

Mustererkennung in Datennetzwerken

Zu einer Relationalen Soziologie neuer Formen »Künstlicher Intelligenz«

Roger Häußling, Marco Schmitt

1. Einleitung

Die Neue Künstliche Intelligenz – und hier insbesondere Deep Learning-Verfahren – stellt die Gesellschaft und damit auch die Soziologie vor neue Herausforderungen! Diese Verfahren stehen für einen neuen Typ von Technologie: sie sind selbstlernend dank künstlicher neuronaler Netze. Ein Pionier der ersten Stunde, der schon Ende der 1940er Jahre mit solchen neuronalen Netzen experimentierte, war Alan Turing. Er brachte bereits 1950 das Spezifische dieser neuen Technologie auf den Punkt: »Erlernete Prozesse führen nicht zu Ergebnissen, die hundertprozentig sicher sind; wenn sie es täten, könnten sie nicht verlernt werden.« (Turing 1950) Techniksoziolog:innen sprechen von höheren Freiheitsgraden, die dazu führen, dass derartige Technologien zu Interaktionspartner:innen des Menschen und mehr und mehr zu Entscheidungsträger:innen werden. Entsprechend findet man den Einsatz dieser neuen KI bereits heute bei selbstfahrenden Autos, bei der Krebsdiagnostik, im Börsenhandel, im US-amerikanischen Wahlkampf und im so genannten Predictive Policing zur Aufdeckung von kriminellen Netzwerken – um nur einige besonders prominente Anwendungsfälle zu nennen.

Offensichtlich werden immer mehr gesellschaftliche und soziale Entscheidungsprozesse in automatisierte Kalkulationen verlagert. Der große Vorteil dieser Technologie, Muster jenseits menschlicher Wahrnehmungsmöglichkeiten in riesigen Datensätzen zu erkennen, bildet gleichzeitig auch das Problematische an der neuen KI: Wie und warum sie zu bestimmten Ergebnissen gelangt, bleibt oftmals unklar. Dieser Intransparenz steht eine normative Macht des scheinbar objektiv Berechneten gegenüber. Sich gegen

eine KI-basierte, medizinische Diagnose beispielsweise zu entscheiden und stattdessen auf menschliche Erfahrung der entsprechenden Expert:in zu setzen, wird immer schwieriger.

Aber der Einfluss dieser neuen KI ist bereits heute noch weitreichender, was man an den so genannten Recommendation-Systemen der globalen Handelsplattformen des Internets verdeutlichen kann: Bedürfnisse und Interessen werden von automatisierten Kalkulationen unterlaufen, sodass am Ende nicht mehr unterscheidbar ist, was auf ureigene Intentionen und was auf subtil agierende KI fußt.

Als Techniksoziolog:in fragt man sich aber auch, warum ausgerechnet jetzt und ausgerechnet in einer Gesellschaft, wie der unsrigen, so sehr die Verheißungen der neuen KI auf offene Ohren stoßen. Eine mögliche Antwort könnte darin liegen, dass mit dem Internet und all unseren smarten mobilen Geräten eine Datenflut einsetzte, die gleichzeitig für eine Krise der Kontrolle steht (vgl. auch Mackenzie 2006). Machine Learning verspricht hier eine Wiedergewinnung der Kontrolle, aber – so die kritische Frage – zu welchem Preis und wer kontrolliert wie wen? Ein anderer Pionier der Künstlichen Intelligenz, Norbert Wiener, hat hierzu die denkwürdigen Worte formuliert: »Wenn wir Maschinen programmieren, um einen Krieg zu gewinnen, müssen wir gut nachdenken, was wir mit ›gewinnen‹ meinen.« (Wiener 1952)

Wenig soziologische Theorieangebote scheinen geeignet zu sein, die Besonderheiten des Phänomens Deep Learning sachadäquat erfassen zu können und für soziologische und gesellschaftstheoretische Perspektiven fruchtbar zu machen. Eine Ausnahme bildet Harrison Whites Theorie von Identität und Kontrolle (White 1992 und 2008). Im vorliegenden Beitrag soll aufgezeigt werden, dass zentrale soziologische Aspekte von KI durch diese Theorieangebote sehr grundlegend beschrieben und erforscht werden können. Hierzu soll Problem- und Gegenstands-zentriert vorgegangen und die bisherigen soziologischen Antworten auf zentrale soziale und gesellschaftliche Herausforderungen durch die neue KI vergleichend dargelegt werden. Die gute Passung zwischen dem Gegenstand der neuen KI und einer an White orientierten Relationalen Soziologie resultiert daraus, dass sowohl das soziologische Theorieangebot von White, als auch die einflussreichen Ansätze des Deep Learnings die Mustererkennung als zentralen Aspekt ansehen. Hierbei soll der vorliegende Beitrag einerseits die relationalen Konzepte am Phänomenbereich selbst schärfen und andererseits ihre Reichweite für die Erklärung und Interpretation der gesellschaftlichen und sozialen Dimensionen der neuen KI ausloten.

Ein relationaler Ansatz impliziert eine Perspektive, die stets die Einbettungskonstellationen miterfasst. Insofern ist KI nicht nur technisch zu begreifen, sondern immer auch sozial – und zwar sowohl was die Herstellung der sog. Learner anbelangt, als auch die Trainingsphase – insbesondere, wenn sie supervised ist – wie auch schließlich in der Anwendungsphase eines trainierten künstlichen neuronalen Netzes, bei denen automatisierte Kalkulationen auf soziale und gesellschaftliche Entscheidungsprobleme treffen.

Zunächst starten wir mit dem Problem des *Kontextwechsels* (oder *switching* bei White), das auch avancierte Verfahren künstlicher Intelligenz immer wieder vor große Probleme stellt. Hieran wollen wir deutlich machen, welchen Beitrag das theoretische Modell von Harrison White bei der sozialwissenschaftlichen Betrachtung der neueren Entwicklungen auf dem Gebiet der Künstlichen Intelligenz leisten kann. Im Anschluss sollen dann aber auch andere Konzepte aus der White'schen Theorie eingebracht werden, die ein großes Potenzial für die Analyse und Untersuchung der gesellschaftlich relevanten Aspekte des Phänomens der neuen KI besitzen. Dabei ist vor allem auf die Begriffe *Netdom* und *Stil* einzugehen, die beide Möglichkeiten bieten, Kontexte in einer Weise zu typisieren, die Übergänge einfacher markieren bzw. deutlich machen, welche konkrete Änderungen zu Kontextwechsel führen. Schließlich arbeitet sich der Beitrag zu den Grundbegriffen *Kontrolle* und *Identität* vor, an denen sich dann auch gleich zahlreiche gesellschaftlich relevante Problemlagen entzünden. So sind die Kontrollverstrickungen in verschiedene Richtungen verfolgbar, weil es zum einen um die Kontrolle über Lern-Daten ebenso geht, wie um die Kontrolle der Ergebnisse, welche Phänomene überhaupt von den Verfahren kontrolliert werden sollen, wie dies passiert und an welchen Stellen dann wiederum die Kontrolle anderer Akteur:innen eingebaut wird. Gleichzeitig muss auch auf die Konstruktion sozialer Einheiten scharf gestellt werden, die zunehmend unter Mitarbeit von Verfahren Künstlicher Intelligenz erzeugt werden oder diese selbst beschreiben. Schließlich bietet der Vorschlag von White interessante Möglichkeiten, auch mit den unterschiedlichen Skalierungsproblemen umzugehen, die ebenso für KI-Verfahren relevant sind, deren Reichweite sich verändert.

Diese theoretischen Vorschläge einer soziologischen Grundierung des Phänomens der neueren KI als erfolgreiche Transformation des technologischen Feldes einerseits und als die Gesellschaft insgesamt transformierende Entwicklung andererseits, ermöglichen eine Analyse der Veränderungspotenziale unterschiedlicher gesellschaftlicher Domänen und der sie tragenden Prozesse.

2. Zu den soziologischen Herausforderungen der neuen KI

Machine Learning ist – so zeigt es auch der gegenwärtige sozialwissenschaftliche Diskurs (siehe Einleitung in diesem Band) – ohne Einbeziehung seines soziotechnischen Umfelds nicht sinnfällig soziologisch analysierbar. Dabei sticht ein soziotechnischer Aspekt besonders ins Auge: Die digitale Datenfülle, welche die Bedingung der Möglichkeit für Machine Learning-Prozeduren überhaupt erst schafft. Wenn man die Geschichte der Digitalisierung bzw. präziser die Geschichte der Computerisierung¹ in den Blick nimmt, kann man für die ersten Jahrzehnte das komplette Gegenteil diagnostizieren: Es herrschte zunächst ein Datenmangel vor – Großrechner etwa, die ganze Hallen füllten, und doch nur ein Bruchteil der Rechenleistung besaßen wie ein herkömmliches Smart Phone heute. Und als dann die ›Datenlast‹ zunahm, etwa mit dem Aufstieg des kommerziellen Internets, geriet die sich immer weiter digitalisierende Gesellschaft mehrmals in ein Load Faktor-Dilemma (vgl. Hughes 1979): zu viel Daten für zu wenig Rechenleistung. WWW wurde damals ironischer- und zugleich treffenderweise als »word wide waiting« übersetzt. Dass heute große Serverfabriken den gesamten Traffic des Internets abzusaugen in der Lage sind, konnte man damals kaum erahnen, geschweige denn, dass man in quasi Echtzeit Berechnungen vornimmt, um aus diesen Milliarden von Daten Muster in dynamischen Prozessen zu identifizieren.

Von Manovich (2001: 223) stammt das Postulat, dass Datenumfang und Komplexität der diese Daten bearbeitenden Softwaresysteme in einem engen Zusammenhang stehen, nämlich dergestalt, dass je weniger Daten vorhanden sind, die Softwareprogramme aus umso mehr Programmzeilen bestehen. Wohingegen komplexe Datenbanken einfache Algorithmen nach sich ziehen. Und tatsächlich bestehen die Learner von ML-Verfahren oftmals nur aus ein paar hundert Zeilen, wohingegen die Datenmengen, auf die sie zugreifen, riesig sind. Doch dazu gleich ausführlicher! Für Manovich ist das Internet – und aus heutiger Warte sollte man ergänzen, der allumfängliche Einsatz von

1 An anderer Stelle wurde der Vorschlag unterbreitet (vgl. Häußling 2019: 325f.), zwischen Digitalisierung und digitaler Technologie zu unterscheiden. Dies erlaubt, besser auf technologische Entwicklungen der vergangenen rund 20 Jahre scharf zustellen, die nicht zuletzt dafür verantwortlich sind, dass der Begriff Digitalisierung zu einem Buzzword wurde. Digitale Technologie gibt es hingegen schon seit geraumer Zeit, etwa wenn man an Zuses Z3 denkt.

Smart Devices – eine Sollbruchstelle für das Selbstverständnis der Programmierung und des Datenhandlings in der digitalen Sphäre. Denn das Internet ›vergleichültige‹ alles: Eine Internetseite kann sich beliebig aus Text-, Bild- und/oder Videodateien zusammensetzen. Sie kann sich auch permanent in ihrer Ausgestaltung ändern und wird auch zunehmend auf die einzelnen Bedürfnisse jeder Nutzer:in hin individualisiert. Mit anderen Worten: Aus einer schier unendlich anmutenden Menge vorliegender Daten setze sich eine solche Internetseite kontingent zusammen. Sie sei also nichts anderes als eine Ansammlung ebenso heterogener wie austauschbarer Elemente. Letztere seien Computerfiles, die stets ediert werden können und weniger auf Vollständigkeit denn auf Erweiterbarkeit und partielle Ersetzbarkeit angelegt seien. Kurzum: Für Manovich ist jede Internetseite ein in-Erscheinung-tretender Ausschnitt aus Datenbanken und das Web insgesamt ein sich fortwährend wandelnder Datenkorpus (vgl. ebd.: 225). Ja, das Internet dürfte sogar das komplexeste Datenbankphänomen unserer heutigen Zeit sein. Dies wird – wie gesagt – durch den massen- und flächendeckenden Einsatz von Smart Devices nur noch auf die Spitze getrieben, da unzählige situierte Daten durch diese Geräte anfallen, die für unterschiedlichste Apps, für Profiling-Zwecke und für vieles andere mehr verwendet werden. Auch hier steht die Datenfülle im Vordergrund. Selbst vermeintliche Datenabgase können für unerwartete Zwecke verwendet werden. Etwa: Wenn Smartphones Profile des Gehens anlegen und aus diesen anfallenden Daten vor jeder möglichen ärztlichen Diagnostik eruiert werden kann, ob eine Parkinson-Erkrankung bei der Person vorliegt, die das Smartphone mit sich führt (Belic et al. 2019). An diesem Beispiel wird auch deutlich, in welchem umfassenden Ausmaß von den anfallenden Daten aus gedacht und engineert wird.

Entsprechend liegt bei Machine Learning-Verfahren das Hauptaugenmerk auf der Güte der Daten. Sie werden unentwegt generiert, gereinigt, organisiert und indiziert. Für Manovich besitzen Daten Objektcharakter, wohingegen Algorithmen für (kausalistische) Prozesse stehen. In vielerlei Hinsicht könnten Computerspiele als ein Paradebeispiel des alten algorithmusgetriebenen Paradigmas der digitalen Sphäre gewertet werden. Sie folgten einer narrativen Logik, bei der der Reiz am Spiel nicht zuletzt darin besteht, die Logik des Spielalgorithmus zu entschlüsseln. Eine Internetseite folge demgegenüber einer komplett anderen Anordnungslogik der Elemente. Hier werden instantan beliebig austauschbare Elemente zu einem Ganzen zusammengefügt. Das Computermodell hierfür ist demzufolge ein gänzlich anderes als beim Computerspiel: Geht es bei letzterem um die Erzeugung eines direktionalen Handlungs-

stroms, bei dem das gerade Ablaufende als Wirkung des Vorausgegangenen inszeniert wird, geht es bei der Internetseite um die Herstellung eines beliebig zusammenstellbaren Contents. Datenbanken repräsentieren für Manovich die Welt als nicht-hierarchische, oder sonst wie vorab geordnete Liste von Werten, die beliebig arrangiert werden können. Wenn man so will, koexistiert alles in Datenform auf gleicher Augenhöhe: Belangloses und Wichtiges, Bedrohliches genauso wie Rettendes, Wahrheiten und Lügen, Reales und Fiktionales etc.

Als Objekt rücken Datenbanken für Manovich auch immer stärker in das Zentrum der kreativen Bemühungen, der digitalen Sphäre Neues hinzuzufügen. So sind eine Vielzahl von Apps eines Smartphones nur deshalb im Einsatz, weil sie um die anfallenden GPS- oder Bewegungsdaten herum entwickelt wurden. Ohne diese Daten würde keine Navigation glücken, oder uns dazu anleiten, auf den gesundheitlichen Sollwert an Schritten pro Tag zu gelangen. Datenbanken sind in der digitalen Sphäre nicht nur das wichtigste Gut geworden, sondern, neue digitale Dienste zu entwickeln, bedeutet im Kern, eine Schnittstelle zu Datenbanken zu konstruieren. Die unterschiedlichsten Trajektorien können aus ein und derselben Datenbank emergieren, die – gemäß Manovich – wie Hypernarrative funktionieren. Ganz so, wie bei einem chronologischen Verlauf der Internetnutzung einer Person, würde die kontingente Nutzung einer beliebigen Datenbank sein eigenes Ready Made-Narrativ erzeugen. Dieses Vorgehen gleicht der Montagetechnik in der Bildenden Kunst, bei der Photoschnipsel mit gemalten Elementen und/oder Alltagsobjekten ›zusammengewürfelt‹ werden.

In Weiterführung dieses Gedankens von Manovich ist es nicht verwunderlich, dass sich gerade in dieser Phase der Digitalisierung, bei der alles datenmäßig vergleichgültigt wird, das Phänomen der Filterblasen und Echokammern breitmacht. Selbst unter Rückgriff auf ein und dieselbe Datenbank lassen sich nämlich antagonistische Ready-mades erzeugen. Echokammern machen aber einen Prozess sichtbar, den Manovich in seiner Argumentation weniger stark akzentuiert: nämlich nicht nur die aktive Verknüpfung von Elementen ist bedeutsam für die post-narrative, datenbankgetriebene Phase der Digitalisierung, sondern auch das Abschotten und Kappen möglicher Verknüpfungen. Genau das leisten eben Machine Learning-Verfahren auch. Sie sind im Kern Erzeuger von Netzwerken, die neben Konnektivitäten eben auch strukturelle Löcher aufweisen. Und das ist nicht nur in dem Sinne zu verstehen, dass sie künstliche neuronale Netze in den Hidden Layers entstehen lassen, die wie große Filter und Absorber funktionieren. Sondern es ist auch auf einem abstrakten datentheoretischen Sinn zutreffend, dass nur eine

bestimmte Auswahl an Daten relationiert und von dem Rest der Datenwelt abgeschottet wird. Aus der Netzwerkforschung ist bekannt, dass nicht nur das Vorhandensein einer Relation aussagekräftig ist, sondern eben auch das Nicht-Vorhandensein einer Relation. Um genau diese inkludierende und gleichzeitig exkludierende Grenzarbeit geht es beim Netzwerkknüpfen der Machine Learning-Verfahren.

Ein schier unendliches Meer an Daten liegt ohne jegliche prästabilisierte Ordnung vor. Diese Daten stehen für nichts Geringeres als die Welt selbst, also alles, was wir denken, fühlen und spüren können. Genau diese Welt ist zerlegt in ein Chaos – im doppelten Wortsinn – gleichgültiger Letztelemente – Bits und Bytes. Diese von Daten repräsentierte und gleichzeitig vollzogene Welt kennt keine Tiefe mehr: Alles ist auf der gleichen Oberfläche, keine Hierarchie von oben und unten, keine Himmelsrichtungen, die uns einen Weg vorgeben könnten. Aus diesem Fundus aus Allem lassen sich nun beliebige Assemblagen bzw. Netzwerke formieren, die nicht nur Reales in beliebigen Auswahlen repräsentieren, sondern dieses Reale auch gleichzeitig formieren. Auf einer sehr abstrakten Ebene ist genau das die Funktion von Machine Learnern. In Anlehnung an Galloway und Thacker könnte man Machine Learner als Protokolle bezeichnen, welche die Bedingungen der Möglichkeit für Sinnerzeugung und Kontrolle in der digitalen Sphäre schaffen. Vielleicht trifft der Begriff lokales Programm die Funktionsweise von Machine Learning-Verfahren noch besser. Denn der Ausschnitt an Daten, den ein Machine Learning-Verfahren bearbeitet, ist trotz des Begriffs Big Data und in ironischer Abkehr zu diesem Begriff verschwindend gering angesichts der in Daten zerlegten Welt. Lokal meint hier natürlich nicht eine geographische Gegebenheit, sondern eine gegenstandsgetriebene Auswahl im Heterogenen – Aufnahmen von krebskranken und nicht-krebskranken Gehirnen im Unterschied zu allen Daten, die für anderes stehen, etwa. Relationiert und entkoppelt wird hier nicht nur auf der harten Ebene dichotomer Unterschiede (wie etwa krank versus gesund), die bei supervised-Verfahren in der Lernphase von Menschen vorgegeben und in der Anwendungsphase eigentätig vom Machine Learning-Verfahren vollzogen werden. In den Hidden Layers werden kleinste Details relationiert, wie etwa bestimmte Schattierungen an einer bestimmten Stelle des Bildes vom Gehirn, und andere Details diskriminiert. Diese kleinsten Details sind ihrerseits wiederum in Bits und Bytes zerlegt, die unzweideutig von ihren benachbarten Bits und Bytes getrennt sind. Selbst also auf der Ebene der digitalen Elementarteilchen findet nichts Anderes statt als ein Knüpfen von Netz-

werken, wenn man ein solches Knüpfen immer auch als ein Kappen anderer möglicher Relationen begreift.

Lokal sind diese transklassischen Programme deshalb, weil sie keinem vorab existierenden Narrativ oder keiner vorab als gültig ausgewiesenen Theorie folgen, sondern sich als versuchsweise einsetzbare Filter im Meer der Daten zeigen, deren emergente Ergebnisse dann darüber entscheiden, ob sie brauchbar sind oder nicht. Deepl.com verdeutlicht augenscheinlich, dass es keiner präzisen Theorie der Übersetzung bedarf – die es trotz unzähliger Bemühungen seitens der Linguistik und Sprachwissenschaften auch nicht gibt –, um überraschend gute Übersetzungen mittels Machine Learning-Verfahren zu generieren. Die Filterung setzt bereits da an, wo es um die Fütterung des Learners mit präzisen Exemplaren der Ziele der zu entwickelnden maschinellen Diagnostik geht; also Beispiele für gute Übersetzungen im gerade benannten Fall. Noch abstrakter betrachtet, handelt es sich um Verfahren, die tentativ Verknüpfungen und Abkopplungen im opaken Meer der Daten vornehmen und bei denen das evolutionäre Prinzip, *Survival of the Fittest* im Sinne eines *good enough* bzw. *fit enough* (Simon 1990), vollumfänglich umgesetzt worden ist.

Um dieses Weben und Umweben von Datennetzwerken zu realisieren, bedarf es einer anderen Strategie als diejenige, die sich in den klassischen Algorithmen manifestiert. Letztere waren nichts Anderes als riesige logische Verzweigungsbäume, die kausale Routen durch den Code legen; Routen im Sinne von linearen Narrativen, um den Gedanken von Manovich noch einmal aufzugreifen. Ein Netzwerk ist alles andere als linear zu begreifen. Rückkopplungen, Schleifen, Interferenzen sind vielmehr seine Markenzeichen. Insofern sind die Resultate der Machine Learner im Grunde keine Codes im klassischen Sinne mehr. Deshalb sprechen wir von transklassischen Programmen. Sie nähern sich nicht nur – wie weiter oben dargelegt – nicht-binären, analogen Herangehensweisen, sie versuchen darüber hinaus das in eine Sprache zu überführen, was der Logik genau dieser Sprache zu tiefst zu wieder läuft. Der Output des Learners ist ein in Codes überführtes künstliches neuronales Netz. Backpropagation im oben dargelegten Sinn gehört also genauso zum Markenzeichen von Machine Learning-Verfahren, wie das, was Sudman das »Unschärfesystem mit probabilistischen Resultaten« (s.o.) genannt hat. Gleichsam ein emergent aus Konnektionen und Abkopplungen resultierender Filter, ein Netzwerk, das wie ein Fischernetz bestimmte Dinge auffängt und andere durch seine Maschen gleiten lässt.

Insofern findet eine Umkehrung dessen statt, was als mittelbar und was als unmittelbar wirksam wahrgenommen wird. War es früher (also in Daten-armen Zeiten) der Algorithmus, der wahrnehmbar seine Wirkungsketten entfaltete, wohingegen die Daten und Datenbanken nur latent als ›Futter‹ für den Algorithmus aufgefasst wurden, kehrt sich das Verhältnis nunmehr um: Die Datenbank als digitale Versammlung von Welt bildet den wirklichen Bestand, der von flüchtigen und unscheinbaren Codes gefiltert wird. Und es kann in gleichsam beliebiger Form gefiltert werden. Ein Zusammenhang, eine Bedeutung ist dabei ein Resultat des konnektionistischen Paradigmas und nicht mehr länger eine in den Code hineingelegte Prämisse.

Eine solche transklassische Programmierung im Sinne eines soziotechnischen Tatbestands stellt die Gesellschaft und damit auch die Sozialwissenschaften vor grundlegend neue Herausforderungen. Sie sind nicht nur weit in die Wirklichkeit hineingreifende soziotechnische Phänomene, sie stehen auch für ein neues Selbst- und Weltverständnis des Menschen, das sich deutlich von den bis dahin gültigen Verständnissen unterscheidet. Entsprechend ist es dringend geboten, ein genaues Bild dieser Machine Learning-Verfahren zu gewinnen. Gerade die elaborierte netzwerktheoretische Begrifflichkeit Harrison Whites erscheint uns als besonders geeignet, auf Spezifika dieser soziotechnischen Verfahren scharf zu stellen, um ein genaueres Bild von ihnen techniksoziologisch zu zeichnen. Genau diesem Unterfangen widmen sich die folgenden Unterkapitel.

3. Herausforderungen der neuen KI und der Beitrag der soziologischen Netzwerktheorie von Harrison White

Der soeben dargelegte konnektionistische Ansatz von Machine Learning-Verfahren steht in unseren Augen – wie so manches mehr in unserer gegenwärtigen Zeit – für ein Denken und Agieren gemäß einer genuinen Netzwerklogik. Der Begriff künstliche neuronale Netze sagt hierzu im Grunde schon alles. Um Relationen und deren Gewichtungen geht es im Backpropagation – der zentralen Prozedur des Deep Learnings, wie dargelegt. Ein Learner ist eine Maschine, die Netzwerke erzeugt. Regelmäßigkeiten, Strukturen und Muster sind die einzig verbliebenen Orientierungsgrößen, um sich in einer Welt des Heterogenen zurechtzufinden, in der es im Grunde nur Einbettungskonstellationen gibt – also weiter diversifizierende Netzwerkkonstellationen. Diese essentiellen Eigenschaften von Machine Learning-Verfahren verweisen auf

das ihnen zugrundeliegende Netzwerk-Paradigma. Insofern sind wir davon überzeugt, dass allen voran netzwerkforscherische Ansätze zu einer sachadäquaten sozialwissenschaftlichen Erschließung der neuen KI beitragen können. Was liegt also näher, den bislang elaboriertesten Ansatz der Netzwerktheorie und -analyse, nämlich denjenigen von Harrison White, heranzuziehen, und daraufhin zu überprüfen, welches Erkenntnispotenzial in ihm steckt? Genau dies soll nun im Folgenden geschehen. Hierbei stellen wir zentrale Herausforderungen der Machine Learning-Verfahren in den Fokus, verdeutlichen, inwiefern diese jeweiligen Herausforderungen Herausforderungen sind, die sich aus der den Verfahren innewohnenden Netzwerklogik ergeben, und konfrontieren diese mit den theoretischen Einsichten Whites, die er – völlig unabhängig von Überlegungen zu KI – für die strukturelle Bestimmung von Netzwerken im Allgemeinen vorgenommen hat. Dabei ist es schon Whites Ausgangspunkt der Theoriebildung den Ausgangspunkten der neueren KI-Entwicklungen verwandt. White geht von zwei Grundphänomenen aus, die Mustererkennung zentral stellen, Selbstähnlichkeit und Verteilung. Wiederholungen ähnlicher Verteilungen, also Muster, sind der Ausgangspunkt seiner Konzeptbildung für soziale Strukturen.

Das Problem des Kontextwechsels in der neuen KI als Switching in soziotechnischen Netzwerken

Mit dem Wechsel von Repräsentationsmodellen von Wissen, wie sie die Expertensysteme der klassischen KI kennzeichnen, hin zu Lernmodellen auf der Basis von Mustererkennung (zunehmend angelehnt an die Netzwerkstrukturen von Gehirnen) hat sich auch die Anforderung an diese ML-Verfahren grundlegend verändert. Da sie in der Lage sind, zu lernen, also aus der Beobachtung von Regelmäßigkeiten Entscheidungsregeln abzuleiten, entsteht die Hoffnung einer erhöhten Anpassungsfähigkeit dieser ML-Verfahren. Dies wird einerseits als wichtiger, wenn nicht gar zentraler, Schritt auf dem Weg zu einer Allgemeinen Künstlichen Intelligenz (AIG) angesehen, führt aber zur Flexibilisierung der Anwendungsgebiete, wie wenn das AlphaGo nicht nur Schach und Go spielt, sondern in kurzer Zeit alle möglichen Brettspiele erfolgreich spielen kann; oder wenn ein ML-Verfahren für Autonomes Fahren unterschiedlichste Merkmale auf der Fahrbahn erkennen kann und daraus Entscheidungen ableitet. Dennoch bleiben die Anwendungsgebiete noch immer sehr spezialisiert. Selbst ein Wechsel zwischen unterschiedlichen Kulturkontexten kann diese ML-Verfahren immer noch vor große Probleme

stellen. Damit ist das Problem des Kontextwechsels direkt angesprochen, dass auch in sozialen Situationen einschlägig ist und verschiedene Dimensionen des Sozialen tangiert. Hier ist auch der Hinweis auf die Wirksamkeit der Daten kennzeichnend, denn die Daten sind häufig spezifisch und, um besseres Lernen zu ermöglichen, auf einen Kontext zugeschnitten. Für den Wechsel müssen zusätzliche Muster gelernt werden, die den Prozess des Wechsels steuern. Der abduktive Sprung, der häufig bei neueren KI-Ansätzen unterstellt wird, bleibt häufig noch aus, wobei im Spezialfall durchaus überraschende Ergebnisse erzielt werden können – besonders wenn die Struktur der Daten nicht bekannt ist.

In der Netzwerktheorie ist das gerade dargelegte Problem ebenfalls bedeutsam, weil Netzwerke zunächst als grenzenlos betrachtet werden können. Fragt man nur nach Beziehungen im Allgemeinen, dehnen sich Netzwerke immer weiter aus, ohne wirklich abgeschlossen zu werden. Zur Untersuchung von Netzwerken müssen hier jedoch Grenzen eingeführt werden. Nach White geschieht dies vor allem durch Festlegung der Beziehungstypen (types of ties) und Identitätsformen. Dabei unterscheidet er verschiedene Komplexitätsstufen solcher Identitäten, die zwar in spezifischen sozialen Situationen entstehen, aber durch Erzählungen in andere Kontexte wandern können. Deshalb sind diese Grenzen in ständiger Bewegung, wenn man sich soziale Situationen ansieht. Daher führt White im Nachgang zur ersten Auflage von *Identity & Control* den Begriff des Switching (Kontextwechsels) ein (White 1995), der deutlich machen soll, dass es kommunikative Marker für Übergänge zwischen Kontexten gibt, die dann jeweils einen Kontextwechsel einerseits ankündigen, ihn damit wahrscheinlicher machen und auf diese Weise Veränderungen an den beteiligten Netzwerken, Beziehungs- und Identitätsformen vornehmen. Gleichzeitig – und dies ist für White sehr wichtig – werden damit diese Kontexte auch aneinandergespleißt, d.h. man kann der Spur solcher Wechsel folgen und so komplexere Identitäten erkennen und auch Spillover-Effekte (Padgett & Powell 2013)² nachvollziehbar machen. Die Modellie-

-
- 2 Unterscheidet man verschiedene Netzwerkdomänen, kann es durch die über Personen oder andere Knoten vermittelten Beziehungen zwischen diesen Netzwerkdomänen zu einem Spill-over kommen. D.h. nach Padgett und Powell, dass Veränderungen in einer Netzwerkdomäne auch zu Änderungen in anderen Netzwerkdomänen führen können, etwa wenn es einer Person gelingt, einen Zugewinn an Zentralität in der Familie zu nutzen, um auch im Netzwerk von politischen Ämtern mehr Gewicht zu erhalten. Ähnliches kann jedoch auch für die Diffusion von Ideen angenommen werden.

rung des Problems ist allerdings nicht ganz einfach, da ein ML-Verfahren die Kontextmarker ebenso erkennen müsste, wie auch die für den jeweiligen Kontext zentralen Muster. Dies gelingt auch menschlichen Akteur:innen nur mit entsprechendem Kontextwissen, welches erlaubt, Marker und Muster leicht zu verbinden; oder durch Rückfallpositionen, die von den Akteur:innen eingenommen werden, wenn der unterstellte Kontext offensichtlich nicht passt. White geht davon aus, dass Sprache hier eine zentrale Rolle spielt, ebenso wie Stile, die ebenfalls Marker und Muster koppeln und so dabei helfen, Kontexte schnell zu differenzieren. Andererseits hebt White hervor, dass es gerade auch eine Stärke sozialer Situationen ist, hier klare Differenzierungen zumindest eine Zeit lang im Ungefähren zu lassen (Mische/White 1998), sodass Optionen offengehalten werden und man nicht zu schnell auf klare Muster scharf stellt, die unangebracht sein könnten.³ Diese Vermeidung des Scharfstellens ist dabei als eine der großen Herausforderungen für KI-basierte ML-Verfahren zu sehen, die eine Allgemeine Künstliche Intelligenz anstreben. Der stetige Umgang mit Kontingenzen und eine Offenheit für vage Konstellationen stellt diese ML-Verfahren immer noch vor große Probleme. Dies liegt auch daran, dass ihre Aufgabenstellung bislang häufig anders aussieht, weil sie Klarheiten produzieren sollen. Techniksoziologisch ist an der Herangehensweise von White allgemein zu beachten, dass auch Materialitäten als solche Wechselmarker dienen können. Häufig sind es Räume oder Gegenstände, die, ähnlich wie Sprache, solche Wechsel nahelegen. Das Konzept des Switchings (und auch des Stitchings)⁴ könnte also auch in anderen Analysen von Technik Verwendung finden, die sich mit Wandel durch die Einführung neuer Artefakte in bestehenden soziotechnische Netzwerke beschäftigen, oder dem Wandern von unterschiedlichen technologischen Entwicklungen in neue Netzwerkkonstellationen.

Dabei tritt die technologische Neuartigkeit der neuen KI gerade am Switching-Thema deutlich zu Tage: Wie beispielsweise Halfmann (1996) herausarbeitet, ist ein durchgängiges Kennzeichnen ›klassischer‹ Technik, dass

-
- 3 Hier sehen wir eine Parallele zu dem Unschärfeaspekt bei der neuen KI, den Sudmann (2018) herausarbeitet.
- 4 White erwähnt diese Stitchings als Kehrseite seines Switchingsbegriff im Interview in Schmitt & Fuhse 2015 und meint damit, dass ein Kontextwechsel immer auch eine verfolgbare Spur zwischen den Kontexten hinterlässt, etwa in der Form von am Gespräch beteiligten Personen, oder einem Streit, der von einem Thema zum nächsten springt.

sie weitgehend dekontextualisiert funktioniert. Nur elementare ›harte‹ Kontexte, wie derjenige der Schwerkraft zum Beispiel, sowie ebenfalls ›harte‹ infrastrukturelle Kontexte, wie etwa die Stromversorgung bei Maschinen, bilden Bedingungen der Möglichkeit eines Funktionierens. Für Soziolog:innen besonders bedeutsam, sei jedoch Technik gerade von der sozialen Kontextspezifität weitgehend entbettet. Ein Wecker beispielsweise funktioniert unerbittlich auf jedem Kontinent, in jedem sozialen Milieu und in jeder denkbaren, gerade ablaufenden Interaktionssituation. Diese Entkopplung vom Mitteilungsaspekt, wie Halfmann in Anlehnung an den Kommunikationsbegriff Luhmanns es nennt, ist nicht zuletzt dafür verantwortlich, dass alles Mögliche dann je nach konkreter Situation in die Technik hineinprojiziert werden kann: Das Auto als Fortbewegungsmittel, als Statussymbol, als Schlafstätte, als Schadstoffquelle etc. Mit der neuen KI bekommen wir es quasi zum ersten Mal mit einer Technik zu tun, die in Umkehrung zur ›klassischen‹ Technik einen genuin kontextsensitiven Fokus aufweist. Auch hierin äußert sich also ihr transklassischer Charakter.

Das Problem der Grenzziehung durch neue KI als Phänomene der Bildung von Nettdoms und Stilen

Das Problem der Grenzziehung kann man direkt an das Problem des Kontextwechsels anschließen, da es auch hier um die Klärung von Kontext geht. In KI-Modellen, die auf Deep Learning bauen, sind diese Grenzen zunächst durch die Trainingsdaten gesetzt. Die Trainingsdaten sind letztlich der Kontext, auf dessen Basis das ML-Verfahren lernt. Danach wird dieser Kontextrahmen jedoch erweitert, da das lernende Netzwerk nun auf neue Daten losgelassen wird. Interessant ist hier auch wiederum die Vorgehensweise beim AlphaGo-ML-Verfahren, welches die zu lernenden Spiele einfach immer wieder gegen sich selbst spielt und dabei einen riesigen Korpus an Vergleichsdaten erzeugt, indem es das Spiel simuliert. Die Grenzen sind hier jedoch durch die Spielregeln der verschiedenen Brettspiele klar definiert. Ein solches Selbstlernen durch Simulation ist also in gewisser Weise vor allem dann erfolgreich, wenn die Grenzen klar bestimmbar sind, oder mit Winograd/Flores (1989) formuliert, wenn es sich um einen wohldefinierten Problemraum handelt. Es geht hier also um Kontrollgewinne, die auf der Möglichkeit der ML-Verfahren beruhen in umgrenzten sozialen Bereichen selber weitere passende Daten zu generieren und so quasi experimentell lernen. Daten werden im Verlauf von diesen ML-Verfahren immer weiter erzeugt und teilweise

gehört es zur Selbstverbesserung dieser ML-Verfahren, mit Simulationen zu arbeiten, um auf mehr Daten zu Lernzwecken zurückgreifen zu können. In vielen sozialen Kontexten ist diese Klarheit jedoch nicht gegeben und so geraten die lernenden Verfahren an Grenzen, wenn ihnen keine klaren Grenzen ihres Anwendungshorizonts vorgegeben wurden bzw. sie keine eindeutigen Grenzen aus dem Datenmaterial herausfiltern können.

Dies ist nun ein Problem, mit dem sich auch menschliche Akteur:innen herumschlagen müssen, und damit ein Phänomen, dem sich auch alle soziologischen Differenzierungstheorien widmen. In der relationalen Theorie Whites spricht man seit der Neuauflage von *Identity & Control* (2008) von Netzwerkdomänen, oder kurz: *Netdoms*. Ein *Netdom* kombiniert spezifische Typen von Verbindungen und zugehörige Typen von Identitäten (auf einer kulturell-definitiven Ebene) sowie eine ebenfalls spezifische Netzwerkstruktur (auf einer klassisch netzwerkanalytischen Ebene). Ein Beispiel für eine Netzwerkdomäne wäre ein Freundschaftsnetzwerk innerhalb einer Firma, das man unterscheiden kann von einem Ratgeber-Netzwerk etc. Der Begriff bietet, wie die meisten Begriffe bei White, eine große Anwendungsbreite und ist praktisch beliebig skalierbar. Er kombiniert kulturelle Schablonen mit sich dynamisch aufbauenden Beziehungsstrukturen. Schwierig ist auch hier die Erkennbarkeit, da *Netdoms* nicht immer durch klar abgrenzbare Begrifflichkeiten vorstrukturiert sind. Eine weitere Begrifflichkeit Whites kann hier Abhilfe schaffen, die sich explizit an die Erkennbarkeitsproblematik koppelt: *Stile*.

Stile kennzeichnen nach White flexible Sozialstrukturen (ebenfalls skalierbar und mit extensiver Anwendbarkeit), die genau auf der Basis wiederkehrender, selbstähnlicher Muster Signalfunktion und Sensibilisierung verknüpfen. In einem *Stil* – entwickelt von White am Beispiel von Kunststilen (White/White 1993) – wird ein selbstähnliches Muster benutzt, um eine komplexe Identität zu signalisieren, die eine trainierte Beobachter:in (Expert:in) schon an kleinen Ausschnitten des Musters erkennen kann. KI-Verfahren könnte man an dieser Stelle als trainierte Beobachter ansehen, die genau aus solchen Daten Profile erstellen, um dann auf Identitäten zurückzurechnen. Problematisch ist hieran, dass diese Grenzkonstruktionen der KI kombiniert mit den Schwierigkeiten solcher Verfahren mit dem Wechseln von Kontexten (s.o.) zu einer problematischen Verhärtung von Mustern und damit sozialen Identitäten führen kann, die in anderen sozialen Situationen für gewöhnlich länger offengehalten würden. Diese vorschnellen Abgrenzungen könnten dann durchaus sozial schwerwiegende Folgen haben. Es geht hier tatsächlich um die Übergabe von Kontrolle bei der Identitätskonstruktion von Personen und Gruppen

an Technik und damit auch um einen Kontrollverlust dieser sozialen Entitäten bei den entsprechenden Grenzziehungen. Stile halten diese Verdichtungen auch länger offen, indem sie zwar aus Ausschnitten Strukturen erkennbar machen, aber auch hier Flexibilität und Möglichkeiten zum aktiven Stillbruch implizieren. Da Stile als Signale verwendet werden (auch durchaus bewusst), muss man hier auch die Möglichkeiten des strategischen Einsatzes von Markern einkalkulieren.

Techniksoziologisch ist hier zu beachten, dass Grenzziehungen für den Einsatz von Technologien extrem wichtig sind. Häufig geht es darum, das Funktionieren durch Ausgrenzung von Kontexten und Komplexität sicher zu stellen. Hier kann der Bezug auf den Stilbegriff extrem hilfreich werden. Wie sich Identitätskonstruktionen in soziotechnischen Netzwerken ändern, ist häufig genau an diesen Ausgrenzungen besonders gut zu erkennen, etwa auch an der transklassischen Form neuerer KI-Verfahren, die eben eine Kontextsensibilität markieren sollen und daher die klassische Grenzziehung von Technik als entbettet verlassen. Markierungen dieser Grenzen durch Räume, Einrichtungen und Interfaces sind daher von großem Interesse und können bei der Analyse von Transformationsprozessen helfen.

Das Problem der Steuerung von und mittels neuer KI als soziotechnische Kontrollprojekte

Das Problem der Steuerung schwebt über der gesamten Diskussion um den Einsatz künstlicher Intelligenz, vor allem, wenn man von ethischer, rechtlicher und politischer Seite auf das Thema schaut. Aber auch ökonomisch ist die Steuerung von bestimmten Abläufen, vor allem die Geschwindigkeit dieser Steuerung ein großes Thema. Die Frage ist hier stets, wer steuert wen und an welcher Stelle werden dann Entscheidungen von erheblicher Tragweite getroffen. Hier werden gleich mehrere Themenkomplexe aus der Literatur angesprochen. Zum einen natürlich das Verhältnis von Kontrolle und Opakheit der ML-Verfahren (s. Einleitung im vorliegenden Band). Dabei ist KI, wie oben schon erwähnt, zum einen als Antwort auf immer komplexere Entscheidungssituationen zu verstehen, wo die Datenlage für menschliche Beobachter zu unübersichtlich wird. Kontrolle wird hier abgegeben, weil man Kontrolle schon verloren hat, oder anders formuliert: es geht darum Kontrolle durch technische Unterstützung erst überhaupt wieder zurückzugewinnen. Dabei ändern sich jedoch die Bedingungen der Ausübung von Kontrolle, weil die Empfehlungen der KI zunehmend nicht mehr hinterfragt werden können, oder man die Ant-

wort auf diese Frage nur sehr bedingt versteht bzw. nachvollziehen kann. Besonders problematisch wird dieser Kontrollverlust natürlich vor dem Hintergrund der ebenfalls diskutierten Betaisierung dieser ML-Verfahren (s. ebenfalls Einleitung). Wenn Empfehlungen aufgrund von Verfahren getroffen werden, deren Datengrundlagen eventuell noch nicht ausreichen, stellt das die Benutzer:innen vor neue Herausforderungen.

Wenn man Steuerungsversuche als Kontrollprojekte versteht und sich die Frage stellt, wo sich welche Kontrollansätze wie miteinander verknüpfen, bietet sich der Kontrollbegriff von Harrison White an, der Kontrolle zur Grundlegung jeder Art von Relationierung macht. Beziehungen zwischen Entitäten sind in dieser Sichtweise Kontrollverschränkungen, die hier unterschiedliche Bindungen stabilisieren, von denen Steuerung als sehr direkte Durchgriffsmöglichkeit nur eine Möglichkeit von vielen Kontrollmöglichkeiten darstellt. Kontrollprojekte lassen sich hierbei natürlich auf unterschiedlichen Ebenen identifizieren, da auch Erzählungen (oder Stories bei White) als solche Kontrollprojekte eingesetzt werden können.

Daher spielt die Debatte um Steuerung durch die neue KI eine wichtige Rolle, da hier der Möglichkeitsraum für den Einsatz und die Reichweite dieser Verfahren unterschiedlichen soziotechnischen Konstellationen ausgearbeitet wird. Dabei wird vor allem relevant, wie technologische Aspekte in soziale Prozesse eingebettet werden und auf welcher Ebene der Kontrollversuch unternommen wird. Neben der Kontrolle von Entscheidungen auf der Output-Ebene, die verschiedene Formen zwischen Empfehlungen und direkten Eingriffen annehmen kann, gibt es auch eine Kontrolle auf der Input-Ebene, bei der zum einen Daten ausgewählt werden können, von denen dann gelernt wird, und zum anderen auch durch Einstellungen der Parameter in den neuronalen Netzen (Stichwort: Backpropagation). Dies geht bis hin zu einer nachträglichen Kontrolle der Ergebnisse im Hinblick auf Kriterien die man erfüllt sehen möchte, zum Beispiel im Rahmen einer Qualitätskontrolle.

In dieser Komplexität der Kontrollverschränkungen im Einsatz von Machine- und Deep Learning-Verfahrenen zeigt sich dann auch wieder das Problem der Opakheit bzw. der mangelnden Transparenz dieser Verfahren. Es wird zu Teilen schwierig für jemanden sein, herauszufinden, warum ihm die KI einen spezifischen Vorschlag macht. An dieser Stelle wird dann auch die Verantwortungsproblematik deutlich, da Kontrollverschränkungen gekoppelt mit Intransparenz dazu führen, dass Resultate solcher soziotechnischen Netzwerke letztlich nicht mehr klar zurechenbar sind und daher Regeln dafür getroffen werden müssen, wie sich die Verantwortung im Netzwerk verteilt.

Unter Netzwerkbedingungen – netzwerktheoretisch gesprochen – ist sowieso die klassische Vorstellung von Verantwortung abzulehnen und zugunsten einer dynamisch-rückgekoppelten Sichtweise auf mögliche Quellen des Bewirkens und tatsächlich eintretender Wirkungen zu ersetzen (vgl. hierzu auch die »Agency of Assemblages« bei Bennett (2005)). Zentraler Bezugspunkt ist nunmehr die Frage nach der Bildung welcher Relationen auf der Basis welcher Kontrollprojekte, die schließlich das gesamte soziotechnische Netzwerk auszeichnen. Diese Verstrickung von Kontrollprojekten und deren Vermittlung über technische Artefakte kann als ein zentrales Thema jeder Techniksoziologie herausgestellt werden. Wenn Kontrollprojekte materialisierte Formen annehmen, kommt es damit zu einer spezifischen Verhärtung. Dies bedeutet nicht, dass es nicht Möglichkeiten gibt, diese Verhärtung zu umgehen und/oder sie für andere Formen von Kontrolle zu nutzen, es bedeutet aber, dass die Kontrolle hier eine andere Ausdrucksform angenommen hat, die sich durch veränderte Merkmale (Dauerhaftigkeit, Widerstand gegen andere Kontrollversuche etc.) auszeichnet.

Das Problem der Zuschreibung innerhalb der und durch die neue KI als relationale Identitätsbildungsprozesse

Schließlich ändern sich auch die Identitätsbildungsprozesse von Personen und Organisationen, wenn Algorithmen wesentliche Beiträge hierzu leisten. Dies kann man schon an der zunehmenden Dominanz von Rankingsystemen bei der Bewertung dieser Identitäten sehen (Espeland/Sauder 2007; Sauder/Espeland 2009). Hier kommt es auch, wie im chinesischen Social Scoring-System, oder auch nur bei der Bewertung als Top Rezensent bei Amazon, zu einer letztlich stark datengetriebenen Identitätskonstruktion, bei der man sich nicht mehr an direkten Beobachtungen oder Hörensagen (Stories) orientiert, sondern an abgeleiteten Bewertungssystemen, bei denen man weder genau weiß, auf welche Daten sie sich stützen, noch wie der Algorithmus daraus eine finale numerische oder andere Bewertung generiert. Durch die Vermischung unterschiedlicher Identitätsfacetten in den Datengrundlagen können dann auch neue Informationen gewonnen werden, die in der Art eines Profiling über diverse Daten hinweg operieren und damit eine stärker integrierte Identität erzeugen, als es die Person selbst eventuell tun würde. Es kommt hier dann zu Realexperimenten mit Personen und ihrer jeweiligen Identität, über deren Konstruktion sie ein weiteres Stück ihrer Hoheit verlieren. Tatsächlich kommt es hier dann durch die KI-Verfahren auch zu abduktiven Sprüngen,

etwa wenn jemandem aufgrund spezifischer, ihr oder ihm vielleicht nicht mal bekannter Eigenschaftskonstellationen ein Kredit verweigert wird. Dies ermöglicht zum einen forensische Ansätze der Datenanalyse, also eine überzeugende Rekonstruktion von Identitäten aus verteilten Spuren (hierbei kann auch das Identitätskonzept von White (s.o.) helfen, siehe außerdem McFarland et al. 2016), zum anderen aber auch die Erzeugung einer sensiblen Maschine, die auf bestimmte Spurenelemente besonders stark reagiert. So lassen sich aus unterschiedlichen Datenkorpora von Positionen (wo war eine Person, oder welche anderen Personen hat sie getroffen), über Erzählungen (was hat sie dabei gesagt oder geschrieben) bis hin zu komplexen Spuren der Bewegung zwischen unterschiedlichen Kontexten eine umfassende Identitätskonstruktion ableiten. Hier erscheint dann auch die Kontrollproblematik in neuem Licht; denn wer hat hier jetzt noch welche Kontrolle über die so entstehenden Identitäten. Die freie Verknüpfung unterschiedlicher Datenströme ermöglicht dabei Konstruktionen, die der Person oder der sozialen Gruppe, auf die sie sich beziehen, gar nicht zugänglich sind. Die Daten werden hierbei in einer Weise wirksam, die ganz neue, sozial hoch relevante Zuschreibungsprozesse möglich macht und diese der Kontrolle entzieht.

Der Ansatz von White, soziale Identitäten auf unterschiedlichen Komplexitätsformen zu beschreiben, ist geeignet, um hier die entsprechenden datengetriebenen Varianten zu analysieren. Die Theorie bietet dabei Anschlussmöglichkeiten, da sie klar zwischen positionalen und narrativen Elementen unterscheiden kann, diese jedoch in Beziehung zueinander setzt. Damit ist die Relationierung zwischen unterschiedlichen Datenmaterialien schon integriert. White unterscheidet prinzipiell fünf Formen von Identität mit steigender Komplexität und größerer Reichweite. Während Identitäten sich situativ durch eine wechselseitige Positionierung bilden und damit die einfachste Form von Identität realisieren, können diese Positionen in einer zweiten Stufe in der Form einfache Narrative transportierbar gemacht werden. Diese Möglichkeit kann dann eine Positionierung über mehrere Kontexte hinweg bewirken; und dieser Weg von Positionen durch verschiedene Kontexte ist dann selbst auch eine Identität auf der dritten Komplexitätsstufe. Diese Formen können ihrerseits wiederum in der Form von Geschichten verdichtet werden (z.B. als Karriere) und bilden erneut eine transportable Form von Identität. Schließlich unterscheidet White auch noch eine fünfte Komplexitätsform, bei der es um eine Integrationsleistung geht, die in der Lage ist, alle diese Identitätsformen in einem übergreifenden Profil zu integrieren. Dies gelingt zum Beispiel in der Form der Person. Allgemeiner veranschlagt White

hier den Begriff des Stils, der ein stochastisches Profil beschreibt, dass in der Lage ist, solche Integrationsleistungen zu vollbringen.

Für die Analyse der gesellschaftlichen Auswirkungen neuerer Formen der KI sind dabei wichtig, welche Arten von Spuren sie nutzt, was sie daraus konstruiert und was davon wieder sichtbar gemacht wird, um etwa als transportable Einheit benutzt zu werden. Dabei ist bedeutsam, dass die KI-Verfahren auch Positionierungen eigentätig vornehmen, selbst Positionen einnehmen und Verdichtungen anbieten. Damit verschieben sich Kontrollverstrickungen und bestehende Positionen von Identitäten, wie z.B. professionelle Identitäten von Ärzt:innen etc. (siehe den Beitrag von Bongert & Schwarz im vorliegenden Sammelband). KI-Verfahren sind dabei in diese Kontrollprojekte unterschiedlicher, sozial relevanter Identitäten involviert und bestimmen diese zu weiten Teilen mit. So sind mittlerweile Kaufprofile fester Bestandteil sozial relevanter Identitäten, die aggregiert und über Datenhändler weiterverkauft werden. Solche Einheiten bieten jeweils auch neue Kontrollchancen, die man nutzen kann. Grundsätzlich ist in Anlehnung an Whites Theorie davon auszugehen, dass neue Verdichtungen von stochastischen Prozessen, auf welcher Grundlage sie auch immer vorgenommen werden, immer auch neue Wege der Kontrolle etablieren und sich so mit anderen Identitäten verstricken und damit, streng relational gedacht, diese verändern. Ist das Kaufprofil einer Person verfügbar und mit anderen Daten verknüpfbar, ergeben sich neue Wege diese Person anzusprechen, oder mit diesem Profil zu arbeiten. Diese datengetriebene Konstruktion von Identitäten ermöglicht also neue Arten von Kontrolle, indem diese Daten in unterschiedliche soziale Praktiken und Selbst- und Fremdbeschreibungen integriert werden.

Auch an dieser Stelle kann die Grundidee der Rolle von Erzählungen und Zuschreibungsprozessen bei der Konstruktion sozialer Relevanz auf andere Technologien ausgeweitet werden. Diese Technologien gehen immer in Identitätskonstruktionen ein, da man keine Kranführer:in ohne Kran sein kann. Andererseits werden Technologien jedoch auch immer selbst Ziel von Erzählungen und ihnen werden spezifische soziale Relevanzen zugeschrieben, wie man es in bedeutendem Umfang auch im Diskurs um die neuen DL-Verfahren beobachten kann.

Die Skalierungsproblematik in der KI als Reichweitenfestlegung in Einbettungskonstellationen

Schließlich müssen wir uns der Frage der Skalierung dieser KI-Verfahren zuwenden. Skalierung kann hier in zwei Richtungen gelesen werden: Zum einen geht es um die Reichweite der angebotenen Lösungen zwischen Spezialproblemen und einer allgemeinen künstlichen Intelligenz (AIG), zum anderen geht es dabei um immer umfassendere Datensätze oder gesellschaftliche Anwendungsgebiete, die für Speziallösungen zur Verfügung stehen. Die Reichweite ist dabei eine wichtige Bezugsgröße, da White ein Angebot macht, zu erklären, über welche Wege die Skalierung sozialer Formationen erfolgt. Situative stochastische Verteilungen verdichten sich zunächst noch in einer sozialen Situation zu Positionierungen, die sprachlich zu erzählerischen Einheiten gebündelt und damit in andere situative Kontexte überführt werden können. Gelingt mittels dieser Überführung eine Verknüpfung von Kontexten, ergibt sich eine kohärente soziale Spur, die selbst wieder zu einer Einheit verdichtet werden kann. Durch solche gelingenden Verdichtungen mit Verknüpfungen ergeben sich Reichweitengewinne.

Schaut man sich jetzt die Anwendungsfelder der neueren KI an, wird schnell deutlich, dass sie zwar vielfältige neue Einheiten produziert, also Verdichtungen vornimmt, die Verknüpfung allerdings noch häufig außerhalb ihrer Aufgabengebiete liegt. Dennoch existiert schon eine Reihe von Versuchen, auch die Verknüpfung zu automatisieren und so große Reichweiten produzieren zu können. An den beiden einleitend erwähnten Reichweitenproblemen von spezifisch zu allgemein und von Nischenanwendungen zu umfassenden Anwendungen ist jeweils eine spezifische Form dieser Kopplung von Verdichtung und Verknüpfung zu beobachten. Diese Reichweitenvergrößerung lässt sich ebenfalls häufig in der Form von Realexperimenten beobachten. Die ML-Verfahren laufen einfach und lernen (etwa AlphaZero auf immer mehr Arten von Spielen) und es wird beobachtet, wie weit sie damit kommen, immer neue Daten zu integrieren oder selbst zu erzeugen.

Aus netzwerktheoretischer Sicht ist für den ersten soeben dargelegten Fall vor allem das Einbettungsproblem ein aussichtsreicher Erklärungsansatz. Eine Einbettung wird nicht ohne weiteres aus Lerndaten direkt ersichtlich und sie ersetzt häufig Informationen, die nicht in diesen Daten auftauchen. Damit ist im Anschluss an die Diskussion zur Identitäts- und Kontrollproblematik zu beachten, dass solche Verfahren immer in schon existierende soziale Kontexte eingeführt werden. Es gibt also schon vorgängige Verstrickungen, die in unter-

schiedlichen Ausmaßen in die Spezialanwendung integriert sind bzw. deren Funktionsfähigkeit bedingen. Hierbei ist jeweils zu bedenken, in welcher Weise die Lerndaten diese Kontexte spiegeln, oder integrieren können. Die vielfältigen Diskussionen um die Probleme von Bias oder das Scheitern von Anwendungen bei leicht veränderten oder neuen Kontexten deuten bereits auf das Problem hin, dass die Einbettung in der soziotechnischen Konstruktion nicht ausreichend reflektiert worden ist. Hieraus ergibt sich dann auch für die zweite Reichweitenproblematik eine konstitutive Vertrauensproblematik, für die Lösungen angeboten werden müssen. Weiterverwendbare Einheitenbildung muss ihre Fähigkeit zur Verknüpfung diverser Kontexte erst zeigen und nachvollziehbar unter Beweis stellen, um größere gesellschaftliche Reichweite zu erlangen.

Reichweite und Skalierbarkeit sind in der Techniksoziologie sehr grundlegende Themen, wenn es zum Beispiel um die Diffusion von Innovationen geht, oder wenn sich ganze gesellschaftliche Formationen auf bestimmte technologische Grundlagen beziehen, die etwa den Energiehaushalt einer Gesellschaft (Kohle, Öl, Gas etc.) bestimmen. Whites Netzwerktheorie bietet hier ein offenes Skalierungsmodell mit mehreren Konzepten, mit denen ein solcher Reichweitengewinn beschrieben und erklärt werden kann. Festzuhalten bleibt hier, dass sich auch technisch realisierte Kontrollprojekte gegenüber anderen Projekten behaupten müssen, genauer: sich mit diesen verknüpfen, oder von ihnen ablösen müssen, um ihre Reichweite auszudehnen und dabei durch Switching und Stitching neue Kontexte erobern.

4. Schluss

Die neuen ML- und DL-Verfahren, die der Erforschung künstlicher Intelligenz einen neuen Aufschwung beschert haben, sind durch ihre gesellschaftliche Relevanz ebenso Thema für die Soziologie, wie auch durch ihren transklassischen Charakter eine theoretische Herausforderung. Auf diese theoretische Herausforderung sollte in diesem Beitrag scharf gestellt werden. Dabei sollte deutlich geworden sein, dass netzwerktheoretische Konzepte, wie die hier vorgestellten aus der Theorie von Harrison White sehr geeignet sind, um mit diesen theoretischen Herausforderungen umzugehen. Dies liegt daran, dass die Konzepte zwei Merkmale aufweisen, die eine gewisse Verwandtschaft zu den Mustererkennungsprozessen der DL-Verfahren, die hier im Fokus stehen, aufweisen. Das erste Merkmal ist die explizite Inkorporation von Unsicher-

heit und Chaos in die Konzepte selbst. Alle Konzepte weisen Unschärfen auf, die Momente von Chaos und Ordnung zusammen denken. An jeder Stelle können Muster nur gehalten werden, wenn Kontrolle sich verschränkt und gerade aus dieser Verschränkung ergeben sich stets neue Lücken, aus denen Veränderungen erwachsen können. Das zweite Merkmal bezieht sich auf die Skalierbarkeit der Konzepte. Die Konzepte bezeichnen Muster, die man auf unterschiedlichen sozialen Skalen beobachten können. Ein explorativer Stil kann etwa in einer Einzelsituation als Strategie einer Teilnehmer:in beobachtet werden, aber auch als Stil einer Person über verschiedene Situationen hinweg und als Stil einer Organisation, einer wissenschaftlichen Produktionsgemeinschaft, oder einer ganzen Nation. Zusätzlich haben wir diese Wahlverwandtschaft zwischen techniksoziologischem Anwendungs- und Theoriebezug auch genutzt, um das Theorieangebot von White techniksoziologisch in ersten Schritten zu erweitern. Die Perspektive von Identität und Kontrolle bringt hier Möglichkeiten ein, von soziotechnischen Netzwerken nicht nur als Metapher zu sprechen, sondern mit dem umfangreichen Arsenal netzwerkanalytischer Methoden zu arbeiten.

5. Literatur

- Belić, Minja/Bobić, Vladislava/Badža, Milica/Šolaja, Nikola/Đurić-Jovičić, Milica/Kostić, Vladimir S. (2019): »Artificial intelligence for assisting diagnostics and assessment of Parkinson's disease – A review«, in: *Clinical neurology and neurosurgery* 184.
- Bennett, Jane (2005): »The Agency of Assemblages and the North American Blackout«, in: *Public Culture* 17(3), S. 445–466.
- Espeland, Wendy N./Sauder, Michael (2007): »Rankings and reactivity: How public measures recreate social worlds«, in: *American journal of sociology* 113(1), S. 1–40.
- Halfmann, Jost (1996): Die gesellschaftliche »Natur« der Technik: eine Einführung in die soziologische Theorie der Technik, Opladen: Leske+Budrich.
- Häußling, Roger (2019): Techniksoziologie, Opladen/Toronto: utb.
- Hughes, Thomas P. (1979): »The electrification of America: the system builders«, in: *Technology and Culture* 20(1), S. 124–161.
- Mackenzie, Adrian (2006): *Cutting code: Software and sociality* (Vol. 30), New York: Peter Lang.

- Manovich, Lev (2001): *The language of new media*, Cambridge/Massachusetts: MIT Press.
- McFarland, Daniel A./Lewis, Kevin/Goldberg, Amir (2016): »Sociology in the era of big data: The ascent of forensic social science«, in: *The American Sociologist* 47, S. 12–35.
- Mische, Ann/White, Harrison (1998): »Between conversation and situation: Public switching dynamics across network domains«, in: *Social research* 85, S. 695–724.
- Padgett, John F./Powell, Walter W. (2012): *The emergence of organizations and markets*, Princeton/Oxford: Princeton University Press.
- Sauder, Micheal/Espeland, Wendy N. (2009): »The discipline of rankings: Tight coupling and organizational change«, in: *American sociological review* 74(1), S. 63–82.
- Schmitt, Marco/Fuhse, Jan (2015): *Zur Aktualität von Harrison White: Einführung in sein Werk*, Wiesbaden: Springer-Verlag.
- Simon, Herbert A. (1990): »Bounded Rationality«, in: John Eatwell/Murray Milgate/Peter Newman (Hg.), *Utility and Probability*, London: Palgrave Macmillan, S. 15–18.
- Sudmann, Andreas (2018): »On the media-political dimension of artificial intelligence«, in: *Digital Culture & Society* 4(1), S. 181–200.
- Turing, Alan M. (2007): »Computermaschinerie und Intelligenz (1950)«, in: Karin Bruns/Ramón Reichert (Hg.), *Reader Neue Medien: Texte zur digitalen Kultur und Kommunikation*, Bielefeld: transcript Verlag, S. 37–64.
- White, Harrison C. (2008): *Identity and Control. How social formations emerge*. Second edition, New Jersey: Princeton University Press.
- White, Harrison C. (1992): *Identity and Control. A Structural Theory of Social Action*, Princeton/New Jersey: Princeton University Press.
- White, Harrison C./White, Cynthia A. (1993): *Canvases and careers: Institutional change in the French painting world*, Chicago: University of Chicago Press.
- White, Harrison C. (1995): »Network switchings and Bayesian forks: reconstructing the social and behavioral sciences«, in: *Social Research* 62 (4), S. 1035–1063.
- Wiener, Norbert (1952): *Mensch und Menschmaschine*, Berlin: Metzner.
- Winograd, Terry/Flores, Fernando (1989): *Erkenntnis-Maschinen-Verstehen: zur Neugestaltung von Computersystemen*, Berlin: Rotbuch.

