblicher Fähigkeiten in den Mittelpunkt der Frage nach der Aktualisierung von Systemstrukturen in konkreten Situationen gestellt wird. Abstrakte Systeme sind darauf angewiesen, dass sich in den heterogenen Lebensformen *implizite pragmatische Kompetenzen* ausbilden, die eine strukturkonforme Anwendung von Regeln sicherstellen. Das soziologisch geläufige handlungstheoretische Problem sozialer Ordnung wird also in die Frage transponiert, wie abstrakte gesellschaftliche Systeme reproduziert (und dabei: modifiziert) werden, obwohl ihre abstrakten Regeln einer prinzipiell nicht ›von oben‹ steuerbaren Anwendungspraxis ausgeliefert sind und zwischen unterschiedlichen Systemen pragmatisch übersetzt werden muss.

Es liegt auf der Hand, dass damit Prozesse der Weitergabe und Festigung von (implizitem) Wissen – und mithin Sozialisationsprozesse – in den Mittelpunkt des differenzierungstheoretischen Interesses rücken. Sozialisation soll hier einfach den Prozess bezeichnen, in dem Akteure sich darauf einstellen, dass sie in der Gesellschaft sind.⁶ Das differenzierungstheoretische Interesse an Sozialisation besteht darin, zu klären, auf welche Weise Akteure jene Kompetenzen und Dispositionen erwerben, die sie dazu befähigen und motivieren, gesellschaftliche Großstrukturen zu reproduzieren und zu ändern. Im Fall der TMD sind dies insbesondere Fähigkeiten, abstrakte Regeln situativ flexibel anzuwenden. Ohne praktische Regelanwendungskompetenz können sich die Funktionssysteme und Organisationen nicht reproduzieren, ohne das implizite Wissen um Verhältnismäßigkeiten kann die Übersetzung zwischen verschiedenen Integrationseinheiten nicht gelingen. Weil Sozialisation einer pfadabhängigen, umweltabhängigen Eigenlogik folgt, die von sich aus die gesellschaftlichen Bedarfe an Übersetzungskompetenz nicht

6 Der Begriff meint also nicht »Entwicklung zu etwas Höherem«, sondern schlicht Adaption an ein soziales Umfeld. »Fehlsozialisation« gibt es nur vom Standpunkt der Bestandserfordernisse bestimmter sozialer Einheiten (Milieus, Organisationen oder Systeme), die für ihre Reproduktion auf bestimmte Leistungen angewiesen sind. Musterschüler und gewalttätige Schulabbrecher sind je nach Bezugsgesichtspunkt funktional sozialisiert, je nachdem, ob man an Karrieren in Anwaltskanzleien oder organisierter Kriminalität denkt.

deckt, sind komplexe Gesellschaften auf *Erziehung* angewiesen: d. h. auf eine Lenkung des ontogenetischen Kompetenzerwerbs in eine erwünschte, für die Reproduktion bestimmter sozialer Strukturen *funktionale* Richtung. Während Sozialisation die eigenständige Anpassung von Eigenstrukturen in Reaktion auf die soziale Umwelt meint, versucht Erziehung, diesen Prozess zu »formen« (Prange 2008). In praktisch allen Gesellschaften wird Sozialisation durch Erziehung beeinflusst, aber nur in der modernen Gesellschaft ist die sekundäre Erziehung flächendeckend in Form eines Funktionssystems ausdifferenziert, über Organisationen kontrolliert und auf der Ebene der Leistungserbringung professionalisiert. Angesichts der Tatsache, dass die Moderne durch eine Vielzahl gesellschaftlicher Differenzierungsverhältnisse und eine entsprechend komplexe und evolutiv unwahrscheinliche Sozialstruktur gekennzeichnet ist, ist dies auch dringend nötig. Sämtliche soziale Einheiten von der Familie über die Organisation bis zum Funktionssystem sind auf praktische Kompetenzen zu ihrer effektiven Aktualisierung angewiesen. Weil diese Kompetenzen zu vielfältig sind, um in Familien reproduziert zu werden, kommt dem Erziehungs- und Bildungssystem eine wichtige Rolle zu, in dem junge Menschen zwecks strukturkonformer Kompetenzübertragung in ständig anwachsenden Zeitspannen festgehalten werden.⁷

Anhand der Unterscheidung von Sozialisation und Erziehung lässt sich eine instruktive – und wie im Folgenden gezeigt werden soll: keineswegs zufällige – Parallele zwischen den Sozialisationsverhältnissen der modernen Gesellschaft und der Geschichte des wissenschaftlichen Feldes der KI ziehen. In beiden Kontexten stößt man an die Grenzen der Explizierbarkeit des funktionsnotwendigen Wissens und findet auch ähnliche Lösungen. Sehr vereinfacht hat sich im Erziehungssystem ein Paradigmenwechsel von erziehungszentriertem »Frontalunterricht«, in dem Schüler explizites Wissen lernen und reproduzieren sollen, hin zu einem sozialisationszentrierten Erziehungsverständnis vollzogen. Erziehung läuft natürlich stellenweise immer auch über die Explikation von Wissen, die moderne Pädagogik und erst recht die höhere Bildung zeichnen sich freilich durch die Einsicht aus, dass sich Sozialisationsprozesse durch explizite Regeln nur sehr ungenügend steuern lassen (vgl. Ricken 2010). Luhmann und Schorr sprechen in diesem Zusammenhang von einem »Technologiedefizit« (Luhmann/Schorr 1981, 1996). Moderne Erziehung funktioniert deshalb wesentlich stärker als *Rahmung von Sozialisationsprozessen*, d. h. über die Kontrolle des Kontexts, in dem eigenständiges Lernen stattfindet. Pädagogisch institutionalisiert wird nicht mehr eine Autoritätsrelation zwischen Lehrern und Schülern, in der letztere das ausformulierte Wissen ersterer abnehmen und von den Lehrern in ihrer Übernahmeleistung kontrolliert werden. Institutionalisiert wird vielmehr die Erwartung, dass die Schüler sich selbst jene Regeln und Verhaltensweisen erschließen, die sie zum kompetenten Umgang mit pädagogisch manipulierten Umweltaforderungen befähigen. Man versetzt Kinder in eine Welt, in der Erfolge in Arithmetik

7 Nach Daten der Weltbank ist die globale Dauer der Jahre im Bildungssystem von durchschnittlich 9,2 Jahren im Jahr 1990 beständig bis auf 12,7 Jahre im Jahr 2019 gestiegen. (United Nations Development Programme. Human Development Index, Indicator: Expected Years of Schooling <http://hdr.undp.org/en/indicators/69706>, letzter Aufruf 10.10.2022).

und Gedichtanalyse mit überproportionaler sozialer Bestätigung versehen werden und setzt auf konvergente Lernprozesse. Kontrolle wird dabei nicht über die Sicherstellung der korrekten Übertragung expliziter Wissensinhalte ausgeübt, sondern über die Definition von abstrakter gehaltenen Zielkompetenzen und Tests, in denen diese Kompetenzen erhoben werden sollen. Man verzichtet auf die Standardisierung der Prozedur, die zu bestimmten Leistungen führt, sanktioniert die Ergebnisse aber durch Noten, Lob und Tadel sowie subtilere Signale der (Miss-)Billigung von Performanzen. Von einem »Technologiedefizit« wird man angesichts des verwissenschaftlichten, modernen Leistungs- und Leistungsmessungsregimes (PISA und andere) nicht mehr sprechen wollen – es handelt sich vielmehr um eine *indirekte Technisierung des Erziehungssystems* zugunsten eines Outcome-orientierten, individualisierenden Leistungssystems (Biesta 2016a, 2016b). An dieser Stelle geht es nicht um eine normative Bewertung dieser Entwicklung, sondern um die soziale Funktion einer indirekt technisierten Erziehung über die Manipulation von Lernbedingungen. Welches Problem wird dadurch gelöst? Die Vermutung lautet: Sozialisation unter der Bedingung von Kontextsteuerung und Sanktionierung ist eine soziale Lösung des von Wittgenstein identifizierten Regelfolgeproblems. Ihre Funktion liegt in der Stabilisierung des Verhältnisses von Regel/Regelanwendung, auch wenn die Regeln hochabstrakt und entsprechend konkretisierungsbedürftig sind, außerdem in der Ermöglichung von Erwartbarkeiten, wenn explizite Regeln unmöglich sind.⁸ Wie Robert Brandom gezeigt hat, bedarf es für strukturkonforme Sozialisation keiner Explikation von Regeln; allein über Sanktionierung gelungener Performanzen durch Anschlüsse und fehlschlagender oder unerwünschter Handlungen durch negative Sanktionen lassen sich soziale Praktiken der Regelanwendung stabilisieren (Brandom 1997: 538, 2000: 77 ff.). Dies bedeutet, dass das unlösbare Problem der Formulierung sämtlicher Anwendungsbedingungen einer Regel pragmatisch umgangen werden kann; es reichen Signale der sozialen Anerkennung oder Ablehnung von Performanzen. Lerneffekte lassen sich punktuell – z. B. durch anschlussfähige Performanzen oder formale Tests – nachweisen.

Wie im Folgenden zu zeigen sein wird, ist die gesellschaftstheoretische Funktion von implizitem und explizitem Wissen und der Modus ihrer Vermittlung in Sozialisation und Erziehung zentral, um die Funktionsweise und soziale Bedeutung von KI zu verstehen. Neuere KI-Systeme setzen, genau wie das Erziehungssystem, an dem Problem an, den kompetenten Umgang mit Regeln von einer Einheit auf die andere zu übertragen, wenn die Anwendungsbedingungen der Regel nicht vollständig explizierbar sind. Wie beim Erziehungssystem wird das eigenständige Lernen in kontrollierten Umgebungen als Lösung anvisiert. Und wie beim Erziehungssystem vollzieht sich dieser Wandel über die Erfahrung des Scheiterns des »Frontalunterrichts«. Nachdem in den 1940er und 1950er Jahren frühe Versuche, selbstlernende Maschinen nach dem Vorbild des menschlichen Gehirns zu konstruieren, u. a. an mangelnder Rechenkapazität gescheitert waren, wurde das wissenschaftliche Feld der KI zwischen

8 Typischerweise betrifft dies Fälle, in denen Regeln nicht artikulierbar sind, weil sich die entsprechenden Kompetenzen nicht (vollständig) versprachlichen lassen. Es gibt aber auch Fälle der normativen Unzulässigkeit einer expliziten Regel bei gleichzeitiger Funktionalität ihrer praktischen Befolgung, wie etwa im Fall von »brauchbarer Illegalität« (Kühl 2020).

den 1960er und 1990er Jahren von der symbolistischen Schule dominiert. Diese war der Auffassung, dass das Design intelligenter Maschinen auf einer Kenntnis der kognitiven Prinzipien, nach denen der Geist funktioniert, beruhen sollte und dass diese Regeln einprogrammiert und verändert werden können sollten (Cardon et al. 2018). Die symbolistische Strömung setzte also auf das informationstechnische Äquivalent von ›Frontalunterricht‹. Es wurde versucht, Kompetenzen in Regelabstraktion und -anwendung an Maschinen zu übertragen, indem Menschen diese Regeln explizit in einer Programmiersprache formulierten und implementierten. Maschinen wurden mit logischen Ontologien, Arten der Wissensrepräsentation und Schlussregeln ausgestattet, die intelligentes Verhalten simulieren sollten. Dieses Verfahren erzielte eine Reihe von Erfolgen insbesondere in kontrollierten Umgebungen, für die sich die Anwendungsbedingungen von Regeln relativ gut definieren ließen. Ein bekanntes Beispiel für die Erfolge symbolistischer, auf expliziten Regeln basierender KI ist etwa der Sieg des Computers *Deep Blue* gegen den damaligen Schachweltmeister Garry Kasparov im Jahr 1997 oder der Sieg des IBM-Programms Watson gegen seine menschlichen Kontrahenten bei Jeopardy 2011. Doch außerhalb von Umgebungen, in denen sich wie beim Schach Erfolgsbedingungen klar definieren und Situationen der Regelapplikation vorhersehen lassen, stieß das symbolistische Programm an prinzipielle Grenzen. Die symbolistischen KI-Systeme schafften es selten aus den Laboren hinaus, weil sie jenseits kontrollierter Umgebungen äußerst anfällig für nichtvorhersehbare Variationen in den Umweltbedingungen waren. Gerade dass die Technik zum blinden Gehorsam den immer gleichen Regeln unter festgelegten Bedingungen erzogen wurde, machte sie weniger nützlich, anfällig für Fehler und Selbstblockaden, ähnlich wie Bürokratien sich durch Dienst nach Vorschrift auf raffinierte Weise lahmlegen lassen. Schon Wittgenstein und Heidegger hatten gesehen, dass die Welt nicht als Summe von Fakten, die durch explizite Regeln verknüpft sind, repräsentiert werden kann und deshalb das Frontalunterrichtsmodell der KI ähnlich limitiert ist, wie sein pädagogisches Pendant (siehe die einflussreiche Kritik bei Dreyfus 1976, 1992). Eine Reihe von Fehlschlägen und die damit verbundene Einsicht in die prinzipielle Nichtexplizierbarkeit der Hintergrundkompetenzen, auf denen menschliche Praktiken aufruhen, führte zum ersten KI-Winter der 1970er Jahre, einer Phase der Stagnation und Fragmentierung des Forschungsfeldes bei drastisch zusammengestrichenen Forschungsbudgets. Das innerhalb des symbolistischen Paradigmas unlösbare Grundlagenproblem lautete: *Wie kann man Regeln gemeinsam mit Ihren Anwendungsbedingungen technisieren, wenn man diese Anwendungsbedingungen nicht explizit als Regeln formulieren kann?*

In den späten 1980er und 1990er Jahren nimmt ein Paradigmenwechsel zu konnektionistischen Lernarchitekturen an Fahrt auf. Die symbolistische Vorstellung, wonach intelligenten Maschinen möglichst viel explizites Wissen und Entscheidungsregeln einzuprogrammieren sei, wird abgelöst von Formen des Machine Learning (ML), in denen aufgabenspezifische Konzepte nicht über explizite Regeln, sondern über eine Vielzahl von Beispielen erworben werden. Dies ging mit einem Wechsel zu algorithmischen Architekturen einher, die nicht nach dem Muster logischer Hierarchien, sondern nach dem Vorbild neuronaler Netze gestaltet sind. Weil es sich um ›tiefe‹ Netze mit mehreren Schichten simulierter Neuronen handelt, spricht man von Deep Learning. Die Idee des Deep Learning ist nicht neu, aber mit neuer Hardware, größeren Datenbanken und

der Verknüpfung verschiedener Datentypen (Big Data) und verbesserten Algorithmen konnten praktische Durchbrüche bei einer Vielzahl von Benchmarks erzielt werden, die der Umsetzbarkeit induktiven und impliziten Lernens neue Evidenz verlieh (Cardon et al 2018). Entscheidend für die Soziologie ist aber nicht die technische Binnenstruktur der Algorithmen, sondern die Art ihrer Relationierung zur sozialen Welt. Diese ändert sich fundamental, weil sich mit dem Übergang zu selbstlernenden Maschinen das Medium der Übersetzung zwischen Gesellschaft und Maschine ändert. Technisiert wird nicht mehr das explizite Welt- und Regelwissen von Menschen, sondern latente Strukturen in großen Datensätzen, aus denen die Algorithmen eigenständig Regeln für die Verarbeitung neuer Daten ableiten können. Aufgabenspezifische Algorithmen werden von allgemeineren Algorithmen geschrieben, die darauf programmiert sind, komplexe Funktionen für die Strukturierung von Daten zu erstellen und immer weiter zu verbessern. Menschengeschriebene Programme, die nur wenige hundert Codezeilen lang sind, generieren Programme, die mehrere Millionen Codezeilen lang sind (Domingos 2018: 9 f.).

In der Mensch-Maschine-Relation entspricht dies einer Umstellung des Lehrparadigmas von direkter *Erziehung* (*Lehren* durch Explikation von Regeln und Anwendungsbedingungen, *Lernen* durch Kopieren der Regeln) auf indirekte *Erziehung durch Sozialisation* (*Lehren* durch Kontextmanipulation; *Lernen* durch eigenständige Extrapolation von Regeln und Selbstkorrektur auf Basis von Feedback). ML-Algorithmen können anhand von Daten über den gewünschten oder typischen In- und Output anderer Systeme deren Leistung emulieren. In der menschlichen Sozialisation ließe sich der Modus des Lernens mit Lernen durch Demonstration am Beispiel vergleichen. Die ML-Algorithmen lernen nicht, was jemand explizit weiß, sondern, wie man tut, was jemand tut⁹. Das bedeutet: Die ›Erziehung‹ der Algorithmen findet nicht mehr als Übertragung von Wissen statt, sondern nimmt den Umweg über Daten, der das Problem der Nichtartikulierbarkeit impliziten Regelwissens umgeht.

Durch ML werden nichtbiologische materielle Dinge also in einem gewissem Sinn sozialisationsfähig: Sie lernen durch Feedback, sich eigenständig an eine Umwelt anzupassen. Das heißt nicht, dass diese Algorithmen nicht auf menschliches Regelwissen und Unterscheidungsvermögen angewiesen wären. Ganz im Gegenteil zehren ML-Systeme parasitär von den Unterscheidungspraxen menschlicher Akteure, die jene Regelmäßigkeiten in den Daten erzeugen, die als Struktur gelernt werden können. Aber dieses Wissen muss nicht mehr expliziert und von Menschen in Formen der symbolischen Repräsentation überführt werden, die für Maschinen anschlussfähig sind. Expliziert werden müssen nicht mehr aufgabenspezifisch Kompetenzen, sondern allgemeine Regeln des Lernens. Um die Relevanz der Entlastung von Explikationszwängen zu begreifen, stelle man sich vor, man müsste Kindern das Schwimmen beibringen, indem man ihnen *explizit sagt*, wie man in welcher Phase des Schwimmzugs, Schultern, Oberarme, Unterarme, Handgelenken und Finger jeweils in Relation zum vorangegangenen Augenblick positionieren müsste, statt einfach Beispiele für gute Schwimmzüge vorzumachen und

9 Logisch lässt sich das Verhältnis als »P-P-sufficiency«, oder practice-to-practice sufficiency bestimmen (Brandom 2008).

die Kinder aus ihren Fehlschlägen und Erfolgen im Umgang mit dem Wasser lernen zu lassen. Wie bei Kindern können für die Vermittlung von Kompetenzen bestimmte basale (Lern-)Fähigkeiten vorausgesetzt werden, so dass es an keinem Punkt des Lernvorgangs nötig wird, zu sagen, wie genau man schwimmt, rechnet, oder Objekte voneinander unterscheidet. Das Resultat ist ein Modus der Technisierung, der nicht mehr das explizite Verständnis eines Zusammenhangs voraussetzt. Die Regeln der Hervorbringung einer Performanz bleiben auch bei der eigenständigen Encodierung durch Maschinen implizit; sie können zwar von Maschine zu Maschine übertragen werden, verbergen sich aber in der präzisen Unüberschaubarkeit komplexer mathematischer Funktionen, die sich *nicht* durch Exaktheit der korrekten Repräsentation generativer Regeln, sondern durch Funktionalität bei der Simulation einer Kompetenz auszeichnen. Dies ermöglicht Kontrolle ohne Verständnis: Es ist wesentlich einfacher, festzustellen, ob etwas funktioniert oder nicht funktioniert, als zu sagen, wie genau etwas funktioniert, und es ist einfacher, Beispiele für richtige Reaktionen zu geben, als die Regeln zu benennen, nach denen in allen möglichen Situationen richtig reagiert wird. Durch ML wird also die Übertragung von Fähigkeiten an materielle Artefakte von Explikationszwängen entlastet: Es reicht, datenförmige Beispiele für erwünschte Performanzen vorzuhalten und Optimierungsparemeter zu definieren. Dadurch wächst der Kreis der technisierbaren sozialen Leistungen ins Unermessliche. Die Systeme sind zwar datenhungriger und in diesem Sinne begriffsstutziger als menschliche Kinder (GPT-3 ist beispielsweise laut einer Schätzung auf etwa 2000 mal mehr Sprachdaten trainiert als ein zehnjähriges menschliches Kind, siehe Warstadt/Bowman 2022: 19; zur Generalisierungsfähigkeit von Kindern siehe Tomasello 2020), allerdings sind durch das Internet und eine Vielzahl von Quantifizierungsprozessen viele Arten von Daten nicht mehr knapp, so dass der vorläufige Mangel an Abduktionseffizienz auf Seiten der Algorithmen kein prinzipielles Funktionshindernis mehr darstellt. Andererseits rechnen sie schneller, vergessen weniger, werden nicht müde oder schlecht gelaunt, und sind nicht wie menschliche Körper an eine einzelne raumzeitliche Instanz gebunden. Machine Learning erschließt die überbordende, für menschliches Bewusstsein und Kommunikation zu sperrige Komplexität großer Datensätze als Ressource der Technisierung von Kompetenzen und der Erzeugung neuer Technik. Datafizierung und ML stützen und fordern sich wechselseitig; es sind intereffikative Binnenprozesse im Herzen der Digitalisierung.

Dieses technisch ermöglichte Steigerungsverhältnis von Datafizierung und automatisierter Informationsverarbeitung soll im Folgenden genauer auf sein *Zusammenspiel mit sozialen Strukturen* untersucht werden. Was bedeutet es, wenn Maschinen und Programme in dem hier umrissenen Sinn sozialisationsfähig werden und über die Definition von Zielparametern indirekt erzogen werden können? Welchen gesellschaftlichen Unterschied macht es, wenn die Technisierung von Kompetenzen nicht mehr die Explikation der Regeln erfordert, die für die Hervorbringung der Kompetenzen nötig sind, sondern das Sammeln relevanter Daten ausreicht? Was bedeutet die Technisierung des Impliziten für das Soziale?

Auf Basis der Theorie multipler Differenzierung und der Rolle, die implizites Wissen und Sozialisation in ihr spielen, lässt sich eine erste Vermutung formulieren. Die im

Folgenden zu entwickelnde These lautet: *KI ermöglicht die Technisierung von Übersetzungskaskaden bzw. Mikro-Makro-Verknüpfungen*. KI wäre demnach bedeutsam für die Technisierung jener Prozesse der Abstraktion und Respezifikation, in denen zwischen verschiedenen abstrakten gesellschaftlichen Integrationseinheiten übersetzt wird. Maschinen gewinnen Anschluss an die datafizierte Spuren der praktischen Normativität impliziten Wissens und können sich dadurch in Übersetzungsprozesse einklinken. Übersetzt wird nach der Theorie multipler Differenzierung immer dann, wenn Sinngehalte unterschiedlicher Systeme aufeinander bezogen werden müssen. Dabei sind zwei Fließrichtungen der Übersetzung besonders relevant: erstens die Top-Down-Spezifikation abstrakter Regeln in konkrete Situationen; wenn etwa Asylrecht (System) im konkreten Kontext einer Erstaufnahmeeinrichtung (Organisation) für Flüchtlinge umgesetzt werden muss (Interaktion im Rahmen von Milieus), oder die Anwendung von Rechtsparagrafen in der Interaktionssituation eines Gerichtsverfahrens konkretisiert wird. Die gegensätzliche Fließrichtung der Übersetzung ist Bottom-Up und meint Übersetzungen von spezifischen Prozessen in eine Sprache, die in abstrakteren sozialen Einheiten anschlussfähig ist. In der Theorie multipler Differenzierung ist der Bottom-Up-Prozess vor allem für die Ausdifferenzierung abstrakterer sozialer Einheiten bedeutsam (vgl. etwa Renn 2021b). Ein einfacher Fall von Bottom-Up-Übersetzung ist etwa die Artikulation impliziter Regeln als explizite Normen oder Aussagen, z. B. wenn Schemata der ästhetischen Wahrnehmung in der Kunstkritik expliziert werden und dadurch die Ausbildung der Kunst als eigenständige Sphäre des Sozialen begünstigen. Bottom-Up-Übersetzung kommt aber nicht nur bei der Ausdifferenzierung von Systemen, sondern immer dann zum Tragen, wenn die Besonderheit lokaler Kontexte in gesellschaftliche Makrostrukturen Eingang finden; man mag dabei an gezielte Beeinflussung von Systemen durch strategische Irritation ›von unten‹ denken (Mölders 2019) oder an Fehlschläge bei der Anwendung abstrakter Regeln, die das Nachsteuern auf übergeordneter Ebene veranlassen, etwa die unzähligen Kompromisse, die Organisationen mit ihren internen und externen Milieus eingehen, um ihnen im Rahmen der eigenen Prozesslogik entgegenzukommen und dadurch effizienter zu funktionieren.

Die entscheidenden Fließrichtungen der Übersetzung sind also a) Prozesse der Explikation von Regeln und Regelmäßigkeiten bisher impliziter Handlungsmuster und b) der Anwendung abstrakter Regeln in konkreten Situationen. Wie im Folgenden zu zeigen ist, klinkt sich das Machine Learning in diese Relation ein und verteilt die Machtverhältnisse zwischen abstrakteren und konkreteren sozialen Einheiten neu. Es lohnt sich, auch noch einen weiteren Aspekt der sozialen Strukturierung hinzuzunehmen, nämlich die Integration von Regeln zu kohärenten Handlungsprogrammen oder Strategien. In der TMD wie auch der soziologischen Systemtheorie ist der Rekurs von Regeln auf Regeln bedeutsam, um die Ausdifferenzierung von sozialen Systemen zu erläutern. Auch hier gilt, dass die Regelung von Regeln durch Regeln unter dem Gesichtspunkt interner Konsistenz nicht in den Regeln selbst enthalten ist und auch nicht logisch aus ihnen gefolgert werden kann; auch hier ist implizites Wissen nötig, das sich gegen eine konventionelle Technisierung sperrt. Ich werde im Folgenden zeigen, dass sich selbstlernende Maschinen in alle drei Bereiche der Übersetzung und systemischen Selbstorganisation einschalten.

Machine Learning kann implizites Wissen für die Abstraktion, Respezifikation und Integration von Regeln vertreten – und zwar anders als konventionelle Technik *nicht*, indem es expliziert und durch technisch materialisierte Formeln ersetzt wird, sondern indem *sozialisierbare Maschinen* die Muster praktischer Kompetenz technisch emulieren.

2.2 Drei Typen des Machine Learning, drei Arten der Substitution impliziten Wissens: Respezifikation, Abstraktion, pragmatische Integration

In der KI-Forschung hat sich eine Differenzierung von verschiedenen Lernproblemen/ Lernmechanismen durchgesetzt, die KI-Systeme danach differenzieren, wie sie jeweils aus Daten lernen und in welcher Weise Daten vorformatiert sein müssen, um Lernen zu ermöglichen. Diese Kategorisierung nach Supervised Learning, Unsupervised Learning und Reinforcement Learning ist auch soziologisch instruktiv, weil sie Anschlussstellen von Technik und Sozialem definiert. Regelanwendung, Regelformulierung und systemische Integration von Regeln lassen sich verschiedenen Typen des Machine Learning zuordnen.

2.1.1 KI als Technisierung von Regelanwendung: Supervised Learning

Eine wichtige Art des Lernens, die hinter vielen kommerziellen Anwendungsmöglichkeiten von KI steckt, ist das sogenannte Supervised Learning. Überwachtes Lernen dient meistens der Klassifikation und erfordert Rohdaten, in denen Daten mit korrekten Zuordnungen bereits definiert sind – also etwa Bilder, denen bereits bestimmte Labels als Bildbeschreibungen zugeordnet sind (»Eine Katze«). Der Computer soll eine Funktion lernen, die auf Basis der Beispiele (»Trainingsdaten«) die automatische Klassifikation auch neuer Daten ermöglicht. Das ML-System findet latente Gemeinsamkeiten zwischen den (oft viele Millionen) Beispielen. Das Lernen besteht in diesem Fall darin, auf Basis von gegebenen Input-Output-Paaren eine immer bessere Funktion für die Vorhersage des Outputs bei gegebenem Input zu schätzen. Das eigentlich Interessante ist, dass diese Funktion im Erfolgsfall auch auf neue, bisher nie gesehene Beispiele generalisiert, also z. B. auch auf nie gesehene Bildern Katzen und Hunde unterscheidet. Supervised Learning ist infrastrukturell voraussetzungsreich, weil es große Datenbanken für Training und Test der Systeme erfordert. Ihre Funktion besteht darin, menschliches Klassifikationsvermögen zu automatisieren. Bereits bekannte Regeln und Unterscheidungen können automatisch angewandt werden, wobei der Algorithmus die nichtexplizierbaren Anwendungsbedingungen der Regel aus den Daten lernt. Aktuelle Anwendungsgebiete für Supervised Learning sind etwa Bilderkennung, Qualitätsprüfung bei Produkten, Diagnose von Krankheiten, bildgebende Diagnostik (z. B. Hautkrebserkennung) u.v.m. Technisierbar wird durch Supervised Learning die korrekte Anwendung einer Regel, bei der man zwar richtige von falschen Anwendungen unterscheiden, aber nicht explizit sagen kann, nach welchen Kriterien diese Unterscheidung sich richtet. Der idealtypische Anschluss von überwachend lernenden Algorithmen an soziale Einheiten besteht in der

Spezifikation abstrakter Regeln und Programmvorschriften. Supervised Learning ist also eine technische, gegenüber Sozialisation funktional äquivalente Lösung des von Wittgenstein formulierten Problems, dass Regeln ihre eigene Anwendung nicht vorschreiben können. Diese Regelanwendungskompetenz ist nicht gleichbedeutend mit dem Verstehen der Regel. Klassifizierende Supervised-Learning-Algorithmen wissen nicht, welchen Unterschied es macht, etwas als »Katze« zu bezeichnen; sondern nur, wann es auf Basis von Inputdaten richtig ist, das Label »Katze« zu vergeben. Für einen derart trainierten Klassifikationsalgorithmus gilt deshalb auch der Wittgenstein'sche Satz, dass die Grenzen der Sprache die Grenzen der Welt seien, in aller Schärfe. Alle Daten werden ausschließlich auf ihre Passung oder Nicht-Passung zu gegebenen Kategorien betrachtet; jenseits der Kategorien gibt es nichts. Ein Algorithmus, der nur zwischen Katzen und Hunden zu unterscheiden gelernt hat, wird auch Elefanten, Schallplatten und religiöse Symbole nur nach ihrer jeweiligen Hunde- oder Katzenähnlichkeit klassifizieren. Es wäre also irreführend zu behaupten, dass Computer durch Supervised Learning den Gebrauch bestimmter *Begriffe* lernen könnten – sie lernen, *Label* zu applizieren, sie lernen aber nur sehr eingeschränkt, was diese Label bedeuten (vgl. Brandom 2009).

2.2.2 KI als Technisierung von Regelabstraktion: Unsupervised Learning

Unsupervised Learning ist eine Methode, um große Datensätze automatisch auf latente Muster absuchen zu lassen oder Inhalte auf zugrundeliegende Dimensionen zurückzuführen. Wie beim Supervised Learning wird nach Strukturen gesucht, die tieferliegende Gemeinsamkeiten zwischen Fällen aufdecken könnten, aber es sind keine Label zur Bezeichnung dieser Strukturen vorgegeben (Russell et al. 2016: 817). Unsupervised Learning beobachtet die Welt nicht anhand semantischer Kategorien in Datensätzen, sondern anhand latenter Strukturen, die gerade deswegen Informationswert haben, weil sie Gemeinsamkeiten zwischen Elementen und Ereignissen zutage fördern, für deren Zusammenhang es noch keine Begriffe gibt. Es ist daher auch nicht ausgemacht, dass die gefundenen Cluster mit sprachlichen Unterscheidungen zusammenfallen, so dass es anders als beim Supervised Learning schwierig sein kann, die Outputs der Maschine an menschlich verstehbare Kategorien anschlussfähig zu machen. Vielleicht bilden Menschen, die Rotwein, Katzenfutter und schwarze Rollkragenpullover kaufen, einen eigenen Typus, für den uns aber nicht unbedingt ein Begriff zur Verfügung steht. Wenn der Algorithmus entdeckt, dass dieser Typus auch an Büchern von Sartre interessiert ist, mag sich auch für menschliche Beobachter eine verbale Bezeichnung aufdrängen – aber der Rückschluss von geclusterten Daten auf semantische Kategorien bleibt prekär, unscharf und potenziell irreführend und ist für viele Anwendungen auch gar nicht nötig. Aktuelle Anwendungsgebiete des Unsupervised Learning sind etwa Konsumentenanalysen, Datenkompression, und digitale Empfehlungssysteme (vgl. Mueller/Massarón 2016: 169), aber auch Natural-Language-Processing und damit Aufgaben wie Textvervollständigung oder Übersetzen. Große Sprachmodelle (Large-Language-Models) wie ChatGPT wurden hauptsächlich unsupervised trainiert (wobei die PR-Abteilungen der Tech-Unternehmen mittlerweile empfehlen, von »self-supervised« zu sprechen, um die Suggestion der Kontrolliertheit aufrecht zu erhalten). Unsupervised Learning löst das von Wittgenstein formulierte Problem, dass aus verschiedenen Anwen-

dungen keine eindeutige Regelformulierung abgeleitet werden kann. Aus der Vielzahl an Handlungsmustern müssen einige Regelmäßigkeiten als »diejenigen ausgezeichnet werden, mit denen übereingestimmt werden sollte, einige Muster als diejenigen, die fortgesetzt werden sollten.« (Brandom 2000: 70).¹⁰ Unsupervised-Learning-Algorithmen unterlaufen dieses Problem, indem sie Regeln finden, die zwar nicht mit Notwendigkeit aus den Daten folgen und insofern arbiträr sind, die aber für gegebene Zwecke *funktionieren* und die angesichts neuer Beispiele kontinuierlich optimiert werden können (Jordan/Mitchell 2015: 258). Der idealtypische Anschluss an soziale Systeme besteht in der *Sensibilisierung von Systemprogrammen für neue Anwendungsmöglichkeiten* (etwa, wenn ein Algorithmus automatisch erfasst, dass man Personen, die heute Windeln kaufen, in wenigen Jahren auch Gartentrampoline anbieten kann). Auch die Leistung von Large Language Models liegt gerade nicht in ihrer regelgetreuen Befehlsausführung, sondern im Finden interessanter Fortsetzungen. Diese Sensibilisierung abstrakterer sozialer Einheiten für konkrete Chancen der Durchsetzung ihrer Programme, muss nicht implizit in der Struktur der Algorithmen bleiben, sondern kann auch anregend für die *Explikation neuer Unterscheidungen* wirken, die in der Folge steuerungswichtig werden. Für ein Beispiel mag man an die strategische Beeinflussung von automatisch identifizierten Wählergruppen mit eigens abgestimmter Wahlkampfkommunikation denken, wie dies beim Cambridge-Analytica-Skandal der Fall war. Es ist allerdings eine offene Frage, ob Unsupervised Learning Explikation primär anregt oder ersetzt – schließlich ist es für viele Zwecke nicht nötig, die Muster, auf denen Entscheidungen beruhen, zu explizieren. Unsupervised Learning kann also auch genutzt werden, um die Kopplung von Entscheidungen an menschliche Urteile aufzuheben und so zu einer partiellen Entsprachlichung sozialer Systeme führen: Es reicht, relativ abstrakte Zielvorgaben zu formulieren – etwa: Kunden auf einem Streamingportal ähnliche Musik vorzuschlagen, wie die, die sie und andere Kunden mit einem ähnlichen Geschmack dort bereits gehört haben – ohne dass die gefundenen Patterns notwendigerweise semantisch expliziert werden müssten.

2.2.3 KI als Technisierung von Konditionalprogrammen: Reinforcement Learning

Ein dritter Typus der maschinellen Sozialisation besteht im Reinforcement Learning. Reinforcement Learning ist ein komplexerer Lerntypus, weil er die Unterscheidung von Agent und Umwelt einführt und die Interaktion von Algorithmus und Datensatz als *zeitlichen*, kontingenten Prozess modelliert, in dem die Reihenfolge, in der Ereignisse in einem Prozess auftreten, wichtig ist. Wie im Unsupervised Learning interagiert der Algorithmus mit einem Datensatz, in dem es keine Beispiele für korrekte Regelanwendungen

10 Wittgenstein verdeutlicht dies an der Frage nach der richtigen Fortsetzung einer Zahlenreihe – auch bei Beispielen, in denen eine gegebene Reihe von Zahlen scheinbar durch eine einfache Regel erzeugt wird – nehmen wir das Beispiel: 1001, 1002, 1003, 1004 ... Neben der – warum auch immer – offensichtlichen Regel A: »Addiere 1 zu der vorangegangenen Zahl«, lassen sich unendlich viele komplexere Regeln angeben, die ebenfalls diese Zahlenreihe erzeugen würden [Regel B: Addiere 1 bis zur angegebenen Zahl bis Du bei 1004 angekommen bist, danach addiere 10]. Weil es unendlich viele Regeln gibt, die mit der Zahlenreihe kompatibel sind, wird die Fortsetzung beliebig (Kripke 1982; Wittgenstein 2003: §§143-148).

gibt. Im Unterschied zum Unsupervised Learning gibt es aber eine abstrakte Zielvorstellung – den Gewinn beim Aktienhandel zu maximieren, ein Spiel zu gewinnen, oder unfallfrei zu einem bestimmten Ort zu fahren. Aktuelle Einsatzgebiete dieses Typus von ML sind etwa Robotik, autonomes Fahren, Handel und eine Vielzahl virtueller Agenten; etwa solche, die Schach, Go und verschiedene Videospiele in einer Zahl von Spielrunden, für die menschliche Spieler mehrere Jahrtausende benötigen würden, gegen sich selbst auf übermenschlichem Niveau zu spielen lernen. Reinforcement Learning ermöglicht die Automatisierung instrumentell-rationalen Verhaltens auf einer allgemeineren Stufe, die nicht Regeln, sondern Strategien zu abstrakt definierten Zielen automatisiert. Dies ermöglicht eine *abstraktere Definition korrekter Performanzen*, die nicht mehr über Regeln für einzelne Operationen (richtig/falsch), sondern über Ziele läuft, wie beim Schach etwa den gegnerischen König matt zu setzen, ganz gleich, wie dies erreicht wird; oder durch Aktienhandel größtmögliche Gewinne zu erzielen, ganz gleich, nach welchen Kriterien man Aktien kauft und wie lange man sie hält. Der digitale Agent beeinflusst mit der Wahl einer Aktion die Zustände seiner Umwelt. Nach der Auswahl einer oder mehrerer Aktionen erhält der Agent Feedback in Form von einer mit einer Sanktion versehenen Beobachtung des Umweltzustandes, den die Aktion hervorgerufen hat. Der Agent lernt, indem er im Zeitverlauf die Funktion zur Auswahl der Aktionen so anpasst, dass Bestrafungen minimiert und Belohnungen maximiert werden. Es geht beim Reinforcement Learning weder um die Applikation von vorher bekannten Regeln, noch um die Explikation von Regelmäßigkeiten, sondern um das Finden von Strategien. Strategien erfordern die situationsadäquate Wahl von Regeln, nach denen Aktionen ausgewählt werden, um ein bestimmtes Ziel zu erreichen. Reinforcement Learning hat ein beeindruckendes Potenzial für die Transformation sozialer Strukturen, da es nicht nur die Technisierung der Regelfindung oder -ausführung ermöglicht, sondern potenziell ganze Systemprogramme automatisiert werden könnten. Explizit spezifiziert werden muss nur ein abstrakter Wert (etwa: Profitmaximierung), die Regeln, nach denen für die Erreichung dieses Wertes vorgegangen werden muss, müssen weder einprogrammiert noch aus menschlichen Daten erschlossen werden, sondern werden selbst gefunden. Allerdings besteht ein zur klassischen symbolistischen KI analoges Problem, weil eine annähernd perfekte Simulation der Umwelteffekte der algorithmischen Entscheidungen nötig ist, so dass derzeit Reinforcement Learning vor allem in kontrollierten Umgebungen beeindruckt, in komplexen Umwelten (etwa im innerstädtischen Straßenverkehr) jedoch noch an Grenzen stößt.

3. Diskussion: Die Beziehung von implizitem und explizitem Wissen als Leitfaden für das Verständnis von KI

3.1 Verschiebung im Verhältnis Individuum & Gesellschaft

Die soziale Funktion von selbstlernenden Algorithmen unterscheidet sich gravierend von der Funktion konventioneller Computertechnologie. Zwar reagieren sowohl menschengeschriebene Programme als auch selbstlernende Algorithmen auf das Problem des

Komplexitätsgefälles und der unzureichenden Kanalkapazität, aber die Lösung ist eine grundsätzlich andere. Klassische Computertechnologie zielt auf Übersetzungsverhältnisse mit kompetenten Personen ab, die die Kapazitätsgrenzen des Sozialen steigern, indem sie a) personale Informationsverarbeitungskapazität und b) die Frequenz von Kommunikation über digitale Verbreitungsmedien steigern. Diese klassische Digitaltechnologie lässt sich in ihrer sozialen Bedeutung über das *Interface* zwischen *User* und digitaler Technologie begreifen. Automatisch gesammelte, aggregierte und vorprozessierte Daten werden im Interface auf eine Weise präsentiert, die an menschliche Kognition anschlussfähig ist und kommuniziert werden kann; Kopplung findet auf der Ebene der Informationsverarbeitung statt.

Demgegenüber zeichnet sich maschinelles Lernen und insbesondere das Deep Learning durch eine prinzipiell opake Weise der Informationsverarbeitung aus. Digitalisierung macht praktisches Wissen als Muster mobil und macht die Anwendung – ohne den Umweg über eine Explikation – standardisierbar. Man weiß nicht genau, *was* man implementiert, aber man weiß, *dass* es funktioniert und kann es, bei hinreichender Robustheit des Modells, auf unterschiedliche Kontexte generalisieren. Maschinell erschlossene Muster sind deshalb *kein* Interface zwischen menschlichem und maschinellem Sinn, sondern eine Möglichkeit, menschliche Kompetenzen punktuell zu substituieren. Zwar transformieren selbstlernende Algorithmen Daten in Informationen, aber diese Informationen sind nicht auf Anschlussfähigkeit für Menschen hin ausgelegt; sie sind zunächst nur für das System selbst informativ. Dann wird es aber auch fragwürdig, die *soziale* Funktion von KI oder Digitalisierung an ihrer Fähigkeit zur Mustererkennung festzumachen oder wie Nassehi, den Sinn der Digitalisierung in einer neuen, musterhaften *Selbstbeschreibung* der Gesellschaft zu sehen (Nassehi 2019). Machine Learning optimiert nicht menschliche Fähigkeiten zur Mustererkennung und semantischen Verarbeitung, sondern nutzt Muster zur Emulation menschlicher Kompetenzen. Der für menschliche Sozialsysteme anschlussfähige Teil von selbstlernenden Algorithmen sind gerade nicht die Modellierungen der Welt, mit denen sie arbeiten, sondern die *Outputs*, die sie generieren (Katze Ja/Nein; Kreditvergabe Ja/Nein; Kaufen/Nicht-Kaufen...). In ihrer gesamten Art der Problemadressierung und den aktuell bereits sichtbaren Resultaten deuten die Fortschritte der KI-Forschung also eine gänzlich andere Lösung des Kapazitätsproblems an: KI ermöglicht eine aufgabenspezifische Entkopplung von sozialen Systemen und praktisch kompetenten Personen; mithin in einer Verlagerung der sozialen Strukturreproduktion von bewusstseinsgestützten Kommunikationsprozessen auf algorithmische Selektionen. Sicherlich regt das opake Funktionieren oder Nichtfunktionieren der Algorithmen nachträgliche Versuche der Übersetzung von Mustern in Gründe an, ähnlich wie kontemporäre Schachspieler die rätselhafte Geniezüge Schachprogramme in neue Regeln für die Evaluation von Stellungen zu übersetzen trachten (Sadler/Regan 2019) – aber diese eigentümlich nachhinkenden sozialen Deutungsversuche wird man schwerlich mit dem Kern der Sache verwechseln können. Aktuell ist noch nicht absehbar, wie weit die sich abzeichnenden Möglichkeiten reichen, Menschen von »Leistungs-« in »Publikumsrollen« (Stichweh 2009) sozialer Systeme zu verschieben. Vorläufig stehen die Zeichen sicherlich eher auf Supplementierung und Erweiterung menschlicher Kompetenzen, so dass jene

pragmatische menschliche Urteilskraft, die nach wie vor benötigt wird, mit technisch vergrößerter Hebelwirkung versehen wird. Aber *prinzipiell* steht eigentlich außer Frage, dass die Funktionsprinzipien von Machine Learning die Technisierung großer Teile der Regelfolge-, Regelfindungs- und Regelintegrationsoperationen ermöglichen, die für Systembildung, Programmierung und Respezifikation abstrakter Systeme vonnöten sind.

3.3 Kontrolle, Macht und Hierarchie

Die Technisierung sozialer Übersetzungsverhältnisse zieht unweigerlich substantielle Verschiebungen der Machtverhältnisse zwischen gesellschaftlichen Einheiten nach sich. Wir orientieren uns zunächst an Joachim Renns Überlegungen zu den in der Widerständigkeit lokaler Handlungspraxen verorteten Grenzen von Verdinglichung und Herrschaft (2006: 454–473). Totale Herrschaft scheitert zuverlässig an ihrer eigenen Ineffizienz, denn abstrakte Systeme seien für die Unterwerfung der Lebenswelt immer auf deren Kollaboration angewiesen. Es bestehe die »Notwendigkeit, die Rückübersetzung zu delegieren«, weil »die Asymmetrie der Übersetzung zwischen Systemen oder Organisationen und Milieus oder Personen an eine Grenze« stoße, deren Überschreitung die »Ineffizienz und Instabilität diktatorischer Herrschaft, vollständiger Marktförmigkeit und totaler Verwaltung« zu Tage fördere (2006: 466). Die Unterdeterminiertheit von systemischen und organisationellen Imperativen ist das Pfund, mit dem Milieus und Personen wuchern, wenn sie auslegen, was abstrakte Marktimperative, Befehle und Verwaltungsvorschriften in konkreten Situationen genau *bedeuten*. Die interpretatorische Freiheit ermöglicht vielfältige Kompromisse und sogar subtile Strategien des Unterlaufens. Aber gerade dieser Freiheitsspielraum der Auslegung ist, um eine Formulierung von Dirk Baecker (2018) auf den Kopf zu stellen, eine Lücke, die der Rechner zu *schließen* erlaubt. Die Weiterentwicklung der computergestützten Datenanalyse durch Machine Learning führt nicht einfach zu einer effizienteren Erfüllung der Funktion von Daten. Wo menschliches Handeln nicht vollständig automatisiert werden kann, deutet sich ein *Funktionswechsel von Daten von der modellhaften Repräsentation zur Regulation sozialer Strukturen* an. Supervised Learning etwa ist wie gemacht für die Kontrolle korrekter Ausführungen zentral vorgegebener Regeln, wobei die Definitionsmacht für Korrektheit vom »street level« (Lipsky) in die Hinterräume des *back office* wandert (Beer 2017; Gillespie 2014). KI bildet nicht einfach Muster ab, sondern reproduziert sie selektiv. Unterschiedlich große Einsicht in das Funktionieren von Algorithmen und unterschiedliche Möglichkeiten, Zielparameter für die Optimierung und Leistungsstandards zu definieren, bedeutet unterschiedliche Chancen, Regeln »auch gegen Widerstreben« (Weber 2019: 210) durchzusetzen. Die Muster von heute sind die Best-Practice-Modelle von morgen und die verbindlichen Leistungsstandards von übermorgen (Beyes 2021; Rosenblat et al. 2017).

Es wäre aber falsch, davon auszugehen, dass KI zwangsläufig zu zentral gebündelter Verhaltenskontrolle oder gar totaler Herrschaft mit einseitigen Befehls- und Gehorsamspflichten führt. Es scheint aktuell zumindest nicht ausgeschlossen, über die Wege von Recht und Politik die Zwillingsdrohung von digitalem Überwachungskapitalismus

(Zuboff 2015) und intelligentem Überwachungsstaat (Liang et al. 2018) abzuwenden. Vor dem Hintergrund der technischen Logik der Entwicklung und ihrer sozialstrukturellen Brauchbarkeit scheint hingegen eine *Verschärfung der Machtasymmetrien zwischen abstrakten und konkreten sozialen Einheiten* fast unvermeidlich. In dem Maß, in dem Praktiken datafiziert und jede einzelne Performanz potenziell auf ihre Konformität mit übergeordneten Organisations- oder Systemzielen evaluiert werden kann, entstehen Alternativen zur funktionsnotwendigen Delegation von Übersetzung an untergeordnete Einheiten. Die Spezifikation vieler abstrakter Regeln, die Artikulation von lokalen Bedarfen und die Überwachung der Konformität der Umsetzung von Regeln bedarf dann nicht mehr notwendig dem Rückgriff auf praktisch kompetente Personen und Milieus. Wo dieser Rückgriff nötig bleibt, bestehen deutlich bessere Chancen, durch Überwachung und Sanktionierung erwünschten Verhaltens, durch die Inszenierung von Praktiken der Bewertung und von Konkurrenzen die Rahmenbedingungen praktischen Handelns zu verändern und Milieus und Personen in dem oben ausgearbeiteten Sinn zu ›erziehen‹.

Gleichzeitig macht sich die Ausweitung von smarter Top-Down-Kontrolle, bei aller offenkundigen Machtungleichheit, nicht als krasses Herrschaftsverhältnis bemerkbar. Konventionelle technokratische Herrschaft erfordert die *Standardisierung der Anwendungsbedingungen* abstrakter Imperative – ganz gleich, ob man dabei an Techniken der Disziplinierung gehorsamer Körper (Foucault 2013, 2019) oder die Expansion klinisch-experimenteller ›Standardbedingungen‹ auf die Gesamtgesellschaft denkt (Latour 1983). Digitale Überwachungs- und Sanktionsregime ermöglichen im Gegensatz zu konventionellen, abstrakten Machtmitteln ein hohes Maß situativer Flexibilität bei der lokalen Einbettung von Befehlen. Durch KI wird Herrschaft gerade nicht verdinglicht. Statt abstrakte Regeln gegenüber der Praxis widersinnig durchzusetzen und starren Gehorsam zu erzwingen, kommen die Regeln den Mustern der durch sie regulierten Praxis auf halber Strecke entgegen. Man muss sich algorithmische Herrschaft als eine Ordnung vorstellen, die nicht durch sichtbare Autoritätsfiguren verkörpert wird und der man gern und selbstverständlich gehorcht; eigene Handlungsimpulse müssen der Herrschaft nicht oder nur selten untergeordnet werden, sondern werden bereits im Vorhinein in Rechnung gestellt und selektiv verstärkt. Herrschaft wird so feingliedrig, dass man sie kognitiv und praktisch nur schwer (be)greifen kann, sie zerrinnt zwischen den Fingern.¹¹

11 Empirisch lässt sich dies etwa am Auseinanderklaffen expliziter Einstellungen und tatsächlicher Verhaltensmuster bei der Nutzung von Empfehlungsalgorithmen belegen: Nur zehn Prozent der deutschen Bevölkerung sind der Meinung, dass Empfehlungsalgorithmen ihnen die bestmöglichen Ergebnisse liefern und 67 Prozent halten diese Algorithmen für nicht vertrauenswürdig (Kieslich/Došenović/Marcinkowski 2021). Aber diese Skepsis schlägt kaum oder gar nicht auf das Verhalten durch, das sich massiv durch Empfehlungsalgorithmen beeinflussen lässt. Beispielsweise werden nur 20 Prozent der auf Netflix gesehenen Filme gezielt gesucht, 80 Prozent hingegen über algorithmische Empfehlungen angesteuert (vgl. Pathak 2017: 221). Allgemein bezeugt der enorme Aufstieg der Plattformen, deren Kerngeschäft die Regulation konsumkräftiger Aufmerksamkeit ist, die Effektivität algorithmischer Verhaltensbeeinflussung (Pfeiffer 2021; Staab 2019).

4. Fazit: Techno-Logik der Digitalisierung und Funktion von KI

Es ist Aufgabe der Soziologie, Analysen zum Verhältnis von Technik und Gesellschaft vorzulegen, die Aussagen über wahrscheinliche Strukturtransformationen erlauben, ohne sich dabei in futurologischer Spekulation zu verlieren. Zwischen den unattraktiven Extrempositionen von Futurologie und Technikskeptizismus bleibt der Mittelweg, die Möglichkeit einer umfassenden Technisierung sozialer Verhältnisse weder zu leugnen, noch sich in technikdeterministischen (Alb-)Träumen zu verlieren, sondern schlicht nach dem Verhältnis von Technologie und Gesellschaft zu fragen. Wo dieser Aufsatz spekuliert hat, tut er dies nicht in Bezug auf zukünftige Wunder der Technik, sondern über Effekte der Diffusion, Skalierung und Vernetzung bereits jetzt verfügbarer Technologie. Auch bei dieser konservativen Analyse, die nicht von den Versprechungen, sondern nur von aktuellen Möglichkeiten der Technisierung des Sozialen durch KI ausgeht, zeigt sich aber ein enormes Potenzial der KI für die Transformation der Gesellschaft.

Die bisherige differenzierungstheoretische Diskussion, ob die Digitalisierung zu einem Wechsel der Differenzierungsform führt oder ob doch alles beim Alten bleibt, ist dabei möglicherweise ähnlich verfehlt, wie die Frage, ob Computer »wirklich« intelligent sind. Erst wenn man gesellschaftliche Differenzierung ausgehend von dem Problem der Regelabstraktion und der Regelfolge betrachtet, wird es möglich, die soziale Signifikanz von KI nicht im Wechsel der Differenzierungsform, sondern in der Revolution des Verhältnisses abstrakter und konkreter sozialer Einheiten zu sehen. In den allermeisten sozialen Situationen und insbesondere in solchen, die für die Reproduktion von Makrostrukturen relevant sind, ist nicht das gesamte Tableau genereller menschlicher Intelligenz, sondern eine rollenförmig vorformatierte, zwar flexible, aber musterhafte Spezialkompetenz vonnöten. Diese Kompetenzen lassen sich zwar nicht selbst als Sets von Regeln explizieren, können aber, falls Zwecke klar genug beschrieben werden können und große Datenmengen vorhanden sind, von selbstlernenden Algorithmen encodiert und automatisiert werden. Die Rolle dieser Algorithmen für die Übersetzung zwischen abstrakten und konkreten gesellschaftlichen Systemen ist *nicht unterstützend, sondern potenziell substitutiv*: Bereichsspezifische Komplexe der Definition von Regeln und ihre Anwendung können umfassend technisiert werden. Regelabstraktion, Regel und Regelanwendung können von derselben sozialen Instanz kontrolliert werden. Die Bindung sozialer Strukturproduktion an das serielle Medium menschlicher Aufmerksamkeit und an implizites Wissen wird aufgeweicht.. Das konveniente Beharren auf der Widerständigkeit des impliziten Wissens gegen Explikation, das beruhigende Mantra, dass wir nur dort von Maschinen ersetzt werden können, wo »wir uns wie Maschinen verhalten« (Heintz 1995: 40), hat seine Überzeugungskraft verloren (siehe auch Collins 2018). Die wirklich augenfällige differenzierungstheoretische Entwicklung, die derzeit absehbar ist, ist deshalb nicht ein Wechsel der Differenzierungsform, sondern die Vertiefung der Top-Down-Integration von abstrakten und konkreten gesellschaftlichen Teilsystemen.

Literatur

- Baecker, Dirk (2018): *4.0 oder Die Lücke die der Rechner lässt*. Leipzig: Merve Verlag.
- Beer, D. (2017): »The social power of algorithms«. In: *Information, Communication & Society* 20(1), S. 1–13.
- Beyes, Timon (2021): »Strukturwandel des Geheimen: Öffentlichkeit im Überwachungskapitalismus«. In: Seeliger, Martin/Sevignani, Sebastian (Hg.): *Ein neuer Strukturwandel der Öffentlichkeit? Sonderband Leviathan* 37. Baden-Baden: Nomos, S. 91–114.
- Biesta, Gert J. J. (2016a): *Beyond learning. Democratic education for a human future*. London/New York: Routledge Taylor & Francis Group.
- Biesta, Gert J. J. (2016b): *The Beautiful Risk of Education*. New York: Routledge.
- Böschchen, Stefan/Kastenhofer, Karen/Marschall, Luitgard/Rust, Ina/Soentgen, Jens/Wehling, Peter (2006): »Scientific Cultures of Non-Knowledge in the Controversy over Genetically Modified Organisms (GMO): The Cases of Molecular Biology and Ecology«. In: *GAIA – Ecological Perspectives for Science and Society* 15(4), S. 294–301.
- Brandom, Robert B. (1979): »Freedom and Constraint by Norms«. In: *American Philosophical Quarterly* 16(3), S. 187–196.
- Brandom, Robert B. (1994): *Making it Explicit: Reasoning, Representing, and Discursive Commitment*. Cambridge: Harvard Univ. Press.
- Brandom, Robert B. (1997): »Heideggers Kategorien in »Sein und Zeit««. In: *Deutsche Zeitschrift für Philosophie* 45(4), S. 531–549.
- Brandom, Robert B. (2000): *Expressive Vernunft. Begründung, Repräsentation und diskursive Festlegung*. Frankfurt a.M.: Suhrkamp.
- Brandom, Robert B. (2008): *Between Saying and Doing: Towards an Analytic Pragmatism*. Oxford: Oxford University Press.
- Brandom, Robert B. (2009): »How Analytic Philosophy has Failed Cognitive Science«. In: Cristina Amoretti/Carlo Penco/Federico Pitto (Hg.): *Towards an Analytic Pragmatism. Workshop on Bob Brandom's Recent Philosophy of Language*. Genoa: CEUR Workshop Proceedings, 121–133.
- Brennen, J. Scott/Kreiss, Daniel (2016): »Digitalization«. In: Jensen, Klaus Bruhn/Rothenbuhler, Eric W./Pooley, Jefferson D./Craig, Robert T. (Hg.): *The International Encyclopedia of Communication Theory and Philosophy*. Wiley, S. 1–11.
- Cardon, Dominique (2017): »Den Algorithmus dekonstruieren. Vier Typen digitaler Informationsberechnung«. In: Seyfert, Robert/Roberge, Jonathan (Hg.): *Algorithmenkulturen. Über die rechnerische Konstruktion der Wirklichkeit*. Bielefeld: Transcript, S. 131–150.
- Cardon, Dominique/Cointet, Jean-Philippe/Mazières, Antoine (2018): »Neurons Spike Back. The Invention of Inductive Machines and the Artificial Intelligence Controversy«. In: *Réseaux* 5(n° 211), S. 173–220.
- Collins, Harry (2018): *Artificial intelligence. Against humanity's surrender to computers*. Cambridge [u. a.]: Polity Press.
- Dickel, Sascha (2022): »Der kybernetische Blick und seine Grenzen. Zur systemtheoretischen Selbstbeschreibung der digitalen Gesellschaft«. In: *Berliner Journal für Soziologie*, <https://doi.org/10.1007/s11609-022-00475-9>
- Domingos, Pedro (2018): *The master algorithm. How the quest for the ultimate learning machine will remake our world*. New York: Basic Books.
- Dreyfus, Hubert L. (1976): »What Computers Can't Do«. In: *British Journal for the Philosophy of Science* 27(2), S. 177–185.
- Dreyfus, Hubert L. (1992): *What computers still can't do: A critique of artificial reason*. Cambridge: MIT Press.
- Esposito, Elena (2017): »Artificial Communication? The Production of Contingency by Algorithms«. In: *Zeitschrift für Soziologie* 46(4), S. 249–265.

- Flaßhoff, Golo/Kero, Sandra/Anicker, Fabian: »ChatGPT, wie viele Menschen kennen Dich bereits?«. Pressemitteilung vom 1.2.2023.
- Foucault, Michel (2013): *La société punitive. Cours au Collège de France (1971–1973)* hg. v. Ewald, François/Fontana, Alessandro/Harcourt, Bernard E. Paris: Ehes Gallimard Seuil.
- Foucault, Michel (2019): Überwachen und Strafen. *Die Geburt des Gefängnisses*. Frankfurt am Main: Suhrkamp.
- Fourcade, Marion (2016): »Ordinalization«. In: *Sociological Theory* 34(3), S. 175–195.
- Fourcade, Marion/Johns, Fleur (2020): »Loops, ladders and links: the recursivity of social and machine learning«. In: *Theory and Society*, S. 803–832.
- Fuller, Steve (1998): »Society's shifting human-computer interface: A sociology of knowledge for the information age«. In: *Information, Communication & Society* 1(2), S. 182–198.
- Galloway, Alexander R. (2012): *The interface effect*. Cambridge/Malden, MA: Polity.
- Gillespie, Tarleton (2014): »The relevance of algorithms«. In: Gillespie, Tarleton/Boczkowski, Pablo J./Foot, Kirsten A. (Hg.): *Media Technologies*. The MIT Press, S. 167–194.
- Gouldner, Alvin Ward (1965): *Wildcat Strike: A Study in Worker Management Relationships*. New York: Harper & Row.
- Harth, Jonathan/Lorenz, Caspar-Fridolin (2017): »»Hello World« – Systemtheoretische Überlegungen zu einer Soziologie des Algorithmus«. In: *kommunikation@gesellschaft* 18(2), S. 1–18.
- Heintz, Bettina (1995): »»Papiermaschinen«: Die sozialen Voraussetzungen maschineller Intelligenz«. In: Rammert, Werner (Hg.): *Soziologie und künstliche Intelligenz. Produkte und Probleme einer Hochtechnologie*. Frankfurt am Main: Campus-Verl., S. 37–54.
- Heintz, Bettina (2021): »Big Observation – Ein Vergleich moderner Beobachtungsformate am Beispiel von amtlicher Statistik und Recommendersystemen«. In: *Kölner Zeitschrift für Soziologie und Sozialpsychologie* 73(1), S. 137–167.
- Heintz, Bettina/Tyrell, Hartmann (Hg.) (2016): *Interaktion – Organisation – Gesellschaft revisited. Anwendungen, Erweiterungen, Alternativen*. Berlin, Boston: De Gruyter Oldenbourg.
- Hellmann, Kai-Uwe: »Interaktion – Organisation – Gesellschaft revisited. Aktualisierungen zu Niklas Luhmanns grundbegrifflicher Systematisierung der Soziologie«. <https://www.sozio.polis.de/interaktion-organisation-gesellschaft-revisited.html>.
- Holton, Robert/Boyd, Ross (2021): »»Where are the people? What are they doing? Why are they doing it?«(Mindell) Situating artificial intelligence within a socio-technical framework«. In: *Journal of Sociology* 57(2), S. 179–195.
- Hookway, Branden (2014): *Interface*. Cambridge, Massachusetts: The MIT Press.
- Joas, Hans (1992): *Die Kreativität des Handelns*. Frankfurt am Main: Suhrkamp.
- Jordan, Michael I./Mitchell, T. M. (2015): »Machine learning: Trends, perspectives, and prospects«. In: *Science* 349(6245), S. 255–260.
- Kieslich, K./Došenović, P./Marcinkowski, F. (2021): »Algorithmische Empfehlungssysteme. Wie denkt die deutsche Bevölkerung über den Einsatz und die Gestaltung algorithmischer Empfehlungssysteme?«. In: *Factsheet Nr 5 des Meinungsmonitor Künstliche Intelligenz*.
- Knorr-Cetina, Karin/Bruegger, Urs (2002): »Global Microstructures: The Virtual Societies of Financial Markets«. In: *American Journal of Sociology* 107(4), S. 905–950.
- Kripke, Saul A. (1982): *Wittgenstein on rules and private language. An elementary exposition*. London: Blackwell.
- Kühl, Stefan (2020): *Brauchbare Illegalität. Vom Nutzen des Regelbruchs in Organisationen*. Frankfurt/New York: Campus Verlag.
- Latour, Bruno (1983): »Give me a Laboratory and I Will Raise the World«. In: Knorr-Cetina, Karin/Mulkey, Michael (Hg.): *Science Observed: Perspectives on the Social Study of Science*. Beverly Hills: Sage Publications, S. 141–170.
- Leiserson, Charles E./Thompson, Neil C./Emer, Joel S./Kuszmaul, Bradley C./Lampson, Butler W./Sanchez, Daniel/Schardl, Tao B. (2020): »There's plenty of room at the Top: What will drive computer performance after Moore's law?«. In: *Science* 368(6495), S. 1–9.

- Liang, Fan/Das, Vishnupriya/Kostyuk, Nadiya/Hussain, Muzammil M. (2018): »Constructing a Data-Driven Society: China's Social Credit System as a State Surveillance Infrastructure«. In: *Policy & Internet* 10(4), S. 415–453.
- Lipp, Benjamin/Dickel, Sascha (2022): »Interfacing the human/machine«. In: *Distinktion: Journal of Social Theory*, S. 1–19.
- Lipsky, Michael (1980): *Street-Level Bureaucracy. Dilemmas of the Individual in Public Services*. New York: Russel Sage Foundation.
- Luhmann, Niklas (1962): »Der neue Chef«. In: *Verwaltungsarchiv* 53, S. 11–24.
- Luhmann, Niklas (1981): »Kommunikation mit Zettelkästen«. In: Baier, Horst/Kepplinger, Mathias/Reumann, Kurt (Hg.): *Öffentliche Meinung und sozialer Wandel*. Opladen: Westdeutscher Verlag, S. 222–228.
- Luhmann, Niklas (1984): *Soziale Systeme*. Frankfurt a. M.: Suhrkamp.
- Luhmann, Niklas (1991): »Die Form ›Person««. In: *Soziale Welt*, S. 166–175.
- Luhmann, Niklas (1999 [1973]): *Zweckbegriff und Systemrationalität*. Frankfurt a. M.: Suhrkamp.
- Luhmann, Niklas (2002): *Das Erziehungssystem der Gesellschaft*. Frankfurt a. M.: Suhrkamp.
- Luhmann, Niklas (2005): *Interaktion – Organisation – Gesellschaft*. Wiesbaden: VS.
- Luhmann, Niklas/Schorr, Karl-Eberhard (1981): »Wie ist Erziehung möglich?«. In: *Zeitschrift für Sozialisationsforschung und Erziehungssoziologie* 1(1), S. 37–54.
- Luhmann, Niklas/Schorr, Karl-Eberhard (Hg.) (1996): *Zwischen System und Umwelt. Fragen an die Pädagogik*. Frankfurt am Main: Suhrkamp.
- Manovich, Lev (1999): »Database as Symbolic Form«. In: *Convergence* 5(2), S. 80–99.
- Mölders, Marc (2019): *Die Korrektur der Gesellschaft. Irritationsgestaltung am Beispiel des Investigativjournalismus*. Bielefeld: Transcript.
- Mueller, John Paul/Massaron, Luca (2016): *Machine learning for dummies*. Hoboken, NJ: John Wiley & Sons Inc.
- Nassehi, Armin (2019): *Muster: Theorie der digitalen Gesellschaft*. München: C.H. Beck.
- Nell, Linda (2020): *Die multiple Differenzierung des Rechts. Eine pragmatistisch-gesellschaftstheoretische Perspektive auf den globalen Rechtspluralismus*. Weilerswist: Velbrück.
- Pathak, Nishith (2017): *Artificial Intelligence for .NET Speech, Language, and Search. Building Smart Applications with Microsoft Cognitive Services APIs*. Berkeley CA: Apress.
- Perrault, Raymond/Shoham, Yoav/Brynjolfsson, Erik/Clark, Jack/Etchemendy, John/Grosz, Barbara/Lyons, Terah/Manyika, James/Mishra, Saurabh/Niebles, Juan Carlos (2019): *The AI Index 2019 Annual Report*. Stanford: Stanford University.
- Pfeiffer, Sabine (2021): *Digitalisierung als Distributivkraft. Über das Neue am digitalen Kapitalismus*. Bielefeld: Transcript.
- Prange, Klaus (2008): »Formen des Erziehens in Geschichte und Gegenwart«. In: Koch, Lutz (Hg.): *Handbuch der Erziehungswissenschaft. Band I: Grundlagen – Allgemeine Erziehungswissenschaft*. Boston: BRILL, S. 939–955.
- Pröschold, Bernd (2019): »Kommunikation mit nichtmenschlichen Entitäten aus systemtheoretischer Sicht«. In: Schetsche, Michael/Anton, Andreas (Hg.): *Intersoziologie*. Weinheim: Beltz Juventa, S. 159–175.
- Reinsel, David/Gantz, John/Rydning, John (2018): »The Digitization of the World from Edge to Core«. In: *IDC White Paper #US44413318*.
- Renn, Joachim (2006): *Übersetzungsverhältnisse. Perspektiven einer pragmatistischen Gesellschaftstheorie*. Weilerswist: Velbrück.
- Renn, Joachim (2014): *Performative Kultur und multiple Differenzierung. Soziologische Übersetzungen I*. Bielefeld: Transcript.
- Renn, Joachim (2016): *Selbstentfaltung – Das Formen der Person und die Ausdifferenzierung des Subjektiven. Soziologische Übersetzungen II*. Bielefeld: Transcript.
- Renn, Joachim (2021a): *Indirekte Referenz – Pragmatischer Realismus und Medientheorie. Soziologische Übersetzungen 3*. Bielefeld: Transcript.

- Renn, Joachim (2021b): »Das Medium Recht und die Evolution seiner Formen«. In: Ders.: *Indirekte Referenz – Pragmatischer Realismus und Medientheorie. Soziologische Übersetzungen 3*. Bielefeld: Transcript, S. 197–243.
- Renn, Joachim (2021c): »Praxis als Medium der Vernunft und die Rationalität des impliziten Wissens«. In: Ders.: *Indirekte Referenz – Pragmatischer Realismus und Medientheorie. Soziologische Übersetzungen 3*. Bielefeld: Transcript, S. 161–196.
- Ricken, Norbert (2010): »Allgemeine Pädagogik«. In: Jantzen, Wolfgang u. a. (Hg.): *Behinderung, Bildung, Partizipation – Enzyklopädisches Handbuch der behindertenpädagogik*. Stuttgart: Kohlhammer, S. 15–42.
- Rosenblat, Alex/Levy, Karen E.C./Barocas, Solon/Hwang, Tim (2017): »Discriminating Tastes: Uber's Customer Ratings as Vehicles for Workplace Discrimination«. In: *Policy & Internet* 9(3), S. 256–279.
- Russell, Stuart J./Norvig, Peter/Davis, Ernest/Edwards, Douglas (2016): *Artificial Intelligence. A Modern Approach*. Boston [u. a.]: Pearson.
- Sadler, Matthew/Regan, Natasha (2019): *Game Changer: AlphaZero's Groundbreaking Chess Strategies and the Promise of AI*. Alkmaar: New in Chess.
- Staab, Phillip (2019): *Digitaler Kapitalismus – Markt und Herrschaft in der Ökonomie der Unknappheit*. Berlin: Suhrkamp.
- Stichweh, Rudolf (2009): »Leitgesichtspunkte einer Soziologie der Inklusion und Exklusion«. In: Stichweh, Rudolf/Windolf, Paul (Hg.): *Inklusion und Exklusion: Analysen zur Sozialstruktur und sozialen Ungleichheit*. Wiesbaden: VS Verlag für Sozialwissenschaften, S. 29–42.
- Tegmark, Max (2017): *Life 3.0. Being human in the age of artificial intelligence*. New York: Alfred A. Knopf.
- Tomasello, Michael (2020): *Mensch werden. Eine Theorie der Ontogenese*. Berlin: Suhrkamp.
- Warstadt, Alex/Bowman, Samuel R. (2022): »What Artificial Neural Networks Can Tell Us about Human Language Acquisition«. In: Lappin, Shalom/Bernardy, Jean-Philippe (Hg.): *Algebraic Structures in Natural Language*. Boca Raton: CRC Press, S. 17–60.
- Weber, Max (2019): *Max Weber-Gesamtausgabe. Band I/23: Wirtschaft und Gesellschaft. Soziologie. Unvollendet. 1919–1920*, hg. v. Borchardt, Knut/Hanke, Edith/Schluchter, Wolfgang. Tübingen: Mohr Siebeck.
- Wehling, Peter (2009): »Nichtwissen–Bestimmungen, Abgrenzungen, Bewertungen«. In: *Erwägen Wissen Ethik* 20, S. 95–106.
- Wittgenstein, Ludwig (2003): *Philosophische Untersuchungen*. Frankfurt/a.M.: Suhrkamp.
- Zhang, Daniel/Mishra, Saurabh/Brynjolfsson, Erik/Etchemendy, John/Ganguli Deep/Grosz Barbara/Lyons Terah/Manyika James/Niebles, Juan Carlos/Sellitto, Michael/Shoham, Yoav/Clark, Jack/Perrault, Raymond (2021): *The AI Index 2021 Annual Report. The AI Index Steering Committee, Human-Centered AI Institute*. Stanford: Stanford University.
- Zuboff, Shoshana (2015): »Big other: Surveillance Capitalism and the Prospects of an Information Civilization«. In: *Journal of Information Technology* 30(1), S. 75–89.

Anschrift:

Dr. Fabian Anicker
 Institut für Sozialwissenschaften, KMW I
 Heinrich-Heine-Universität Düsseldorf
 Universitätsstraße 1
 40225 Düsseldorf
 f.anicker@hhu.de