

Wissenstransfer in Bildung und Weiterbildung: Der Beitrag Künstlicher Intelligenz

Gergana Vladova, Norbert Gronau, Sylvio Rüdian

1. Einführung in das Thema

Zum Begriff des Lernens existieren zahlreiche Theorien und Definitionen, es besteht jedoch Einigkeit darüber, dass Lernen zu einer Verhaltensänderung führt und sowohl vom Einzelnen als auch von der Umwelt abhängig ist. Lernen kann als ein Prozess der menschlichen Anpassung beschrieben werden, “it is a process whereby knowledge is created through the transformation of experience” (Kolb 1984; Lewin 1951). Dies findet statt, wenn ein Lernender mit und in einer Umgebung interagiert oder durch diese stimuliert wird, wobei Erfahrung eine zentrale Rolle spielt (Jarvis 1987). Im Lernprozess können unterschiedliche Medien eingesetzt werden. Im Kontext der betrieblichen Weiterbildung hat die fortschreitende Digitalisierung die Lernziele und Lernintensität verändert sowie auch mit neuen digitalen Medien den Prozess des Lernens und der Wissensvermittlung bereichert. Die Bedeutung dieser Medien steigt kontinuierlich, wobei als einer der wichtigsten Trends die Digitalen Lernassistenten – Systeme, die Lernende in Dialogform in ihrem Lernprozess begleiten und unterstützen – gesehen werden, die sich als bedeutende Lernform etablieren werden (vgl. bspw. MMB 2019).

Im Kontext der betrieblichen Weiterbildung wird die spezielle Gruppe erwachsener Lernender in den Mittelpunkt gestellt. Diese unterscheiden sich weitgehend von jüngeren Lernenden, die im Rahmen der schulischen Bildung am Lernprozess beteiligt sind. Erwachsene werden beim Lernen viel mehr von ihren eigenen Vorstellungen dazu geleitet, was notwendig und bedeutsam für sie ist und übernehmen dadurch viel deutlicher Verantwortung für ihr Lernen (Illeris 2002, S. 219). Dementsprechend ist es entscheidend, dass ihr Interesse geweckt wird und die Bedeutung oder Wichtigkeit der Lerninhalte erkennbar sind (ebd.).

Dies stellt die betriebliche Weiterbildung vor eine große Herausforderung, da die Bedürfnisse der Lernenden divers sein können und entsprechend erkannt und adressiert sein müssen. Illers (2003) unterscheidet drei Hauptgruppen von erwachsenen Lernenden, die jeweils spezifische Ausgangssituationen und Ziele für die Weiterbildung aufweisen:

- Erwachsene mit einer mehr oder weniger sicheren Position im Arbeitsleben, die ihre Kompetenzen weiterentwickeln müssen, mit dem Ziel des Erwerbs einer zusätzlichen Qualifikation im Kontext ihrer beruflichen Entwicklung;
- Erwachsene, die ihren Arbeitsplatz verloren haben oder verlieren werden, weil ein Arbeitsbereich veraltet war oder sie von der Entwicklung überholt wurden;
- Junge Menschen oder junge Erwachsene, die auf dem Weg ins Berufsleben sind und daher eine allgemeinere berufliche und persönliche Grundqualifikation benötigen.

In all diesen Fällen knüpft die berufliche Weiterbildung an die Erstausbildung an und wird als bewusstes Erwerben neuer beruflicher Qualifikationen auf Basis von bereits vorhandenem Wissen definiert. Das berufliche Lernen findet formal in entsprechenden Aus- und Weiterbildungseinrichtungen, non-formal, z.B. in einem Seminar im Rahmen der allgemeinen Weiterbildung, oder auch informell durch das sogenannte Alltags- und Erfahrungslernen statt.

Die Betriebliche Weiterbildung wird vor diesem Hintergrund mit großen Herausforderungen konfrontiert, unter anderem insbesondere folgende:

Lernen muss personenbezogene Bedürfnisse adressieren, ohne jedoch die organisationalen Ziele zu vernachlässigen. Die Lerngruppe ist sehr heterogen. Dies betrifft u.a. Bedürfnisse, Vorwissen, Kenntnisse und Akzeptanz beim Umgang mit neuen Medien. Die Lernziele und -inhalte können sowohl als konkret definierbar als auch visionär und somit schwer fassbar und vermittelbar gesehen werden (vgl. Vladova et al. 2017). Chancen bieten sich jedoch durch den Einsatz neuer Lernmedien, wobei insbesondere Lernassistenten eine Rolle in Zukunft spielen wird (MMB 2019).

Dieser Beitrag nutzt diese Herausforderungen und Chancen als Ausgangspunkt und Rahmen für die Überlegungen zur Rolle von Künstlicher Intelligenz (KI) beim Transfer von Wissen in der Bildung und Weiterbildung. Wir fokussieren uns auf die Weiterbildung als strukturierten formalen oder informellen Lernprozess und betrachten ihn als Wissenstransfer- und Konversionsprozess (vgl. Nonaka/Takeuchi 1995), in welchem Interaktionen zwischen Sender und Empfänger stattfinden.

Diskutiert werden drei Thesen zum Einsatz von KI im Lernprozess, die zwei theoretische Modelle als Ausgangspunkt der Thesenformulierung und Diskussion verwenden:

- Wesentliche Elemente des Informationstransferprozesses basieren auf der Grundlage des klassischen Kommunikationsmodells (Sender-Empfänger-Modells) von Shannon und Weaver (1949).
- Diese theoretische Grundlage wird erweitert und die Unterschiede zwischen stillschweigendem Wissen und explizitem Wissen (Information) sowie die möglichen Wissenskonsationen zwischen diesen zwei Wissensarten werden anhand des Modells von Nonaka und Takeuchi (1995) erläutert.

Beide theoretischen Konzepte werden zunächst vorgestellt und ihre wichtigsten theoretischen Annahmen erläutert, um die Grundlage für die anschließende Diskussion von drei Thesen über Möglichkeiten, Grenzen und Herausforderungen des Wissens- und Informationstransfers mittels KI im Bildungs- und Lernkontext zu schaffen.

2. Kommunikationsmodell von Shannon und Weaver (1949)

Der Fokus des klassischen Kommunikationsmodells des Mathematikers und Telekommunikationsspezialisten (Shannon/Weaver 1949), auch Sender-Empfänger-Modell genannt, liegt auf der Optimierung des Kommunikationsprozesses. Das Modell beinhaltet sechs Elemente (vgl. Abbildung 1) und beschreibt im Wesentlichen die Übertragung eines Signals von einem Sender über einen Kanal an einen Empfänger. Auf der Seite des Senders und Empfängers sind jeweils ein Kodierer (Sendegerät), der den Signal kodiert, sowie ein Dekodierer (Empfängergerät), welcher diesen dekodiert, positioniert. Zu berücksichtigen ist ebenso das sechste Element – die mögliche Störung im Kanal, die die erfolgreiche Übertragung verhindert oder beeinträchtigt.

Die Beschreibung des Modells richtet sich an technische Übertragungsmittel und -kanäle und in diesem Zusammenhang auch an entsprechende Störungen wie Kanalausfall oder Tonverzerrungen. Wenn diese Interpretation auf die zwischenmenschliche direkte Kommunikation übertragen wird, können physische Störungen gemeint werden – wie die Schwierigkeit, jemanden zu verstehen, wenn es zu laut in der Umgebung ist, aber auch unterschiedliche mentale Fähigkeiten und Wissensniveaus oder unzureichende Motivation und fehlende Aufmerksamkeit (Roehner 2012).

Shannon und Weaver (1949, S.2) identifizieren drei große Kommunikationsebenen:

- 1) Das technische Problem: Wie genau kann die Botschaft übertragen werden?
- 2) Das semantische Problem: Wie genau wird die Bedeutung verstanden?

3) Das Impact-Problem: Wie effektiv beeinflusst die erhaltene Bedeutung das Verhalten des Empfängers?




Abbildung 1: Kommunikationsmodell nach (Shannon/Weaver, 1949)

Im pädagogischen Kontext verweist das Modell auf die Bedeutung gemeinsamer Wissensstrukturen für Sender und Empfänger (semantische Ebene). Eine einfach nachvollziehbare Ausprägung hierzu ist das Vorhandensein einer gemeinsamen Sprache auf beiden Seiten. Weiterhin sind aber auch jegliche Unklarheiten, entstanden im Rahmen der Kodierung oder Dekodierung der Nachricht, als nachteilig für den Austausch von Wissen zu betrachten. Als weiterer Aspekt sollte die Bedeutung der Wahl eines geeigneten Lernmediums (Kommunikationskanal) als Einflussfaktor betrachtet werden. Die Messung des Lernergebnisses entspricht darüber hinaus dem Wirkungsproblem.

3. Wissenskonzersionen nach Nonaka und Takeuchi (1995)

Im Hinblick auf die Betrachtung von Weiterbildung als Wissenstransferprozess sollte das sehr einfache Kommunikationsmodell erweitert werden, indem der jeweilige Inhalt der Botschaft berücksichtigt wird. Hier stellt sich die Frage, was genau Wissen ist.

Eine häufig verwendete Definition von Wissenstypen in der wissenschaftlichen Literatur ist die von Polanyi (1966), die zwischen stillschweigendem Wissen (personengebunden) und explizitem Wissen (nicht personengebunden) unterscheidet. Personengebundenes Wissen ist nicht vollständig übertragbar, d.h. es ist damit weitgehend das Ergebnis des gezielten Umgangs mit der Umwelt und dient als Grundlage für die Entstehung von explizitem Wissen. Beide Arten von Wissen entstehen auf unterschiedliche Weise, erfordern unterschiedliche Methoden der Übertragung und sind auf unterschiedliche Weise messbar (Gronau/Grum 2019; Gronau et al. 2016).




Nonaka/Takeuchi (1995; 1997, S.74ff.) haben sich als erste mit dem Zusammenwirken beider Wissensformen - stillschweigend und explizit – befasst

und die folgenden vier Formen der Wissensumwandlungen eingeführt, die entstehen, wenn die beiden Wissensformen aufeinander treffen, und ihren Übergang ineinander beschreiben (vgl. Tabelle 1). Das von beiden Wissenschaftlern entwickelte Modell der Wissensspirale setzt den Fokus auf die Wissensschaffung im Unternehmen. Es wird als „eine neue Theorie“ (Nonaka/Takeuchi, 1997, S.39) hierzu verstanden. Dabei räumen sie eine besondere Bedeutung der historischen und nationalkulturellen Unterschiede im Kontext der Forschung und der Praxis bezüglich des Umgangs mit Wissen im Organisationskontext ein (Nonaka/Takeuchi 1997, S.40). Insbesondere drei Hauptmerkmale des japanischen Denkens prägen die japanische Auffassung hierzu unterschiedlich als die westliche:

- Einheit von Mensch und Natur,
- Einheit von Körper und Geist,
- Einheit von Ich und anderen.

Im selben Kontext und diesen Erkenntnissen folgend räumen sie in Anlehnung an (Polanyi, 1966) dem stillschweigenden Wissen eine besondere Rolle im Prozess der Wissensschaffung ein, was in ihrem Verständnis insbesondere die Einheit von Körper und Geist adressiert (Nonaka/Takeuchi, 1997, S. 72):

Etwas zu erkennen heißt, durch stillschweigende Einfügung von Einzelheiten ein Gesamtbild zu schaffen. Um dieses wiederum als sinnvolles Ganzes zu begreifen, müssen wir unseren Körper in die Einzelheiten integrieren. Einfühlung löst also die Gegensätze zwischen Geist und Körper, zwischen Vernunft und Gefühl auf. Ein Großteil unseres Wissens entspringt zweckgerichtetem Handeln im Umgang mit der Welt.

Art der Konversion	Interpretation im Kontext des Lernens und der Bildung
<p>Sozialization (stillschweigend zu stillschweigend):</p>  <p>Erfahrungsaustausch, bei dem aus stillschweigendem Wissen ein neues stillschweigendes Wissen entsteht, wie beispielsweise gemeinsame mentale Modelle oder bestimmte Fähigkeiten. Der Erwerb erfolgt durch Beobachtung, Intuition und Praxis (Beispiel: Master-Trainee-Beziehung).</p>	<p>Die Sozialisation spielt im Kontext der allgemeinen und beruflichen Bildung eine besondere Rolle. Aus Sicht des Wissensmanagements ist diese Konversationsart die einzige, die die Möglichkeit bietet, stillschweigendes Wissen direkt zu teilen. Angesichts der unterschiedlichen mentalen Modelle von Lernenden und Lehrenden ist dieser Wissenstransfer jedoch immer mit einem Wissensverlust verbunden.</p>
<p>Externalisierung (stillschweigend zu explicit):</p>  <p>Artikulation, Kodierung und Dokumentation des individuellen stillschweigenden Wissens in explizite Konzepte. Metaphern, Analogien, Modelle usw. werden verwendet, um stillschweigendes Wissen in Konzepte umzuwandeln (Beispiel: Erstellung eines Lessons Learned-Dokuments).</p>	<p>Durch den Prozess der Externalisierung können explizierbare Teile des stillschweigenden Wissens des Wissensträgers – im anvisierten Kontext des Lehrers – weitergegeben und den Lernenden zugänglich gemacht werden.</p>
<p>Kombination (explizit zu explizit):</p>  <p>Diese Wissenskonversion bietet einen Rahmen, in dem bestehendes explizites Wissen verknüpft wird und dadurch ein neues explizites Wissen entsteht.</p>	<p>Die Kombination ist für die Erstellung von Lernmaterial unerlässlich. Dieser Prozess kann direkt vom Lehrer, vom Lernenden oder automatisiert im Informationssystem durchgeführt werden.</p>


Denkbar sind Prozesse wie Klassifizieren, Kombinieren, Sortieren, Zusammenstellen usw. (Beispiel: Erstellung eines neuen Dokuments durch Zusammensetzen von bereits existierenden Dokumenten).	
<p>Internalisierung (explizit zu stillschweigend):</p>  <p>Integration von explizitem Wissen in individuelles stillschweigendes Wissen. Entscheidend sind hier die individuellen Fähigkeiten und Erfahrungen sowie die Fähigkeit, die Erfahrungen anderer zu verstehen (Beispiel: Das Lesen eines Vortrags und die Verknüpfung mit bereits gemachten eigenen Erfahrungen).</p>	Gemessene Lernergebnisse können als typisches Beispiel für Internalisierungserfolg und -ergebnis gesehen werden.

Table 1: Wissenskonversionen im Lernkontext

4. Drei Thesen zum Einsatz Künstlicher Intelligenz im Lernprozess

Künstliche Intelligenz wird immer wichtiger und immer mehr Anwendungsgebiete zeichnen sich ab. Fragezeichen verbleiben allerdings bei der Qualität und möglichen Schwachstellen des Maschinellen Lernens, speziell in Bezug zu und im Vergleich mit menschlicher Intelligenz.

Die Potenziale vom Einsatz von KI sind vielschichtig und tangieren diverse Bereiche der Wissenschaft, Praxis und des alltäglichen Lebens. Dies findet Resonanz in der Ausrichtung von Forschungsaktivitäten, bei der Planung und Aufstellung von wirtschaftlichen Akteuren sowie unabdingbar auch im politischen Kontext. Das spiegelt sich z.B. in der 2018 von der Bundesregierung verabschiedeten nationalen Strategie zu dem Thema (Bundesregierung 2018, S. 6) sowie in den Prognosen über das wachsende Wertschöpfungspotential durch KI in Deutschland und seine starke Auswirkung auf die Steigerung des Bruttoinlandsproduktes (PricewaterhouseCoopers 2018, S. 4). Für Unternehmen eröffnen sich zahlreiche Möglichkeiten des Einsatzes von KI, die sowohl bestimmte Tätigkeiten im betrieblichen Kontext übernehmen und steuern können, als auch vermehrt intellektuelle Aufgaben ausführen und als menschliche Substitute mit problemlösungsbasierten Fähigkeiten und einer Funktionsweise, die

den menschlichen Hirn- und Denkprozessen stark ähnelt, betrachtet werden (Brynjolfsson/McAfee 2017, S. 4; Hildesheim/Michelsen 2019, S. 120). Vor diesem Hintergrund stellt sich auch vermehrt die Frage, welche Rolle KI in der Bildung und Weiterbildung spielen kann und was dabei zu berücksichtigen gilt, wenn eine Maschine am Lernprozess beteiligt ist und somit als Wissensvermittler agiert.

Künstliche Intelligenz kann als Teilgebiet der Informatik eingeordnet werden (Buxmann/Schmidt 2019, S. 6). In früheren Definitionen wird Künstliche Intelligenz hauptsächlich als Simulation menschlicher Intelligenz durch eine Maschine eingeordnet und die Ähnlichkeit zu menschlichen kognitiven Prozessen wie Verstehen, Denken und Lernen in den Vordergrund gebracht (Buxmann/Schmidt 2019, S. 3; Pan 2016, S. 410). Spätere Definitionen betonen weiterhin die Vorbildliche Funktion des Menschen und der menschlichen Kognition „Artificial intelligence (A.I.) is the study of how to make computers do things that people are better at“ (Rich 1985, S. 117; Ertel 2016, S. 4), wobei insbesondere Schlussfolgern, Problemlösen, Planen, Wissensrepräsentation, Lernen, Sprachverstehen und -produktion, Bildverstehen hervorzuheben sind (Schmid 2013, S. 45).

In diesem Beitrag wird explizit auf rechnerunterstützte Lehr-/Lernsystemen, die Maschinelles Lernen im Kontext der (Weiter-)Bildung nutzen, etwa im Bereich der Learning Analytics und des Educational Data Mining fokussiert und folgende Themen formuliert:

- These I: Im Bildungsprozess ist KI geeignet für die Strukturierung, Übermittlung und Evaluation des Lerninhaltes und des Lernergebnisses. Diese Aufgaben können als Wissenskonversionen (Kombination, Internalisierung und Externalisierung) mit explizitem Wissen (Information) als Input und Output angesehen werden.
- These II: KI eignet sich **nicht** für den Transfer stillschweigenden Wissens und für die Erzeugung/Simulation einer sozialen Lernumgebung (Maximierung der Fähigkeiten des Lernenden, mit anderen durch Diskussion, Zusammenarbeit und Feedback zu interagieren).
- These III: KI ist **nicht** dazu geeignet, die gesamte Umwandlung von explizitem in stillschweigendes Wissen (Internalisierung) im Rahmen eines Lernprozesses zu begleiten und das (als Lernergebnis) erworbene stillschweigende Wissen kann nicht erfasst werden.

Im Beitrag werden diese Thesen aus technischer und anwendungsorientierter Perspektive diskutiert.

5. Diskussion der Thesen

Die Diskussion der Thesen erfolgt anhand von Online-Kursen als computerbasiertes Framework, auf welches die Lernenden Zugriff haben. In der Anfangszeit wurden Online-Kurse entwickelt, um den Lernenden lediglich den Zugang zu bestehenden Lernmaterialien zu ermöglichen. Später wurden die Online-Kurse durch weiterführende Lösungen ergänzt, um asynchrone Gruppen zu organisieren, individuelle Nachrichten zu ermöglichen und interaktive Echtzeit-Events zur Selbstbildung anzubieten. Dies hat den Kommunikationsprozess vereinfacht, insbesondere die asynchrone Kommunikation zwischen den Teilnehmern sowie zwischen Lehrenden und Lernenden.

5.1. Diskussion These I: KI geeignet für die Strukturierung, Übermittlung und Evaluation des Lerninhaltes und des Lernergebnisses.

Laut Graham et al. (2001) kann ein Online-Kurs durch verschiedene Good Practices bewertet werden. Ein guter Online-Kurs ermutigt die Schüler mit klaren Richtlinien, Kooperationen, aktivem Lernen, Feedback, definierten Fristen und anspruchsvollen Aufgaben. Darüber hinaus werden dabei verschiedene Hintergründe – Stärken und Schwächen der Teilnehmenden – sowie der Einsatz unterschiedlicher Lernmethoden berücksichtigt. Das alles ist mit einer Personalisierung verbunden, in welchem die größten Vorteile von maschinellem Lernen zurzeit gesehen werden. Online-Kurse können personenbezogen kompetenzorientiert sein (Paquette et al. 2015), wobei die Lernverhalt oder die Lernstilen angepasst werden können (Tseng et al. 2008) mit dem Ziel, das Lernergebnis zu optimieren.

Mit der heutigen Technologie bieten sich diverse Möglichkeiten zur *Strukturierung von Lernmaterial* nach Inhalten (McAndrew et al. 2006). Dies kann durch eine Kombination aus Clustering und neurolinguistischer Programmierung (NLP) erreicht werden. Inhalte können als eine Reihe von Wörtern und Lernmaterialien betrachtet werden, die viele Wörter desselben Clusters teilen. Als Ergebnis kann eine hierarchische Struktur entstehen, bei der der Algorithmus den Inhalt selbst nicht verstehen muss (Vellido et al. 2011). Andere Ansätze nutzen Wortnetze, in denen Inhalte mit bestimmten Themen verknüpft werden können (Fellbaum 2012). Wortnetze sind meist manuell angepasst und ihre Herstellung erfordert Experten und viel menschlichen Einsatz. Ein computergestütztes System hat somit die Fähigkeit und den Vorteil, Lernmaterialien nach Inhalten schnell zu strukturieren.

Ein Online-Kurs selbst *vermittelt Lernmaterial*, das in der Regel von Dozenten erstellt wird. Aus technischer Sicht konzentrieren wir uns in diesem Übermittlungsprozess auf die Transportschicht im Sender-Empfänger-Modell (Shannon/Weaver 1949), und betrachten den Lehrenden als Versender und den Lernenden/Weiterbildenden als Empfänger. Innerhalb dieser Interaktion

erweitert ein dritter, virtueller Agent das Modell. Dieser ermöglicht es innerhalb des Lernsystems, direktes Feedback zu geben, wobei keine direkte Kommunikation zwischen dem Lernenden und dem Lehrenden erforderlich ist. Der Ersteller des Lernmaterials definiert auch die Musterlösungen, die das System mit den Antworten der Lernenden vergleichen kann, um Feedback zu geben. Die Technologie kann darüber hinaus die vom Lernenden erzielten Ergebnisse an den Lehrer vermitteln. Ein Schwerpunkt der Learning Analytics Community ist die Erforschung von Daten und die Erstellung von Dashboards, die den Lernprozess des Lernenden visualisieren. Diese helfen dabei, Daten zu aggregieren und aufzubereiten, um sie für Lehrer/Ausbilder nutzbar zu machen.

Abbildung 1 veranschaulicht die Kommunikation zwischen Lehrenden, Lernenden und dem virtuellen Agenten eines Online-Kurses.

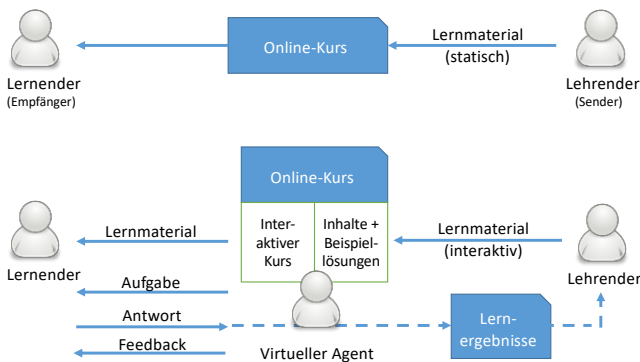


Abbildung 1: Virtuelle Agenten in Online-Kursen

In diesem Beitrag werden *Lernergebnisse* definiert als Wissen, das vom Lehrenden an den Lernenden weitergegeben wird und das als Leistung des Lernenden messbar ist (Samy/Naser 2012), mit Ausnahme anderer Variablen wie die Zufriedenheit des Lernenden oder das wahrgenommene Lernen. *Lernerfolge und Lernergebnisse* können durch Technologien des maschinellen Lernens auf der einen Seite (auch in Echtzeit) vorhergesagt werden (vgl. Rüdian et al. 2019). Am Ende des Lernprozesses müssen die Teilnehmer Aufgaben wie einen Lückentext- oder Multiple-Choice-Test absolvieren oder offene Aufgaben mit natürlicher Sprache beantworten. Learning Analytics untersucht Metadaten für die Vorhersage von Lernergebnissen. Clickstream-Daten, die durch den Einsatz von interaktiven Lernmaterialien erzeugt werden, können dazu verwendet werden, die Aktivität des Lernenden in Bezug auf das Ergebnis zu strukturieren oder um Abbrüche vorherzusagen (Kloft et al. 2014). Darüber hinaus ist die Technologie in der Lage, gefährdete Schüler frühzeitig zu identifizieren, so dass Lehrer so schnell wie

möglich eingreifen können (Zhang / Rangwala 2018), was auch als Teil der Optimierung des Lernprozesses verstanden werden kann. Die Bewertung des wahrgenommenen expliziten Wissens (als erzielt Lernergebnis) kann durch geeignete Abschlussprüfungen im Vergleich zu anderen Online-Kursen prognostiziert werden. KI, die sich auf die Personalisierung in der Bildung konzentriert, kann helfen, das Lernen zu optimieren.

5.2. Diskussion These II: Die KI eignet sich nicht für den Transfer stillschweigenden Wissens und für die Erzeugung/Simulation einer sozialen Lernumgebung.

Die Forschung zur kognitiven und affektiven Zustandsmodellierung hat gezeigt, dass gesichtsbasierte Detektoren des Geistes, die sich durch Aufgabenkontexte bewegen, bereits erfolgreich sind. Gemäß (EDM 2017) können gesichtsbasierte Parameter genutzt werden, um die Aufmerksamkeit beim Lesen oder Ansehen eines Films vorherzusagen. Dieser Ansatz könnte in einem sozialen Lernumfeld genutzt werden, um Menschen zu identifizieren, die nicht mehr motiviert sind, um sie wieder einzubeziehen. Es wird die Fähigkeit des Lernenden, miteinander zu interagieren, nicht maximieren, aber es könnte die Bereitschaft zur Teilnahme an einer Diskussion zeigen. Je mehr Teilnehmer die aktuelle Diskussion aufgrund von gedanklicher Ablenkung verlassen, desto problematischer wird der soziale Austausch. Da Gedankenwanderungen als Teil der Aufmerksamkeit erkannt werden können, kann diese Technologie den Prozess der Sozialisation verbessern. In einer sozialen Lernumgebung wird dieser Zustand rechtzeitig erkannt und die Nutzer werden durch Hinweise oder Motivation und Anregung zur Teilnahme beeinflusst. Neben der Erkennbarkeit ist die Technologie nach dem derzeitigen Stand der Wissensmanagementforschung *nicht für den Transfer von stillschweigendem Wissen geeignet*. Es kann den Teilnehmern helfen und sie unterstützen, indem es eingreift, wenn sie sich an Bildungsaktivitäten nicht motiviert genug beteiligen.

Es ist zu beachten, dass stillschweigendes Wissen personengebunden ist, z.B. im Kopf eines Experten vorhanden ist (Polanyi 1966; Sternberg et al. 2000). Im Gegensatz zu explizierbarem und explizitem Wissen, das z.B. durch Fragebögen erfasst werden kann, erfordert die Erhebung von stillschweigendem Wissen die Fähigkeit, einen Experten und einen konkreten Wissensinhalt zu identifizieren. Parsaye et al. (1988, S. 365) haben drei Möglichkeiten gezeigt, um stillschweigendes Wissen zu erfassen: durch Befragung von Experten, durch eine Einführung oder Aufgabenanalyse, durch eine Beobachtung bei der Lösungssuche und -findung für ein bestimmtes Szenario- oder Musterproblem. Wir fokussieren uns auf die dritte Möglichkeit.

Aus technischer Sicht kann die Beobachtung von Experten bei ihrer Suche nach der Lösung für ein bestimmtes Problem durch Technologie, wie z.B. Process Mining, erfolgen. Dazu muss eine Lernumgebung alle Werkzeuge bereitstellen, die

der Experte zur Lösungsfindung benötigt. Ein Computergestütztes System ist in der Lage, alle Interaktionen zu erfassen und mit Verhaltensdaten zu kombinieren, die helfen können, um den Prozess von anderen Personen zu reproduzieren, ohne eine direkte Erklärung vom Experten zu bekommen. Zu diesem Zweck wurde jedoch das Wissen des Experten mit Hilfe von Technologie externalisiert und nicht durch Sozialisation weitergegeben.

Eine KI ist in der Lage, die Schritte im Interaktionsprozess des Experten während der Problemlösung zu bewerten und in zuvor definierten Klassen anzuordnen. Dadurch ist es möglich, zusätzlich zu identifizieren, wodurch sich Experten in ihren Handlungen von Nicht-Experten unterscheiden. *Auf diese Weise können Teile des stillschweigenden Wissens durch Technologie in explizites Wissen umgewandelt werden*, unter der Voraussetzung, dass eine Lernumgebung alle Werkzeuge bereitstellt, die zur Lösung eines Problems notwendig sind, und der Prozess erfasst und von anderen genutzt werden kann.

- 5.3. Diskussion These III: Die KI ist nicht dazu geeignet, die gesamte Umwandlung von explizitem in stillschweigendes Wissen im Rahmen eines Lernprozesses zu begleiten.

Im Allgemeinen können Maschinen nur Aufgaben ausführen, für die sie erschaffen wurden (Chaminade et al. 2012). Dazu gehören Probleme, die vom Menschen beschrieben und gelöst werden können, meist unabhängig von computergestützten Aufgaben. Solange der Programmierer nicht weiß, wann das übermittelte explizite Wissen in stillschweigendes Wissen eines konkreten Lernenden überführt wird und es nicht explizit als Prozess mit unterschiedlichen Inputfaktoren beschreiben kann, kann auch ein computerbasiertes Programm diese Aufgabe nicht erfüllen. Um den Punkt der stattfindenden Konversion zu erkennen, ohne jedoch sie erklären zu können, müssen die maschinellen Lernalgorithmen den klar definierten Prozess der Wissenskonversion beschrieben bekommen oder gesammelte Daten, die die Art des transferierten Wissens widerspiegeln, zur Verfügung haben.

Die Internalisierung kann mit der Erkennung von Mustern in Verbindung gebracht werden. Ein Hauptfeld der schwachen KI ist die Mustererkennung, die zur Analyse von Bildern oder beliebigen Datentypen verwendet wird. Überwachtes maschinelles Lernen ("supervised learning") erfordert Daten als Input (z.B. Bilder) und mindestens ein bekanntes Ausgabemerkmal pro Bild (z.B. eine Kategorie, zu der das Bild gehört (Tou und Gonzalez 1974)). Algorithmen wie neuronale Netze können diese Daten nutzen, um ein Modell zu trainieren. Während des Lernprozesses werden die Gewichte aller Neuronen in einem neuronalen Netzwerk optimiert, um bekannte Daten vorherzusagen. Das Modell, genauer gesagt, die erlernten Gewichte, die die meisten verwendeten Daten zu bekannten Klassen einordnen, können als endgültiges Modell verwendet werden. Informatiker

verwenden Methoden, um die Daten in eine lernende und testende Teilmenge zu überführen, um ein Modell mit Daten zu testen, die nicht verwendet wurden, um ein Modell zu lernen. Dies wird als Cross-Validierung bezeichnet (Krogh und Vedelsby 1995). Die erlernten Gewichte der Neuronen selbst können als mathematische Funktion betrachtet werden, bei der ein Signal auf das nächste Neuron übertragen werden kann. Der letzte Schritt eines solchen Algorithmus summiert alle verbleibenden Signale und liefert Klassen oder den Regressionswert des letzten Neurons. Dies kann als eine technische Art der Internalisierung interpretiert werden. Die Algorithmen des maschinellen Lernens erhalten explizites Wissen, in Form von Daten mit bereits bekannten Ergebnissen. Bei neuen Daten ist das Verfahren in einem nächsten Schritt in der Lage, ein Ergebnis zu liefern, ohne eine Erklärung dafür zu haben, warum und wie dieses zustande gekommen ist. Neuronale Netze können als Blackbox-Technologie betrachtet werden, die Muster erkennt, ohne sie zu zeigen. Aus der Perspektive der Internalisierung ist diese Art der Wissensanwendung für den Menschen tolerierbar, es stellt sich die Frage, wie dies auf Maschinen übertragbar ist, die die Fähigkeit haben, Millionen von Daten in kurzer Zeit zu verarbeiten.

Eine Methode der Internalisierung ist "learning by doing". Diese Variante des Lernens findet sich oft bei Informatikern, wenn z.B. eine Programmierungssprache durch Selbstbildung erlernt wird. Die Lernenden verwenden Codeausschnitte und wenden sie an, ohne zu wissen oder zu verstehen, was der Code wirklich tut. Diese Experten sind sich bewusst, dass sie ihr vorhandenes Wissen in Kombination mit Erfahrungen anderer nutzen, z.B. bei der Beantwortung von Fragen auf Plattformen oder Online-Foren, die Lösungen oder nur Teillösungen anbieten. An dem Punkt, an dem die Lernenden den komplexen Prozess hinter dem kopierten Quellcode verstehen, findet der Transfer von Wissen statt. In diesem Fall muss der Benutzer nicht unbedingt in der Lage sein, alle Details eines Codes zu erklären (als Teil seines stillschweigenden Wissens), aber er kann Artefakte verwenden, die aus der Erfahrung anderer entstehen.

Diesen Teil der Wissenskonversion kann technologisch in einem Szenario gemessen werden, in welchem die Lernenden nicht in der Lage sind, das erworbene Wissen zu explizieren (erfassbar z.B. in einem Exit-Test mit fachspezifischen Fragen), aber gleichzeitig eine Aufgabe erfolgreich lösen können, bei welcher dieses Wissen angewendet wird. Da die Ergebnisse des Tests und der Anwendung während der Aufgabe erfasst und gemessen werden können, wäre die Phase der Internalisierung dadurch identifizierbar gemacht worden. Für dieses Szenario wird keine komplexe KI benötigt. Es erfordert die Erstellung eines Tests, bei dem ein Benutzer nicht erklären kann, wie (A, explizit), aber es ihm gelingt (B, stillschweigend) das Wissen zur Lösung einer Aufgabe anzuwenden. Diese beiden Metriken A und B können verglichen werden, wobei die Erfolgsrate von A niedrig und B hoch sein muss, mit der Einschränkung, dass A lösbar sein muss, wenn der

Benutzer einen Teil seines (expliziten) Wissens nutzen kann und B die Anwendung erfolgreich ist, aber nicht die Erklärung desselben (stillschweigenden) Wissens.

In einem Testaufbau kann das explizite Wissen bestimmt werden, welches als Ausgangspunkt für die Konversion in stillschweigendes Wissen (Internalisierung) erforderlich ist. Die benötigte Lernumgebung beinhaltet die Metriken A und B innerhalb von verschiedenen Schritten eines Lernprozesses mit technologischer Unterstützung. Während des Online-Kurses müssen die Erfolgsraten der Teilnehmer zwischen einigen Interaktionen, bei denen die Teilnehmer etwas lernen, was vom Kursleiter definiert und strukturiert wird, mehrmals erhoben werden. Der Bereich zwischen zwei Tests, in dem wir in der Lage sind, Internalisierung zu erkennen, wird das gelernte Material sein, das den Wissenstransfer beeinflusst hat. Dieser Ansatz ist in Abbildung 2 veranschaulicht.

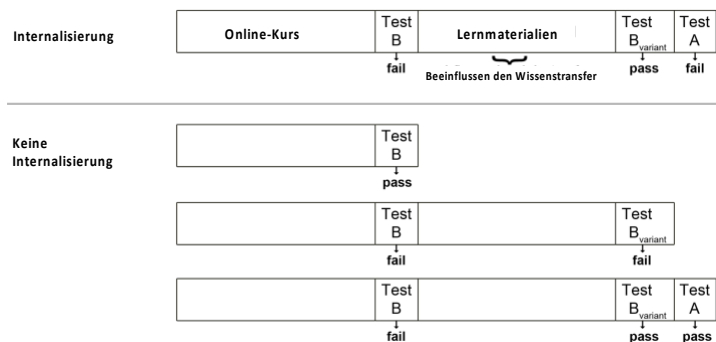


Abbildung 2: Experimenteller Ablauf zur Erfassung von Internalisierung in einem Lernprozess

Aus praktischer Sicht stellt eine solche Struktur eine große Herausforderung dar: Die Kennzahlen A und B müssen vergleichbare Ergebnisse liefern, ohne jedoch die gleichen Aufgaben und Fragen innerhalb des Kurses zu wiederholen. B muss mindestens zweimal vorhanden sein: 1) Am Anfang eines Kurses, um zu messen, dass der Teilnehmer nicht in der Lage ist, die Aufgabe (B) zu lösen und 2) an dem Punkt, an dem der Teilnehmer B_{variant} gelöst hat, aber immer noch nicht in der Lage ist, A zu lösen. An jedem Punkt, an dem die Internalisierung getestet wird, müssen verschiedene Versionen von B erstellt werden, wobei A nur folgt, wenn B zuvor gelöst wurde. Die Anzahl der B-Varianten kann dabei begrenzt werden, so dass das Testgebiet innerhalb eines Kurses für neue Teilnehmer Schritt für Schritt reduziert wird. Auf diese Weise erhalten wir die notwendigen Informationen, die verinnerlicht werden müssen, um eine spezifische Wissensbasis zu schaffen. Die Abschätzung, wo sich die optimalen Testpunkte befinden, kann mit algorithmischen Ansätzen erfolgen.

Der allgemeine Charakter des Experiments erfordert nicht unbedingt computergestützte Technologien, sie reduzieren jedoch den Aufwand für die Erfassung aller Interaktionen, die Anpassung des Testpunktes und die Durchführung dieser Aufgabe mit einer großen Anzahl von Personen.

6. Zusammenfassung und Ausblick

Der Beitrag diskutiert mögliche Anwendungen Künstlicher Intelligenz im Kontext des Lernens und betrachtet Lernprozesse als Wissensumwandlungs- und Wissenstransferprozesse. Auf der Basis zweier theoretischer Modelle, des Sender-Empfänger-Modells von Shannon/Weaver (1949) sowie des Modells der Wissensumwandlungen von Nonaka/Takeuchi (1995) wurden drei Thesen zu Möglichkeiten, Grenzen und Herausforderungen des Einsatzes von KI analysiert. Ziel dabei ist es, zu einem besseren Verständnis des Konzeptes der Digitalisierung und der Mensch-Computer-Interaktion in der Bildung und Weiterbildung beizutragen.

Ohne den Anspruch zu erheben, alle bestehenden Fragen und Möglichkeiten vollständig adressiert zu haben, soll die Auseinandersetzung mit Lernen und Bildung unter Einbeziehung der KI als Kommunikationspartner, der für die Auswahl, Strukturierung und Vermittlung von Lerninhalten sowie für den Umgang mit und die angemessene Reaktion auf Lernergebnisse verantwortlich ist, angeregt werden. Aktuelle Entwicklungen im Bereich von Learning Analytics zeigen, dass die automatische Erstellung von Lernkursen für die Bildung und Weiterbildung an Bedeutung gewinnt. In einer denkbaren Vision wird die KI als Unterstützer für den Lehrer gesehen, um Lernergebnisse in Zukunft zu verbessern und Prozesse visualisierbar und nachvollziehbar zu machen. Sie wird den Lehrer nicht komplett ersetzen.

Obwohl dies immer noch eine Vision ist, hat diese Diskussion gezeigt, dass KI zu allen ausgewählten Thesen einen Beitrag leisten kann, wobei das größte Potenzial im Vergleich zur menschlichen Intelligenz beim Umgang mit Daten und explizitem Wissen identifiziert wurde. Darüber hinaus werden auf die Thesen II und III weitere Argumente für den Einsatz von KI geliefert und Möglichkeiten bei der Umwandlung von stillschweigendem Wissen aufgezeigt, eine Wissensart, die bisher nur als ein strikter Teil der menschlichen Intelligenz gesehen wird.

Der Lernprozess zwischen der KI und den Lernenden wird maßgeblich dadurch beeinflusst, dass es sich um unterschiedliche Wissensstrukturen beim Menschen und bei der Maschine handelt, wobei Menschen stillschweigendes Wissen besitzen und vielseitiger, unstrukturierter und dynamischer sein können. Maschinen dagegen sind dazu geeignet, Aufgaben auszuführen, für die sie geschaffen und programmiert wurden. Computergestützte Technologien sind in der Lage, eine

Vielzahl von Aufgaben zu erfüllen, die auf eine bestimmte Anwendung beschränkt sind – das sogenannte Qualifikationsproblem in der KI.

Die in diesem Beitrag verwendeten theoretischen Modelle sollen um interdisziplinäre Erkenntnisse erweitert werden, z.B. aus den Bereichen der Philosophie, Ethik, Psychologie. Wichtige künftige Fragen adressieren z.B. den Begriff der Intelligenz, die Arten von Intelligenz und ihre Einzigartigkeit, den Vergleich der Maschine mit dem menschlichen Intellekt und die mögliche Entwicklung neuer Kriterien, nach denen die Intelligenz von Maschinen gemessen werden sollte.

Die durch die Digitalisierung initiierten Veränderungen im Bildungs- und Weiterbildungsprozess sind besonders relevant, da sie sich auf den Wissenstransfer und den Kompetenzaufbau beim Menschen konzentrieren. Die KI bietet hierzu viele Möglichkeiten, die in diesem Beitrag ansatzweise für den Bereich der assistierten Online-Kurse diskutiert wurden. Bildung ist einer der wichtigsten Faktoren, um mit Ungleichheiten umzugehen und es jedem Einzelnen zu ermöglichen, die Umwelt mitzugestalten. Die einführenden Überlegungen zur Weiterbildung haben die spezifischen Merkmale von erwachsenen Lernenden verdeutlicht, insbesondere die Notwendigkeit, individuell und ergebnisorientiert zu lehren.

In einer Zukunft, in der nicht nur Wissen und Können, sondern auch Kommunikations- und Sozialkompetenzen von der KI beeinflusst werden können, ist eine Überarbeitung und Diskussion bestehender theoretischer Konzepte erforderlich.

Literatur

- Brynjolfsson, E., McAfee, A. (2017). The Business of Artificial Intelligence: What It Can -- and Cannot -- Do for Your Organization. In: Harvard Business Review Digital Articles July, 3 – 11.
- Bundesregierung (2018). Strategie Künstliche Intelligenz der Bundesregierung - Stand: November 2018. https://www.ki-strategie-deutschland.de/home.html?file=files/downloads/Nationale_KI-Strategie.pdf (Abruf am 20.06.2019).
- Buxmann, P., Schmidt, H. (2019). Grundlagen der Künstlichen Intelligenz und des Maschinellen Lernens. In: Buxmann, P., Schmidt, H. (Hrsg.) (2019). Künstliche Intelligenz, Springer: Berlin, Heidelberg, 3 – 19.
- Chaminade, T., Rosset, D., Fonseca, D., Nazarian, B., Lutchter, E., Cheng, G., Deruelle, Ch. (2012). How do we think machines think? An fMRI study of alleged competition with an artificial intelligence in Towards a neuroscience of social interaction.

- Ertel, W. (2016). Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung, Springer Vieweg: Wiesbaden.
- Fellbaum, C. (2012). WordNet. In: C. Chapelle (Ed.): The Encyclopedia of Applied Linguistics. Oxford: John Wiley and Sons.
- Hildesheim, W., Michelsen, D. (2019). Künstliche Intelligenz im Jahr 2018 – Aktueller Stand von branchenübergreifenden KI-Lösungen: Was ist möglich? Was nicht? Beispiele und Empfehlungen. In: Buxmann, P. Schmidt, H. (Hrsg.): Künstliche Intelligenz, Springer: Berlin, Heidelberg, 119 – 142.
- Graham, Ch., Cagiltay, K., Lim, B., Craner, J., Du, Th.M. (2001). Seven Principles of Effective Teaching: A Practical Lens for Evaluating Online Courses, Technology Source.
- Gronau, N., Thim, C., Ullrich, A., Vladova, G., und Weber, E. (2016). A proposal to model knowledge in knowledge-intensive business processes. BMSD.-Rhodes, Greece, 16, 98-103.
- Gronau, N., Grum, M. (2019). Knowledge Transfer Speed Optimizations in Product Development Contexts. Berlin: Gito.
- Illeris, K. (2003). Workplace learning and learning theory. Journal of workplace learning, 15(4), 167-178.
- Illeris, K. (2002). The three dimensions of learning.
- Jarvis, P. (1987). Adult learning in the social context. New York, NY: Croom Helm.
- Kloft, M., Stiehler, F., Zheng, Z., Pinkwart, N. (2014). Predicting MOOC Dropout over Weeks Using Machine Learning Methods. Proceedings of the Conference on Empirical Methods in Natural Language Processing (EMNLP 2014), 60–65.
- Kolb, D. A. (1984). Experiential learning: Experience as the source of learning and development. New Jersey: Prentice-Hall.
- Krogh, A., Vedelsby, J. (1995). Neural network ensembles, cross validation, and active learning. In Advances in neural information processing 7, 231-238, MIT Press: Cambridge MA.
- Lewin, K. (1951). Field theory in social science. New York, Harper and Row.
- McAndrew, P., Goodyear, P., Dalziel, J. (2006). Patterns, designs and activities: unifying descriptions of learning structures. International Journal of Learning Technology, 2(2-3), 216–242.
- Mmb Institut (2019). Mmb-Trendmonitor 2018/2019. Auf dem Weg zum Assisted Learning? Ergebnisse der 13. Trendstudie „mmb Learning Delphi“. Online unter: <https://www.mmb-institut.de/downloads>
- Nonaka, I., Takeuchi, H. (1995). The knowledge creating Company - how japanese companies create the dynamic innovation. Oxford University Press.
- Nonaka, I., Takeuchi, H. (1997). Die Organisation des Wissens: Wie japanische Unternehmen eine brachliegende Ressource nutzbar machen. Frankfurt/Main: Campus.
- Paquette, G., Mariño, O., Rogozan, D., Léonard, M. (2015). Competency-based personalization for massive online learning. Smart Learning Environments. Springer Open access.

- Pan, Y. (2016). Heading toward Artificial Intelligence 2.0. In: *Engineering* 4, 2016, 409 – 413.
- Parsaye, K., Chignell, M. (1988). *Expert Systems for Experts*. Hoboken, NJ: Wiley.
- PricewaterhouseCoopers GmbH Wirtschaftsprüfungsgesellschaft (2018). Auswirkungen der Nutzung von künstlicher Intelligenz in Deutschland (Juni 2018). <https://www.pwc.de/de/business-analytics/sizing-the-price-final-juni-2018.pdf> (Abruf am 20.06.2019).
- Rich, E. (1985). Artificial intelligence and the Humanities. In: *Computers and the Humanities* 2, 117 – 122.
- Roehner J., Schuetz, A. (2012). *Psychologie der Kommunikation (Basiswissen Psychologie)*. Springer VS. (in German)
- Rüdian, S., Vladova, G., Gundlach, J., Kazimzade, G., und Pinkwart, N. (2019). Predicting culture and personality in online courses. In *Supporting Lifelong Learning (SLLL / AIED)*. Chicago.
- Samy S., Naser, A. (2012). Predicting learners performance using artificial neural networks in linear programming intelligent tutoring system. *International Journal of Artificial Intelligence & Applications (IJAAI)*, Vol.3, No.2.
- Schmid, U., Funke, J. (2013). Kreativität und Problemlösen. In: Stephan, A., Walter, S. (Hrsg.): *Handbuch Kognitionswissenschaft*, J.B. Metzler: Stuttgart, 335 – 343.
- Shannon, C. E., W. Weaver (1949). *The Mathematical Theory of Communication*. University of Illinois Press.
- Sternberg, R. J., Forsythe, G. B., Hedlund, J., Wagner, R. K., Williams, W. M., Horvath, J. A., ... & Grigorenko, E. (2000). *Practical intelligence in everyday life*. Cambridge University Press.
- Stewart, A., Bosch, N., DMello, S. (2017). Generalizability of Face-Based Mind Wandering Detection Across Task Contexts. *Proceedings of the Proceedings of the 10th International Conference on Educational Data Mining (EDM 2017)*.
- Tou, J. T., Gonzalez, R. C. (1974). *Pattern recognition principles*. NASA.
- Tseng, J.C.R., Chu, H., Hwang, G., Tsai, Ch. (2008). Development of an adaptive learning system with two sources of personalization information. In: *Computers & Education*, Volume 51, Issue 2, 776-786.
- Vellido, A., Castro, F., Nebot, A. (2010). *Handbook of Educational Data Mining: Chapter 6, Clustering Educational Data*, 75-92.
- Vladova, G., Ullrich, A., Reiff-Stephan, J. (2017). Der Mensch im Umfeld von Industrie 4.0. In: Weinert, N., Plank, M., Ullrich, A. (Hrsg). *Metamorphose zur intelligenten und vernetzten Fabrik*, Springer-Vieweg, 23-30.
- Zhang, L., Rangwala, H. (2018). Early Identification of At-Risk Students Using Iterative Logistic Regression. *Proceedings of the 19th International Conference (AIED 2018) London, UK, June 27–30*.