

# Möglichkeiten und Grenzen der Optimierung von Verfahren Tiefer Interpretation durch Softwareunterstützung

Burkhard Schäffer

**Zusammenfassung:** In dem Beitrag werden Parallelen aufgezeigt zwischen Verfahren des sog. Deep Learnings im Kontext von künstlicher Intelligenz (KI) und gängigen Ablaufschemata im Bereich qualitativ-rekonstruktiver Verfahren empirischer Sozialforschung: Methodologien wie die Dokumentarische Methode, die Objektive Hermeneutik, die Grounded Theory oder das Narrationsstrukturelle Verfahren haben alle mehr oder weniger nicht methodisierbare Bereiche, auf die mit Begriffen wie Abduktion oder Intuition eingegangen wird. Die Parallele zur KI wird in den sog. Hidden layers gesehen, also den verborgenen Schichten algorithmischer Berechnung bei sprachverarbeitenden Systemen, die von Informatiker\*innen ebenfalls nicht oder nur unter unverhältnismäßig großem Aufwand rekonstruiert werden können. Vor diesem Hintergrund werden die angesprochenen qualitativ-rekonstruktiven Methodologien als Verfahren *Tiefer Interpretation* rekonstruiert und abschließend ein Forschungsprojekt vorgestellt, welches eruiert, inwiefern eine QDA<sup>1</sup>-Software für das Interpretieren mit der Dokumentarischen Methode (DokuMet QDA<sup>2</sup>) durch KI unterstützt werden kann.

**Schlagwörter:** Künstliche Intelligenz (KI), Algorithmen, Natural Language Processing, Dokumentarische Methode, Verfahrenslogiken, Deep Learning, QDA Programme

## Possibilities and limits of optimizing procedures of Deep interpretation by software support

**Abstract:** In this article, parallels are shown between procedures of so-called deep learning in the context of artificial intelligence (AI) and common flow schemata in the field of qualitative-reconstructive procedures of empirical social research: methodologies such as the Documentary Method, Objective Hermeneutics, Grounded Theory or the Narrative Structural Approach all have more or less non-methodisable areas, which are addressed with terms such as abduction or intuition. The parallel to AI is seen in the so-called hidden layers, i.e. the hidden layers of algorithmic computation in language-processing systems, which cannot be reconstructed by computer scientists either, or only with disproportionate effort. Against this background, the aforementioned qualitative-reconstructive methodologies are reconstructed as procedures of *deep interpretation* and, finally, a research project is presented that investigates to what extent a QDA software for interpreting with the documentary method (DokuMet QDA) can be supported by AI.

---

1 QDA = Qualitative Data Analysis

2 DokuMet QDA, [www.dokumet.de](http://www.dokumet.de)

**Keywords:** artificial intelligence (AI), algorithms, natural language processing, documentary method, procedural logics, deep learning, qualitative data analysis programmes

## Einleitung

Im Rahmen der Methodologie der Dokumentarischen Methode (Bohnsack 2021) wurde, wie bei allen anspruchsvollen Verfahren Tiefer Interpretation<sup>3</sup> auch, ein Modus der Näherung an empirisches Material entwickelt, der sich von anderen ‚tiefen‘ Interpretationsverfahren wie z.B. der Objektiven Hermeneutik (Wernet 2021), verschiedenen Spielarten der Grounded Theory (Strübing 2014; Breuer/Muckel/Dieris 2019) oder dem Narrationsstrukturellen Verfahren (Schütze 2016) einerseits unterscheidet, andererseits aber auch viele Gemeinsamkeiten aufweist. Dieser Modus kann bis zu einem gewissen Grad mit Regelmäßigkeiten im Sinne von Wenn-Dann-Anweisungen beschrieben werden. Z.B. verbirgt sich hinter den strikten ‚Nacheinandergeboten‘ aller sequenzanalytischen, also aller im weitesten Sinne hermeneutischen und rekonstruktiven Verfahren qualitativer Sozialforschung die Regel: Wenn ein Text interpretiert werden soll, dann muss die Reihenfolge der Wörter und Sätze eingehalten werden, es darf also nicht ‚vorgegriffen‘ werden.

Vor diesem Hintergrund wird in dem Beitrag einerseits der Frage nachgegangen, ob solche Verfahrensheuristiken, die bei allen sequenzanalytischen Methodologien anzutreffen sind, bis zu einem gewissen Grade auch als Algorithmen beschrieben werden können, also „Verfahren zur schrittweisen Umformung von Zeichenreihen“ (Duden) oder ob es sich hier eher um Verfahrenslogiken im praxeologischen Sinne handelt, also um Modi Operandi des Interpretierens, die nicht, wie ein Algorithmus nach eindeutigen Regeln, sondern eher im Sinne einer Mischung von teils expliziten, teils impliziten Regelmäßigkeiten zu konzipieren sind, wie sie auch vielen habitualisierten Handlungspraxen in der Alltagswelt unterliegen (Kap. 2). Dem vorangestellt ist ein Kapitel (1) über künstliche Intelligenz und sog. Deep Learning Algorithmen, ohne dass die zu entfaltenden Überlegungen zu den Gemeinsamkeiten von Verfahren Tiefer Interpretation mit Deep Learning nicht nachvollziehbar ist. Demnach haben Deep-Learning-Architekturen und Verfahren Tiefer Interpretation die Gemeinsamkeit, dass bei beiden versteckte Schichten (sog. Hidden Layers) der Bearbeitung empirischen Materials anzutreffen sind, die die Nachvollziehbarkeit und intersubjektive Überprüfbarkeit erschweren. So können aufgrund von Grenzen der Berechenbarkeit (Mainzer 2014) Informatiker\*innen, wenn überhaupt nur unter größtem Aufwand genau rekonstruieren, wie eine Deep-Learning-Anwendung zu ihren Ergebnissen kommt<sup>4</sup>, aber auch kein\*e Interpretierende\*r kann alle Schritte rekonstruieren, wie sie oder er zu seinem/ihrer theoretischen Modell oder Typologie etc. gekommen ist. In einem dritten Kapitel werden schließlich vor dem Hintergrund der in Kap. 1 und 2 entfalteten Überlegungen Möglichkeiten und Grenzen der Optimierung von Verfahren Tiefer Interpretation durch Softwareunterstützung am Bei-

---

3 Zu diesem Begriff vgl. Kap. 2.2

4 Denn was vor dem Hintergrund eines einfachen Algorithmenbegriffs zunächst eindeutig erscheint, wird dann komplexer, wenn man sich anschaut, wie Algorithmen in sog. Deep-Learning-Architekturen im Rahmen von sog. „künstlicher Intelligenz“ (KI) Verwendung finden. Hier lassen sich auf Grund von „Grenzen der Berechenbarkeit“ (Mainzer 2014) keine eindeutigen deterministischen Ableitungen von Eingabe und Ausgabe mehr herleiten, sondern wir haben es mit vielfältigen „Diffractionen“ (Barad 2012) zwischen Algorithmen untereinander und im Austausch mit humanen Entitäten zu tun, sodass Algorithmen in der einschlägigen Diskussion zunehmend „Handlungsträgerschaft“ (Latour) zugebilligt wird.

spiel eines Forschungsprojekts namens KISOFT vorgestellt, das sich der Unterstützung der Dokumentarischen Methode durch künstliche Intelligenz widmet (3).

## 1 Algorithmen oder: „Rechenvorschriften“, die ‚Interpretieren‘ ‚lernen‘

In der informatischen Literatur werden Algorithmen ganz prosaisch als „wohldefinierte Rechenvorschriften“ für endliche Rechenoperationen beschrieben, die „eine Eingabe“ in eine „Ausgabe umwandeln“ (Cormen et al. 2013, S. 5). Turing (1936) hat dies in den Bedingungen für eine „Turingmaschine“ konkretisiert. Für unsere Zwecke reicht folgende, bei Wikipedia zu findende Beschreibung der Eigenschaften eines Algorithmus aus<sup>5</sup>:

***Eindeutigkeit:** ein Algorithmus darf nicht widersprüchlich, sondern muss eindeutig beschrieben werden; **Ausführbarkeit:** jeder Einzelschritt muss ausführbar sein; **Finitheit:** die Beschreibung des Algorithmus muss endlich sein; **Terminierung:** nach endlich vielen Schritten muss der Algorithmus enden und ein Ergebnis liefern; **Determiniertheit:** Er muss bei gleichen Voraussetzungen stets das gleiche Ergebnis liefern; **Determinismus:** zu jedem Zeitpunkt der Ausführung besteht höchstens eine Möglichkeit der Fortsetzung. Der Folgeschritt ist also eindeutig bestimmt.*

Nicht nur technische Geräte, wie Automotoren, Heizungsanlagen etc. unterliegen in diesem Sinne einer algorithmischen Gesetzmäßigkeit. Auch Kochrezepte, Trainingspläne o.ä. können als Beispiele für Algorithmen herangezogen werden. Sie stellen allerdings Grenzfälle dar, da hier Abweichungen vom Plan (der ‚Eingabe‘) möglich sind, ohne dass z.B. das Rezept (die ‚Ausgabe‘) gleich ganz misslingen muss. Das Interesse der Sozial- und Geisteswissenschaften an Algorithmen richtet sich aber weder auf Automotoren noch auf Kochrezepte. Was die „Software Studies“ (z.B. Manovich 2013), die „Critical Algorithm Studies“ (z.B. Gillespie 2014) oder die „Critical Code Studies“ (z.B. Kitchin/Dodge 2011) an Codes, Protokollen und Algorithmen fasziniert, ist die „social power of algorithms“ (Beer 2017), also die Verwobenheit und Rückgekoppeltheit von Algorithmen untereinander und mit ihren kulturellen und sozialen Umwelten. Die empirisch schwer fassbaren „Algorithmenkulturen“ (Seyfert/Roberge 2017) entfalten in der Perspektive der angegebenen Disziplinen ihre Wirkungen eher unterhalb von Wahrnehmungsschwellen (vgl. zu den „schweigenden“ Dimensionen von Algorithmen Schäffer 2017).<sup>6</sup>

Vor diesem allgemeinen Hintergrund werden den datenbanksteuernden bzw. auf Datenbanken zugreifenden Algorithmen Eigenschaften zugeschrieben, die bis vor Kurzem noch dem Humanen vorbehalten waren, wie z.B. das Lehren (vgl. Klinge 2020). Ihnen wird als „Aktanten“ (Latour 1998) Handlungsträgerschaft zugebilligt, bzw. wird zumindest betont, dass in Handlungssituationen die Grenzen zwischen Menschen und Maschinen in Akteur-Netzwerkskonstellationen nicht mehr so genau zu ziehen seien. Zudem werden Algorithmen mit menschlichen Eigenschaften in Zusammenhang gebracht, allen voran mit der Fähigkeit zu ‚Lernen‘: Bei sog. „Deep Learning“-Anwendungen künstlicher Intelligenz (KI) werden

5 <https://de.wikipedia.org/wiki/Algorithmus>

6 Neben den Algorithmen stehen zudem „Datenbanken als Treiber der Digitalisierung“ (Häußling 2020, S. 137) in den sog. „critical data studies“ im Fokus. „Das Denken in Datenbanken besitzt nach Manovich einen ähnlich revolutionären Charakter wie die Einführung der Zentralperspektive in die Malerei zu Beginn der Renaissance“ (Häußling 2020, S. 137 mit Bezug auf Manovich 2001).

algorithmische Verarbeitungsprozesse aus dem „Machine Learning“ benutzt, die mit sog. „neuronalen Netzen“ arbeiten.<sup>7</sup>

## 1.1 Deep Learning oder: Algorithmen, die ‚lernen‘, Preise vorherzusagen oder Bilder zu erkennen

Worauf es beim Deep Learning ankommt, wird im Folgenden im Anschluss an eine populärwissenschaftliche Erläuterung eines Softwareentwicklers (Raicea 2017) dargelegt: Lernende neuronale Netzwerke bestehen nach Raicea, vereinfacht gesagt, aus drei Schichten (Layers), von denen zwei sichtbar sind, nämlich die Eingangsschicht (Input Layer) und die Ausgangsschicht (Output Layer). Dazwischen sind je nach Konstruktion unterschiedlich viele verdeckte Schichten (Hidden Layers), die die Eingangsinformationen zu einem Output verarbeiten (vgl. Abb. 1).

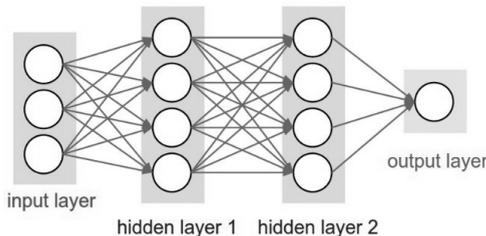


Abb. 1 Hidden Layers. Quelle: <https://cs231n.github.io/neural-networks-1/>

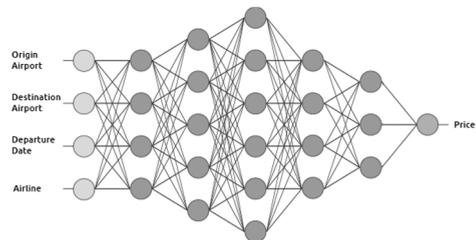


Abb. 2: Preisberechnung mit Deep Learning nach Raica 2017

Die Idee beim Deep Learning ist nun, dass man ein solches Layerkonstrukt mit großen Datensätzen ‚trainieren‘ kann, um Problemstellungen zu bearbeiten. Raicea veranschaulicht dies am Beispiel eines Programms für die Preisvorhersage für einen Flug auf der Basis der Informationen Abflugs- und Zielflughafen, Abflugdatum und Fluggesellschaft (vgl. Abb. 2): Man gibt der Maschine zunächst vier beliebige Eingangswerte ein (z.B. Hamburg nach Berlin, 18.00 Uhr, Lufthansa) und lässt sie auf dieser Basis einen Preis auswerfen. Jede Verbindung zwischen den Neuronen (Kreisen in der Grafik) ist mit einem Gewicht assoziiert, das die Eigenschaften dieses Neurons beschreibt, z.B., ob, mit welcher Intensität und wohin es eine Information weiterleitet oder auch nicht. Dies beeinflusst dann die weitere Verarbeitung in der nächsten, komplexeren Schicht. Im Beispiel werden im Laufe der wiederholten Durchgänge vermutlich die ‚Abflugzeitneuronen‘ generell ‚schwerer‘ gewichtet, weil sie stärker den Preis beeinflussen, als die beiden ‚Airportneuronen‘, die mit der Zeit entsprechend ‚leichter‘ gewertet werden. Dieser Prozess wird milliardenfach wiederholt und das Programm kommt dem Ergebnis so immer näher, ‚lernt‘ also den Preis vorherzusagen auf der Basis früherer Inputs (also Abflugzeiten usw.) und Outputs (Preisen).

Dieses ‚Lernen in Schichten‘ kommt auch bei der maschinellen Bilderkennung zum Einsatz. Tsoutis (2019) hat dies in Bezug auf „Merkmalshierarchien“ bei Deep-Learning-Architekturen visuell gut auf den Punkt gebracht (Abb. 3): Zunächst werden einfache Merkmale eines Bildes wie Punkte und Striche erkannt, auf der nächsten Ebene schon Formen und schließlich Gesichter. Jede Ebene ist komplexer und baut auf der vorherigen auf: „Die Faust-

<sup>7</sup> Auch hier haben wir es mit der Gehirnmetaphorik mit einem anthropomorphen Bezug zu tun.

regel lautet: je tiefer eine Schicht im Deep Learning Netzwerk liegt, desto komplexer werden die Merkmale, die jeder einzelne Knotenpunkt dieser Schicht erkennt“ (Tsoutis 2019).

Grundsätzlich wird bei allen Deep Learning-Modellen zwischen „überwachtem“ und „unüberwachtem“ Lernen unterschieden (Jannidis/Kohle/Rehbein 2017, S. 289). Beim überwachten Lernen ist es „Aufgabe des Computers, aus einer Reihe von Beispielen einen Zusammenhang zwischen den Eigenschaften der Beispiele und den Klassen, denen die Beispiele zugehörig sind, zu erkennen“ (ebd). Die Flugpreisermittlung ist hierfür ein idealtypisches Beispiel, da die Klassen (Flughäfen, Preise etc.) schon vorher feststehen. Beim unüberwachten Lernen dagegen ›lernt‹ der Computer, „Gruppen ähnlicher Gegenstände (sogenannte Cluster) zu bilden und voneinander zu unterscheiden (z.B. Gesichter, BS), ohne diese Cluster aber mit vorgegebenen Klassenlabels zu versehen“ (ebd., S. 290). Einfach gesprochen: Es werden hier Unmengen von Daten auf Korrelationen von zuvor nicht festgelegten Dimensionen hin durchsucht und: Diese Korrelationen sind nicht linear ‚verdrahtet‘, sondern in rekursiven Rückkopplungsschleifen und insofern zirkulär miteinander verbunden.

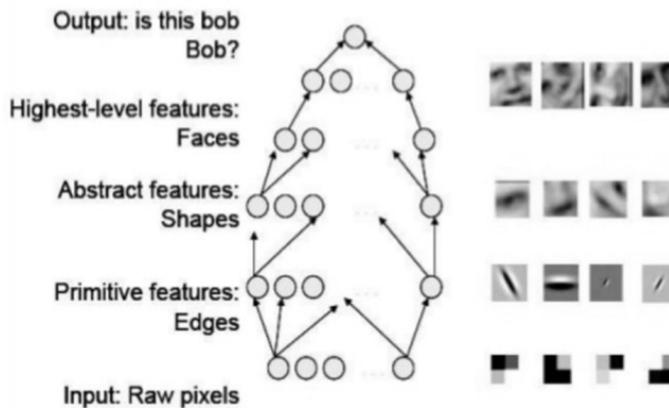


Abb. 3: Die Merkmalshierarchie (engl. feature hierarchy) vereinfacht dargestellt: Quelle: Mirza/Malik/Syed 2018 zitiert nach Tsoutis 2019

Wie genau diese Prozesse im Inneren der Deep-Learning-Architekturen vonstattengehen, wie sich also die Layers der Programme in diesem rekursiven Prozess auf- und miteinander einjustieren, kann auch von den Informatiker\*innen nicht vorhergesagt und wohl nur schwer rekonstruiert werden, da die Komplexität der Rückkoppelungseffekte zwischen den verschiedenen Schichten so hoch ist, dass zwar *prinzipiell* jeder nächste Schritt berechenbar wäre, da ja jedes einzelne ‚Neuron für sich‘ einen Algorithmus darstellt, der sich nach den eingangs beschriebenen Gesetzmäßigkeiten (also deterministisch) ‚verhält‘. Gleichwohl gelangt man hier durch die schiere Zahl der Rechenschritte an „Grenzen der Berechenbarkeit“ (Mainzer 2014), die an anderer Stelle mit dem „Schmetterlingseffekt“ (Lorenz 1972) beschrieben werden: Ganz kleine Änderungen der Ausgangsbedingungen (bei der Wettervorhersage ein Schmetterlingsflügel Schlag in Brasilien) können am Ende sehr große Auswirkungen zeitigen (die Bildung eines Tornados in Texas), die nicht vorhergesagt werden können.<sup>8</sup>

8 Mainzer fasst dies unter der Überschrift „deterministisches Chaos“ (2014, S. 127ff., insbesondere 132ff.) zusammen: „Im deterministischen Chaos ist die Dynamik durch ein nichtlineares Wachstumsgesetz vollständig determiniert. Allerdings sind langfristige Wirkungen praktisch nicht vorausberechenbar, da der Rechenaufwand wegen der empfindlichen Abhängigkeit von den Anfangsdaten exponentiell wächst“ (ebd., S. 135).

Beim Flughafenbeispiel und auch beim Bilderkennungsbeispiel haben wir es durchaus mit einem rudimentären Prozess der ‚Interpretation‘ zu tun: Auf Basis einer überschaubaren Menge an Parametern und auf der Basis von Training mit Realdaten sagt das Programm den Preis voraus bzw. ‚erkennt‘ ein Gesicht, es ‚interpretiert‘ also empirische Daten. Allerdings sind hier die Trainingsbedingungen recht übersichtlich und vor allem: Gerade beim Flughafenbeispiel handelt es sich mehr um ein ‚Rechnen‘, als um ein ‚Interpretieren‘ im engeren Sinne, da die Ausgangswerte ja eindeutig als numerische Werte vorliegen.<sup>9</sup> Bei der Bilderkennung ist das schon anders und bei Sprache stellen sich nochmals ganz andere Probleme dar, wie im Folgenden gezeigt wird.

## 1.2 Natural Language Understanding mit General pretrained Transformern (GPTs)

In den „Digital Humanities“ (vgl. Jannidis/Kohle/Rehbein 2017) und der Korpuslinguistik (Hirschmann 2019) werden statistische Textauswertungen schon länger z.B. zur Vorsortierung relevanter Stellen oder zur Suche und Markierung ähnlicher Passagen in großen Textkorpora bzw. zur Suche nach der Benutzung bestimmter Begriffe oder Begriffskombinationen in bestimmten Wortumfeldern etc. genutzt. Auch in den Sozialwissenschaften halten Methoden des machine learning zunehmend Einzug. So machen Edelmann et al. (2020) in einem Review über „Computational Social Sciences and Sociology“ auf die breite Anwendung dieser neuen Zugänge für viele Bereiche der Soziologie aufmerksam.<sup>10</sup>

Bei der Verarbeitung natürlicher Sprache im Modus unüberwachten Lernens kommen „Natural Language Processing“ (NLP)-Modelle ins Spiel, die sich ein „Natural Language Understanding“ (NLU) zum Ziel gesetzt haben. In jüngster Zeit machen hier sog. „Generative Pretrained Transformer“ (GPTs) große Fortschritte. Dies sind Programme, die auf Basis von sehr großen Datensätzen vortrainiert sind und relativ aufgabenunabhängig mit Texten umgehen können. Sie sind insofern eine Weiterentwicklung der eingangs vorgestellten KIs: „Vor GPT wurden die meisten NLP-Modelle mittels überwachtem Lernen speziell für eine bestimmte Aufgabe geschult, etwa um Stimmungen (positiv, neutral, negativ...) in einem Text zu erkennen. Dazu mussten vorab große Datenmengen manuell durch den Menschen definiert werden, zum Beispiel durch die händische Bezeichnung der Stimmung von Texten“ (Nord 2021). Die GPT-Modelle dagegen brauchen diesen menschlichen Zwischenschritt nicht mehr. Sie tun dies eigenständig auf der Basis eines Grundtrainings mit großen Sprachdatenbanken und können dann je nach Modelltyp (GPT1, GPT2, GPT3 usw.) auf immer größere Mengen an Information zurückgreifen.<sup>11</sup> Das derzeitige GPT-3-Modell greift z.B. neben verschiedenen Datenbanken auch auf Wikipedia zu und meistert „Aufgaben wie das Schreiben von Artikeln, die schwer von menschengemachten Texten zu unterscheiden“ sind (ebd.). In Brown et al. (2020) werden die Fähigkeiten von GPT3 in Abhängigkeit davon beschrie-

---

9 Die Zeiten, codierte Nummern von Flughäfen und Fluggesellschaften und Preise verfügen zwar über ein unterschiedliches Skalenniveau, sind aber problemlos aufeinander zu beziehen.

10 Im Abstract zum Artikel zählen die Autoren auf: „(a) social network analysis and group formation; (b) collective behavior and political sociology; (c) the sociology of knowledge; (d) cultural sociology, social psychology, and emotions; (e) the production of culture; (f) economic sociology and organizations; and (g) demography and population studies.“ <https://www.annualreviews.org/doi/full/10.1146/annurev-soc-121919-054621#article-denial> (12. April 2021).

11 „In recent years the capacity of transformer language models has increased substantially, from 100 million parameters [...], to 300 million parameters [...], to 1.5 billion parameters [...], to 8 billion parameters [...], 11 billion parameters [...], and finally 17 billion parameters [...] (Brown et al. 2020, S. 4).

ben, wie viele Lösungsbeispiele man dem Programm überhaupt noch geben muss, damit es eine Aufgabe erfüllen kann: gar kein Beispiel, ein Beispiel oder ein paar Beispiele? Ein zentrales Ergebnis ist Folgendes: Je größer die Anzahl der Parameter aus den zuvor eingespeisten Datenbanken ist, auf die das Programm zurückgreifen kann, desto besser kann es seine Aufgabe auch ohne jede Anweisung erfüllen. Man kann ihm eine Frage oder eine Aufgabe stellen und es beantwortet oder erledigt sie eigenständig. Die schiere Quantität der Parameter entscheidet hier über die Qualität der Ergebnisse – ein m.E. durchaus beunruhigender Gedanke für qualitativ Sozialforschende, die – wie alle Menschen – nur über eine begrenzte Fähigkeit verfügen, Informationen zu sichten und zu verarbeiten. Wenn nun ein Programm quasi mühelos z.B. 1000 Interviews auf der Basis von Milliarden von Parametern miteinander nach von ihm selbst entwickelten Kriterien vergleicht, liegt die Beunruhigung u.a. darin, dass der Mensch sich nicht sicher sein kann, ob er in seiner Auswahl von Interviews etwas Entscheidendes übersehen haben könnte.

Die Rückkoppelungen zwischen solch automatisierten, Sprache mehr und mehr ‚verstehenden‘ algorithmischen KI-Systemen ist für den oben beschriebenen sozialwissenschaftlichen und philosophischen Algorithmen Diskurs zentral. Angesichts von Systemen, die selbst Geschichten erfinden können, erscheint die Rede von der ‚fraktalen Handlungsträgerschaft‘ der Algorithmen (Seyfert/Roberge 2017, S. 10) mehr und mehr plausibel, da sich an diesem Beispiel zeigt, dass das (hier: sprachliche) ‚Handeln‘ der Algorithmen immer schwerer von menschlichem Handeln zu unterscheiden ist, bzw. genauer: weil das ‚Zusammenhandeln‘ von Menschen mit Algorithmen im Sinne Latours immer schwerer eindeutig auf menschliche oder nichtmenschliche Handlungsträgerschaften reduzierbar ist. Dies ist mit dem Begriff der ‚Algorithmenkultur‘ (Seyfert/Roberge 2017) m.E. zutreffend verdichtet. Im Folgenden wird vor dem Hintergrund der bislang entfalteten Begrifflichkeit der Interpretationsprozess qualitativ-rekonstruktiv Forschender im Hinblick auf ihm innewohnende ‚Algorithmen‘ bzw. heuristische Verfahrenslogiken untersucht.

## 2 Rekonstruktiv-sequenzielle Verfahren als heuristische Verfahrenslogiken im praxeologischen Sinn

Der ursprüngliche Titel dieses Beitrags war mit ‚Zum Algorithmus der Dokumentarischen Methode‘ überschrieben. Nach einigen Rückmeldungen erscheint mir der Begriff einer ‚heuristischen Verfahrenslogik im praxeologischen Sinn‘ jedoch passender, da die Unterschiede mathematisch definierter Algorithmen zu dem, was Menschen beim Interpretationsprozess tun, doch zu groß sind. Der Zusatz ‚im praxeologischen Sinn‘ ist deshalb wichtig, weil es sich oft um Logiken der Interpretationspraxis im Bourdieuschen Sinne handelt, also solche, die implizit beim Interpretieren Anwendung finden, ohne dass die Interpretierenden hierüber bei jedem Schritt explizit Rechenschaft ablegen. Im Gegensatz zu den mathematisch präzisen Turing-Algorithmen (‚TAs‘), wie sie in Kap. 1 beschrieben wurden, sind heuristische Verfahrenslogiken (‚HVs‘) im praxeologischen Sinn, wie sie bei rekonstruktiv-sequenziellen Verfahren zum Einsatz kommen, nämlich nicht ein-, sondern vieldeutig, ja manchmal sogar widersprüchlich. Ihre Ausführbarkeit ist prinzipiell gegeben, aber ob es sinnvoll ist, entscheidet der\*die Interpretierende. Das Prozedere ist prinzipiell nie abgeschlossen (nonfinit), es wird irgendwann angehalten, weil die Interpretin oder der Interpret keine Zeit mehr haben, weiter zu interpretieren oder ihnen nichts mehr einfällt. Zudem ist der Interpretationsprozess zirkulär angelegt: Ergebnisse einer Interpretation verändern den Kontext für eine vorherge-

hende Interpretation, die wiederum die erste konstituiert. Er ist nicht determiniert und seine Anschlüsse sind folgerichtig auch nicht eindeutig bestimmbar (vgl. Tabelle 1).

<b>Turing-Algorithmus (TA)</b>	<b>Heuristische Verfahrenslögelik (HV)</b>
<i>Eindeutigkeit:</i> Es darf keine widersprüchliche Beschreibung vorliegen. Diese muss eindeutig sein.	<i>Vieldeutigkeit:</i> Sie kann widersprüchliche Dimensionen haben, muss also nicht eindeutig sein.
<i>Ausführbarkeit:</i> Jeder Einzelschritt muss ausführbar sein.	<i>Ausführbarkeit:</i> Jeder Einzelschritt ist prinzipiell ausführbar. Über die Sinnhaftigkeit entscheidet der*die Interpretierende*r.
<i>Fintheit:</i> Die Beschreibung des Algorithmus muss endlich sein.	<i>Non-Finitheit und Zirkularität:</i> Die Beschreibung heuristischer Verfahrenslögeliken ist prinzipiell nie abgeschlossen.
<i>Terminierung:</i> Nach endlich vielen Schritten muss der Algorithmus enden und ein Ergebnis liefern.	<i>Terminierung:</i> Nach endlich vielen Schritten muss die Verfahrenslögelik vom Interpretierenden angehalten und ein Zwischenergebnis geliefert werden.
<i>Determiniertheit:</i> Der Algorithmus muss bei gleichen Voraussetzungen stets das gleiche Ergebnis liefern.	<i>Non-Determiniertheit:</i> Hier gibt es keine gleichen Voraussetzungen, folglich auch keine gleichen Ergebnisse.
<i>Determinismus:</i> Zu jedem Zeitpunkt der Ausführung besteht höchstens eine Möglichkeit der Fortsetzung. Der Folgeschritt ist also eindeutig bestimmt	<i>Non-Determinismus:</i> Zu jedem Zeitpunkt der Ausführung bestehen vielfältige Möglichkeiten von Anschlüssen. Der Folgeschritt ist also nicht eindeutig bestimmt.

Tabelle 1: Vergleich mathematischer Algorithmus und heuristische Verfahrenslögelik

Von einem Algorithmus im engeren Sinne lässt sich dann nicht mehr sprechen, weshalb der Begriff heuristische Verfahrenslögelik im praxeologischen Sinn angemessener ist. Zwar sind im Rahmen der verschiedenen qualitativen Methodologien Regeln und Regelmäßigkeiten zu verzeichnen, die z.T. durchaus algorithmische Qualitäten besitzen, aber der Begriff der Verfahrenslögelik markiert die Differenz besser. Allerdings gibt es eine Parallele zu den oben besprochenen algorithmischen Deep-Learning-Architekturen: Auch Methodologien verfügen über ihre ‚Hidden Layers‘, die analog zum Berechenbarkeitsproblem von Deep-Learning-Verfahren Reste des Unerklärlichen aufweisen. Die ‚Hidden Layers‘ qualitativ-rekonstruktiver Forschung werden in den verschiedenen methodologischen Sprachspielen jedoch anders bezeichnet: so etwa mit dem Begriff der „Abduktion“ (vgl. hierzu Reichertz 2013, siehe auch Schäffer 2020, S. 72 ff.) oder dem Begriff der „Intuition“ (Gigerenzer 2008) – aber zurück zur Frage, ob sich qualitative Methodologien als heuristische Verfahrenslögeliken darstellen lassen. Ein Blick auf den Ablaufprozess der Dokumentarischen Methode mag dies veranschaulichen.

## 2.1 Zur heuristischen Verfahrenslögelik der Dokumentarischen Methode

Die Dokumentarische Methode (Bohnsack 2021) lässt sich mittlerweile als ein Prozess beschreiben, der schon ein recht hohes Maß an verfahrenslögelischer Standardisierung erreicht hat: Zunächst wird das interessierende Geschehen einer Handlungspraxis auf irgendeine Art einem Prozess der Transformation in Schrift, meistens durch Transkription unterzogen, so dass am Ende ein schriftliches Urdokument entsteht, auf das man sich als Datenbasis beziehen kann. Dieser Schritt der Transformation in Schriftlichkeit auf der Basis von Transkriptionsregeln, wie z.B. TiQ („Talk in Qualitativ Social Research“, vgl. Przyborski/Wohlrab-Sah 2014; grundlegend: Dittmar 2009), kann noch am ehesten als ‚echter‘ Algorithmus rekonstruiert werden, da hier die eindeutigsten Verfahrensvorschriften in Form von Transkripti-

onsregeln vorliegen. Die Transkription ist beides: erkenntniskonstituierend, aber auch begrenzend. Denn aus praxeologischer Sicht ist die Welt nicht ‚Text‘ (zu dieser These: Kraimer/Garz 1994), sondern ‚Praxis‘, was weit über einen engen Textbegriff hinausgeht; dennoch ist die primäre Bezugnahme der Methodologie fokussiert auf einen sehr engen Textbegriff. Was dem Flughafenalgorithmus also die Zahlenwerte, ist der heuristischen Verfahrenslogik der Dokumentarischen Methode – und wie wir sehen werden allen anderen rekonstruktiven Methodologien Tiefer Interpretation auch – die Verfasstheit in Schriftlichkeit in einen recht strengen Format, weshalb man durchaus von einem „Paradigma des Transkripts mit Zeilennummern“ (Schäffer 2022a) sprechen kann.<sup>12</sup>

Im weiteren Verlauf des Interpretationsprozesses der Dokumentarischen Methode wird die Zeichenfolge des Transkripts dann der „Formulierenden“, „Reflektierenden“ (Bohnsack 2021, S. 138ff.) und schließlich der „Typenbildenden Interpretation“ (Schäffer 2020, S. 71ff.) unterzogen. Die Parallele zu den Layer-Architekturen beim Deep Learning fällt schon hier ins Auge: Jeder Interpretationsschritt ‚approximiert‘ die vorhergehenden Schritte, ist also auf einem ‚höheren‘ Level der Komplexität angesiedelt.

Die Dokumentarische Methode hat insofern, wie andere anspruchsvolle Methodologien auch, eine ganz eigene heuristische Verfahrenslogik, ein typisches Ablaufschema des Interpretierens entwickelt. Im Zuge der Entwicklung der Software DokuMet QDA haben wir versucht, uns die einzelnen Unterschritte zu vergegenwärtigen. In Abb. 4 ist das Prozedere der zentralen Verfahrenslogik der Dokumentarischen Methode, am Beispiel der Reflektierenden Interpretation einer Gruppendiskussion in einem Ablaufdiagramm dargestellt (vgl. Schäffer/Klinge/Krämer 2020, S. 170f.).

Auf der linken Seite ist das sequenzielle Gebot bei der reflektierenden Interpretation einer Gruppendiskussion rekonstruiert: Man wählt eine Passage (PAS1) aus, beginnt mit der Interpretation einer Äußerung (RI), rekonstruiert ihren Sinn für sich und mit Bezug auf Vorgänger- und Anschlussabschnitt, erarbeitet, falls interpretierbar sinn- und soziogenetische Aspekte für die „typenbildende Interpretation“ (Schäffer 2020) heraus und wiederholt das Ganze so lange, bis man am Ende der ausgewählten Passage angelangt ist. Dann fokussiert man auf den Orientierungsrahmen, indem man nach internen und externen Vergleichshorizonten sucht und weitere sinn- bzw. soziogenetische Dimensionen rekonstruiert, die man ebenfalls in Aspekten darlegt. Wie weit man auf die Vergleichshorizonte ganz rechts zurückgreifen kann (also auf andere Passagen, andere Interpretationen oder gar andere Typenbildungen) hängt vom Fortschritt des Gesamtprojekts ab: Zu Beginn spielt sich viel auf der linken Seite ab, später, wenn man in der Phase der Typenbildung angelangt ist, mehr auf der rechten. Allerdings zeigt die Erfahrung, – und hier ist einer der ‚Hidden Layer‘ der Dokumentarischen Methode verborgen – dass bereits während der ersten Phase Abduktionen auftauchen, d.h. plötzliche Erkenntnisse, die weit über den gerade interpretierten Abschnitt hinausweisen. Dies erzwingt Sprünge zwischen den Ablaufschemata: Wenn man z.B. eine Idee für eine Typenhypothese hat, sollte man sie aufschreiben und später gezielt weiterverarbeiten können und nicht sklavisch die Passage bis zum Ende durchinterpretieren, auf die Gefahr hin, dass die „Sparks“ (Anselm Strauss) oder Abduktionen (Peirce) verloren gehen. Dies ist

12 Die Bezugnahme auf diese Texte als ‚empirisch‘ im Sinne von *empeiria* (Erfahrung/Erfahrungswissen) ist vor dem Hintergrund der weitreichenden Entkontextualisierung durch die Transkription sowie durch die weiteren Verarbeitungsschritte problematisch. Es ist eben gerade keine ‚Erfahrung‘ oder ‚Erfahrungswissen‘, sondern ‚nur‘ die schriftliche Information über Erfahrungsrekonstruktionen, mit der sich die Methodologien der Dokumentarischen Methode, des Narrationsstrukturellen Verfahrens, aber auch die der Objektiven Hermeneutik oder der Grounded Theory beschäftigen. Im Übrigen hat schon Platon im Phaidros dieser Form schriftlicher Information eine gehörige Portion von Skepsis entgegenbracht, weil sie nicht antworten könne, wenn man sie etwas frage (dass er das in Schriftform getan hat, gehört dann zu den Pointen Platonischen Denkens).

mit den reversiblen Abduktionspfeilen in der Grafik gemeint. Zudem ist zu betonen, dass die Grafik eine zu starke Linearität des Forschungsprozesses suggeriert, was schlicht der Darstellung geschuldet ist.

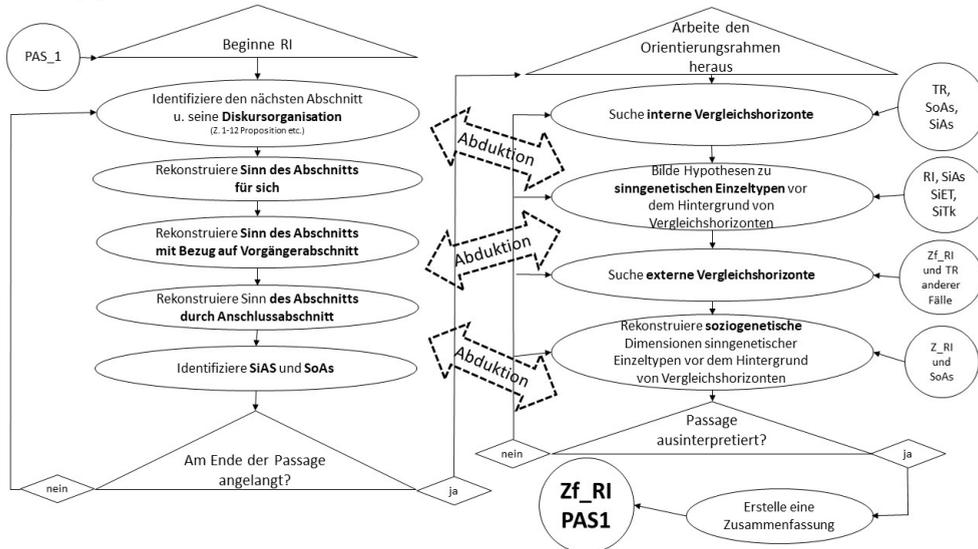


Abb. 4: Detail Reflektierende Interpretation bei Dokumentarischer Methode, vgl. Schäffer et al. 2020, S. 171

Vielmehr ist der Forschungsprozess der Dokumentarischen Methode grundlegend zirkulär angelegt, durchaus im Sinne des hermeneutischen Zirkels, wobei Abduktionen den Zirkel bzw. die Spirale am Laufen halten (vgl. hierzu auch: Bohnsack 2017, S. 77f.; Schäffer 2020, S. 72ff.).

## 2.2 Ein allgemeines Modell der Beschreibung von Verfahren ‚Tiefer Interpretation‘

Man kann solche Ablaufschemata mit all ihren Einschränkungen, was Abkürzungen/Umwege/unorthodoxe Verwendungen etc. anbelangt, m.E. auch für andere Methodologien aufzeigen. Sie stellen alle Modi des Interpretierens dar, auf die ich in Anlehnung an Deep-Learning-Modelle als ‚Tiefe Interpretation‘ Bezug nehmen möchte. Heuristischen Verfahrenslogiken unterschiedlicher qualitativer Zugänge sind insofern mehr oder weniger tiefe, zwingend sequenzielle Verfahrensschritte inhärent (wie die eben aufgezeigten). Während inhaltsanalytische Verfahren recht schnell Textstellen unter Codes subsumieren und insofern nicht die Tiefe sequenzanalytischer Verfahren erreichen, gehören Methodologien wie z.B. die Grounded Theory (Strübing 2014), das Narrationsstrukturelle Verfahren (Schütze 2016), die Objektive Hermeneutik (Wernet 2021) und auch die Dokumentarische Methode (Bohnsack 2021) zu den heuristischen Verfahrenslogiken, mit denen sich Verfahrensschritte ‚Tiefer Interpretation‘ betreiben lassen.

Im Folgenden möchte ich ein allgemeines Beschreibungsmodell von Interpretationsprozessen vorschlagen, das es ermöglicht, verschiedene Verfahren Tiefer Interpretation miteinander zu vergleichen. Hier ist m.E. die Idee geschichteter Erkenntnisprozesse der Deep-Learning-Modelle (vgl. Kap. 1.1) zentral: Man kann jede Methodologie und ihre daraus resultierenden Interpretationsschritte formal in folgendem Dreiebenenmodell beschreiben: Es gibt einen Input – eine Transkription, ein Bild, ein Video, eine Beobachtung oder ein Dokument – gefolgt von einem unterschiedlich komplexen Verarbeitungsprozedere, in das die verschiedenen grundlagentheoretischen und methodologischen Steuerungsaspekte hineinspielen. Als Output bekommen wir dann eine Fallrekonstruktion, eine Typologie, ein theoretisches Modell etc. (vgl. Abb. 5).

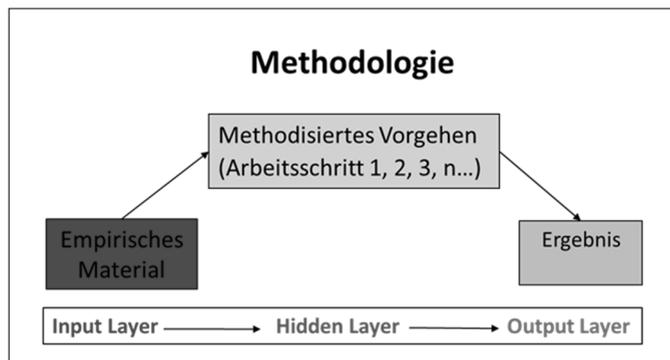


Abb. 5: Allgemeines Modell von Verfahren Tiefer Interpretation (in Anlehnung an Abb. 1)

Die Parallele zum Deep Learning liegt hier m.E. auf der Hand: Viele der Verfahrensschritte sind für eine\*n Endbenutzer\*in genauso wenig durchschaubar, wie die sich selbst organisierenden neuronalen Netze für die Informatiker\*innen. Begriffe wie „Abduktion“ von Charles Sanders Peirce (Peirce 1979, § 5.1899) oder „Sparks“ bei Anselm Strauss müssen dann dafür herhalten, das kreative Moment qualitativ-rekonstruktiver Forschung irgendwie fassbar zu machen.

Wendet man das Modell von Input Layer, Hidden Layer und Output Layer auf die Grounded Theory, die Narrationsanalyse, die Objektive Hermeneutik und die Dokumentarische Methode an, gelangt man zu folgenden Darstellungen (vgl. Abb. 6–9):

In veröffentlichten Fallrekonstruktionen, und hier zeigt sich die Parallele zu den Deep-Learning-Anwendungen am deutlichsten, bekommt man meistens nur ausschnittsweise den gesamten Prozess zu Gesicht und muss den Ergebnissen vertrauen. Überwiegend sind einzelne Interpretationsschritte exemplarisch, oft nur ausschnitthaft im Anhang der Studien aufgeführt. Neben der Ausschnitthaftigkeit kommt hier noch das Problem hinzu, dass solche Darstellungen immer auf der Darstellung „gegenwärtiger Vergangenheiten“ beruhen, d.h. Vergangenheiten von Arbeitsschritten, bei denen man bei der sog. „Rekonstruktion“ schon wusste, in welche Richtung es mit der Interpretation später weiterging (vgl. Schäffer 2020, S. 81). Das Problem bei allen qualitativen Methodologien ist also die Schicht in der Mitte, der Hidden Layer, der mal mehr mal weniger stark (oder auch gar nicht) expliziert wird.

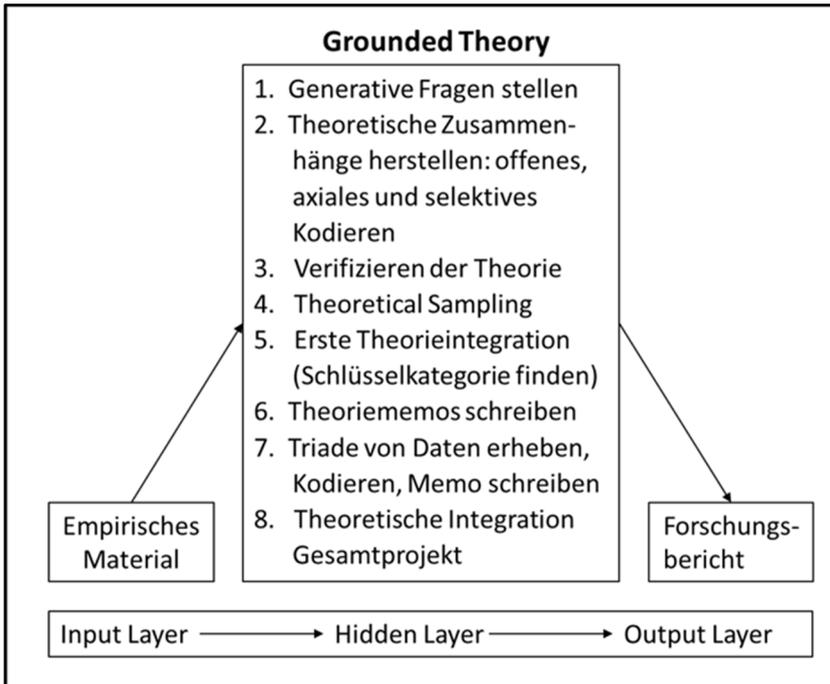


Abb. 6: Grounded Theory (vgl. Strauss 1991; Strübing 2014)

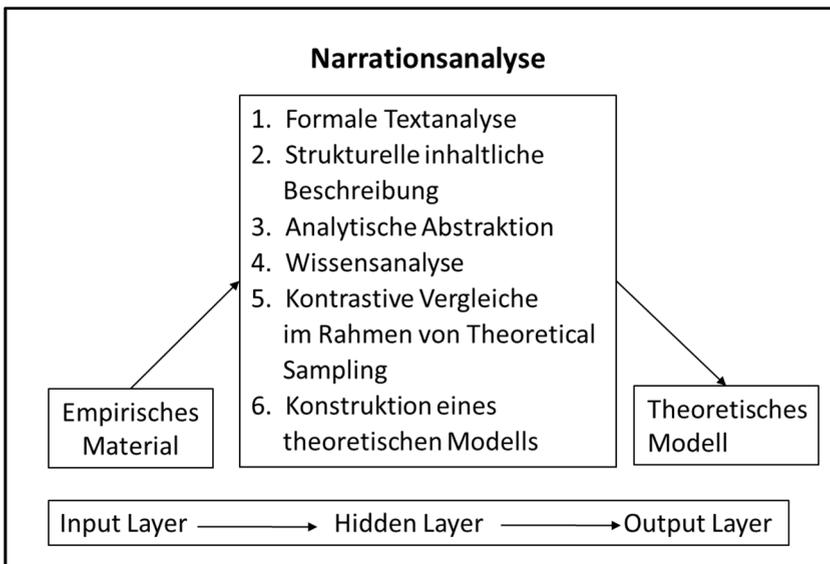


Abb. 7: Narrationsanalyse nach Fritz Schütze (2016)

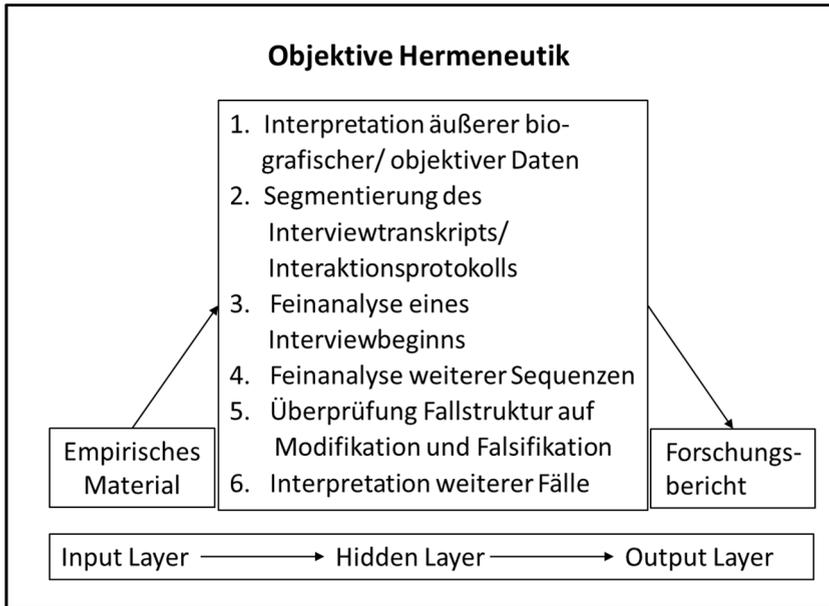


Abb. 8: Objektive Hermeneutik nach Ulrich Oevermann (Wernet 2021)

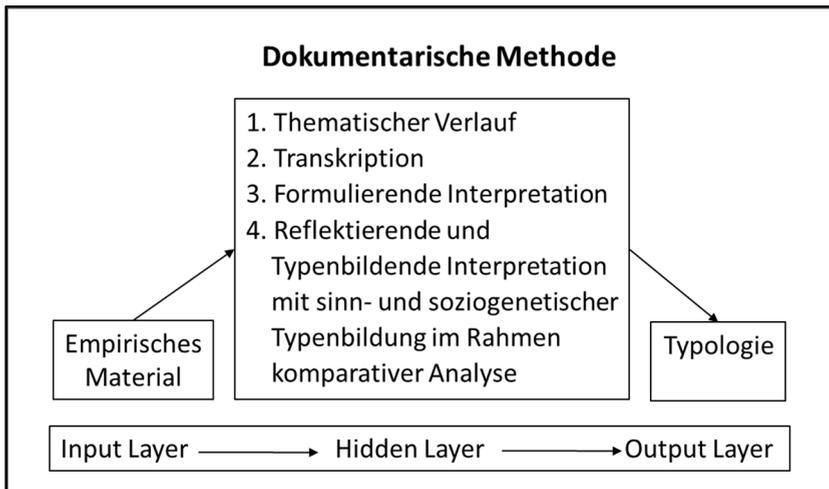


Abb. 9: Dokumentarische Methode nach Ralf Bohnsack (2021) mit Ergänzung zu typenbildender Interpretation nach Schäffer (2020)

Der Ort, an dem die *Hidden Layer qualitativ-rekonstruktiver Sozialforschung* vielleicht noch am klarsten zu rekonstruieren wären, sind die Forschungswerkstätten, die in allen vier Methodologien eine wichtige Rolle einnehmen (vgl. Riemann 2018; Franz 2020; Schäffer 2010; Schäffer/Klinge/Krämer 2020, S. 164f.) und bei der wissenschaftlichen Sozialisation von „Interpretationseinstellungen,-Orientierungen und -Haltungen“ eine wichtige Rolle einnehmen (vgl. hierzu: Schäffer 2022b). ‚Qualitative Hidden Layers‘ der Prozesshaftigkeit qualitativen Forschens können hier in sehr aufwendiger Weise studiert werden. Um Prozesse Tiefer Interpretation auch nur annähernd zu rekonstruieren, müsste insofern eine vergleichende Forschungswerkstattforschung etabliert werden, die die jeweiligen Interpretationsstände im status nascendi, also im aktuellen Prozess der Interpretation rekonstruiert. Franz (2020, S. 273f.) macht hier den m.E. zielführenden Vorschlag, „sachliche“, „soziale“, „zeitliche“ und „räumliche Sinndimensionen“ bei der Arbeit in Forschungswerkstätten bzw. Interpretationsgruppen zu differenzieren. Das hier vorgestellte Modell Tiefer Interpretation würde dies als Metaebene des Vergleichs ermöglichen bzw. ist zumindest eine notwendige Vorbedingung hierfür.

### 3 Möglichkeiten und Grenzen der Optimierung von Verfahren Tiefer Interpretation durch künstliche Intelligenz

Vor dem Hintergrund der Überlegungen zur Konzeption eines Konzepts ‚Tiefer Interpretation‘, das wesentlich auf dem Vergleich des ‚Handelns‘ algorithmischer und menschlicher Akteurskonstellationen beruht – vereinfacht gesprochen: dem Vergleich von Deep-Learning-Architekturen u.a. mit Forschungswerkstattpraxen – möchte ich abschließend noch Möglichkeiten und Grenzen der Optimierung von Verfahren Tiefer Interpretation durch die beschriebenen Deep-Learning-Anwendungen künstlicher Intelligenz diskutieren. Dies werde ich am Beispiel der projektierten Implementierung künstlicher Intelligenz in eine herkömmliche QDA-Software für das Interpretieren mit der Dokumentarischen Methode (hierzu: Schäffer/Klinge/Krämer 2020) bewerkstelligen (3.2). Dem vorangestellt sind noch einige Anmerkungen zur Einordnung dieser neuen Entwicklungen in ein Kontinuum des Einsatzes von Medientechnologien in qualitative Forschung.

#### 3.1 Zum Kontinuum des Einsatzes von Medientechnologien in qualitativer Forschung oder: vom Gänsefederkiel zum Einsatz von KI in QDA Programmen

Vergegenwärtigt man sich die Geschichte qualitativer Forschung, die wesentliche Entwicklungsschübe der Weiterentwicklung von Medientechnologien verdankt, so sind die derzeit erhältlichen QDA-Programme nur eine Fortsetzung einer kontinuierlichen Weiterentwicklung. Ihre Anfangspunkte liegen weit zurück: beim Gänsefederkiel, mit dem Engels (1848) „Die Lage der arbeitenden Klasse in England“ beschrieben hat, den Schreibmaschinen und Kameras der Marienthalstudie (Jahoda/Lazarsfeld/Zeisel 1975), den klobigen Tonbandgeräten der Gruppenexperimentstudie von Pollock (1955) Mitte der 50er Jahre, den Kassettenrecordern in den 70er Jahren, mit dem Fritz Schütze seine Gerichtsstudien betrieben hat

(Schütze 1978), dem Einsatz von Computern ab Mitte der 80er, Anfang der 90er Jahre und schließlich den immer mehr Bereiche des qualitativen Forschungsprozesses umgreifenden Digitalisierungsschüben in den 10er und 20er Jahren in diesem Jahrhundert (genauer hierzu: Schäffer 2022a).

Die beim Forschungsprozess eingesetzten Medientechnologien sind überwiegend „geblackboxt“, um eine Formulierung Latours (1998) aufzugreifen, d.h. sie sind kurz nach ihrer Einführung in den Fundus selbstverständlichen Handlungswissens qualitativer Sozialforschung abgesunken: Dass z.B. die Arbeit auf der Basis von Transkripten mit Zeilennummern erst mit der Entwicklung des Kassettenrecorders seit Ende der 70er Jahre Fahrt aufnahm oder die heute selbstverständliche Suche und Rekombination von Textstellen unter Zuhilfenahme von Computertechnologie in der ‚Schreibmaschinenzeit‘ noch mühsam per Hand durchgeführt werden musste, ist nur noch den Wenigsten präsent. Bei künstlicher Intelligenz ist das derzeit noch nicht der Fall. Ihre Anwendungen werden in der sozial- und geisteswissenschaftlichen Community m.E. mit einer Mischung aus Ausblendung und Befürchtung auf der einen, aber auch mit wachsendem Interesse und Faszination auf der anderen Seite verfolgt (vgl. z.B. im Kontext qualitativer Marktforschung: Kirchmair 2020). Vermutlich wird die Integration von KI in QDA-Programme in ein paar Jahren genauso selbstverständlich sein, wie heutzutage die Anwendung von QDA- oder Schreibprogrammen im Workflow qualitativer Forschender und wird nicht als Zäsur, sondern nur als ein weiterer Schritt in einem Kontinuum der Medientechnikgeschichte qualitativer Forschung wahrgenommen werden. Die folgenden abschließenden Ausführungen zur Kombination von QDA-Software mit KI unterliegen insofern der Gefahr, von zukünftigen Forschenden in ihrer Problemhaftigkeit nicht mehr verstanden zu werden.

### 3.2 Möglichkeiten und Grenzen der Kombination von herkömmlicher QDA-Software mit künstlicher Intelligenz im KISOFT Projekt

In einem gerade begonnenen Projekt namens KISOFT<sup>13</sup> gehen wir der Frage nach, inwiefern die in Kap. 1.2 beschriebenen Deep Learning Algorithmen zum Natural Language Processing (NLP) zur Unterstützung des Interpretationsprozesses bei der Dokumentarischen Methode herangezogen werden können. Das KISOFT Projekt ist ein anwendungsorientiertes Forschungsprojekt, das zum Ziel hat, sog. künstliche Intelligenz in den Forschungsprozess einfließen zu lassen und hierbei die Zusammenarbeit menschlicher und nichtmenschlicher Interpretierender empirisch zu beobachten sowie medien- und erkenntnistheoretisch zu reflektieren.

Die Idee ist, keine eigene KI zu erzeugen, sondern Schnittstellen von DokuMet QDA zu bereits bestehenden Applikationen künstlicher Intelligenz (KI) wie z.B. GPT3 (vgl. Kap. 1.2) zu entwickeln, sodass ein\*e Interpretierende\*e die Möglichkeit hat, über DokuMet QDA eine Anfrage an die KI Anwendung zu stellen. Diese bearbeitet dann die Anfrage, spielt das Ergebnis wieder zu DokuMet zurück, so dass es dem\*der Interpretierenden in entsprechend aufbereiteter Form (in einem ‚Fenster‘ von DokuMet QDA) zur Verfügung gestellt werden kann. Die ‚Anregungen‘ der KI können dann von der\*dem Interpretierenden in einem weiteren wieder händischen und von keinem Algorithmus gesteuertem Arbeitsschritt verarbeitet oder auch verworfen werden.

---

13 <https://dtecbw.de/home/forschung/unibw-m/projekt-kisoft>

An einem Forschungsbeispiel zur Coronapandemie<sup>14</sup> soll dies kurz veranschaulicht werden: Der NDR Podcast<sup>15</sup> von Christian Drosten und in jüngster Zeit Sandra Ciesek hat mittlerweile 84 Folgen von jeweils 10 bis 20 Seiten Text, also über 1000 Seiten Interviewmaterial. Der Podcast ist im Coronaprojekt u.a. in der Hinsicht interessant, dass hier neue Formen der Vermittlung coronarelevanter, wissenschaftlicher Information an die Bevölkerung betrieben werden, die sich mit verschiedenen Modi der 'Erziehung' der Bevölkerung (wie z.B. Reden von Politiker\*innen) ergänzen, z.T. aber auch in die Position von „Ko-Erziehenden“ gelangen (vgl. Klinge/Nohl/Schäffer 2022). In DokuMet QDA lassen sich einzelne Episoden gut sequenziell interpretieren und im „Typengenerator“ der Software verschiedene Verdichtungsschritte des Materials vornehmen (Schäffer 2020; Schäffer et al. 2020), aber den Gesamtkorpus bekommt man natürlich nie ‚durchinterpretiert‘. Im Rahmen der Dokumentarischen Methode kann man höchsten eine Auswahl an „Eckfällen“ selektieren (z.B. den ersten Podcast von Drosten und von Ciesek und weitere, nach inhaltlichen Kriterien ausgesuchte Episoden) und dann interpretieren. Aber wie macht man „Eckfälle“ intersubjektiv überprüfbar fest? Hier kommt die KI ins Spiel: Über DokuMet QDA als Relais, so das Konzept, könnten alle Interviews in ausgewählte Deep-Learning-Anwendungen hochgeladen und die offene Frage gestellt werden: „Finde heraus, ob und wie sich die Antworten von Christian Drosten mit der Zeit verändern“ oder „Finde heraus, ob und wie sich die Antworten von Christian Drosten von denen von Sandra Ciesek unterscheiden“. Das sind klassisch ‚offene‘ Fragen qualitativer Sozialforschung, die es hier dem Programm überlassen, im Modus „unüberwachten Lernens“ (vgl. Kap. 1.1) zu bestimmen, was ‚Veränderung‘ oder ‚Unterscheidung‘ heißen mag. Es ist natürlich auch möglich, stärker eingegrenzte Arbeitsaufgaben an die KI zu schicken: „Finde heraus, ob und wie Drosten Begrifflichkeiten des Lehrens und Lernens in seinen Argumentationen einsetzt“. Die Antwort von der KI wird dann auf der Oberfläche von DokuMet QDA den Interpretierenden zur Verfügung gestellt. Was diese dann mit den Ergebnissen der KI machen, in die die im Sinne Latours (1998, S. 41) „geblackboxten“ Relevanzen des Programms eingeflossen sind, ist eine hochinteressante, nur empirisch zu lösende Fragestellung: Lässt sich das Mensch-Maschine-Maschine-System, also Interpretierende\*r – DokuMet QDA – GPT3 so aufeinander kalibrieren, dass es für Nutzer\*innen von DokuMet QDA einen Mehrwert beim Interpretieren darstellt? Wenn die Maschine die Frage z.B. so beantwortet, dass Drosten seine Antworten ab Folge 17 anders zu formulieren beginnt oder sich die Antworten von Drosten und Ciesek in der und der Hinsicht unterscheiden, hätte man erste Kriterien für die Eckfallauswahl an der Hand. Gleichzeitig muss natürlich in geeigneter, d.h. in intersubjektiv überprüfbarer Weise kontrolliert werden, welche Rolle die Ergebnisse der KI bei der Gesamtinterpretation gespielt haben. Hierin liegt nach meinem Dafürhalten die größte Herausforderung, denn der\*die menschliche Interpretierende kann vor dem Hintergrund der in Kap. 1.1 dargestellten Grenzen der Berechenbarkeit bei Deep-Learning-Anwendungen prinzipiell nicht nachvollziehen, wie die KI zu ihren Ergebnissen gelangt ist, homolog zu den Grenzen der Nachvollziehbarkeit menschlicher Interpretationsprozesse im Kontext von Forschungswerkstätten und erst recht beim „einsamen Schreiben“ des\*der Materialeinbringenden im Anschluss an eine Forschungswerkstattssitzung (hierzu instruktiv: Wernet 2021, S. 143ff.). Bei unreflektierter Übernahme der Vorschläge der KI kann dies zu einer Entfremdung der Rekonstruktionsarbeit im Forschungsprozess führen. Das Entfremdungsargument ist gerade für qualitativ Forschende zentral, weil

---

14 Das Projekt wird von der Volkswagenstiftung unter dem Titel „Between educating and teaching the adult population. Andragogical perspectives on the Corona Pandemic“ gefördert (AZ: 99 317). Für einen ersten Überblick: <https://www.unibw.de/home/news/koennen-erwachsene-zu-richtigem-verhalten-erzogen-werden>

15 <https://www.ndr.de/nachrichten/info/podcast4684.html>

hier alle Befürchtungen quasi gebündelt werden. Zudem kann sich auch ein neuer ‚digital gap‘ öffnen zwischen denjenigen, die über die fortgeschrittene Technologie verfügen und denen, die keinen Zugang zu ihr haben. Allerdings wird die Leistungsfähigkeit von KIs oft auch überschätzt. Die KI ‚wirft‘ ja keine vollständige Interpretation aus, von der „Singularitätsgrenze“ sind wir insofern vermutlich noch weit entfernt. Mit der „technologischen Singularität“ wird der Zeitpunkt bezeichnet, „ab dem Maschinen in der Lage sind, mit Hilfe künstlicher Intelligenz Maschinen zu schaffen, die weit intelligenter sind als der Mensch“ (Misselhorn 2018, S. 205).

Ein weiterer Aspekt ist m.E. weitaus kritischer zu betrachten: In die NLP-Modelle sind offensichtlich systematische Bias eingeflossen, die mit dem Trainingsmaterial zusammenhängen. Genauso wie eine Gesichtserkennungssoftware schwarze Gesichter schlechter erkennen kann<sup>16</sup>, wenn sie überwiegend mit weißen Gesichtern vortrainiert wurde, hängen auch Sprachmodelle davon ab, was in den Trainingsdaten verarbeitet wird. Brown et al. (2020, S. 35f.) machen in ihrer Bestandsaufnahme von neueren Entwicklungen der NLP-Modelle genau hierauf aufmerksam: „Biases present in training data may lead models to generate stereotyped or prejudiced content“ (ebd.). Sie verweisen hier insbesondere auf Bias im Hinblick auf Gender, Race und Religion. Obgleich von den Autor\*innen die Forderung erhoben wird, diese Probleme zu beheben<sup>17</sup>, werden bei unseren Versuchen mit unterschiedlichen KIs diese und andere Bias sicher eine Rolle spielen, weshalb hierauf ein besonderes Augenmerk gerichtet werden muss. Zur „Standortge“- rspt. „Seinsverbundenheit“ der Interpretierenden (Bohnsack 2017, S. 180f.) kommt insofern hier die der KIs hinzu und muss analytisch berücksichtigt werden. Die Option, die KIs aufgrund dieser Bias gar nicht erst zu benutzen, würde ich ablehnen, sondern vielmehr folgende Haltung einnehmen: Die Fähigkeiten der Technologie sollten genutzt werden, wohlwissend, dass sie die Bias reproduzieren kann (und vermutlich auch wird). In gewisser Weise ähnelt das der Diskussion um Klassiker in den Sozial- und Geisteswissenschaften: Wir beziehen uns bspw. nach wie vor auf viele Klassiker, *obwohl* sie in ihren Schriften an anderer Stelle nachweislich antisemitisches, rassistisches oder frauenfeindliches Gedankengut verbreitet haben. Hier ist insofern eine kritische Sensibilität beim Arbeiten *zusammen mit* diesen neuen „Aktanten“ (Latour 1998) in der qualitativen Sozialforschung gefordert.

Der Reiz des gesamten Unterfangens liegt m.E. in der Kombination der menschlichen Fähigkeit zur ‚Tiefen Interpretation‘ (Kap. 2.2), in die intuitive und abduktive Aspekte einfließen mit der Maschinenfähigkeit zur komplexen Verarbeitung und überraschenden Rekontextualisierung großer Datenmengen aus vergleichsweise unstrukturierten Informationen, wie Interviews, Beobachtungsdaten, Bildern etc. Aus techniksoziologischer Perspektive kann man durchaus von einem „Hybridakteur“ menschlicher „Akteure“ und nichtmenschlicher „Aktanten“ sprechen (Latour 1998, S. 35f.), die zusammen etwas Neues entstehen lassen, was ohne die Technologie nicht entstehen würde, analog bspw. zur ‚Kassettenrecorderzeit‘, als sich Anselm Strauss, Juliet Corbin, Fritz Schütze, Ralf Bohnsack, Ulrich Oevermann und viele andere aufmachten, die qualitative Sozialforschung zu revolutionieren. Insofern verbergen sich in der Fragestellung auch weitreichende erkenntnistheoretische Implikationen im Hinblick auf die generelle Medien- und Technologieabhängigkeit menschlicher Erkenntnis.

16 Hierauf macht eine Dokumentation bei Netflix aufmerksam (Coded Bias) und wird hier besprochen: <https://www.sueddeutsche.de/kultur/coded-bias-netflix-doku-1.5268189>

17 „In order to pave the way for effective bias prevention in general purpose models, there is a need for building a common vocabulary tying together the normative, technical and empirical challenges of bias mitigation for these models“ (Brown et al. 2020, S. 35).

## Literatur

- Barad, K. (2012): *Agentieller Realismus. Über die Bedeutung materiell-diskursiver Praktiken*. Aus dem Englischen von Jürgen Schröder. Berlin.
- Bohnsack, R. (2017): *Praxeologische Wissenssoziologie*. Opladen.
- Bohnsack, R. (2021): *Rekonstruktive Sozialforschung. Einführung in qualitative Methoden*. 10. Auflage Opladen/Berlin/Toronto.
- Beer, D. (2017): The social power of algorithms. In: *Information, Communication and Society*, 10. Jg., H. 1, S. 1–13. <https://doi.org/10.1080/1369118X.2016.1216147>
- Breuer, F./Muckel, P./Dieris, B. (2019): *Reflexive Grounded Theory: eine Einführung für die Forschungspraxis*. 4. Auflage Wiesbaden. <https://doi.org/10.1007/978-3-658-22219-2>
- Brown, T./Mann, B./Ryder, N./Subbiah, M. et al. (2020): *Language Models are Few-Shot Learners*. Cornell University. <https://arxiv.org/abs/2005.14165> (16. April 2021)
- Cormen, T.H./Leiserson, C.E./Rivest, R./Stein, C. (2013): *Algorithmen – Eine Einführung*. München.
- Dittmar, N. (2009): *Transkription. Ein Leitfaden mit Aufgaben für Studenten, Forscher und Laien*. Wiesbaden.
- Edelmann, A./Wolff, T./Montagne, D./Bail, C.A. (2020): *Computational Social Science and Sociology*. In: *Annual Review of Sociology*, 46. Jg., S. 61–81. <https://doi.org/10.1146/annurev-soc-121919-054621>
- Franz, J. (2020): Zur Bedeutung von Interpretationsgruppen für rekonstruktive Forschungsprozesse – Eine systematisierende Analyse. In: Dörner, O./Klinge, D./Krämer, F./Endreß, F. (Hrsg.): *Metapher, Medium, Methode. Theoretische und empirische Zugänge zur Bildung Erwachsener*. Opladen, S. 263–278. <https://doi.org/10.2307/j.ctvs32t8r.17>
- Kraimer, K./Garz, D. (Hrsg.) (1994): *Die Welt als Text. Theorie, Kritik und Praxis der objektiven Hermeneutik*. Frankfurt.
- Gigerenzer, G. (2008): *Bauchentscheidungen. Die Intelligenz des Unbewussten und die Macht der Intuition*. München.
- Gillespie, T. (2014): “The Relevance of Algorithms”. In: Gillespie, T./Boczkowski, P./Foot, K. (Hrsg.): *Media Technologies: Essays on Communication, Materiality, and Society*. Cambridge, S. 167–194. <https://doi.org/10.7551/mitpress/9780262525374.003.0009>
- Häußling, R. (2020): Daten als Schnittstellen zwischen algorithmischen und sozialen Prozessen. Konzeptionelle Überlegungen zu einer Relationalen Techniksoziologie der Datafizierung in der digitalen Sphäre. In: Maassen, S./Passoth, J.-H. (Hrsg.): *Soziologie des Digitalen – Digitale Soziologie. Soziale Welt. Sonderband 23*, S. 134–150. <https://doi.org/10.5771/9783845295008-134>
- Hirschmann, H. (2019): *Korpuslinguistik. Eine Einführung*. Stuttgart. <https://doi.org/10.1007/978-3-476-05493-7>
- Jahoda, M./Lazarsfeld, P.F./Zeisel, H. (1975) [1933]: *Die Arbeitslosen von Marienthal. Ein soziographischer Versuch*. Frankfurt a.M.
- Jannidis, F./Kohle, H./Rehbein, M. (Hrsg.) (2017): *Digital Humanities. Eine Einführung*. Stuttgart. <https://doi.org/10.1007/978-3-476-05446-3>
- Kirchmair, R. (2020): Messen oder Verstehen? Zur Zukunft der qualitativen Forschung. In: Keller, B./Klein, H.-W./Wachenfeld-Schell, A./Wirth, T. (Hrsg.): *Marktforschung für die Smart Data World. Chancen, Herausforderungen und Grenzen*. Wiesbaden, S. 217–228. [https://doi.org/10.1007/978-3-658-28664-4\\_15](https://doi.org/10.1007/978-3-658-28664-4_15)
- Kitchin, R./Dodge, M. (2011): *Code/Space: Software and Everyday Life*. Cambridge. <https://doi.org/10.7551/mitpress/9780262042482.001.0001>
- Klinge, D. (2020): Lehrende Algorithmen – spielend-behavioristische Lernanregungen von Apps als digitale Technologien. In: *Hessische Blätter für Volksbildung*, S. 65–75. <http://doi.org/10.3278/HBV2003W007>
- Klinge, D./Nohl, A.-M./Schäffer, B. (2022, i.E.): Zwischen Erziehung und Wissensvermittlung für Erwachsene. Andragogische Perspektiven auf die Corona Pandemie. In: *Zeitschrift für Pädagogik*, 68. Jg., H. 3.

- Latour, B. (1998): Über technische Vermittlung. Philosophie, Soziologie, Genealogie. In Rammert, Werner (Hrsg.), Technik und Sozialtheorie. Frankfurt a.M.
- Lorenz, E.N. (1972): Predictability: Does the flap of a butterfly's wings in Brazil set off a tornado in Texas? Titel des Vortrags im Jahr 1972 während der Jahrestagung der American Association for the Advancement of Science.
- Mainzer, K. (2014): Die Berechnung der Welt. Von der Weltformel zu Big Data. München.
- Manovich, L. (2001): The Language of New Media. Cambridge.
- Manovich, L. (2013): Software Takes Command. New York/London.
- Mirza, B./Malik, Y./Syed, T. (2018): A synergistic framework-big data analytics challenges and potential solutions from deep learning.
- Misselhorn, C. (2018): Grundfragen der Maschinenethik. Stuttgart.
- Nord, T. (2021): Was ist GPT-3 und spricht das Modell Deutsch? <https://www.lernen-wie-maschinen.ai/ki-pedia/was-ist-gpt-3-und-spricht-das-modell-deutsch/> (12. April 2021)
- Peirce, C.S. (1979): Collected papers of Charles Sanders Peirce. 3. print. 8 Bände. Cambridge.
- Pollock, F. (1955): Gruppenexperiment. Ein Studienbericht. (Frankfurter Beiträge zur Soziologie, Bd. 2). Europäische Verlagsanstalt, Frankfurt a.M.
- Przyborski, A./Wohrab-Sahr, M. (2014): Qualitative Sozialforschung. 4. erweiterte Auflage München. <https://doi.org/10.1524/9783486719550>
- Raicea, R. (2017): Want to know how Deep Learning works? Here's a quick guide for everyone. <https://medium.com/free-code-camp/want-to-know-how-deep-learning-works-heres-a-quick-guide-for-everyone-1aedeca88076> (10. April 2021)
- Reichertz, J. (2013): Die Abduktion in der qualitativen Sozialforschung. Über die Entdeckung des Neuen. Wiesbaden. <https://doi.org/10.1007/978-3-531-93163-0>
- Riemann, G. (2018): Forschungswerkstatt. In: Bohnsack, R./Geimer, A./Meuser, M. (Hrsg.): Hauptbegriffe qualitativer Forschung. 4. Auflage Opladen.
- Schäffer, B. (2010): Gruppendiskussionen lehren und lernen. Aspekte einer rekonstruktiven Didaktik qualitativer Forschung. In: Bohnsack, R./ A. Przyborski/ B. Schäffer: Das Gruppendiskussionsverfahren in der Forschungspraxis. Opladen: Verlag Barbara Budrich, zweite vollständig überarbeitete und aktualisierte Auflage, S. 285-299.
- Schäffer, B. (2017): Medienvielfalt und Medienwissen: vom impliziten Medienwissen zur ‚schweigenden‘ Dimension der Algorithmen. In: Kraus, A./Budde, J./Hietzge, M./Wulf, C. (Hrsg.): Handbuch Schweigendes Wissen. Erziehung, Bildung, Sozialisation und Lernen. Weinheim: Beltz, S. 462–478.
- Schäffer, B. (2020): Typenbildende Interpretation. Ein Beitrag zur methodischen Systematisierung der Typenbildung der Dokumentarischen Methode. In: Ecarius, J./Schäffer, B. (Hrsg.): Typenbildung und Theoriegenerierung. Methoden und Methodologien qualitativer Bildungs- und Biographieforschung. 2. überarbeitete und erweiterte Auflage Opladen: Verlag Barbara Budrich, S. 65–88. <https://doi.org/10.2307/j.ctvtxw2zx.6>
- Schäffer, B. (2022a): „Das Medium ist die Methode“. Zur Technikgeschichte qualitativer Methoden. In: Fuchs, T./Demmer, C./Kreitz, R./Wiezorek, C. (Hrsg.): Aufbrüche, Umbrüche, Abbrüche. Wegmarken qualitativer Bildungs- und Biographieforschung. Opladen: Verlag Barbara Budrich, S. 145–165.
- Schäffer, B. (2022b): Zur Präkonfiguration von Interpretationseinstellungen,-Orientierungen und -Haltungen durch onto-epistemologische Aufschreibesysteme. In: Engel, J./Demmer, C./Fuchs, T./Wiezorek, C. (Hrsg.): Haltungen. Zugänge der qualitativen Bildungs- und Biographieforschung. Opladen.
- Schäffer, B./Klinge, D./Krämer, F. (2020): Softwarevermitteltes Forschen, Lehren und Lernen mit der Dokumentarischen Methode. In: Zeitschrift für Qualitative Forschung, 21. Jg., H. 2, S. 163–183. <https://doi.org/10.3224/zqf.v21i2.02>
- Schütze, F. (1978): Strategische Interaktion im Verwaltungsgericht. Eine soziolinguistische Analyse zum Kommunikationsverlauf im Verfahren zur Anerkennung als Wehrdienstverweigerer. In: Hassmer, W./Hoffmann-Riem, W./Weiss, M. (Hrsg.): Schriften der Vereinigung für Rechtssoziologie. Band 2. Interaktion vor Gericht. Baden-Baden, S. 19–100.
- Schütze, F. (2016): Sozialwissenschaftliche Prozessanalyse. Grundlagen qualitativer Sozialforschung. Opladen.

- Seyfert, R./Roberge, J. (Hrsg.) (2017): *Algorithmenkulturen. Über die rechnerische Konstruktion der Wirklichkeit*. Bielefeld.
- Strauss, A. (1991): *Grundlagen qualitativer Sozialforschung*. München.
- Strübing, J. (2014): *Grounded Theory. Zur sozialtheoretischen und epistemologischen Fundierung eines pragmatistischen Forschungsstils*. 3., überarbeitete und erweiterte Auflage Wiesbaden.
- Tsoutis, S. (2019): *Deep Learning – neuronale Netze und mehr*. [https://www.link-niedersachsen.de/blog/blog\\_technik\\_wissenschaft/deep\\_learning](https://www.link-niedersachsen.de/blog/blog_technik_wissenschaft/deep_learning) (17. April 2021)
- Turing, A. (1936): *On Computable Numbers, with an Application to the Entscheidungsproblem*. In: *Proceedings of the London Mathematical Society*, 42. Jg., H. 2, S. 230–265. <https://doi.org/10.1112/plms/s2-42.1.230>
- Wernet, A. (2021): *Einladung zur Objektiven Hermeneutik. Ein Studienbuch für den Einstieg*. Opladen.