Gefördert vom:

Bundesministerium
für Bildung, Familie, Senioren,
Frauen und Jugend

RAHMENPROGRAMM
EMPIRISCHE BILDUNGS-FORSCHUNG

Künstliche Intelligenz in der Schule

Eine Handreichung zum Stand in Wissenschaft und Praxis

Katharina Scheiter, Elisabeth Bauer, Yoana Omarchevska,
Clara Schumacher, Michael Sailer

Bonn
Mai 2025

Hrsg. im Rahmen des KI-Begleitprozesses im Rahmenprogramm empirische Bildungsforschung

Vorwort

Die vorliegende Forschungssynthese „Künstliche Intelligenz (KI) in der Schule“ will mit Blick auf die schulische Praxis alle Akteurinnen und Akteure dabei unterstützen, den Herausforderungen im Umgang mit Künstlicher Intelligenz aktiv zu begegnen. Sie bietet einen umfassenden Überblick über zentrale Aspekte in verschiedenen Handlungsfeldern und den aktuellen Stand der Forschung. Gängige Befürchtungen und Vorurteile (negative wie positive) gegenüber KI werden – so weit wie es in diesem dynamischen Feld möglich ist – einem Faktencheck unterzogen. Die Synthese leistet damit auch einen Beitrag, verbreiteten „Mythen“, Ängsten sowie überzogenen Erwartungen entgegenzuwirken.

Um möglichst nah an den Bedürfnissen und Anliegen von Schule zu bleiben, wurden bei der Erstellung des Papiers Expertinnen und Experten aus der und für die Schulpraxis einbezogen. Im Rahmen von zwei Workshops wurden mögliche Themenfelder diskutiert, um die Bedarfe von Akteurinnen und Akteuren der schulischen Praxis in den Blick zu nehmen. Diese Impulse aus der schulischen Praxis fanden im Text Einzug und manifestieren sich darüber hinaus auch durch konkrete Praxisbeispiele. Die Synthese der Perspektiven aus Forschung und Praxis ermöglicht eine Darstellung aktueller Evidenzen der empirischen Bildungsforschung unter Berücksichtigung einzelner schulpraktischer Realitäten sowie deren Umsetzung in der schulischen Praxis.

Wir möchten uns bei den Expertinnen und Experten aus der Bildungspraxis Hendrik Haverkamp (Evangelisch Stiftisches Gymnasium Gütersloh; Mitgründer FelloFish, ehemals fiete.ai), Gerd Mengel (ehemals Don-Bosco-Schule Rostock, Gymnasium; Schulleiter), Kai Wörner (Realschule am Europakanal Erlangen II; Lehrkräftefortbildung), Nicole Wrana (Grundschule Bogenstraße Solingen; Schulleiterin, Lehrkräftefortbildung) und Stefan Jänen (Grundschule Bogenstraße Solingen) sehr herzlich für ihr Engagement und für die reichhaltigen Impulse bedanken.

Zielgruppen der Forschungssynthese sind sowohl Lehrkräfte, die bereits KI in und um ihren Unterricht verwenden und sich eine Synthese aktueller Evidenzen wünschen, als auch am Thema KI interessierte Personen, die sich Impulse zu konkreten Befunden und Umsetzungsmöglichkeiten wünschen. Darüber hinaus versucht die Forschungssynthese, bewusst auch kritische Personen anzusprechen, deren potenzielle Sorgen ernst zu nehmen und differenziert Antworten auf potenzielle Fragen bereitzustellen.

Was die Forschungssynthese nicht leisten kann und will, ist, Vollständigkeit für sich zu beanspruchen – insbesondere bezogen auf Regularien in einzelnen Bundesländern und die Verfügbarkeit spezifischer Tools. Aufgrund der hohen Entwicklungsgeschwindigkeit im Feld „KI im Bildungsbereich“ kann ein statisches Dokument diesen Vollständigkeitsanspruch nicht sinnvoll einlösen. Stattdessen werden beispielhafte Anwendungen genannt und deren Einsatz im Unterricht illustriert sowie Implikationen auf Grundlage empirischer Evidenzen ausgesprochen. Auch kann dieses Papier nur eine Momentaufnahme liefern. Aktuell werden täglich neue Studien zum Einsatz von KI zur Unterstützung von Bildungsprozessen veröffentlicht. In der Forschungssynthese werden daher auch eher große Linien in der Diskussion um KI in der Schule nachgezeichnet anstatt auf Einzelergebnisse einzugehen, die auch vor dem Hintergrund der rasanten technischen Entwicklungen einer hohen Vorläufigkeit unterliegen.

Die Erstellung der Forschungssynthese „Künstliche Intelligenz (KI) in der Schule“ fand im Kontext des KI-Begleitprozesses im Rahmenprogramm Empirische Bildungsforschung statt. Wir hoffen, dass das Ergebnis dem Leitgedanken des Rahmenprogramms Empirische Bildungsforschung „Gemeinsam für bessere Bildung“ gerecht wird.

Künstliche Intelligenz in der Schule

Eine Handreichung zum Stand in Wissenschaft und Praxis

Katharina Scheiter, Elisabeth Bauer, Yoana Omarchevska, Clara Schumacher, Michael Sailer

Inhaltsverzeichnis

1. Einleitung 4
2. Funktionsweise und Verfügbarkeit von KI 5
   2.1 KI-Systeme: Ist KI gleich KI? 5
   2.2 Verhindern Datenschutz und Risikobewertungen die Nutzung von KI im Bildungskontext grundsätzlich? 8
   2.3 Macht die mangelnde Verfügbarkeit von KI den Einsatz in der Schule unmöglich? 10
   2.4 Trifft KI objektivere und fehlerfreiere Aussagen als Menschen? 12
3. Lernen und KI 15
   3.1 Lernziele: Benötigen wir mit dem Aufkommen von KI kein Faktenwissen mehr? 19
   3.2 Lernerfolg: Gibt es Risiken? 20
   3.3 Lernwirksamkeit: Gibt es schon belastbare Forschung? 22
   3.4 Lernvoraussetzungen: Für wen ist KI lernwirksam und sinnvoll? 24
   3.5 Lernerfolgskontrollen: Macht eine Überprüfung des Lernerfolgs im Zeitalter von KI überhaupt noch Sinn? 26
4. Die Rolle von Lehrkräften 28
   4.1 Das Verhältnis von Lehrkraft und KI: Wozu braucht es noch Lehrkräfte? 28
   4.2 Kompetenzen von Lehrkräften: Brauchen Lehrkräfte mehr oder weniger Wissen im Zeitalter von KI? 30
   4.3 KI: Auch ein Werkzeug für Lehrkräfte? 32
5. Fazit 34
6. Literatur 35
7. Weiterführende Literatur und Informationen 42

1. Einleitung

Während die allgemeine Digitalisierung Deutschlands in den Bereichen Freizeit, Arbeit und Bildung eher langsam und unsystematisch voranschreitet, hat Künstliche Intelligenz (KI) mit dem kostenfreien Release von ChatGPT im November 2022 disruptive Kräfte entfaltet. Dabei sind KI-basierte Anwendungen selbst im Bildungsbereich schon lange Gegenstand von Forschung und Methoden wie *Machine Learning* sowohl in der Wissenschaft als auch im kommerziellen Bereich in der Anwendung. Die Verfügbarmachung von text- und bildgenerierenden Anwendungen, die eine große Bandbreite von Aufgaben auf teilweise erstaunlich hohem Niveau bewältigen können, ohne dass Nutzende über besondere Fertigkeiten verfügen müssen, hat jedoch dazu geführt, dass die Mächtigkeit von KI-Anwendungen, die bislang eher im Verborgenen für spezielle Personenkreise zugänglich waren, durch eine breite Öffentlichkeit erfahrbar wurde. Seitdem ist vor allem generative KI in (fast) aller Munde – mit sehr unterschiedlichen Reaktionen, die von der Beschreibung dystopischer Untergangsszenarien bis hin zu überbordender Euphorie reichen.

Auch den Bildungsbereich hat generative KI scheinbar auf den Kopf gestellt. Schülerinnen und Schüler nutzen KI zur Erledigung von Hausaufgaben und als Unterstützung beim Schreiben von Essays oder in schriftlichen Prüfungen. Während national und international in der Anfangszeit der Ruf nach einer Verbannung von *ChatGPT* & Co. aus dem Klassenzimmer und den Hörsälen überwog, hat sich überraschend schnell eine differenziertere Sicht durchgesetzt, wonach eine reflektierte Nutzung von KI im Bildungskontext durchaus sinnvoll sein kann. Diese Sichtweise spiegelt sich beispielsweise in bildungspolitischen Dokumenten wie der „Handlungsempfehlung für die Bildungsverwaltung zum Umgang mit Künstlicher Intelligenz in schulischen Bildungsprozessen" der Kultusministerkonferenz (KMK, 2024) oder in den KI-Erlassen einzelner Bundesländer wider. Nur 7 Prozent der in einer repräsentativen Studie befragten Schülerinnen und Schüler in Deutschland im Alter zwischen 14 und 20 Jahren berichteten von einem generellen Verbot von KI an ihrer Schule (Vodafone-Stiftung, 2024).

In aller Kürze (KI-Zusammenfassung):

Die Einführung von Künstlicher Intelligenz (KI) in den Bildungsbereich hat zu disruptiven Veränderungen geführt. Während anfänglich Verbote diskutiert wurden, hat sich inzwischen eine differenziertere Sichtweise durchgesetzt. Die Auseinandersetzung mit KI in der Schule ist aus mehreren Gründen wichtig:

- KI ist eine zukunftsrelevante Technologie, die den Alltag und das Berufsleben prägen wird.
- Schüler müssen auf einen reflektierten Umgang mit KI vorbereitet werden.
- KI bietet Entlastungspotenziale für Lehrkräfte und im Rahmen von Schulorganisation.
- KI bietet Potenziale für die Neugestaltung von Bildungsprozessen.

Eine Auseinandersetzung mit und Nutzung von KI in der Schule ist aus verschiedenen Gründen unerlässlich. Bei KI handelt es sich um eine zukunftsrelevante Technologie, die den Alltag und das Berufsleben von Kindern und Jugendlichen massiv prägt und auch weiterhin prägen wird. KI-Anwendungen bergen dabei sowohl Chancen als auch Risiken, auf die

Lernende angemessen vorbereitet werden müssen, indem sie zu einer reflektierten Nutzung von KI befähigt werden. Laut der bereits erwähnten Studie der Vodafone-Stiftung (2024) sind rund drei Viertel (73 %) der befragten Schülerinnen und Schüler überzeugt, dass der Einsatz von KI eher Chancen bietet. 69 Prozent gehen davon aus, dass KI-Kenntnisse für das Erreichen persönlicher beruflicher Ziele „auf jeden Fall“ oder „eher wichtig“ sein werden. Eine repräsentative Umfrage in der Allgemeinbevölkerung und von Eltern schulpflichtiger Kinder zeigte, dass ebenfalls etwa drei Viertel der hier Befragten (77 %) dabei Lehrkräfte in der Verantwortung sehen, Schülerinnen und Schüler auf eine kompetente und reflektierte Nutzung von KI vorzubereiten (Vodafone-Stiftung, 2023).

Mit KI sind zudem Potenziale für eine Re- und Neugestaltung von Bildungsprozessen verbunden: KI kann Lehrkräfte von zeitaufwändigen Routineaufgaben sowie bei der Entwicklung von Unterrichtsmaterialien entlasten und so auch Freiräume für Beziehungsarbeit und persönliche Interaktion mit einzelnen Lernenden schaffen. KI kann Lernprozesse unterstützen, indem Anwendungen z. B. basierend auf einer (teil-)automatischen Bewertung von Schülerantworten individuelles Feedback vergeben.

Diese Potenziale für den Unterricht nutzbar zu machen ist jedoch kein Selbstläufer, sondern setzt sowohl Forschungsbemühungen als auch die Auseinandersetzung der Bildungspraxis mit entsprechenden Technologien und KI-basierten Unterrichtsszenarien voraus. In der Studie der Vodafone-Stiftung (2024) berichteten allerdings 38 Prozent der befragten Schülerinnen und Schüler, dass die Nutzung von KI-Systemen an ihrer Schule keine Rolle spiele. Weitere 38 Prozent konstatierten, dass einheitliche Regelungen fehlten und die Nutzung von KI von einzelnen Lehrkräften abhänge. Die Gründe für die bisher oft unsystematische und sporadische Nutzung von KI in der Schule sind dabei vermutlich vielfältig.

Ziel des vorliegenden Beitrags ist es, eine Übersicht über den aktuellen Stand der Diskussion zu KI-Technologien in der Schule aus Sicht von Wissenschaft und Praxis zu liefern und damit Orientierungswissen für Lehrkräfte und weitere Vertreterinnen und Vertreter der Bildungspraxis und -verwaltung zu bieten. Dabei werden in der öffentlichen Debatte häufig geäußerte Argumente, die einer Nutzung von KI an deutschen Schulen scheinbar entgegenstehen, aufgegriffen, um sie vor dem Hintergrund der aktuell verfügbaren Evidenz einzuordnen. Naturgemäß kann es sich dabei aufgrund der hohen Dynamik des Themas in der Entwicklung von Technologien, ihrer Erforschung und der Anwendung in der Praxis nur um eine Momentaufnahme handeln. Aufgrund der hohen Bedeutung generativer KI wird diese Technologie in den Fokus gerückt. Auf andere KI-basierte Anwendungen wird jedoch Bezug genommen, um unter anderem die Notwendigkeit einer differenzierten Sicht auf KI zu verdeutlichen.

2. Funktionsweise und Verfügbarkeit von KI

2.1 **KI-Systeme: Ist KI gleich KI?**

Künstliche Intelligenz wird im alltäglichen Sprachgebrauch zum Teil mit spezifischen Anwendungen, wie beispielsweise *ChatGPT*, gleichgesetzt. Damit einhergehend wird zum Teil auch das Argument angeführt, dass alle KI-Anwendungen – insbesondere im Bildungsbereich und schulischen Kontext – mit denselben Herausforderungen (Datenschutz, Verzerrungen etc.) zu kämpfen haben.

Jedoch ist eine differenzierte Betrachtung lohnenswert: KI ist ein Bereich der Informatik, der sich auf die Schaffung von intelligenten „Maschinen“ mithilfe von Algorithmen konzentriert. Es existieren verschiedene Definitionen zum Begriff KI; eine Definition, die auch die Breite an unterschiedlichen Techniken verdeutlicht, stammt aus dem AI Act (Artificial Intelligence Act) der Europäischen Union. Dieser definiert KI als Software, die für einen gegebenen Satz von menschlich definierten Zielen Ausgaben wie Inhalte, Vorhersagen, Empfehlungen oder Entscheidungen erzeugen kann, die die Umgebungen beeinflussen. Nach dem AI Act gehören folgende Techniken zum Bereich KI:

- Maschinelles Lernen (umfasst auch überwachtes, unüberwachtes und bestärkendes Lernen), inklusive Deep Learning
- Logik- und wissensbasierte Ansätze, inklusive Wissensrepräsentation, induktives (logisches) Programmieren, Wissensbasen, Inferenz- und deduktive Schließsysteme, (symbolisches) Schließen und Expertensysteme
- Statistische Ansätze, Bayessche Schätzung, Such- und Optimierungsmethoden.

Diese Techniken bilden die Basis für verschiedene Anwendungen, die auch im Bildungsbereich eingesetzt werden bzw. dort als mögliche Lern- und Arbeitswerkzeuge diskutiert werden. Maschinelles Lernen ist zum Beispiel im Bereich der automatischen Spracherkennung im Bildungsbereich anzutreffen. Ansätze der natürlichen Sprachverarbeitung ermöglichen es in bestimmten, zuvor trainierten Einsatzszenarien, eine automatische Bewertung von geschriebenen Texten vorzuschlagen (Bernius et al., 2022) oder bestimmte Rückmeldungen bereitzustellen, je nach automatisch erkannten Aussagen in Texten (Sailer et al., 2023). Ein weiteres Beispiel sind Wissensrepräsentationen, mit denen versucht wird, Aspekte der Realität für Computer verständlich abzubilden. Sie sind im Bildungskontext häufig die Grundlage von intelligenten tutoriellen Systemen (ITS), die Unterstützung während der Bearbeitung bestimmter Aufgaben zur Verfügung stellen. Auch Vorhersagemodelle sind im Bildungskontext anzutreffen, z. B. um automatisiert Studienabbruch oder -erfolg anhand von Campus-Management-Daten (Logfiles) vorherzusagen (Scheidig & Holmeier, 2023).

Diese Beispiele aus dem Bildungskontext beziehen sich jeweils auf ganz bestimmte Einsatzszenarien und Aufgaben und werden deshalb auch häufig als *bildungsspezifische KI-Anwendungen* bezeichnet (z. B. Feedback-Systeme, ITS oder personalisierte Kurse). Aufgrund ihrer Entwicklung für spezifische Aufgaben werden die dahinterliegenden Systeme auch häufig als *Schwache KI* bezeichnet.

„Generative KI-Anwendungen, die allgemein nutzbar sind und nicht spezifisch für das Lehren und Lernen entwickelt wurden, sind zwar nicht bildungsspezifisch, aber selbstverständlich bildungsrelevante KI-Anwendungen“.

Starke KI – heute im aktuellen Diskurs auch *Artificial General Intelligence (AGI)* genannt – hingegen bezieht sich auf Systeme, die Aufgaben auf menschenähnlichem Niveau durchführen können, ohne auf eine spezifische Aufgabe beschränkt zu sein. Neuere Entwicklungen im Bereich der generativen KI können als ein Schritt auf dem Weg hin zu starker KI gesehen werden, da diese Systeme nicht auf spezifische Aufgaben beschränkt sind. *Generative KI* ist hierbei ein Sammelbegriff für KI-Anwendungen, die oftmals auf eine ganze Reihe an KI-Methoden zurückgreifen, diese kombinieren und große Datenmengen als

Grundlage nutzen (z. B. Large Language Models). Ziel von generativen KI-Anwendungen ist es, alle möglichen Ergebnisse und Produkte herzustellen, beispielsweise Texte, Bilder und Videos. Häufig werden generative KI-Anwendungen auch in Form von Chatbots eingesetzt. Chatbots sind Computerprogramme, die auf KI-Anwendungen zurückgreifen, um eine Konversation zu simulieren. Eines der bekanntesten Beispiele ist *ChatGPT*. Generative KI-Anwendungen, die allgemein nutzbar sind und nicht spezifisch für das Lehren und Lernen entwickelt wurden, sind demnach zwar nicht bildungsspezifisch, aber selbstverständlich *bildungsrelevante KI-Anwendungen*, da auch diese das Lernen mittel- und unmittelbar beeinflussen und verändern können.

Je nach Funktion und je nach zugrundeliegenden Ansätzen ergeben sich für KI-Systeme auch unterschiedliche Vor- und Nachteile. Datenschutzerfordernisse (siehe Abschnitt 2.2), Verzerrungen (Biases, Abschnitt 2.4) und Anwendungsszenarien können sehr unterschiedlich sein. Eine differenzierte Betrachtung von KI-Systemen ist somit erforderlich.

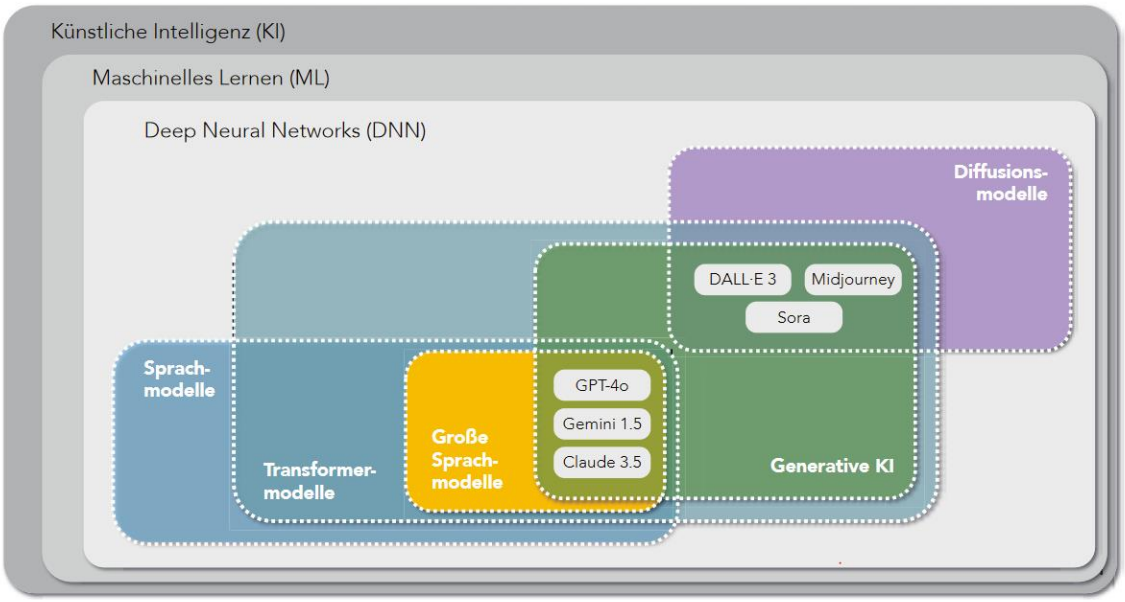


Abbildung 1. Einordnung von KI-Begriffen (Quelle: Buchholtz et al., 2024; Genehmigung zur Verwendung durch Autoren)

Definitionen (in Anlehnung an Buchholtz et al., 2024):

- *Maschinelles Lernen: Algorithmen, die es Computern ermöglichen, Entscheidungen auf Basis von Daten zu lernen und im Folgenden neue und unbekannte Daten zu klassifizieren.*
- *Deep Neural Networks: Mehrschichtige Netzwerke aus Knoten, die in der Lage sind, komplexe Muster in umfangreichen Datensätzen zu erkennen.*
- *Sprachmodelle: Speziell für die Verarbeitung und Erzeugung menschlicher Sprache entwickelte Modelle, die Texte verstehen, generieren und übersetzen können.*
- *Transformermodelle: Modelle mit spezieller Architektur, die es ermöglicht, lange Abhängigkeiten in Texten zu verarbeiten und kontextuell relevante Antworten zu generieren.*
- *Large Language Models (LLMs) bzw. große Sprachmodelle: Modelle, die anhand riesiger Datensätze trainiert wurden, menschenähnlichen Text zu generieren.*
- *Diffusionsmodelle: Modelle zur Generierung von visuellen und audiovisuellen Inhalten.*
- *Generative KI: Sammelbegriff für KI-Anwendungen, die oftmals auf eine ganze Reihe an KI-Methoden zurückgreifen und das Ziel haben, Ergebnisse und Produkte herzustellen, ohne auf eine spezifische Aufgabe beschränkt zu sein.*

2.2 Verhindern Datenschutz und Risikobewertungen die Nutzung von KI im Bildungskontext grundsätzlich?

Ein erster Impuls besteht häufig darin, eine Nutzung von KI im Bildungskontext aufgrund der möglichen Verletzung von Datenschutzbestimmungen der in Deutschland gültigen Datenschutzgrundverordnung (DSGVO) der Europäischen Union (EU) abzulehnen bzw. als nicht möglich einzuordnen. Dabei muss zunächst festgehalten werden, dass ein gesetzlich festgeschriebener Schutz personenbezogener Daten eine positive Anforderung darstellt, indem Grundrechte von Individuen auf Selbstbestimmtheit gestärkt werden und Transparenz als Voraussetzung für eine informierte Nutzung von Anwendungen eingefordert wird. Nach der DSGVO darf nicht von einer stillschweigenden Zustimmung von Nutzenden in die Verwendung ihrer Daten ausgegangen werden. Stattdessen müssen diese über die Erhebung von Daten informiert werden, sie müssen aktiv einwilligen, dies muss freiwillig geschehen und widerrufbar sein unter Einhaltung bestimmter Regularien. Daher ist auch im schulischen Kontext eine Auseinandersetzung mit Datenschutz als Unterrichtsgegenstand unumgänglich, aber auch für die Unterrichtsdurchführung, insbesondere beim Einsatz von Technologien, die Daten erheben und verarbeiten, essenziell.

Speziell für den Einsatz von KI ist der im August 2024 in Kraft getretene *AI Act* der EU relevant, der sich mit den Risiken von KI-Anwendungen auseinandersetzt. Dabei werden Anwendungen nach dem Grad des Risikos, das sich für ein Individuum z. B. aus diskriminierenden automatischen Einschätzungen einer Person ergibt, in vier Kategorien eingestuft: inakzeptabel, hoch, begrenzt und minimal. Zu den inakzeptablen und damit grundsätzlich in der EU verbotenen Anwendungen gehören die Echtzeiterkennung von Gesichtern im öffentlichen Raum und die automatische Erkennung von Emotionen im Bildungskontext oder am Arbeitsplatz. Hoch riskante Systeme sind solche, die Gesundheit, Grundrechte oder die individuelle Sicherheit stark beeinflussen können, indem sie beispielsweise Personen individuell auf der Basis von Persönlichkeits- oder Verhaltensmerkmalen bewerten. Diese Beurteilung kann auch auf KI-Anwendungen im Bildungsbereich zutreffen, der explizit als möglicher Anwendungsbereich für diese Art der Einstufung erwähnt wird. Ein wesentlicher Aspekt der Bewertung wird hier vermutlich sein, inwieweit KI-basierte Einschätzungen verzerrungsfrei sind, d. h. Individuen oder Personengruppen nicht diskriminieren.

Die Implikationen, die sich mittelfristig aus dem *AI Act* für den Einsatz von KI im Bildungskontext ergeben, sind derzeit aufgrund noch fehlender juristischer Bewertungen nicht genau absehbar. Fest steht jedoch, dass Anbieter von KI-Anwendungen eine deutlich stärkere Transparenz herstellen müssen, indem sie Trainingsmethoden und Datenverarbeitung ihrer Modelle offenlegen, um eine Risikobewertung zu ermöglichen.

Aus datenschutzrechtlicher Sicht bedenklich sind eine Vielzahl anmeldepflichtiger generativer KI-Anwendungen wie z. B. die kostenlose Version von *ChatGPT*. Diese Anwendungen werden in der Regel auf nicht-europäischen Servern gehostet und eine Nutzung ist oftmals nur mit einem individuellen Nutzerkonto unter Angabe einer Emailadresse möglich. Zudem werden Eingaben bzw. Prompts in der Regel für das fortlaufende Training des zugrundeliegenden Modells genutzt. Damit erfolgt eine Datenweitergabe außerhalb der EU, die nicht im Einklang mit der DSGVO steht, da diese Daten potenziell mit den Anmeldedaten der Person verknüpft werden können. Dies ist insbesondere dann problematisch, wenn die Prompts weitere personenbezogene Daten enthalten.

„Auch im schulischen Kontext ist eine Auseinandersetzung mit Datenschutz als Unterrichtsgegenstand, aber auch für die Unterrichtsdurchführung, insbesondere beim Einsatz von Technologien, die Daten erheben und verarbeiten, unumgänglich“.

Weder die DSGVO noch zukünftig der *AI Act* verhindern jedoch grundsätzlich den Einsatz von KI in der Schule, sondern sie legen fest, welche Anwendungen genutzt werden dürfen und unter welchen Umständen. Die Auslegung der Regularien fällt dabei derzeit in die Zuständigkeit der einzelnen Bundesländer. Eine Übersicht zum Umgang mit KI in den 16 Ländern wurde durch das Deutsche Schulportal der Robert Bosch Stiftung (Stand: 31. Oktober 2024) bereitgestellt.

Danach haben sich die meisten Bundesländer zu einem konstruktiven Umgang mit KI in der Schule entschlossen, indem sie bestimmte (kommerzielle) Anwendungen zulassen, für deren Anschaffung sie eigene Budgets und Erprobungsräume bereitstellen oder eigene KI-basierte Schnittstellenlösungen z. B. für die Nutzung von Chatbots entwickeln. Die KMK (2024) empfiehlt hierbei neben Beachtung der Rechtsgrundlage den Einbezug bereits vorhandener Prinzipien und Regulierungskriterien sowie die Schaffung möglichst einheitlicher Standards zur Prüfung von KI-Anwendungen. Dabei sollen Hinweise für die rechtskonforme Nutzung sowie eine länderübergreifende Empfehlung zur didaktischen Qualität der nutzbaren KI-Anwendungen bereitgestellt werden.

Aktuell lassen sich zwei Lösungsansätze im Umgang mit generativer KI unterscheiden:

- **Verwendung kostenpflichtiger Pro-Versionen generativer KI-Anwendungen:** Diese ermöglichen eine Konfiguration der persönlichen Einstellungen hin zu einem besseren Schutz persönlicher Daten. Insbesondere kann der Weitergabe der Eingaben für Trainingszwecke widersprochen werden.
- **Zugang über eine datenschutzkonforme Schnittstelle (API):** Existierende Chatbots können datenschutzkonform genutzt werden, indem diesen eine Schnittstelle vorgeschaltet wird, die keine individuelle Anmeldung als nutzende Person notwendig macht und die die Datenweitergabe unterbindet. Diese Technik machen sich beispielsweise kommerzielle Anbieter wie Fobizz oder auch schulKI zunutze. Hier können Lehrkräfte lizenzpflichtige Zugänge für Schülerinnen und Schüler ihrer Klassen anlegen. Beide Anbieter ermöglichen für einige Werkzeuge auch die Wahl zwischen verschiedenen Sprachmodellen. Verschiedene Länder wie z. B. Mecklenburg-Vorpommern und Rheinland-Pfalz bieten landesweit gültige Lizenzen für ihre Schulen an. Andere Länder stellen eigene datenschutzkonforme Schnittstellenlösungen zu existierenden generativen KI-Anwendungen wie ChatGPT bereit. Dazu gehören Sachsen (KAI), Sachsen-Anhalt (emuGPT/emuDALL:E), Baden-Württemberg (fAIrChat), oder Brandenburg (emu; eigene Schnittstelle angekündigt).

Zusätzlich existieren u. a. mit der KI-Toolbox von Cornelsen datenschutzkonforme Anwendungen für Lehrkräfte sowie weitere datenschutzkonforme, KI-basierte Bildungstechnologien, die spezifische Funktionen im Lehr-Lernprozess unterstützen. Letztere nutzen im Hintergrund zumindest teilweise generative Sprachmodelle als technologische Basis. Es handelt sich dabei um spezifisch für den Bildungskontext entwickelte Anwendungen, die die Vorgaben der DSGVO berücksichtigen. Hierzu zählen beispielsweise der Schreibassistent FelloFish (ehemals *fiete.ai*), der Lautlesetutor *LaLeTu* des Klett-Verlags oder das ITS von bettermarks (siehe Abschnitt 2.3). Auch bei der Verwendung solcher Anwendungen sollte die Lehrperson den Empfehlungen der KMK (2024) folgend mit den

Schülerinnen und Schülern besprechen, was Datenschutz bedeutet, was personenbezogene Daten sind und dass sie diese nicht in ihre Anfragen integrieren. Für den Einbezug von Datenschutz als Unterrichtsthema gibt es Angebote wie YoungData der Datenschutzkonferenz, klicksafe der Medienanstalt Rheinland-Pfalz, Data-Kids (Berliner Beauftragte für Datenschutz und Informationsfreiheit) oder das Lehrerhandout Datenschutz geht zur Schule.

Damit Dritte (z. B. Datenschutzbeauftragte, Verantwortliche in der Bildungsverwaltung) Einschätzungen zum Datenschutz sowie Risikobewertungen vornehmen können, müssen Urheberinnen und Urheber für ihre KI-Systeme Details zur Entwicklung und Funktion deutlich transparenter dokumentieren als dies bisher der Fall ist. Nach Chaudhry et al. (2022) sollten die folgenden Fragen dabei Berücksichtigung finden: Welche Sicherheitsmaßnahmen gibt es, um schädlichen Effekten von KI vorzubeugen (*Safety*)? Auf welcher Basis werden Entscheidungen durch die KI getroffen (*Explainability*)? Welche Verzerrungen existieren im KI-System (*Fairness*)? Wer ist verantwortlich bei fehlerhaften Vorhersagen des Modells (*Accountability*)? Sind die Erklärungen der KI verständlich für die Nutzenden (*Interpretability*)?

Diese Fragen sind durch Lehrpersonen nicht eigenständig zu beantworten, aber das Bewusstsein darüber hilfreich bei der Entscheidung für bzw. gegen den Einsatz von KI-Systemen. Zukünftig soll *EduCheck* digital Unterstützung bei der Bewertung des Datenschutzes und Risikos bieten. Hierbei handelt es sich um ein länderübergreifendes Vorhaben (2022-2026) zur Entwicklung eines Prüfverfahrens für digitale Bildungsmedien, welches durch das FWU (Institut für Film und Bild in Wissenschaft und Unterricht gGmbH) umgesetzt wird und mit dem Schulen bei der Suche nach geeigneten Bildungsmedien insbesondere bei der rechtlichen und technischen Prüfung unterstützt werden sollen. Geprüfte Bildungsmedien sollen mit einem Prüfsiegel versehen werden, wenn sie das Prüfverfahren anhand eines standardisierten Kriterienkatalogs durchlaufen haben. Als Reaktion auf die zunehmende Verbreitung KI-basierter Anwendungen haben die Länder entschieden, eduCheck digital auf das Thema KI auszuweiten und hierfür einen eigenen Prüfbereich bzw. eine Integration KI-bezogener Kriterien in bestehende Prüfbereiche vorzusehen.

2.3 Macht die mangelnde Verfügbarkeit von KI den Einsatz in der Schule unmöglich?

Ein Argument gegen die Nutzung von KI im schulischen Bildungskontext basiert auf der Feststellung, dass bislang kaum KI-basierte Anwendungen existieren, die pädagogisch sinnvoll und datenschutzkonform genutzt werden können. Die wenigen existierenden Angebote seien oftmals teuer. In der Tat gibt es im Vergleich zu anderen europäischen und außereuropäischen Ländern in Deutschland noch relativ wenige speziell für den Bildungskontext entwickelte KI-Anwendungen. Insbesondere fehlen umfassende fachspezifische Anwendungen, die mit einem hohen Entwicklungsaufwand verbunden sind, wie beispielsweise ITS. Allerdings verändert sich das Angebot von KI-Anwendungen, die für den Bildungskontext relevant sein können, derzeit innerhalb kürzester Zeit. Zum einen wird auch generative KI für die Schule nutzbar, indem zunehmend Schnittstellenlösungen zur Einhaltung von Datenschutzbestimmungen (siehe Abschnitt 2.2) entwickelt werden. Zum anderen lässt sich die technische Basis von Anwendungen wie ChatGPT für eine relativ einfache Entwicklung KI-basierter Bildungsanwendungen wie bildungsspezifischen Chatbots oder automatischen Bewertungs- und Feedbacksystemen anwenden. So beruht beispielsweise FelloFish als System zur automatischen Bewertung von Essays und zur Vergabe von elaborativem Feedback auf einem allgemeinen Transformer-Modell. Aufwändig

bleibt hingegen die Produktion von ITS und zwar sowohl im Hinblick auf die dafür notwendige Modellierung des Gegenstandsbereichs und der Wissensbasis der Lernenden als auch die Generierung redaktionell geprüfter Übungs- und Lernmaterialien. Entsprechend ist zum jetzigen Zeitpunkt nach wie vor Bettermarks das einzige für den deutschen Markt verfügbare ITS (Mathematik). Hier bleibt abzuwarten, welche Funktionalitäten das durch die Länder beauftragte Adaptive Intelligente System (AIS), welches 2026 für ausgewählte Inhaltsbereiche auf dem Markt verfügbar sein soll, bieten wird.

„Die Verfügbarkeit von KI für den schulischen Kontext wird zum einen durch das sich hoch dynamisch erweiternde Angebot auf dem Markt bestimmt. Zum anderen wird die Verfügbarkeit von KI-Anwendungen in Schulen sehr stark durch die Regulation von Zugriffs- und Beschaffungsmöglichkeiten beeinflusst.“

Besonders bei neu entwickelten KI-basierten Bildungstechnologien scheint eine Übergangsphase der Nutzung mit wissenschaftlicher Evaluation wichtig, um ihre Lernwirksamkeit zu bestimmen und das Angebot datengestützt zu verbessern (SWK, 2024). Die Verfügbarkeit von KI für den schulischen Kontext wird zum einen durch das sich hoch dynamisch erweiternde Angebot auf dem Markt bestimmt. Ständig aktualisierte Übersichten bieten z. B. die Webseite www.find-my-tool.io, auf der verschiedene KI-Anwendungen nach unterschiedlichen Aufgaben- und Funktionsbereichen zusammengestellt werden; das *Virtuelle Kompetenzzentrum: Künstliche Intelligenz und wissenschaftliches Arbeiten* (VK: KIWA) oder englischsprachig www.futurepedia.io.

Zum anderen wird die Verfügbarkeit von KI-Anwendungen in Schulen sehr stark durch die Regulation von Zugriffs- und Beschaffungsmöglichkeiten beeinflusst. Für die Schulen besteht eine Herausforderung in der Anschaffung und Finanzierung von Softwarelizenzen, für die bisher nur einige Bundesländer sogenannte KI-Budgets oder Landeslizenzen für bestimmte Anwendungen zur Verfügung stellen (siehe Übersicht Deutsches Schulportal, s.o.). Ebenso wie für die Anschaffung von Hardware gibt es jedoch keine einheitlichen Regelungen für die Finanzierung und Beschaffung von Software, und es ist nicht gewährleistet, dass alle Schulen Zugriff auf eine bestimmte Ausstattung erhalten. Aufgrund fehlender Regelungen und flächendeckender Versorgung besteht so die Gefahr eines Digital Divide erster Ordnung (Gottschalk & Weise, 2023) dahingehend, dass Schülerinnen und Schüler in sozial privilegierten Schuleinzugsgebieten bzw. aus sozioökonomisch besser gestellten Elternhäusern eher Zugang zu hochwertigen digitalen, KI-gestützten Bildungsangeboten erhalten als Lernende aus weniger privilegierten Verhältnissen. Werden KI-basierte Werkzeuge nicht für alle Schülerinnen und Schüler finanziert, besteht zudem die Gefahr, dass Kinder und Jugendliche, deren Eltern den Kauf teurerer Lizenzen für datenschutzkonforme Varianten generativer KI nicht leisten können, stattdessen kostenfreie Varianten nutzen; diese Varianten verfügen nicht nur meist über einen geringeren Funktionsumfang und eine kleinere Datenbasis, sondern mitunter auch über ein geringeres Datenschutzniveau. Diese Schülerinnen und Schüler bezahlen dann die Nutzung von KI mit ihren eigenen Daten und einer eingeschränkten Sicherheit und Privatheit. Entsprechend empfiehlt die Ständige Wissenschaftliche Kommission in ihrer Stellungnahme zu Large Language Models im Bildungsbereich, dass staatliche Organisationen sicherstellen müssen, “dass alle Lernenden und Lehrenden in Bildungseinrichtungen einen (kostengünstigen oder kostenfreien) Zugriff auf KI-Systeme haben” (SWK, 2024, S. 4).

2.4 Trifft KI objektivere und fehlerfreiere Aussagen als Menschen?

Eine gängige Annahme für den Einsatz von KI ist neben der schnellen Verarbeitung einer Vielzahl an Informationen, dass sie weniger Fehler macht, objektiver sei und weniger Verzerrungen z. B. durch Meinungen, Laune oder Einstellungen unterliegt. Dadurch wäre dann eine fairere und fehlerfreie Bewertung von Lernenden möglich.

Wie unter Abschnitt 2.1 eingeführt, gibt es bildungsspezifische Anwendungsszenarien für KI. Lernende können z. B. auf Basis unterschiedlicher Merkmale bestimmten Gruppen zugeordnet werden (Clustering), Muster in digitalem Lernverhalten identifiziert werden (Dimensionsreduktion) und mit Lernerfolg verknüpft werden, der dann vorhergesagt werden kann (Regression). Unter Berücksichtigung weiterer Informationen über Lernende (z. B. Bildungshistorie, demographische Merkmale, Beeinträchtigungen) können so frühzeitig gefährdete Lernende erkannt und zeitnahe Interventionen ermöglicht werden. Interventionen können z. B. automatisierte Empfehlungen in der digitalen Lernumgebung zu Lernmaterialien oder Empfehlungen zur Anpassung von Lernstrategien sein, um Lernprozesse zu verbessern, aber auch die Lehrperson kann zu Interventionen aufgerufen werden (z. B. Anpassung von Lernmaterialien, die für viele Lernende schwierig waren, Gespräch mit Lernenden). Dies kann nicht abstrahiert von individuellen Faktoren der Lernenden oder der Lerngruppe sowie des Kontexts geschehen, da diese maßgeblich für das Verständnis und die Optimierung von Lernprozessen und -erfolg sind. Individuelle Faktoren (z. B. Alter, Geschlecht, Herkunft, Bildungshistorie, Lernstrategien) sind aufgrund von Datenschutzregularien oder fehlender Datenintegration häufig nicht verfügbar.

„Aufgrund der Verzerrungen kann es zu fehlerhaften Klassifizierungen, Vorhersagen, Gruppenbildungen und Empfehlungen kommen. Im Vergleich zu Film- oder Produktempfehlungen auf Online-Produktplattformen können solche Fehler im Bildungsbereich insbesondere in der formellen Bildung zu folgenschweren Konsequenzen führen und Bildungsverläufe maßgeblich beeinflussen“.

Durch kontextuelle Spezifika (z. B. Lernziele, Klassenstufe, Region) sind die Datensätze, auf denen Künstliche Intelligenz im Bildungsbereich trainiert werden kann, meist verhältnismäßig klein. Künstliche Intelligenz ist dabei nur so gut, wie die Daten, auf denen sie beruht. Bereits bei der Datensammlung kann es zu Verzerrungen kommen (Baker & Hawn, 2022), wie z. B. die Nutzung von Datensätzen, die nicht die aktuelle Realität widerspiegeln und vorurteilsbehaftet sind, die nicht alle Gruppen ausreichend repräsentieren, die Messfehler beinhalten oder in denen relevante Daten bzw. Indikatoren fehlen. Auch unabhängig von den Daten können die Algorithmen fehlerhaft sein oder statistische Ungenauigkeiten haben, die für weniger typische Fälle stärker ausfallen können. Auch Algorithmen, die auf anderen Daten trainiert wurden, als sie später angewendet werden, können zu verzerrten Ergebnissen führen. Durch die Empfehlung, die Algorithmen bereitstellen, beeinflussen sie das Verhalten der Nutzenden, welches wieder als Datengrundlage für den lernenden Algorithmus dient und so zu einer fehlerhaften Feedbackschleife führen kann.

Aufgrund der Verzerrungen kann es also zu fehlerhaften Klassifizierungen, Vorhersagen, Gruppenbildungen und Empfehlungen kommen, welche bestimmte Gruppen stärker betreffen kann. Im Vergleich zu Film- oder Produktempfehlungen auf Online-Produktplattformen können solche Fehler im Bildungsbereich insbesondere in der formellen Bildung zu folgenschweren

Konsequenzen führen und Bildungsverläufe maßgeblich beeinflussen (z. B. Zulassung zu Hochschulsystemen auf Basis von Leistungsvorhersagen, fehlerhafte Bewertungen in automatisiert ausgewerteten Prüfungen, Einfluss auf Selbstwirksamkeit durch Klassifizierung als Risiko-Lernende).

Auch bildungsrelevante KI-Anwendungen (siehe Abschnitt 2.1) sind nicht frei von Fehlern. Bei LLMs wie ChatGPT wird auf eine sehr große Datenmenge aus dem Internet (z. B. Blogs, Zeitschriftenartikel, Websites, Kurznachrichtendienste) zunächst unüberwachtes maschinelles Lernen unter Verwendung eines neuronalen Netzes eingesetzt, um die Ähnlichkeiten, Verbindungen und Muster von Tokens (numerische Repräsentation von Wortteilen) zu lernen. Bei einer Eingabe von Tokens in Form eines Prompts können dann entsprechend des Modells die nächsten wahrscheinlichen Tokens in Form von Wörtern ausgegeben werden. In der überwachten maschinellen Lernphase wird das entstandene neuronale Netz angepasst, indem Menschen die durch das LLM generierten Antworten evaluieren und so ethische und moralische Grenzen, aber auch richtige und fehlerhafte Antworten gelernt werden können. Durch verstärkendes Lernen wird zusätzlich ein Modell generiert, welches die menschlichen Präferenzen für die vom jeweiligen LLM generierten Antworten beinhaltet. Diese Schritte werden mehrfach wiederholt. Dabei können Verzerrungen entstehen durch Fehler, veraltete Informationen, einseitige Sichtweisen, Diskriminierung und Stereotype, die bereits in den Daten enthalten sind, mit denen das Modell trainiert wird.

Beispiel aus der Praxis für die „Vorurteile“ der KI

Ein Paradebeispiel ist hierfür, dass ChatGPT selbst in der Version 4o bei einer Anfrage "Erstelle mir eine Liste der 10 wichtigsten Philosophen!" zwar eine Auswahl präsentiert, die "verschiedene Epochen und Schulen" laut eigener Aussage abdeckt, aber dann dennoch nur sehr eurozentriert auflistet. Zudem werden keinerlei weibliche Vertreterinnen präsentiert. Manche Anbieter von LLMs stellen zudem mittlerweile auch sog. "Custom Bots" zur Verfügung, die in die Rolle eines "künstlichen Zeitzeugen" schlüpfen können. Gerade bei diesen Angeboten ist aber ein weiterer Quellencheck unvermeidlich, da die Trainingsdaten oft noch nicht in die Tiefe gehen.

Künstliche Intelligenz wird immer auf historischen Daten trainiert, was einen historischen Bias begünstigt. Laut open.ai ist das Modell von ChatGPT verzerrt in Richtung westlicher Sichtweisen, funktioniert besser auf Englisch, und Maßnahmen für die Vermeidung von schädlichem Inhalt sind vornehmlich auf Englisch getestet. Aber auch durch die Trainingsschritte, in denen Menschen die generierten Antworten evaluieren, können Fehler entstehen oder deren Weltsicht das Modell beeinflussen. Zusätzlich ist die Generierung der Antworten durch die Nutzenden größtenteils nicht nachvollziehbar[1]. Mögliche Einseitigkeiten oder Fehler können die Nutzenden beeinflussen bzw. das genutzte LLM verstärkt die Stereotype der Nutzenden, indem es ihnen zustimmt. ChatGPT und andere LLM geben moralische Bewertungen in ihren Antworten, die wiederum die moralische Urteilsfähigkeit der

[1] Zwar sind sogenannte *Reasoning*-Modelle (zum Zeitpunkt der Berichtlegung insbesondere DeepSeek *R1*, OpenAI *o3 mini* und Google *Gemini 2.0 Flash Thinking*) dazu in der Lage, Nachdenkprozesse zu imitieren und diese transparent zu machen. Diese expliziten Prozesse umfassen jedoch hauptsächlich die logische Herangehensweise des Modells und gerade *nicht* inhaltliche Implikationen.

rezipierenden Person beeinflussen können, welche diese Beeinflussung unterschätzt (Krügel et al., 2023).

Somit unterliegen auch Menschen kognitiven Verzerrungen, die in die Algorithmen einfließen bzw. durch diese verstärkt werden können. Forschung zur Urteilsverzerrungen von Lehrpersonen zeigt z. B., dass insbesondere Lehrpersonen mit noch geringer Expertise von Ankern zur Vorleistung beeinflusst werden. Bei folgenreichen Diagnosen wie Schullaufbahnempfehlungen zeigte sich bei Lehrpersonen mit Expertise, dass diese relevante Personenmerkmale berücksichtigen und weniger anfällig waren für Fehlentscheidungen und Urteilsverzerrung durch den Anker (Deutschvornote) (Dünnebier et al., 2009). Es zeigten sich aber auch fachspezifische Unterschiede insofern, als dass in Mathematik sowohl Novizen als auch Experten durch Vornoten als Anker beeinflusst wurden und zwar sowohl bei folgenreichen Diagnosen als auch, wenn sie sich lediglich einen ersten Eindruck über die Schülerinnen und Schüler verschaffen sollten (Dünnebier et al., 2009). Auch hinsichtlich des ethnischen Hintergrunds und dem sozioökonomischen Status zeigen sich bei Lehrpersonen stereotype Verzerrungen in Bezug auf die Leistungserwartung der Schülerinnen und Schüler in Deutsch und Mathematik (Lorenz et al., 2016). Aufgrund fehlerhafter Annahmen über Lernende kann es zu unterschiedlicher Behandlung der Lernenden durch die Lehrpersonen kommen und die Leistung dann tatsächlich entsprechend beeinflusst werden (vgl. Pygmalion-Effekt).

In einer Studie mit Achtklässlern (Bewersdorff et al., 2023) wurden Versuchsprotokolle durch Menschen und ein trainiertes LLM hinsichtlich verschiedener Fehler bewertet. Die Übereinstimmung von menschlichen Bewertenden war recht hoch. Der Vergleich der Übereinstimmung zwischen Mensch-Mensch und Mensch-KI bei einigen grundlegenden Fehlertypen war ebenfalls sehr hoch, bei anderen, eher komplexen Fehlern aber gering. Diese Diskrepanzen könnten durch widersprüchliche Aussagen der Schülerinnen und Schüler oder durch unterschiedliche Bezeichnungen derselben Dinge im Verlauf des Protokolls verstärkt worden sein.

In einer aktuellen Studie wurde GPT-4 die zu lesende Literatur und die studentischen Antworten auf Fragen übergeben. Der Chatbot sollte die Antworten mit vorgegebenen Bewertungskriterien (z. B. inhaltliche Relevanz, faktische Korrektheit) und einem Notenschema benoten (Jauhiainen & Garagorry Guerra, 2024). Bei je 10 Bewertungsdurchläufen derselben Antwort vergab GPT-4 in ca. zwei von drei Fällen (69%) dieselbe Note; in jedem vierten Fall (27%) resultierten zwei Bewertungen in einer Diskrepanz von einer Note. Der Vergleich zwischen den Bewertungen von GPT-4 und Lehrenden zeigte allerding lediglich in jedem vierten Fall (26%) übereinstimmende Noten; in etwa der Hälfte der Fälle (46%) lag eine Abweichung um eine Note vor, bei einem weiteren Viertel (24%) betrug die Abweichung zwei Noten. Hierbei war die Qualität der Prompts an das LLM ein entscheidender Faktor. Bei der Bewertung von Abschlussprojektberichten zeigte der Vergleich zwischen den Bewertungen durch Menschen und *GPT-4* eine schlechte Übereinstimmung. Dies änderte sich auch nicht deutlich, wenn paraphrasierte Bewertungskriterien und explizite Rubrics verwendet wurden.

Hinsichtlich der Wahrnehmung von KI-generiertem Feedback und Expertenfeedback zeigte sich in einer Studie von Jansen et al. (2024), dass eine Mehrzahl der teilnehmenden angehenden Lehrpersonen Expertenfeedback als nützlicher empfanden als Feedback einer generativen KI und sie Expertenfeedback auch eher Lernenden bereitstellen würden. Dennoch haben dabei 23 Prozent der Teilnehmenden im direkten Vergleich der Feedbacks das KI-generierte Feedback als nützlicher erachtet, was für die zukünftigen Entwicklungsstufen von generativer KI hoffen lässt und gerade vor dem Hintergrund der

möglichen Zeitersparnis zu berücksichtigen ist. Zudem haben die angehenden Lehrpersonen das KI-generierte Feedback in 85 Prozent der Fälle richtig identifizieren können.

Um Limitationen und mögliche Verzerrungen durch Mensch und Künstliche Intelligenz zu verringern, werden sogenannte Human-in-the-Loop-Ansätze im Bildungsbereich vorgeschlagen (Ninaus & Sailer, 2022). Künstliche Intelligenz kann den Menschen dabei unterstützen, schnell Muster, Trends oder Anomalien in großen Datenmengen zu erkennen oder wiederkehrende und langwierige Aufgaben vorzubereiten, deren Ergebnisse und Vorschläge dann durch die Lehrperson überprüft werden. Dabei sollte KI immer nur als ein unterstützendes Werkzeug betrachtet werden, dessen Einsatz verantwortungsvoll stattfinden muss. Außerdem wird der Fokus auf sogenannte nachvollziehbare oder erklärbare KI gelegt, die Erläuterungen anbietet, auf Basis welcher Informationen die Ergebnisse entstanden sind, welche Indikatoren welchen Einfluss haben oder wie die zugrundeliegenden Algorithmen funktionieren. Dies ermöglicht es, den Nutzenden nachvollziehbare Entscheidungen seitens der KI zu präsentieren, was bei unüberwachtem Lernen und komplexen Modellen aber schwierig ist. Außerdem sollten Modelle weiterentwickelt werden und vorrangig eingesetzt werden, die wissen, wenn sie nichts wissen, so dass fehlerhafte oder wenig valide Ergebnisse gar nicht erst angezeigt werden und Anwendungen wie ChatGPT nicht „halluzinieren“ (vgl. hierzu Abschnitt 3.2). Hierfür sind auch fortlaufende Kontrollen der Ergebnisvalidität und der Genauigkeit der Modelle notwendig.

Zusammenfassend ist es vor diesem Hintergrund unumgänglich, Kompetenzen sowohl bei Lehrpersonen (siehe Abschnitt 4.2) als auch bei Lernenden aufzubauen, so dass sie über die Möglichkeiten sowie die Limitationen von KI und Bildungsdaten informiert sind. Eine allgemeingültige Aussage, ob KI objektivere und fehlerfreiere Ergebnisse erzielt als Menschen, kann aktuell nicht getroffen werden, hierzu bedarf es weiterer systematischer Untersuchungen insbesondere hinsichtlich der beeinflussenden Faktoren (z. B. Aufgabentypen, Fehlertypen, Prompts). Insbesondere für das Erzielen von akkuraten Bewertungsergebnissen mittels generativer KI sind hohe Kompetenzen in der Erstellung von Bewertungskriterien und Prompts wichtig. Um also die Vorteile von KI und Mensch gewinnbringend einzusetzen und Verzerrungen zu verringern, sind Wissen und das Bewusstsein über Vorurteile bei den Nutzenden, aber auch den Entwickelnden unumgänglich.

3. Lernen und KI

Der Lehrer Joscha Falck beschreibt in seinem Blog fünf Dimensionen, anhand derer sich das Verhältnis von KI und Lernen beschreiben lässt: *Lernen mit KI* spezifiziert Anwendungs- und Strategiewissen als Voraussetzung für eine lernförderliche Nutzung von KI. *Lernen über KI* benennt das notwendige Wissen über die Funktionsweise von KI sowie gesellschaftliche, ethische, wirtschaftliche und politische Implikationen ihrer Nutzung. *Lernen durch KI* beschreibt Möglichkeiten der Unterstützung von Lernprozessen durch KI. Für diese drei Beziehungen müssen Lerngelegenheiten geschaffen werden, damit KI sinnvoll in Bildungsprozesse eingebunden werden kann. Die übrigen beiden Dimensionen zeigen Grenzen der Nutzung von KI in der Schule auf: *Lernen trotz KI* betont die Notwendigkeit von Reflexions- und Diskussionsmöglichkeiten zu der Frage, warum Schülerinnen und Schüler noch eigenständig Wissen erwerben sollen, wenn die Maschine doch alles besser weiß. *Lernen ohne KI* betont, dass es auch weiterhin schulische Bildungsprozesse ohne digitale Anwendungen geben muss.

Praxisbeispiele und Materialhinweise für Lernen und KI mit Fokus Grundschule:

Lernen über KI

- Bei FOBIZZ findet sich als Unterrichtsmaterial für die Grundschule die Kollektion „Die Welt der künstlichen Intelligenz für die Grundschule“, die einen Einstieg in das Thema Künstliche Intelligenz für die Grundschule bietet mit Fokus auf KI-Chatbots und die Bilderstellung mit KI.
- Wie funktionieren KI-basierte Textgeneratoren? Mit dem speziell für den Unterricht entwickelten Textgenerator *SoekiaGPT* können einige Grundprinzipien dieser Technologie entdeckt werden (mit Handreichung für Lehrkräfte)

Lernen durch KI

- *Meister Cody* ist ein Beispiel für KI-unterstützte Software zur Diagnostik und individuellen Förderung für Schulen: Mit Meister Cody werden die Schülerinnen und Schüler individuell im Rechnen, Lesen und Rechtschreiben gefördert. Die Software soll dabei unterstützen, nachhaltige Lernerfolge zu erzielen.
- FelloFish kann als Feedbackinstrument bei Schultexten eingesetzt werden um Schreibkompetenzen zu stärken (Vorstellungsvideo beim Deutschen Schulportal)
- In der Grundschule kann KI beispielhaft beim Thema Bildbeschreibung zum Einsatz kommen: Schülerinnen und Schüler lernen beispielsweise eine Bild-generierende KI-Anwendung kennen. Sie beschreiben die Kunstwerke bedeutender Malerinnen und Maler und überprüfen anschließend, ob ihre Bildbeschreibungen präzise genug sind, um mit einer KI-Anwendung ein ähnliches Bild zu generieren. Somit lernen sie auch, worauf es beim Formulieren von Prompts ankommt:
    - Lernende beschreiben möglichst genau ein vorgegebenes Bild und prompten dann die komplette Bildbeschreibung in einen Bildgenerator. Anschließend vergleichen sie Original und das von der KI erzeugte Bild.
    - Fobizz Galerie / Digitale Tafel: Der malende Roboter – KI spielerisch bedienen lernen
    - Fächerübergreifender Unterricht, Kunst: Merkmale künstlerische Gestaltung: Was braucht es unbedingt, um den Gegenstand zu erkennen
    - „Quick, Draw!“ zur Illustration, welche Zeichnungen die KI als entsprechendes Objekt erkennen kann
- Adaptive Lernplattformen: Meister Cody, ITS bettermarks

Lernen mit KI

SuS sollten mögliche Anwendungsbereiche von KI im Schulalltag mithilfe von KI ausprobieren und deren Chancen und Risiken reflektieren (z. B. bei der Erstellung von Präsentationen, Referaten oder Bewertung von Texten)

Mögliche Lernziele:

- Formulieren effektiver Prompts
- Kritisch-reflektierter Umgang unter Berücksichtigung der Grenzen von KI sowie ethischer Herausforderungen (siehe auch Abschnitt 2.4)

- Datenschutz (siehe auch Abschnitt 2.2)
- Grundvoraussetzungen und Chancen in der Mehrperspektivität
- Einschränkungen in der Kreativität

Lernen trotz KI

- Ggf. Sensibilisierung z. B. im Ethikunterricht, dass Verlassen auf KI auch zu Fremdbestimmung und Verantwortungsabgabe führen kann (Unterrichtsbeispiel)
- problematische Aspekte von "Deepfakes" (Artikel in „Die Bayerische Realschule“))

Lernen ohne KI

Verweis auf die Kulturtechniken des Schreibens oder motorische Fächer; Aspekte der Grundbildung; Bedeutung der pädagogischen Beziehung.

Limitationen beim Einsatz von KI in der Grundschule

Das Lernen mit KI bietet viele Vorteile, hat aber klare Grenzen, besonders bei Grundschulkindern. Hier sind einige wichtige Aspekte:

1. Fehlende soziale und emotionale Interaktion

- Grundschulkinder lernen stark durch zwischenmenschliche Beziehungen, z. B. durch Mimik, Gestik und Empathie. KI kann keine echte menschliche Wärme oder Beziehungsaufbau bieten, was im Grundschulalter zentral ist.
- Soziale Fähigkeiten wie Teamarbeit, Konfliktlösung und Empathie können nicht allein durch KI vermittelt werden.

2. Begrenztes Verständnis für individuelle Bedürfnisse

- KI kann differenzierte Aufgaben anbieten, aber sie erkennt keine subtilen, nonverbalen Signale, wie Frustration, Überforderung oder Langeweile[2].
- Kinder mit besonderen Bedürfnissen (z. B. Förderbedarf oder Hochbegabung) benötigen oft einen individuelleren Ansatz, den KI nicht in vollem Umfang leisten kann.

3. Fehlende Kreativität und Spontanität

- Kreatives Denken und freies Spiel sind zentral für Grundschulkinder. KI bietet strukturierte Aufgaben, kann bisher aber selten spontane, kreative Momente oder offene Problemstellungen fördern.

4. Risiko der Überforderung

- Kinder könnten durch zu viele digitale Angebote oder Aufgaben schnell überfordert werden. Insbesondere jüngere Kinder brauchen klare Strukturen und Pausen von Bildschirmen, um gesund zu lernen.

[2] Einige aktuelle KI-Modelle erkennen solche Signale allerdings mitunter, wenn sie verbal (in Textform) oder auch paraverbal (z. B. Intonation bei der Spracheingabe) geäußert werden.

5. Fehlende Bewegung und Sinneserfahrungen

- Lernen im Grundschulalter ist stark mit Bewegung und Sinneserfahrungen verknüpft. KI kann das praktische Lernen, wie Basteln, Bauen oder naturwissenschaftliche Experimente, nicht ersetzen.

6. Gefahr der Abhängigkeit

- Wenn Kinder zu stark auf KI-gestützte Lernmethoden setzen, könnten es schwieriger für sie werden, selbstständig (ohne digitale Unterstützung) Lösungen für Probleme zu finden.

7. Ethik und Datenschutz

- Die Nutzung von KI setzt eine verantwortungsvolle Datenerhebung voraus. Besonders bei Kindern muss sichergestellt werden, dass ihre Daten sicher und anonym bleiben.

8. Motivationsprobleme

- Grundschulkinder brauchen oft unmittelbares, positives Feedback und Lob, das authentisch wirkt. KI gibt zwar Rückmeldungen, aber diese fühlen sich möglicherweise nicht so motivierend an wie von einer realen Person.

Fazit: Ergänzung, kein Ersatz

KI kann ein wertvolles Werkzeug sein, z. B. für differenzierte Aufgaben, interaktive Übungen oder spielerisches Lernen. KI knüpft an die Lebenswirklichkeit der Kinder an und muss somit einen Platz in einem zeitgemäßen Unterricht haben (Kinder haben Vorwissen, das in Relation gesetzt und weiterentwickelt werden muss). KI sollte aber immer nur ergänzend eingesetzt werden und kann keine echten sozialen, kreativen und praktischen Lernmethoden ersetzen.

Hinweise für Lehrkräfte und Lernende mit Fokus Sekundarstufe

In Bezug auf KI-Kompetenzen sind die Meisten Lernende. Einen Einblick darin, welche Kompetenzen in einer von KI geprägten Welt sowohl für Lehrkräfte als auch für Schülerinnen und Schüler erforderlich sind, beschreibt Joscha Falk hier.

Der richtige Umgang mit KI erfordert auch eine Auseinandersetzung mit philosophischen und ethischen Fragen. Unterrichtsmaterialien zur ethischen Auseinandersetzung mit Fragen rund um die KI finden sich für Schülerinnen und Schüler ab 15 Jahren auf der Bildungsplattform „Wandel vernetzt denken“. Ziel ist es, die Entwicklungen selbstbestimmt und aktiv mitzugestalten.

Die Schülerinnen und Schüler werden in eine von KI geprägte Arbeitswelt entlassen. Um auf die damit verbundenen Herausforderungen und Anforderungen vorbereitet zu sein, stellt für die Klassenstufen 9-13 beispielsweise die Telekom Bildungsmedien und Unterrichtsmaterialien zum Thema „KI in der Arbeitswelt“ zur Verfügung.

Als zentrale Ergebnisse aus einem von bildung.digital 2023 initiierten Pilotversuch „KI im Klassenzimmer“, in dem in 71 Schulen ChatGPT im Unterricht eingesetzt wurde, zeigte sich, dass neben einer hinreichenden technischen Infrastruktur und Ausstattung an den Schulen insbesondere „gute Planung“ und „pädagogisches Fingerspitzengefühl“ notwendig sind, um KI im Unterricht sinnvoll einsetzen zu können.

Ein Beispiel für ein nicht auf generativer KI basierendes fachdidaktisch einsetzbares intelligentes Tutoring-System ist das Sprachtutoring-System „Feedbook“. Den Schülerinnen und Schülern werden sofortiges Feedback gegeben und adaptiv Aktivitäten vorgeschlagen, die zu den individuellen Lernwegen passen. Das System konzentriert sich aktuell auf den Englischlehrplan der 7. Klasse.

3.1 Lernziele: Benötigen wir mit dem Aufkommen von KI kein Faktenwissen mehr?

Die zunehmende Integration von KI in Arbeits- und Alltagskontexte wirft die Frage auf, ob in der Schule neben übergreifenden Kompetenzen perspektivisch überhaupt noch Faktenwissen gelernt werden sollte.

Insbesondere generative KI-Systeme wie ChatGPT ermöglichen einen noch intuitiveren und leichteren Zugang zu den nahezu unbegrenzten Informationen des Internets als bereits traditionelle Suchmaschinen, so dass Faktenwissen sehr schnell und einfach zugänglich erscheint. Darüber hinaus unterstützen oder übernehmen KI-Systeme zunehmend Aufgabenbereiche, die zuvor autonom von entsprechend qualifizierten Menschen ausgeführt wurden. Hierunter fällt ein weites Aufgabenspektrum, von der Automatisierung von Routineaufgaben (z. B. Empfehlungssysteme, intelligente Assistenten), über motorische Aufgaben (z. B. Zusammenbau von Bauteilen) und Kommunikation (z. B. Kundensupport), bis hin zu komplexen Tätigkeiten, die mit professioneller Expertise-Entwicklung assoziiert werden (z. B. bildgebende Diagnostik in der Medizin mit Computertomographie etc.; Briganti & Le Moine, 2020; Elliott, 2019). Was also sind angesichts dieser Entwicklungen zukunftsfähige Bildungsziele, die in der Schule weiterhin oder aber auch neuerdings adressiert werden sollten?

Diese Frage knüpft an frühere digitalisierungsbezogene Diskussionen zu Bildungszielen an, die mit den fortschreitenden technologischen Entwicklungen umso relevanter werden. Beispielsweise wurde bereits mit zunehmender Verbreitung und Zugänglichkeit des Internets die Frage aufgeworfen, ob das Lernen von Faktenwissen noch zeitgemäß ist. Unter dem Begriff der *21st century skills* wurde vor allem die Rolle fachübergreifender Fertigkeiten diskutiert, die als zentral für einen erfolgreichen Umgang mit den großen Informationsmengen des Internets erachtet werden (z. B. Greiff et al., 2014). Während es keinen umfassenden Konsens über die Abgrenzung dieser Fertigkeiten gibt, sind verschiedene Modelle und Taxonomien jedoch unterschiedlich verbreitet. Beispielsweise wird das sogenannte 4K-Modell, das *Kommunikation*, *Kollaboration*, *Kreativität* und *Kritisches Denken* als zentrale Bildungsziele definiert, zunehmend als Bezugsrahmen genutzt, unter anderem auch in bildungspolitischen Kontexten (KMK, 2021; 2024). Dabei können Kernkompetenzen weiter differenziert werden, wie beispielsweise das Kritische Denken im Umgang mit verschiedenen Quellen und der Qualität von Informationen. Diese fachübergreifenden Fertigkeiten werden als essentiell angesehen, um sich in einer zunehmend dynamischen und technologiegetriebenen Welt zurechtzufinden. Die Relevanz dieser Fertigkeiten wird also mit zunehmend technologischem Fortschritt umso prominenter (Akata et al., 2020). Die systematische Vermittlung fachübergreifender Kompetenzen, wie beispielsweise im 4K-Modell zusammengefasst, stellt also ein zentrales Bildungsziel der Zukunft dar.

„Auch vor dem Hintergrund einer vermehrten Arbeitsteilung zwischen Menschen und KI-Systemen, bleibt dennoch der Mensch in der Verantwortung, ethische Entscheidungen zu treffen, kreative Lösungen zu entwickeln und technologische Fortschritte kritisch zu hinterfragen.“

Die Vermittlung von Faktenwissen als Bildungsziel bleibt hiervon jedoch unbenommen. Ein breites Grundlagenwissen in verschiedenen Fachbereichen erleichtert den Umgang mit einer Vielzahl von Situationen und Problemstellungen (Chinn & Ravit, 2018). Hierunter fallen auch das Verständnis und die Bewertung von KI-generierten Ergebnissen, deren Nutzung von menschlicher Seite verantwortet wird. Der Erwerb von grundlegendem Faktenwissen ist außerdem eine zentrale Voraussetzung für das Verständnis komplexer Sachverhalte und die Entwicklung spezialisierter Fähigkeiten (Greiff et al., 2014). Dies gilt insbesondere für spezialisierte professionelle Berufe (z. B. Medizin, Ingenieurwesen, etc.). Aber auch für Berufe mit kürzeren Ausbildungszeiten ist ein gewisses Grundlagenwissen Voraussetzung für die erfolgreiche berufliche Qualifizierung.

Für den Umgang mit KI-Systemen sind zudem spezielles Wissen und Fertigkeiten relevant, welche als „*AI Literacy*“ (sinngemäß: KI-bezogene Kompetenzen) zusammengefasst werden (KMK, 2024). Während Art und Umfang der erforderlichen *AI Literacy* von Einzelpersonen weiterhin diskutiert werden, gibt es dennoch Vorschläge zur Konzeptualisierung. Ng et al. (2021) unterscheiden beispielsweise die Teilbereiche “wissen und verstehen”, “nutzen und anwenden”, “bewerten und gestalten” sowie “ethischer Umgang”. Beispiele hierfür sind Wissen über die grundlegende Funktionsweise von KI-Systemen, hieraus resultierende Einschränkungen (z. B. Biases aus Trainingsdaten, Halluzinationen generativer KI, etc.), sowie Wissen und Fertigkeiten zur erfolgreichen Nutzung (z. B. das Generieren von zielführenden Prompts in sprachbasierten Systemen wie ChatGPT).

Bildungsziele der Zukunft bestehen also weiterhin in der Vermittlung von grundlegendem Faktenwissen und Basisfertigkeiten sowie vermehrt auch in der Vermittlung von fachübergreifenden Fertigkeiten für das Informationszeitalter und die Nutzung von KI-Systemen.

3.2 Lernerfolg: Gibt es Risiken?

Bildungsspezifische KI-Anwendungen (z. B. ITS) wie auch bildungsunspezifische aber relevante KI-Anwendungen (z. B. ChatGPT; siehe Abschnitt 2.1) bieten einerseits durch zielgerichtete Unterstützung von Lernenden und Lehrenden Potenziale für Bildungsprozesse. Dennoch können vor allem die bildungsunspezifischen Anwendungen auch problematische Konsequenzen für das Erreichen von Bildungszielen haben, wenn Lernende relevante Lernaufgaben vollständig an das KI-Tool auslagern, statt diese selbstständig zu bearbeiten. Insbesondere beim Fertigkeitserwerb spielt wiederholtes und gezieltes Üben (*deliberate practice*; Ericsson, 2006) eine wichtige Rolle für das grundlegende Erlernen, weiterführende Vertiefen und nachhaltige Automatisieren von Fertigkeiten (Neves & Anderson, 1981). Wenn Lernende also wiederholt relevante Lernaufgaben an KI-Tools auslagern, besteht die Gefahr einer Art „*deskilling effect*“, also dem Nicht-Erlernen oder dem Verlernen von grundlegenden Fertigkeiten und Wissen (Huber et al., 2024). Für Schülerinnen und Schüler bedeutet dies, dass ein unangemessener Gebrauch von KI-Tools zwar kurzfristig Entlastung bringen kann, langfristig jedoch dazu führen könnte, dass wichtige Lernprozesse und die Entwicklung von Fertigkeiten wie Problemlösen vernachlässigt werden (z. B. Stadler et al., 2024).

Auch in alltäglichen und berufsbezogenen Situationen kann übermäßiges Vertrauen in KI-Systeme Entscheidungsprozesse negativ beeinflussen und aufgrund erhöhter Abhängigkeit die Entwicklung wesentlicher Fertigkeiten, wie beispielsweise Problemlösefertigkeiten, unterminieren (Rafner et al., 2022). Wenn in Bereichen wie der Medizin oder dem Finanzwesen KI-gestützte Entscheidungssysteme weitestgehend autonom arbeiten und wenig menschliche Interaktion erfordern, kann dies die Effizienz von Arbeitsprozessen erhöhen und – sofern Entscheidungssysteme ausreichend akkurat sind – auch Vorteile für die Arbeitsergebnisse bieten; gleichzeitig können jedoch Fertigkeiten zur eigenständigen Analyse und Entscheidungsfindung bei Fachkräften unterminiert werden (Hoff, 2011; Sutton, 2018). Dies ist an solchen Stellen problematisch, wo KI-Systeme noch fehleranfällig sind, da die Ergebnisse dennoch von den menschlichen Nutzern verantwortet werden. In solchen Fällen können Risiken jedoch minimiert werden, wenn KI-Systeme für die Mensch-Maschine Interaktion und Kollaboration optimiert sind, beispielsweise, indem Ergebnisse von KI-Systemen nachvollziehbar dargestellt und menschliche Nutzer aktiv zur kritischen Überprüfung der Ergebnisse aufgefordert werden (Buçinca et al., 2021; Vasconcelos et al., 2023).

Auch in anderen Kontexten besteht ein zentrales Problem beim Fertigkeitsverlust auf Seiten von Lernenden und anderen Nutzern darin, dass KI-gestützte Systeme trotz aller Effizienz nicht immer korrekte oder qualitativ hochwertige Ergebnisse liefern. Beispielsweise können Sprachmodelle wie GPT sogenannte „Halluzinationen“ erzeugen, bei denen plausibel klingende, aber falsche oder irreführende Informationen generiert werden (Perković et al., 2024). Ein weiteres Risiko besteht darin, dass diese Modelle unbewusst vorhandene Vorurteile und Verzerrungen aus den Daten, auf Basis derer sie trainiert wurden, übernehmen und verstärken können, was beispielsweise zu kulturellen oder geschlechtsspezifischen Biases in den generierten Inhalten führen kann (Lee et al., 2024; siehe Abschnitt 2.4). Wenn Lernende oder andere Nutzer sich zu stark auf die Korrektheit der Ergebnisse von KI-Systemen verlassen, kann es zur Nutzung oder zum Erlernen von fehlerhaften Informationen kommen. Hinzu kommt, dass sprachmodellbasierte generative KI-Systeme, zum Beispiel im Kontext der Informationssuche, häufig keine oder mitunter falsche Quellenangaben machen, was es für Nutzerinnen und Nutzer erschwert, die Qualität der Informationen zu beurteilen (SWK, 2024). Vor diesem Hintergrund ist der Erwerb fachspezifischen Wissens und fachübergreifender Fertigkeiten umso wichtiger, um als informierter Nutzer die Ergebnisse von KI-Systemen ausreichend bewerten zu können (siehe Abschnitt 3.1). Ähnlich wie in Arbeitskontexten kann auch in Lernkontexten eine aktive Reflexion von KI-Ergebnissen vorteilhaft sein und zudem als Möglichkeit zur Entwicklung der AI literacy von Schülerinnen und Schülern dienen. Für Lernkontexte, in denen die Qualität von KI-Ergebnissen besonders wichtig ist (z. B. Feedback), ist der Einsatz von KI-Systemen empfehlenswert, die für Bildungszwecke spezialisiert sind und geprüfte Informationen nutzen.

Der Einsatz von KI in Bildungsprozessen sollte also sorgfältig gestaltet und orchestriert werden (Holstein et al., 2019). Lernende müssen aktiv in den Lernprozess involviert sein, beispielsweise durch kognitiv aktivierende und kollaborative Aufgabenstellungen. Hierbei können gut gestaltete KI-Systeme vor allem bei anspruchsvollen Aufgaben Unterstützung geben und Lernprozesse bereichern, beispielsweise durch eine automatisierte Erstellung von Feedback anhand von Kriterien, die dem System von einer Lehrkraft vorgegeben werden. Wie Evidenz zu den Effekten von ITS nahelegt, scheinen Lehrkräfte ein relevanter Faktor für die Lerneffektivität der Nutzung von KI-Anwendungen zu sein – insbesondere da vor allem leistungsschwachen Schülerinnen und Schülern die erfolgreiche Nutzung von KI-Tools schwerfallen kann (Steenbergen-Hu & Cooper, 2013; 2014; Sun et al., 2021). Entsprechend

müssen Lehrkräfte – anknüpfend an Bestrebungen zum Ausbau von technologisch-pädagogischen Kompetenzen – idealerweise in Bezug auf die Möglichkeiten und Grenzen von KI-Technologien aus- und weitergebildet werden, um diese in geeigneter Weise einsetzen zu können (siehe Abschnitte 4.1 bis 4.3). Um seitens der Schülerinnen und Schüler eine Gefahr der Auslagerung von Aufgabenstellungen an KI-Systeme außerhalb des Unterrichts zu minimieren, eignet sich der Einsatz von motivational förderlichen Aufgabenstellungen (siehe Huber et al., 2024). Auch „*flipped classroom*“ Ansätze können sinnvoll sein, da hier die Wissensanwendung während des Unterrichts passiert, während passive Wissensvermittlung außerhalb der Unterrichtszeit stattfindet (Akçayır & Akçayır, 2018). KI-Technologien können also wertvolle Werkzeuge im Bildungsbereich sein, ihr Einsatz muss jedoch durchdacht sein. Die Balance zwischen technologischer Unterstützung und der Förderung eigenständigen Lernens ist dabei von zentraler Bedeutung.

„Lernende müssen aktiv in den Lernprozess involviert sein, beispielsweise durch kognitiv aktivierende und kollaborative Aufgabenstellungen. Hierbei können gut gestaltete KI-Systeme vor allem bei anspruchsvollen Aufgaben Unterstützung geben und Lernprozesse bereichern.“

3.3 Lernwirksamkeit: Gibt es schon belastbare Forschung?

Vor dem Hintergrund der zunehmenden Diskussion um den Einsatz von KI in Bildungskontexten wird häufig angenommen, dass es noch keine fundierte Evidenz zur Lernwirksamkeit des Einsatzes dieser Technologien gibt. Im Hinblick auf den Einsatz von generativer KI, die auch die Basis für Chatbots bilden (z. B. *ChatGPT*), gibt es bisher natürlich nur in begrenztem Maße spezifische Evidenz, da diese Technologien erst seit wenigen Jahren verfügbar sind. Das Forschungsinteresse und die Evidenz zum Einsatz von Chatbots wachsen jedoch stetig. Gleichzeitig gibt es belastbare Forschung zum Einsatz anderer Arten von KI in Bildungskontexten, aus der relevante Erkenntnisse zur Lernwirksamkeit und hiermit verbundenen Mechanismen sowie zu Einsatzmöglichkeiten und Gelingensbedingungen abgeleitet werden können.

Seit Jahrzehnten gibt es einen Forschungszweig zu „*Artificial Intelligence in Education*“ (AIED), welcher die Wirksamkeit des Einsatzes verschiedener KI-Anwendungen im Bildungsbereich untersucht (siehe du Boulay et al., 2023). Dieser Forschungszweig beschäftigt sich insbesondere mit dem Einsatz von KI in Form von ITS, welche Lernenden verschiedene Formen adaptiver Unterstützung bieten (D'Mello & Graesser, 2023). Unter adaptive Unterstützung fallen beispielsweise automatisiertes Feedback und adaptive Hilfestellungen, aber auch die Auswahl geeigneter Materialien und Aufgabenstellungen zur Wiederholung und Vertiefung von Inhalten basierend auf gemachten Fehlern und dem erreichten Lernfortschritt (Plass & Pawar, 2020). Diese Einsatzmöglichkeiten illustrieren zwei Mechanismen zur Begünstigung der Effektivität und Effizienz von Lernprozessen mittels Bildungstechnologien (Sailer, Maier, et al., 2024): Einerseits kann KI für die gezielte Unterstützung von Lernprozessen eingesetzt werden (z. B. Feedback und Hilfestellungen); andererseits können KI-Technologien – wie auch andere Technologien – Lernaktivitäten ermöglichen oder erleichtern, bei denen Lernende aktiv Inhalte wiederholen und vertiefen (z. B. adaptive Aufgabenauswahl) oder neue Ideen entwickeln (z. B. im Kontext von Problemlöseaufgaben). Die Effektivität dieser Einsatzmöglichkeiten hängt jedoch wesentlich von ihrem didaktischen Design und Einsatz ab – die Lernwirksamkeit von

Bildungstechnologien kann also nicht über die Technologie an sich definiert werden, sondern nur über die Qualität ihres Einsatzes. Hierbei nimmt die Lehrkraft nach wie vor eine zentrale Rolle in der Planung, Umsetzung und Begleitung von Bildungsprozessen ein.

„Die Effektivität dieser Einsatzmöglichkeiten hängt jedoch wesentlich von ihrem didaktischen Design und Einsatz ab – die Lernwirksamkeit von Bildungstechnologien kann also nicht über die Technologie an sich definiert werden, sondern nur über die Qualität ihres Einsatzes. Hierbei nimmt die Lehrkraft nach wie vor eine zentrale Rolle in der Planung, Umsetzung und Begleitung von Bildungsprozessen ein."

Um die verfügbare Evidenz zu verschiedenen KI-Einsatzmöglichkeiten zusammenzufassen, eignen sich insbesondere Meta-Analysen. Diese integrieren die Effektgrößen von mehreren Studien mit verschiedenen Stichproben und Variationen einer Intervention und bieten daher einen besonders robusten Eindruck der verfügbaren Evidenz eines Forschungsbereichs. Über die Jahre haben einige Meta-Analysen die jeweils verfügbare Evidenz zu verschiedenen KI-Einsatzmöglichkeiten zusammengefasst. Eine kürzlich durchgeführte Meta-Analyse über die Wirksamkeit von KI auf die Lernleistung zeigte eine insgesamt große Wirkung des Einsatzes von KI auf die Lernleistung (z. B. in Tests) und eine geringe Wirkung auf die Lernwahrnehmung (z. B. lernbezogene Haltung und Motivation; Zheng et al., 2023). Es wurden verschiedene Arten von KI-Software untersucht, z. B. adaptive Lernsysteme, Test- und Diagnosesysteme und ITS, die eine ähnliche Wirksamkeit auf die Leistung zeigten. Insbesondere zur Effektivität von ITS gibt es mehrere Meta-Analysen, welche nahelegen, dass ITS positive Effekte im Vergleich zu traditionellem Frontalunterricht, Individualarbeit mit Lehrbüchern oder auch weniger adaptiven Formen von computerbasierten Trainings aufweisen (z. B. Kulik & Fletcher, 2016; Ma et al., 2014) – diese Ergebnisse lassen sich mit den obigen Mechanismen des aktiven Lernens und der adaptiven Unterstützung begründen. Die Effektgrößen bewegen sich dabei je nach Vergleich und abhängig von anderen Variablen häufig in einem mittleren bis großen Bereich. Die Meta-Analysen legen weiterhin nahe, dass ITS Lerneffekte erzielen, die mit Unterricht in Kleingruppen und individueller Instruktion vergleichbar sind, da in all diesen Lernformen relativ granular auf einzelne Lernende eingegangen werden kann (z. B. Ma et al., 2014; VanLehn, 2011). Die Wirksamkeit von ITS variiert jedoch in Abhängigkeit von verschiedenen Einflussfaktoren; beispielsweise erzielen ITS besonders hohe Effektstärken, wenn sie zum Lernen neuer Inhalte eingesetzt werden (Kulik & Fletcher, 2016). Gleichzeitig zeigen meta-analytische Befunde, dass ITS in Kombination mit klassischem Unterricht effektiver sind, als wenn sie diesen ersetzen (Steenbergen-Hu & Cooper, 2014; Sun et al., 2021).

„Gleichzeitig zeigen meta-analytische Befunde, dass ITS in Kombination mit klassischem Unterricht effektiver sind als wenn sie diesen ersetzen."

Aufgrund des zunehmenden Interesses am Einsatz von Chatbots gibt es auch hierzu inzwischen mehrere Meta-Analysen. Diese beziehen sich primär auf Chatbot-Systeme (z. B. chatbasierte ITS), welche bereits vor generativer KI wie z. B. ChatGPT verfügbar waren, und legen ebenfalls mittlere bis große positive Effekte auf den Lernerfolg und teilweise auch auf

motivational-affektive Variablen (z. B. Selbstwirksamkeit und Interesse) nahe (z. B. Alemdag, 2023; Kuhail et al., 2023; Wu & Yu, 2024). Ähnlich wie in Vergleichen der Effektivität von ITS generell zeigen sich auch in Bezug auf chatbasierte Systeme eher größere Effekte im Vergleich mit weniger granular unterstützenden Instruktionsformen (z. B. Frontalunterricht mit großen Gruppen), kleine Effekte im Vergleich mit eher engmaschiger unterstützenden Instruktionsformen (z. B. weniger adaptive Formen von computerbasierten Trainings) und kein Unterschied der Effektivität im Vergleich zu individueller Instruktion (Alemdag, 2023). Chatbots erzielen besonders gute Effekte, wenn sie entweder spezifische Unterstützung bieten (z. B. Fragen beantworten), die Reflexion von Lernenden anleiten oder auch Feedback geben (Alemdag, 2023). Große Sprachmodelle (LLMs) haben sich als wirksam erwiesen, um Sekundarschüler:innen durch Feedback bei der Textüberarbeitung zu unterstützen, was zu qualitativ besseren Ergebnissen sowie erhöhter Motivation und Freude an der Aufgabe führte (Meyer et al., 2024). Allerdings zeigen Studien, dass LLM-Feedback zunächst oft allgemein bleibt und in seiner Qualität stark variieren kann (SWK, 2024; Yoon et al., 2023; Wang & Demszky, 2023). Um eine hohe Feedbackqualität zu gewährleisten, ist ein pädagogisch angemessenes Instruktionsdesign und die Anbindung an aufgabenrelevante Kriterien wichtig. Hierbei können bildungsspezifische KI-Systeme besonders nützlich sein, die Lehrkräfte in der Gestaltung und Nutzung kriteriengeleiteten Feedbacks unterstützen. Zudem zeigt sich, dass Chatbots vor allem zu Beginn ihrer Nutzung hohe Effekte erzielen, was mit einem Neuigkeitseffekt erklärt werden kann, der jedoch über die Zeit nachlässt (Alemdag, 2023; Wu & Yu, 2024).

Insgesamt gibt es also umfangreiche Evidenz zur Lernwirksamkeit von KI im Bildungsbereich, besonders in Bezug auf ITS und teilweise auch in Bezug auf sprachbasierte Lernplattformen. Diese Technologien bieten das Potenzial, Lernende individuell zu unterstützen und zu fördern. Entscheidend ist jedoch, dass ihr Einsatz gut durchdacht und an die Bedürfnisse der Lernenden angepasst wird.

3.4 Lernvoraussetzungen: Für wen ist KI lernwirksam und sinnvoll?

Künstliche Intelligenz hat Einzug in verschiedene Klassenräume gehalten, von der Grundschule bis zur Hochschule und in verschiedenen Fachbereichen wie Natur- und Geisteswissenschaften. Zusätzlich zu diesen Unterschieden im Bildungskontext unterscheiden sich die Schülerinnen und Schüler auch in Bezug auf ihr Vorwissen im Fach und ihre Medien- und KI-Kompetenz. Um zu verstehen, für wen KI effektiv ist, ist es wichtig, individuelle Faktoren wie Vorwissen, Medien- und KI-Kenntnisse und kontextuelle Faktoren wie Bildungsniveau und -kontext und Fach zu berücksichtigen.

Es wird oft angenommen, dass KI nur für ältere Schülerinnen und Schüler geeignet und für jüngere Lernende zu komplex ist, z. B. aufgrund von Schwierigkeiten beim Schreibprozess und der Bewertung von Texten, die von LLM erstellt wurden (SWK, 2024). Eine kürzlich durchgeführte Meta-Analyse mit fast 3000 Studierenden hat gezeigt, dass der Einsatz von KI-Technologien insgesamt einen großen positiven Effekt auf Lernleistungen hat (Zheng et al., 2023). Zusätzlich wurde der Einfluss der Bildungsstufe untersucht. Der Einsatz von KI-Technologien war in der Sekundarstufe (Mittel- und Oberstufe) am wirksamsten, gefolgt von der Hochschul- und Erwachsenenbildung und der Grundschulbildung (Zheng et al., 2023). Daher können KI-Werkzeuge auch bei jüngeren Lernenden nützlich sein, insbesondere in der Sekundarstufe. Außerdem werden KI-basierte Assistenztools in der Inklusionspädagogik bei Schülern mit Autismus und Lernbehinderungen eingesetzt. Die Rolle der KI in der Inklusionspädagogik bezieht sich meist auf die Diagnose und die Verbesserung des Lernens,

die Bewertung und die Bereitstellung von Unterstützung (für eine systematische Übersicht siehe Hopcan et al., 2022). Die Studien in der Übersicht von Hopcan et al. (2022) wurden meist mit Kindergarten- und Grundschulkindern durchgeführt und umfassten kognitive (z. B. Leseverständnis, Mich et al., 2013) und affektive Lernergebnisse. Entsprechend dieser Studienlage empfiehlt die KMK (2024) den Einsatz KI-basierter Werkzeuge auch für die Vermittlung und das Einüben von Basiskompetenzen. Dieser scheinbare Widerspruch zwischen SWK und KMK hat in der Öffentlichkeit für viel Diskussion gesorgt, zeigt aber vor allem, wie wichtig es ist, den Gegenstand der Diskussion klar zu definieren. Während es in der Stellungnahme der SWK um LLM geht, also um Systeme ohne didaktische Vorstrukturierung, beziehen sich die Handlungsempfehlungen der KMK auf KI allgemein und damit auch auf KI-basierte Bildungstechnologien, die durchaus auch für jüngere Kinder sinnvoll sein können.

„Studien zeigen, dass KI zwar in der MINT-Bildung wirksam sein kann (z. B. Chin et al., 2013), aber auch in anderen Bereichen Anwendung findet."

Es wird häufig angenommen, dass KI nur in naturwissenschaftlichen, technischen, ingenieurwissenschaftlichen und mathematischen Fächern (MINT-Fächer) anwendbar ist. Obwohl sich KI-Anwendungen in den Ingenieur- und Technologiewissenschaften mit großen Effektstärken als am effektivsten für die Leistungen der Schülerinnen und Schüler erwiesen haben, hatte die Wirksamkeit von KI-Anwendungen sowohl in den Natur- als auch in den Sozialwissenschaften mittlere Effektstärken, wenn auch geringere als in den Ingenieur- und Technologiewissenschaften (Zheng et al., 2023). Anwendungen der künstlichen Intelligenz wurden aber auch außerhalb des MINT-Kontexts erfolgreich eingesetzt, z. B. im Geschichtsunterricht (Ijaz et al., 2021) und zur Verbesserung sprachlicher Fertigkeiten wie Aussprache, Redefluss und Wortschatz beim Erlernen von Zweitsprachen (Zou et al., 2023). Diese Studien zeigen, dass KI zwar in der MINT-Bildung wirksam sein kann (z. B. Chin et al., 2013), aber auch in anderen Bereichen Anwendung findet.

Wichtige individuelle Merkmale der Lernenden für die Wirksamkeit von KI in der Bildung betreffen die Medien- und KI-Kompetenz. Die KI-Kompetenz besteht aus vier Komponenten: Wissen und Verständnis von KI, Nutzung und Anwendung von KI, Bewertung und Entwicklung von KI sowie KI-Ethik (Ng et al., 2021). Die Medien- und KI-Kompetenz der Schülerinnen und Schüler in Bezug auf das Lernen mit KI steht in Zusammenhang mit dem Konzept der digitalen Kluft (digital divide): Schülerinnen und Schüler mit schwachem sozioökonomischen Hintergrund haben aufgrund des fehlenden Zugangs und der mangelnden Erfahrung mit KI-Werkzeugen größere Schwierigkeiten, ihre KI-Kompetenz zu verbessern (Yang, 2022). Die digitale Kluft wird definiert als „die Kluft zwischen Einzelpersonen, Haushalten, Unternehmen und geografischen Gebieten auf unterschiedlichen sozioökonomischen Ebenen sowohl hinsichtlich ihrer Möglichkeiten des Zugangs zu Informations- und Kommunikationstechnologien als auch hinsichtlich ihrer Nutzung des Internets für eine Vielzahl von Aktivitäten" (OECD, 2001, S. 4). Im Zusammenhang mit KI lässt sich die digitale Kluft auf drei Ebenen beschreiben: Die erste Ebene bezieht sich auf die Ungleichheit beim Zugang zu KI-Anwendungen zu Hause oder in der Schule, die zweite Ebene bezieht sich auf die unterschiedlichen Fähigkeiten und Fertigkeiten zur Nutzung von KI-Anwendungen, die sich aus der Ungleichheit beim Zugang ergibt. Die dritte Ebene der digitalen Kluft bezieht sich auf die Ungleichheit der Lernergebnisse, die sich aus den Unterschieden in den Fähigkeiten

zur effektiven Nutzung von KI ergibt (Wei et al., 2011). Schüler und Schülerinnen mit hohen sprachlichen und fachlichen Kompetenzen können die im Rahmen des LLM erstellten Texte besser verstehen und kritisch beurteilen (SWK, 2024). Darüber hinaus wurde gezeigt, dass KI-Kenntnisse von Grundschülerinnen und -schülern in einem positiven Zusammenhang mit ihrer Absicht stehen, KI für das Lernen zu nutzen (Chai et al., 2020). Daher ist es wichtig, die KI-Kenntnisse von Lernenden mit altersgerechten Methoden in der K-12-Bildung zu fördern. So können Schüler und Schülerinnen in der Grundschule mit Hilfe von forschungs- und spielbasierten Methoden (z. B. blockbasierte Programmierung, Erstellung von Chatbots) an KI herangeführt werden, und diese Fähigkeiten können in der Sekundarstufe mit komplexeren Aufgaben wie dem Bau von Robotern oder dem Training von KI-Algorithmen ausgebaut werden (Ng et al., 2021).

Zusammenfassend lässt sich sagen, dass künstliche Intelligenz nicht nur in der Hochschulbildung nützlich ist und nicht nur in MINT-Fächern eingesetzt werden kann. Künstliche Intelligenz ist besonders effektiv in der Sekundarstufe und kann in einer Reihe von Fächern außerhalb des naturwissenschaftlichen Unterrichts nutzbar werden. Beim Einsatz von künstlicher Intelligenz im Unterricht ist es wichtig, die KI-Kenntnisse der Schülerinnen und Schüler zu berücksichtigen und diese bereits in der Grundschule gezielt zu fördern.

3.5 Lernerfolgskontrollen: Macht eine Überprüfung des Lernerfolgs im Zeitalter von KI überhaupt noch Sinn?

Mithilfe generativer KI lassen sich Antworten auf Wissensfragen und Problemlöseaufgaben in Sekundenschnelle generieren. Erste Versionen von ChatGPT machten dabei noch viele Fehler und halluzinierten Antworten, so dass bei vielen Skeptikern der Eindruck entstanden sein mag, dass KI eben doch nicht mit Menschen mithalten könne. Seit dem Aufkommen leistungsstärkerer Modelle wie GPT-4 gibt es jedoch vielfache Evidenz für die teilweise erstaunliche Leistung generativer KI bei der Bearbeitung typischer Prüfungsanforderungen. Diese führen in der Öffentlichkeit nun oftmals zu der umgekehrten Debatte, inwieweit KI Lernerfolgskontrollen obsolet macht. In dieser Debatte vermischen sich mindestens zwei Argumente. Zum einen wird in Frage gestellt, ob das Wissen, welches in schriftlichen Prüfungen in Schule und Hochschule erfragt wird, überhaupt noch erlernt werden muss, da es bei Bedarf jederzeit durch eine KI bereitgestellt werden kann und ob nicht andere Kompetenzen relevanter für eine erfolgreiche gesellschaftliche Teilhabe sind (siehe Abschnitt 3.1). Zum anderen werden Zweifel geäußert, inwieweit eine valide Einschätzung des individuellen Wissensstands eines Lernenden im Zeitalter von KI überhaupt noch möglich ist bzw. ob Prüfungsergebnisse eindeutig auf die antwortende Person zurückgeführt werden können.

Mittlerweile lässt sich die Behauptung, dass die Leistungen, die in Prüfungen in Schule und Hochschule verlangt werden, nur von Menschen erbracht werden können, nicht mehr halten. Beispielsweise zeigt eine Studie von Katz et al. (2024), dass GPT-4 beide Teile des standardisierten Zulassungstests für Juristen in den USA (*bar exam*) bestehend aus entweder Multiple-Choice oder offenen Fragen erfolgreich absolviert und somit eine Zulassung als Anwalt erhalten würde. Es schneidet zudem in fünf von sieben Inhaltsbereichen des Multiple Choice-Tests besser ab als menschliche Prüflinge. In einer Studie aus England generierten die Autoren mithilfe von GPT-4 Antworten auf Prüfungsfragen mit Kurz-Antwortformat und 1500-Wörter Essay-Aufgaben für online-Klausuren (d. h. unter den realen zeitlichen Rahmenbedingungen der Prüfung) in verschiedenen Modulen eines Bachelor Psychologie-Studiengangs (Scarfe et al., 2024). 94 Prozent der KI-generierten Klausuren wurden nicht als

solche durch die auswertenden Personen identifiziert. KI-generierte Prüfungen wurden eine halbe Note besser bewertet als die durchschnittlichen Leistungen der Studierenden. Die Wahrscheinlichkeit, dass GPT-4 eine bessere Klausurleistung als ein Studierender in einem der Module erbringt, lag bei 83.4 Prozent. In einer länderübergreifenden Studie zeigen Ibrahim et al. (2023) für 32 Universitätskurse, dass ChatGPT mindestens auf gleichem Niveau, wenn nicht sogar besser in den entsprechenden Abschlussklausuren abschneidet als Studierende. Laut open.ai erreicht GPT-4 das 89. (Mathematik) bzw. 93. (argumentatives Lesen und Schreiben) Leistungsperzentil im US-amerikanischen Scholastic Aptitude Test (SAT), einem zentralen High-School-Test, auf dessen Basis über den Zugang zu den Universitäten entschieden wird. Diese Ergebnisse zeigen, dass in Situationen, in denen der Zugriff auf ein internetfähiges Endgerät nicht ausgeschlossen werden kann, keine valide Aussage mehr möglich ist, ob die Person eine Prüfungsleistung eigenständig (d. h. ohne Hilfe der KI) erbracht hat bzw. überhaupt einen Anteil an der Leistungserbringung hatte. Stand heute sind technische Lösungen für die automatische Identifikation KI-basierter Outputs nicht hinreichend zuverlässig, um einen rechtssicheren Nachweis zu führen, dass eine Person die Prüfungsleistung nicht eigenständig erbracht hat.

„Mittlerweile lässt sich die Behauptung, dass die Leistungen, die in Prüfungen in Schule und Hochschule verlangt werden, nur von Menschen erbracht werden können, nicht mehr halten.“

Diese Ausgangssituation macht aber Prüfungen nicht grundsätzlich obsolet, sondern erfordert die Entwicklung alternativer und in einer Kultur der Digitalität zeitgemäßere Formen des Prüfens und Bewertens (vgl. Handlungsempfehlungen der KMK, 2024). Joscha Falck und Hendrik Haverkamp haben diese Alternativen in der Aussage zusammengefasst, dass ein Geprüftwerden “über, mit, von, trotz und ohne KI” erfolgen kann.

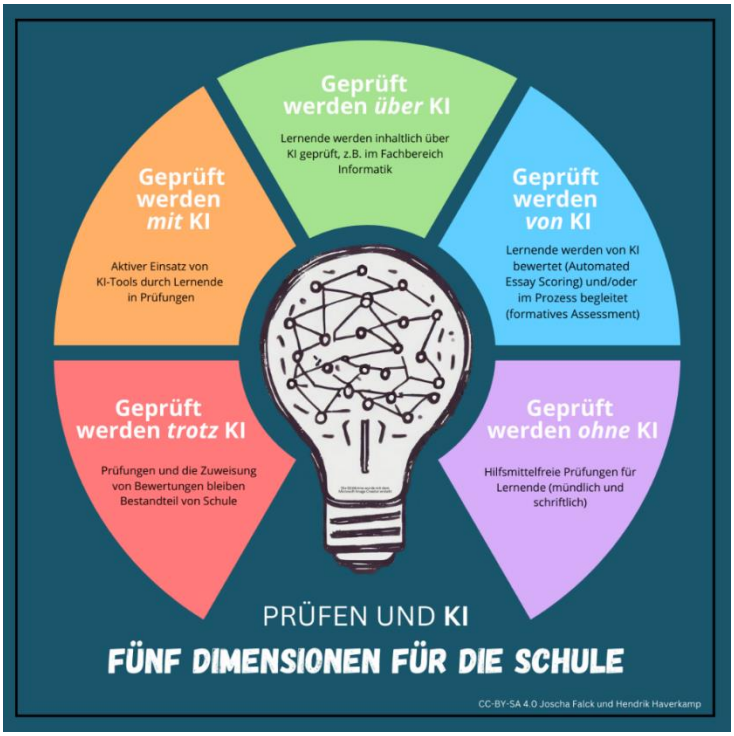


Abbildung 2. Prüfen und KI: Fünf Dimensionen für die Schule (Quelle: https://joschafalck.de/pruefen-und-ki/)

Trotz und ohne KI entspricht dabei der hilfsmittelfreien Prüfung, die z. B. auch mündliche Prüfformate umfasst. Das Prüfen über KI trägt der Tatsache Rechnung, dass im 21. Jahrhundert auch das Wissen über und Fertigkeiten im Umgang mit KI Bestandteil des relevanten Wissenkanons sein sollte, über welchen Kinder und Jugendliche verfügen sollten. Das Prüfen mit und von KI schließt die Nutzung von KI im Prüfungskontext ein, indem beispielsweise als Prüfungsleistung ein durch eine KI generierter Output durch Schülerinnen und Schüler kritisch reflektiert und optimiert wird. Ebenso kann die gemeinsam mit einer KI erbrachte Leistung als ein Ausdruck dessen gewertet werden, zu welchen ko-konstruktiv erbrachten Leistungen Lernende in einer Kultur der Digitalität in der Lage sind. Damit kann eine Prüfungssituation hergestellt werden, die die Realität des modernen Arbeitslebens, in der digitale (KI-basierte) Werkzeuge Teil des Alltags sind, deutlich besser abbildet als hilfsmittelfreie Prüfungen. Neue Prüfungsformate, die Koaktivität und die Fähigkeit, die Ergebnisse von KI zu reflektieren, berücksichtigen, können die Präsentation erstellter Inhalte inkl. einer Verteidigung der erstellten Produkte sein (siehe KMK, 2024).

4. Die Rolle von Lehrkräften

4.1 Das Verhältnis von Lehrkraft und KI: Wozu braucht es noch Lehrkräfte?

Für Lehrkräfte ergeben sich vielfältige didaktische Potenziale von KI im und um den schulischen Unterricht: Potenziale zur Unterstützung der Lernprozesse von Schülerinnen und Schülern finden sich bei ITS, Chatbots, automatisierten adaptiven Hilfestellungen oder automatischen Feedback-Systemen im Kontext von selbstgesteuerten Lerneinheiten, z. B. beim Erledigen von Übungs- oder Hausaufgaben (Ninaus & Sailer, 2022). Generell kann der Einsatz von KI zur Personalisierung von Lernumgebungen und Unterricht beitragen und somit individuelle und passgenaue Förderangebote bereitstellen (Bernacki et al., 2021).

Dabei spielt die pädagogisch-didaktische Einbindung KI-basierter Technologie in den Unterricht eine wichtige Rolle. Selbst vollautomatische tutorielle Systeme wirken nicht von allein. Diese Einbindung von KI-Technologie in den Unterricht sollte vor dem Hintergrund des Zusammenspiels unterschiedlicher kognitiver (digitaler sowie analoger) Werkzeuge im Unterricht betrachtet werden. Entscheidend ist dabei die Abstimmung der verschiedenen Instrumente aufeinander (Scheiter, 2021). Dies umfasst nicht nur die didaktische, sondern auch die fachdidaktische Einbettung, und hängt wiederum auch mit der Art der verwendeten KI-Technologie zusammen, die von generischen (z. B. ChatGPT) bis hin zu spezifischen (fachdidaktischen) Anwendungen reichen kann (siehe Abschnitt 2.1). Hier spielen Fragen der Passung, der Genauigkeit und der Verlässlichkeit von KI-basierten Systemen in den jeweiligen Kontexten eine wichtige Rolle. Der Lehrkraft kommt hier eine entscheidende Bedeutung zu, auch spezifische, z. B. sonderpädagogische, Expertisen sollten berücksichtigt werden (siehe KMK, 2024).

„Selbst vollautomatische tutorielle Systeme wirken nicht von allein.“

Auch für die Diagnose des Lernfortschritts und der Lernleistungen bieten KI-basierte Anwendungen großes Potenzial. Eine (kontinuierliche) formative Diagnose lernrelevanter Prozesse und Zustände und Bewertung von Lern- und Arbeits(zwischen)produkten (z. B. schriftliche Zusammenfassungen, symbolische und non-symbolische Artefakte bei der Bearbeitung von Übungsaufgaben) ist denkbar. Beispielsweise wendeten Meyer et al. (2023) eine Open Source Software für die automatische Kodierung englischsprachiger, argumentativer Essays an und erreichten zufriedenstellende Übereinstimmungen mit speziell trainierten Kodiererinnen und Kodierern. Auch für die automatische Analyse nicht-symbolischer Produkte wie Zeichnungen existieren zumindest im Forschungskontext entsprechende Algorithmen. Die Ergebnisse einer formativen Diagnose und Bewertung können Lehrkräften im Rahmen eines *Dashboards* zur Verfügung gestellt und von diesen für eine adaptive Gestaltung des Unterrichts genutzt werden (Molenaar & Knoop-van Campen, 2017). In solchen Fällen bleibt die volle Entscheidungskompetenz bei den Lehrkräften. KI unterstützt somit lediglich die Lehrkräfte bei ihren diagnostischen und interventionsbezogenen Entscheidungen (siehe auch KMK, 2024 zur Rolle der DGSVO bei Einzelfallentscheidungen).

Generell spielt die Frage danach, wer Entscheidungen in KI-basierten Lernumgebungen trifft, eine wichtige Rolle: adaptive Anpassungen und/oder adaptive Unterstützungen im Rahmen von Lernumgebungen und des Unterrichts können durch die Lernumgebung selbst ausgeführt, durch Schülerinnen und Schüler selbstgesteuert vorgenommen oder auch durch Lehrkräfte initiiert werden (Ninaus & Sailer, 2022). Hybride Lösungen, bei denen die Entscheidungen verschiedener Personen jeweils ein gegenseitiges Monitoring durchlaufen, erscheinen hier besonders vielversprechend (Molenaar, 2021, Sailer, Ninaus, et al., 2024). Auch eine Unterscheidung von Entscheidungen mit höherem und geringerem Risiko und entsprechender Schlussfolgerungen wäre denkbar (Ninaus & Sailer, 2022). Entscheidend für die Auswahl von KI-Systemen und der Rolle von Lehrkräften bei Entscheidungsprozessen ist dabei eine transparente Dokumentation der Funktionsweise und Sicherheit, um Risikobewertungen treffen zu können (Chaudhry et al., 2022, siehe auch Abschnitt 2.2). Eine differenzierte Beurteilung ist für die verantwortungsvolle Nutzung von KI im Unterricht notwendig – generell und vor allem bezogen auf die Nutzung von KI zur Lern- und Leistungsbeurteilung.

Lehrkräften kommt demnach nach wie vor eine sehr wichtige und entscheidende Rolle beim Einsatz von KI in der Schule zu. Dies bezieht sich sowohl auf die Abstimmung von digitalen, KI-basierten und analogen Tools im Unterrichtsgeschehen, als auch auf Einsatzformen, bei denen die Lehrkräfte in ihren Entscheidungen durch KI unterstützt werden.

4.2 Kompetenzen von Lehrkräften: Brauchen Lehrkräfte mehr oder weniger Wissen im Zeitalter von KI?

Fähigkeiten im Umgang mit Künstlicher Intelligenz wurden in den Kompetenzrahmen DigComp 2.2 aufgenommen (Vuorikari et al., 2022) und nehmen so auch Einzug in die Bildung. Die Einführung von künstlicher Intelligenz im Klassenzimmer erfordert von Lehrkräften eine Reihe von Kompetenzen, um entsprechende Anwendungen effektiv und didaktisch sinnvoll in den Unterricht einzubauen und auch bei der Gestaltung von Prüfungsszenarien zu berücksichtigen (siehe Abschnitt 3.5). Ein weit verbreitetes Missverständnis über den Einsatz von KI in der Bildung ist, dass KI für Lehrkräfte zu komplex ist oder dass diese umfangreiches technisches Wissen über KI benötigen, um KI zu verstehen und einzusetzen. Neben Schülerinnen und Schülern (siehe Abschnitt 3.4) benötigen auch Lehrkräfte ein gewisses Maß an KI-Kenntnissen, die definiert werden als „eine Reihe von Kompetenzen, die es dem Einzelnen ermöglichen, KI-Technologien kritisch zu bewerten, effektiv mit KI zu kommunizieren und zusammenzuarbeiten und KI als Werkzeug online, zu Hause und am Arbeitsplatz zu nutzen." (Long & Magerko, 2020, S. 2). Für Lehrkräfte ist es wichtig, die pädagogischen Grundlagen von KI-Tools zu verstehen und zu wissen, welche Arten von Daten von diesen Anwendungen erfasst und gespeichert werden (Sperling et al., 2024). Daher muss ermittelt werden, welche Arten von Kompetenzen Lehrkräfte benötigen, um KI im Unterricht effektiv einzusetzen.

„Um die Kompetenzentwicklung sicherzustellen, empfiehlt die KMK (2024), diese in allen drei Phasen der Lehrkräftebildung zu integrieren und zu überprüfen."

AI Literacy umfasst das Verständnis der grundlegenden Konzepte und Möglichkeiten von KI sowie ihre Auswirkungen und ethische Implikationen. Sie umfasst die Fähigkeiten, mit KI-Systemen effektiv zu interagieren und deren Ergebnisse kritisch zu bewerten (Yan et al., 2024). Außerdem zu unterscheiden sind hierbei die notwendigen Kompetenzen von Lehrpersonen, die Schülerinnen und Schülern auf die technische Nutzung von KI vorbereiten und denen, die KI als inhaltlichen Gegenstand oder als Lernwerkzeug haben. Nach Kim et al. (2021) sind für den technischen Einsatz von KI hohe Kompetenzen erforderlich. Für das Inhaltswissen sind dies z. B. Programmierfähigkeiten, mathematisches Verständnis der zugrundeliegenden Algorithmen aber auch ethische Grundlagen von KI.

Für den Einsatz von KI als Lernwerkzeug und als inhaltlichen Gegenstand bieten die sechs KI-Kompetenzfelder für Lehrpersonen, die Delker et al. (2024) identifiziert haben, einen Überblick:

(1) Theoretisches Wissen über KI: Unterschied zwischen KI und traditionellen Computerprogrammen und wie KI genutzt werden kann; beinhaltet ein Grundverständnis von KI-Methoden wie Machine Learning, Deep Learning, Data Mining oder Neuronalen Netzen aber auch deren Limitationen (z. B. Verzerrungen)

(2) Gesetzlicher und ethischer Rahmen von KI: Verständnis von daten-gestützten ethischen Überlegungen; Bewusstsein für Fairness, Gleichberechtigung und Transparenz im Kontext von KI, um Diskriminierung vorzubeugen; Sicherstellung der Einhaltung regionaler Datenschutzanforderungen (siehe Abschnitt 2.2)

(3) Auswirkungen von KI: Identifikation von Herausforderungen und Potenzialen von KI für Bildung, Gesellschaft und den Arbeitsplatz und notwendige Kompetenzen der Bürgerinnen und Bürger, um diese Gedanken in die Praxis einfließen zu lassen; kritische Medienkompetenz, um sog. Deep Fakes, Fake News oder andere fehlerhafte Inhalte erkennen zu können

(4) Einstellungen zu KI: Offenheit gegenüber KI und aktive Auseinandersetzung, um Anwendungen für die Lernenden zu identifizieren; kritische Reflektion der eigenen Einstellung zu KI

(5) Lehren und Lernen mit KI: Fähigkeit, KI in die Lehre zu integrieren in Form von KI als allgemeines Thema, KI für individuelles und kooperatives Lernen, KI als Assessmenttool; Identifikation, wie KI Bildungsprozesse beeinflusst und wie Menschen und Maschine kooperieren können; Vorbildrolle

(6) Fortlaufende Professionalisierung: Verständnis über die Notwendigkeit kontinuierlicher Weiterentwicklung und Vernetzung; Integration von KI in Organisationsprozesse

Lehrkräfte unterscheiden sich hinsichtlich ihres technologischen Hintergrundwissens und ihrer Erfahrung im Umgang mit KI-Tools. Lehrkräfte, die KI zum ersten Mal einsetzen, haben aufgrund mangelnder Kenntnisse und Fähigkeiten wahrscheinlich technische Schwierigkeiten (Guerro-Roldan et al., 2021), während Lehrkräfte mit höheren KI-Kompetenzen KI leichter in ihrer Verwaltungs- und Lehrtätigkeit einsetzen können (Huang, 2021). Technische Schwierigkeiten können die Unterrichtsqualität beeinträchtigen (Seo et al., 2021), während Lehrkräfte, die die Funktionen verschiedener KI-Tools (z. B. Bewertung, Yang et al., 2022) nutzen können, ihren Unterricht effektiver gestalten können. Lehrkräfte benötigen einige technische Kompetenzen, um digitale Tools und Software (z. B. adaptive Lernsysteme, automatische Feedback-Tools, Lehrer-Dashboards) nutzen zu können, und darüber hinaus benötigen sie pädagogisches Wissen, um geeignete Lernaufgaben und -materialien zu entwerfen (Ng et al., 2023; Vazhayil et al., 2019). Um die Kompetenzentwicklung sicherzustellen, empfiehlt die KMK (2024), diese in allen drei Phasen der Lehrkräftebildung zu integrieren und zu überprüfen. Zusätzlich sollen die Kompetenzanforderungen bedarfsgerecht an die dynamischen technologischen Entwicklungen angepasst werden.

4.3 KI: Auch ein Werkzeug für Lehrkräfte?

Häufig entsteht in der öffentlichen Debatte um den Einsatz von KI der Eindruck, dass KI in der Schule vor allem ein Werkzeug ist, welches von Schülerinnen und Schüler genutzt werden kann.

Wie KI Lehrkräfte unterstützen kann – Erfahrungen aus der Praxis:

Mögliche Unterstützung durch KI bei der Unterrichtsvorbereitung und Organisation:

1. Erstellung von fiktiven Texten für den Unterricht, z. B. Dialoge
2. Erstellung von Skripten für einen Erklärfilm
3. Erstellung einer MindMap für das Gliedern einer Argumentation
4. Erstellung von Unterrichtsskizzen
5. Erstellung von Bildmaterial für Arbeitsblätter oder Erarbeitungsphasen
6. Erstellung von Differenzierungsmaterial für den Unterricht
7. Erstellung von Gutachten für eine Schülerarbeit

Basis

Es muss klar sein, dass Lehrkräfte das Thema "Prompting" im Blick haben und dieses auch beherrschen, um bessere Ergebnisse zu erzielen.

Möglichkeiten des Einsatzes der KI für die Unterrichtsvorbereitung und Organisation aus den Erfahrungen der Grundschule

- Unterrichtseinstiege, Themenrecherche, Reihenplanung, Arbeitsblätter und digitale Aufgaben erstellen lassen, Arbeitsblätter zu YouTube-Videos mit ChatGPT erstellen lassen, Ein Kahoot-Quiz mit ChatGPT erstellen lassen
- Differenzierung: Material in unterschiedlichen Niveaustufen erstellen lassen
- Sonderpädagogik: Ideen zur Umsetzung von Förderzielen, Förderplanerstellung
- Diklusion und KI (Taskcard von Lea Schulz)
- Barrierefreie Bilder mit ChatGPT erstellen (Alternativtexte erstellen etc.), Seeing AI als Unterstützung bei Seebeeinträchtigung (eine Art sprechende Kamera)
- ChatGPT als Lernassistenten einsetzen (Erklärungsaufforderungen durch KI etc.)
- Sprachsensiblen Unterricht planen, Texte zusammenfassen, vereinfachen auf unterschiedlichen Niveaustufen
- Tools wie Meister Cody Diagnostik bieten Möglichkeiten zur Elternberatung, Diagnostik, adaptiven Förderung
- Unterstützung im Rahmen der Organisationstätigkeit
- Elternbriefe in verschiedenen Sprachen über deepl
- Datenschutzkonforme Transkription von Konferenzen, Elterngesprächen
- Planung von Klassenfahrten / Ideen für altersgemäße Schüleraktivitäten, Ausflüge mit Organisation von Elternbriefe, Elternkommunikation, Konzepterstellung

Dabei kann KI durchaus oder vielleicht sogar gerade auch von Lehrkräften bei der Bewältigung ihrer professionellen Aufgaben wie z. B. für die Planung von Unterricht, die Erstellung von Unterrichtsmaterialien, Übungsaufgaben und Prüfungsaufgaben, die Vorbereitung von Beratungs- und Fördergesprächen, die Erstellung von Lehrplänen oder die Planung von Klassenfahrten verwendet werden (Shah, 2023). KI kann hier zu einer zeitlichen Entlastung von Lehrkräften beitragen, indem u. a. zeitaufwändige administrative Aufgaben mit hohem Standardisierungsgrad ausgelagert werden können. Aber auch bezogen auf den unmittelbaren Unterricht können in der Zusammenarbeit mit einer KI Aufgaben effizienter erledigt werden. Es können mit Hilfe generativer KI z. B. verschiedene Textvarianten erzeugt werden, um so im inklusiven Unterricht für Kinder mit besonderem Förderbedarf an ihren Fähigkeiten orientierte Texte in einfacher Sprache zur Verfügung stellen zu können. In Zeiten des Lehrkräftemangels ist jegliche Zeitersparnis bereits positiv zu bewerten. Insbesondere können damit aber auch Freiräume geschaffen werden, die für die Beziehungsarbeit und für die persönliche Unterstützung einzelner Schülerinnen und Schüler genutzt werden können.

In einem kürzlich erschienen Aufsatz von Hein et al. (2024) wird der Einsatz generativer KI für insgesamt 17 Aufgabenbereiche illustriert, die die Unterrichtsvorbereitung, die Organisation von Beratung und Förderangeboten sowie weitere Dienstaufgaben (Verwaltung, Fortbildung) umfassen. Für beispielhafte Aufgaben aus diesen Bereichen wurden Prompts entwickelt und die von ChatGPT generierten Lösungsvorschläge wurden durch Lehrkräfte hinsichtlich der Komplexität der Umsetzung mit ChatGPT und dem notwendigen Revisionsbedarf beurteilt. Die Ergebnisse zeigen, dass viele der Lösungsvorschläge als verhältnismäßig einfach umsetzbar und mit geringem Revisionsbedarf verbunden wahrgenommen werden. Die Anwendungen von KI für diese Aufgaben werden als „Gewinner“ bezeichnet. Negative Einschätzungen ergeben sich vor allem für die Aufgabenbereiche, deren Lösungen aus Sicht der Lehrkräfte nicht unmittelbar genutzt werden können (hoher Revisionsbedarf). Diese Einschätzungen sind insofern interessant, weil sie möglicherweise eine falsche Erwartungshaltung an die Arbeit mit generativer KI widerspiegeln, wonach auf der Basis eines ersten Prompts unterbreitete Lösungsvorschläge unmittelbar, d. h. ohne weitere Modifikationen, nutzbar sein sollten. Eine alternative Sicht besteht darin, mit der KI gemeinsam an der Optimierung von Lösungsvorschlägen zu arbeiten und diese eher als Kollaborationspartner zu begreifen. Dieser Ansatz der schrittweisen Optimierung wird bei Hashem et al. (2024) sichtbar, die illustrieren, wie generative KI für die Entwicklung von Unterrichtsplänen eingesetzt werden kann. Hier wird ChatGPT nach einem ersten Lösungsvorschlag aufgefordert, sich in der Revision stärker an einem theoretischen Modell der Unterrichtsstrukturierung zu orientieren. Dabei wird deutlich, wie durch eine Spezifikation der Promptvorgaben eine Verbesserung der Lösungsvorschläge erzielt werden kann.

Der Arbeitsaufwand für die Erstellung hinreichend spezifischer Prompts kann jedoch trotzdem (zumindest beim ersten Mal) erheblich sein. Zudem beinhalten die Trainingsdatensätze generischer KI-Anwendungen in der Regel keine (qualitätsgesicherten) Inhalte mit besonderer Relevanz für den Bildungsbereich. Eine für den deutschen Markt verfügbare und DSGVO-konforme Alternative präsentiert der Cornelsen Verlag mit cornelsen.ai bzw. der KI Toolbox. Diese unterstützt Lehrkräfte bei organisatorischen Aufgaben, bei der Materialentwicklung, der Unterrichtsplanung und der Korrektur von (handschriftlich bearbeiteten) Aufgabenstellungen in den Fächern Deutsch und Englisch mithilfe vorgefertigter Prompts. Die Antworten der KI-Werkzeuge greifen dabei auch auf Verlagsinhalte zurück und beruhen damit auf redaktionell betreuten Informationsangeboten.

5. Fazit

Die Ausführungen illustrieren die Komplexität und Widersprüchlichkeit des Themas Künstliche Intelligenz im schulischen Bildungswesen. Sie zeigen aber auch, wie wichtig eine differenzierte Betrachtung ist – weder wirkt KI als Wunder-Bildungswaffe, die sämtliche Herausforderungen des Lehrens und Lernens lösen kann, noch macht sie alles obsolet, was wir über Gestaltung von Lehr- und Lernprozessen wissen. Auch bei KI ist der didaktisch sinnvolle Einsatz angeleitet durch gut ausgebildete Lehrkräfte und unter Berücksichtigung bereits vorhandener Kompetenzen von Schülerinnen und Schülern entscheidend. Wie bei der Debatte um die digitale Transformation allgemein stellt sich die Frage, inwieweit KI lediglich zur Anreicherung und kleinteiligen digitalen Umgestaltung bekannter Unterrichtspraktiken genutzt wird oder aber eine tiefgreifende Veränderung des Bildungswesens möglich aber auch notwendig macht. Die durch KI-Anwendungen entstandene Disruption erscheint aber noch deutlicher als es bei anderen digitalen Technologien der Fall ist, insbesondere weil lang etablierte Rollen in Frage gestellt werden: Bleibt die Lehrkraft diejenige Instanz, die erklärt, überprüft und anleitet? Wie verschieben sich Verantwortlichkeiten für die Gestaltung von Bildungsprozessen in dem Dreieck zwischen Schülerinnen und Schüler, Lehrkraft und Technologie? Wie können wir es schaffen, ein eher träges Bildungssystem in Einklang zu bringen mit der sprunghaften Entwicklungsdynamik von KI-Technologie? Wie kann es gelingen, dass Lehrkräfte durch KI entlastet werden, wenn sie aber zunächst Zeit investieren müssen, um die Potenziale von KI kennen und nutzen zu lernen? Auf diese und weitere Paradoxien weist auch Joscha Falck hin. Diese Überblicksarbeit hat nicht den Anspruch, Lösungen für diese Widersprüche bereitzustellen, die teilweise auch grundsätzlichere, normative Diskurse darüber erfordern, welche Bildungsziele uns als Gesellschaft wichtig sind. Vielmehr versucht sie eine Beschreibung des aktuellen Erkenntnisstands, um Orientierungswissen für das Handeln in einer sich ständig ändernden, digital geprägten Welt bereitzustellen.

Nur kurz zum Schluss (KI-Zusammenfassung)

Der Einsatz von KI im Bildungsbereich erfordert eine differenzierte Betrachtung und sorgfältige Implementierung. Lehrkräfte bleiben zentrale Akteure, deren Rolle sich jedoch wandelt. Schulen und Bildungspolitik stehen vor der Herausforderung, Rahmenbedingungen zu schaffen, die einen sinnvollen und ethischen Einsatz von KI ermöglichen. Eine kontinuierliche Anpassung des Bildungssystems an die dynamische Entwicklung von KI-Technologien ist unerlässlich, um Schülerinnen und Schüler optimal auf eine von KI geprägte Zukunft vorzubereiten.

6. Literatur

Akata, Z., et al. (2020). A research agenda for hybrid intelligence: Augmenting human intellect with collaborative, adaptive, responsible, and explainable artificial intelligence. *Computer, 53*(8), 18–28. https://doi.org/10.1109/MC.2020.2996587

Akçayır, G., & Akçayır, M. (2018). The flipped classroom: A review of its advantages and challenges. *Computers & Education*, *126*, 334-345. https://doi.org/10.1016/j.compedu.2018.07.021

Alemdag, E. (2023). The effect of chatbots on learning: a meta-analysis of empirical research. *Journal of Research on Technology in Education,* 1-23. https://doi.org/10.1080/15391523.2023.2255698

Baker, R. S., & Hawn, A. (2022). Algorithmic Bias in Education. *International Journal of Artificial Intelligence in Education*, *32*(4), 1052-1092. https://doi.org/10.1007/s40593-021-00285-9

Bernacki, M. L., Greene, M. J., & Lobczowski, N. G. (2021). A systematic review of research on personalized learning: Personalized by whom, to what, how, and for what purpose(s)? *Educational Psychology Review, 33*(4), 1675–1715. https://doi.org/10.1007/s10648-021-09615-8

Bernius, J. P., Krusche, S., & Bruegge, B. (2022). Machine learning based feedback on textual student answers in large courses. *Computers and Education: Artificial Intelligence*, *3*, 100081. https://doi.org/10.1016/j.caeai.2022.100081

Bewersdorff, A., Seßler, K., Baur, A., Kasneci, E., & Nerdel, C. (2023). Assessing student errors in experimentation using artificial intelligence and large language models: A comparative study with human raters. Computers and Education: Artificial Intelligence, 5, 100177. https://doi.org/10.1016/j.caeai.2023.100177

Briganti, G., & Le Moine, O. (2020). Artificial intelligence in medicine: today and tomorrow. *Frontiers in medicine*, *7*, Article 509744. https://doi.org/10.3389/fmed.2020.00027

Buchholtz, N., Schorcht, S., Baumanns, L., Huget, J., Noster, N., Rott, B., ... & Sommerhoff, D. (2024). Damit rechnet niemand!: Sechs Leitgedanken zu Implikationen und Forschungsbedarfen zu KI-Technologien im Mathematikunterricht. *Mitteilungen der Gesellschaft für Didaktik der Mathematik*, (117), 15-24.

Buçinca, Z., Malaya, M. B., & Gajos, K. Z. (2021). To trust or to think: cognitive forcing functions can reduce overreliance on AI in AI-assisted decision-making. *Proceedings of the ACM on Human-computer Interaction, 5(CSCW1), 1-21.* https://doi.org/10.1145/3449287

Chai, C. S., Lin, P. Y., Jong, M. S. Y., Dai, Y., Chiu, T. K. & Huang, B. (2020). Factors influencing students' behavioral intention to continue artificial intelligence learning. In *2020 International Symposium on Educational Technology* (ISET) (pp. 147–150). IEEE. https://doi.org/10.1109/ISET49818.2020.00040

Chaudhry, M. A., Cukurova, M., & Luckin, R. (2022). A transparency index framework for AI in education. In M. M. Rodrigo, N. Matsuda, A. I. Cristea, & V. Dimitrova (Eds.), *Lecture Notes in Computer Science. Artificial Intelligence in Education. Posters and Late Breaking Results, Workshops and Tutorials, Industry and Innovation Tracks, Practitioners' and Doctoral Consortium* **(Vol. 13356, pp. 195–198).** Springer International Publishing. https://doi.org/10.1007/978-3-031-11647-6_33

Chin, D. B., Dohmen, I. M., & Schwartz, D. L. (2013). Young children can learn scientific reasoning with teachable agents. *IEEE Transactions on Learning Technologies, 6*(3), 248–257. https://doi.org/10.1109/TLT.2013.24

Chinn, C. A. & Ravit, G. D. (2018). What is the value of general knowledge of scientific reasoning?. In F. Fischer, C. A. Chinn, K. Engelmann, & J. Osborne (Eds.), *Scientific reasoning and argumentation* (pp. 77-101). Routledge.

Delcker, J., Heil, J., & Ifenthaler, D. (2024). Evidence-based development of an instrument for the assessment of teachers' self-perceptions of their artificial intelligence competence. *Educational Technology Research and Development*. https://doi.org/10.1007/s11423-024-10418-1

D'Mello, S. K., & Graesser, A. (2023). Intelligent tutoring systems: How computers achieve learning gains that rival human tutors. In *Handbook of educational psychology* (pp. 603-629). Routledge. https://doi.org/10.4324/9780429433726

Du Boulay, B., Mitrovic, A., & Yacef, K. (Eds.). (2023). *Handbook of artificial intelligence in education. Edward Elgar Publishing.* https://doi.org/10.4337/9781800375413

Dünnebier, K., Gräsel, C., & Krolak-Schwerdt, S. (2009). Urteilsverzerrungen in der schulischen Leistungsbeurteilung. *Zeitschrift für Pädagogische Psychologie*, *23*(34), 187-195. https://doi.org/10.1024/1010-0652.23.34.187

Elliott, A. (2019). The culture of AI: Everyday life and the digital revolution. Routledge.

Ericsson, K. A. (2006). The influence of experience and deliberate practice on the development of superior expert performance. *The Cambridge handbook of expertise and expert performance, 38(685-705), 2-2.*

Gottschalk, F. & Weise, C. (2023). Digital equity and inclusion in education: An overview of practice and policy in OECD countries. *OECD Education Working Papers No 299*. Paris: OECD Publishing. https://doi.org/10.1787/7cb15030-en

Greiff, S., Wüstenberg, S., Csapó, B., Demetriou, A., Hautamäki, J., Graesser, A. C., & Martin, R. (2014). Domain-general problem solving skills and education in the 21st century. *Educational Research Review*, *13*, 74-83. https://doi.org/10.1016%2Fj.edurev.2014.10.002

Guerrero-Roldán, A. E., Rodríguez-González, M. E., Bañeres, D., Elasri-Ejjaberi, A., & Cortadas, P. (2021). Experiences in the use of an adaptive intelligent system to enhance online learners' performance: A case study in Economics and Business courses. *International Journal of Educational Technology in Higher Education, 18*(1), 1–27. https://doi.org/10.1186/s41239-021-00271-0

Hashem, R., Ali, N., El Zein, F., Fidalgo, P., & Khurma, O. A. (2024). AI to the rescue: Exploring the potential of ChatGPT as a teacher ally for workload relief and burnout prevention. *Research & Practice in Technology Enhanced Learning, 19*. https://doi.org/10.58459/rptel.2024.19023

Hein, L., Högemann, M., Illgen, KM. et al. (2024). ChatGPT als Unterstützung von Lehrkräften – Einordnung, Analyse und Anwendungsbeispiele. *HMD 61*, 449–470. https://doi.org/10.1365/s40702-024-01052-9

Hoff, T. (2011). Deskilling and adaptation among primary care physicians using two work innovations. *Health Care Management Review*, 36(4), 338-348. https://doi.org/10.1097/HMR.0b013e31821826a1

Holstein, K., McLaren, B. M., & Aleven, V. (2019). Designing for complementarity: Teacher and student needs for orchestration support in AI-enhanced classrooms. In S. Isotani, E. **Millán, A. Ogan, P. Hastings, B. McLaren, & R. Luckin (Eds.)** *Artificial Intelligence in Education: 20th International Conference, AIED 2019, Chicago, IL, USA, June 25-29, 2019, Proceedings, Part I 20* (pp. 157-171). Springer International Publishing. https://doi.org/10.1007/978-3-030-23204-7_14

Hopcan, S., Polat, E., Ozturk, M. E., & Ozturk, L. (2022). Artificial intelligence in special education: a systematic review. *Interactive Learning Environments*, 31(10), 7335–7353. https://doi.org/10.1080/10494820.2022.2067186

Huang, X. (2021). Aims for cultivating students' key competencies based on artificial intelligence education in China. *Education and Information Technologies, 26*(5), 5127–5147. https://doi.org/10.1007/s10639-021-10530-2

Huber, S. E., Kiili, K., Nebel, S., et al. (2024). Leveraging the Potential of Large Language Models in Education Through Playful and Game-Based Learning. Educational Psychology Review, 36(1), 1-20. https://doi.org/10.1007/s10648-024-09868-z

Ibrahim, H., Liu, F., Asim, R. et al. (2023). Perception, performance, and detectability of conversational artificial intelligence across 32 university courses. *Scientific Reports, 13*, 12187. https://doi.org/10.1038/s41598-023-38964-3

Ijaz, K., Bogdanovych, A., & Trescak, T. (2017). Virtual worlds vs books and videos in history education. *Interactive Learning Environments, 25*(7), 904-929. https://doi.org/10.1080/10494820.2016.1225099

Jansen, T., Höft, L., Bahr, L., Fleckenstein, J., Möller, J., Köller, O., & Meyer, J. (2024). Comparing generative AI and expert feedback to students' writing: Insights from student teachers. *Psychologie in Erziehung und Unterricht, 71*(2), 80–92. https://doi.org/10.2378/peu2024.art08d

Jauhiainen, J. S., & Garagorry Guerra, A. (2024). Generative AI in education: ChatGPT-4 in evaluating students' written responses. *Innovations in Education and Teaching International*, 1-15. https://doi.org/10.1080/14703297.2024.2422337

Katz, D. M., Bommarito, M. J., Gao, S., & Arredondo, P. (2024). GPT-4 passes the bar exam. *Philosophical Transactions of the Royal Society A, 382*(2270), 20230254. https://doi.org/10.1098/rsta.2023.0254

KMK, Kultusministerkonferenz (2021, 9. Dezember). *Lehren und Lernen in der digitalen Welt – Ergänzung zur Strategie der Kultusministerkonferenz „Bildung in der digitalen Welt"*. https://www.kmk.org/fileadmin/veroeffentlichungen_beschluesse/2021/2021_12_09-Lehren-und-Lernen-Digi.pdf

KMK, Kultusministerkonferenz (2024, 10. Oktober). *Handlungsempfehlung für die Bildungsverwaltung zum Umgang mit Künstlicher Intelligenz in schulischen Bildungsprozessen*. https://www.kmk.org/fileadmin/veroeffentlichungen_beschluesse/2024/2024_10_10-Handlungsempfehlung-KI.pdf

Kim, S., Jang, Y., Choi, S., Kim, W., Jung, H., Kim, S., & Kim, H. (2021). Analyzing Teacher Competency with TPACK for K-12 AI Education. *KI – Künstliche Intelligenz*, *35*(2), 139-151. https://doi.org/10.1007/s13218-021-00731-9

Krügel, S., Ostermaier, A., & Uhl, M. (2023). ChatGPT's inconsistent moral advice influences users' judgment. *Scientific Reports*, *13*(1), 4569. https://doi.org/10.1038/s41598-023-31341-0

Kuhail, M.A., Alturki, N., Alramlawi, S. & Alhejori, K. (2023). Interacting with educational chatbots: A systematic review. *Education and Information Technologies, 28*, 973–1018. https://doi.org/10.1007/s10639-022-11177-3

Kulik, J. A., & Fletcher, J. (2016). Effectiveness of intelligent tutoring systems: A meta-analytic review. *Review of Educational Research*, *86*(1), 42–78. https://doi.org/10.3102/0034654315581420

Lee, J., Hicke, Y., Yu, R., Brooks, C., & Kizilcec, R. F. (2024). The life cycle of large language models in education: A framework for understanding sources of bias. *British Journal of Educational Technology*. https://doi.org/10.1111/bjet.13505

Long, D. & Magerko, B. (2020). What is AI literacy? Competencies and design considerations. *Proceedings of the CHI Conference on Human Factors in Computing Systems*. 1–16. https://doi.org/10.1145/3313831.3376727

Lorenz, G., Gentrup, S., Kristen, C., Stanat, P., & Kogan, I. (2016). Stereotype bei Lehrkräften? Eine Untersuchung systematisch verzerrter Lehrererwartungen. *KZfSS Kölner Zeitschrift für Soziologie und Sozialpsychologie*, *68*(1), 89-111. https://doi.org/10.1007/s11577-015-0352-3

Ma, W., Adesope, O. O., Nesbit, J. C., & Liu, Q. (2014). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal of Educational Psychology*, *106*(4), 901–918. https://doi.org/10.1037/a0037123

Meyer, J., Jansen, T., Fleckenstein, J., Keller, S., & Köller, O. (2023). Machine Learning im Bildungskontext: Evidenz für die Genauigkeit der automatisierten Beurteilung von Essays im Fach Englisch. *Zeitschrift Für Pädagogische Psychologie, 37*(3), 203–214. https://doi.org/10.1024/1010-0652/a000296

Meyer, J., Jansen, T., Schiller, R., Liebenow, L. W., Steinbach, M., Horbach, A., & Fleckenstein, J. (2024). Using LLMs to bring evidence-based feedback into the classroom: AI-generated feedback increases secondary students' text revision, motivation, and positive emotions. *Computers and Education: Artificial Intelligence*, *6*, 100199. https://doi.org/10.1016/j.caeai.2023.100199

Mich, O., Pianta, E., & Mana, N. (2013). Interactive stories and exercises with dynamic feedback for improving reading comprehension skills in deaf children. *Computers & Education*, *65*, 34–44. https://doi.org/10.1016/j.compedu.2013.01.016

Molenaar, I. (2021). Personalisation of learning: Towards hybrid human-AI learning technologies. In OECD (Ed.), *OECD digital education outlook 2021: Pushing the frontiers with artificial intelligence, blockchain and robots* (pp. 57–77). OECD Publishing.

Molenaar, I., & Knoop-van Campen, C. (2017). Teacher dashboards in practice: Usage and impact. In É. Lavoué, H. Drachsler, K. Verbert, J. Broisin, & M. Pérez-Sanagustín (Eds.), *Lecture Notes in Computer Science. Data Driven Approaches in Digital Education* (Vol. 10474, pp. 125–138). Springer International Publishing. https://doi.org/10.1007/978-3-319-66610-5_10

Neves, D. M., & Anderson, J. R. (1981). Knowledge compilation: Mechanisms for the automatization of cognitive skills. In J. R. Anderson (Ed.), *Cognitive skills and their acquisition* (pp. 57-84). Psychology Press.

Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2021). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence, 2,* Article 100041. https://doi.org/10.1016/j.caeai.2021.100041

Ng, D. T. K., Leung, J.K.L., Su, J., Ng, R. C. W., & Chu, S. K. W. (2023). Teachers' AI digital competencies and twenty-first century skills in the post-pandemic world. *Educational Technology Research and Development, 71*, 137–161. https://doi.org/10.1007/s11423-023-10203-6

Ninaus, M., & Sailer, M. (2022). Closing the loop – The human role in artificial intelligence for education [Perspective]. *Frontiers in Psychology*, *13*. https://doi.org/10.3389/fpsyg.2022.956798

OECD. (2001). Understanding the digital divide. https://www.oecd.org/sti/1888451.pdf

Perković, G., Drobnjak, A., & Botički, I. (2024). Hallucinations in LLMs: Understanding and Addressing Challenges. In 2024 47th MIPRO ICT and Electronics Convention (MIPRO) (pp. 2084-2088). IEEE. https://doi.org/10.1109/MIPRO60963.2024.10569238

Plass, J. L., & Pawar, S. (2020). Toward a taxonomy of adaptivity for learning. *Journal of Research on Technology in Education,* *52*(3), 275–300. https://doi.org/10.1080/15391523.2020.1719943

Rafner, J., Dellermann, D., Hjorth, A., Verasztó, D., Kampf, C., Mackay, W., & Sherson, J. (2022). Deskilling, upskilling, and reskilling: a case for hybrid intelligence. *Morals & Machines, 1*(2), 24-39. https://doi.org/10.5771/2747-5174-2021-2

Sailer, M., Bauer, E., Hofmann, R., Kiesewetter, J., Glas, J., Gurevych, I., & Fischer, F. (2023). Adaptive feedback from artificial neural networks facilitates pre-service teachers' diagnostic reasoning in simulation-based learning. *Learning and Instruction*, *83*, 101620. https://doi.org/10.1016/j.learninstruc.2022.101620

Sailer, M., Maier, R., Berger, S., Kastorff, T., & Stegmann, K. (2024). Learning activities in technology-enhanced learning: A systematic review of meta-analyses and second-order meta-analysis in higher education. *Learning and Individual Differences, 112,* Article 102446. https://doi.org/10.1016/j.lindif.2024.102446

Sailer, M., Ninaus, M., Huber, S. E., Bauer, E., & Greiff, S. (2024). The End is the Beginning is the End: The closed-loop learning analytics framework. *Computers in Human Behavior, 108305*. https://doi.org/10.1016/j.chb.2024.108305

Scarfe, P., Watcham, K., Clarke, A., & Roesch, E. (2024) A real-world test of artificial intelligence infiltration of a university examinations system: A "Turing Test" case study. *PLoS ONE 19*(6): e0305354. https://doi.org/10.1371/journal.pone.0305354

Scheidig, F., & Holmeier, M. (2023). Prognose von Studienabbrüchen angehender Lehrkräfte mit Maschinellem Lernen: Potenziale der Nutzung von Studierenden- und Studienverlaufsdaten aus dem Campus-Management-System. *Unterrichtswissenschaft*, *51*(4), 489-509. https://doi.org/10.1007/s42010-023-00182-1

Scheiter, K. (2021). Lernen und Lehren mit digitalen Medien: Eine Standortbestimmung. *Zeitschrift für Erziehungswissenschaft, 24,* 1039–1060. https://doi.org/10.1007/s11618-021-01047-y

Seo, K., Tang, J., Roll, I., Fels, S., & Yoon, D. (2021). The impact of artificial intelligence on learner–instructor interaction in online learning. *International Journal of Educational Technology in Higher Education, 18*(1), 1–23. https://doi.org/10.1186/s41239-021-00292-9

Shah, P. (2023). AI and the Future of Education: Teaching in the Age of Artificial Intelligence. John Wiley & Sons.

Sperling, K., Stenberg, C. J., McGrath, C., Åkerfeldt, A., Heintz, F., & Stenliden, L. (2024). In search of artificial intelligence (AI) literacy in Teacher Education: A scoping review. *Computers and Education Open*, 100169. https://doi.org/10.1016/j.caeo.2024.100169

Stadler, M., Bannert, M., & Sailer, M. (2024). Cognitive ease at a cost: LLMs reduce mental effort but compromise depth in student scientific inquiry. *Computers in Human Behavior,* Article 108386. https://doi.org/10.1016/j.chb.2024.108386

Steenbergen-Hu, S., & Cooper, H. (2013). A meta-analysis of the effectiveness of intelligent tutoring systems on K–12 students' mathematical learning. *Journal of educational psychology*, *105*(4), 970. https://doi.org/10.1037/a0032447

Steenbergen-Hu, S., & Cooper, H. (2014). A meta-analysis of the effectiveness of intelligent tutoring systems on college students' academic learning. *Journal of educational psychology*, *106*(2), 331. https://doi.org/10.1037/a0034752

Sun, S., Else-Quest, N. M., Hodges, L. C., French, A. M., & Dowling, R. (2021). The effects of ALEKS on mathematics learning in K-12 and higher education: A meta-analysis. *Investigations in Mathematics Learning*, *13*(3), 182-196. https://doi.org/10.1080/19477503.2021.1926194

Sutton, S. G., Arnold, V., & Holt, M. (2018). How Much Automation Is Too Much? Keeping the Human Relevant in Knowledge Work. *Journal of Emerging Technologies in Accounting*, *15*(2), 15–25. https://doi.org/10.2308/jeta-52311

SWK, Ständige Wissenschaftliche Kommission der Kultusministerkonferenz (2024): Large Language Models und ihre Potenziale im Bildungssystem. Impulspapier der Ständigen Wissenschaftlichen Kommission (SWK) der Kultusministerkonferenz. https://doi.org/10.25656/01:28303

VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist, 46*(4), 197–221. https://doi.org/10.1080/00461520.2011.611369

Vasconcelos, H., Jörke, M., Grunde-McLaughlin, M., Gerstenberg, T., Bernstein, M. S., & Krishna, R. (2023). Explanations can reduce overreliance on AI systems during decision-making. *Proceedings of the ACM on Human-Computer Interaction, 7(CSCW1),* 1-38. https://doi.org/10.1145/3579605

Vazhayil, A., Shetty, R., Bhavani, R. R., & Akshay, N. (2019, December). Focusing on teacher education to introduce AI in schools: Perspectives and illustrative findings. In *2019 IEEE tenth international conference on Technology for Education (T4E)* (pp. 71–77). IEEE.

Vodafone-Stiftung (2023). Aufbruch ins Unbekannte – Ergebnisse einer repräsentativen Umfrage in der deutschen Bevölkerung mit besonderem Fokus auf Eltern schulpflichtiger Kinder Schule in Zeiten von künstlicher Intelligenz und ChatGPT. Vodafone-Stiftung. https://www.vodafone-stiftung.de/wp-content/uploads/2023/04/Aufbruch-ins-Unbekannte_Studie-zu-KI-im-Schulkontext.pdf

Vodafone-Stiftung (2024). *Pioniere des Wandels – Wie Schüler:innen KI im Unterricht nutzen möchten.* Vodafone-Stiftung. https://www.vodafone-stiftung.de/wp-content/uploads/2024/03/Pioniere-des-Wandels-wie-Schueler-innen-KI-im-Unterricht-nutzen-wollen-Jugendstudie-der-VS-2024.pdf

Vuorikari, R., Kluzer, S., & Punie, Y. (2022). DigComp 2.2: The digital competence framework for citizens-with new examples of knowledge, skills and attitudes. Publications Office of the European Union. https://doi.org/10.2760/490274

Wang, R. E., & Demszky, D. (2023). Is ChatGPT a good teacher coach? Measuring zero-shot performance for scoring and providing actionable insights on classroom instruction. https://arxiv.org/abs/2306.03090

Wei, K. K., Teo, H. H., Chan, H. C., & Tan, B. C. (2011). Conceptualizing and testing a social cognitive model of the digital divide. *Information Systems Research, 22*(1), 170-187. https://doi.org/10.1287/isre.1090.0273

Wu, R., & Yu, Z. (2024). Do AI chatbots improve students learning outcomes? Evidence from a meta-analysis. *British Journal of Educational Technology, 55*(1), 10-33. https://doi.org/10.1111/bjet.13334

Yan, L., Greiff, S., Teuber, Z., & Gašević, D. (2024). Promises and challenges of generative artificial intelligence for human learning. *Nature Human Behaviour*, *8*(10), 1839-1850. https://doi.org/10.1038/s41562-024-02004-5

Yang, G., Ouyang, Y., Ye, Z., Gao, R., & Zeng, Y. (2022). Social-path embedding-based transformer for graduation development prediction. *Applied Intelligence, 55*. 14119-14136. https://doi.org/10.1007/s10489-022-03268-y

Yang, W. (2022). Artificial Intelligence education for young children: Why, what, and how in curriculum design and implementation. *Computers and Education: Artificial Intelligence, 3*. 100061. https://doi.org/10.1016/j.caeai.2022.100061

Yoon, S.-Y., Miszoglad, E., & Pierce, L. R. (2023). Evaluation of ChatGPT feedback on ELL writers‘ coherence and cohesion. https://doi.org/10.48550/arXiv.2310.06505

Zheng, L., Niu, J., Zhong, L., & Gyasi, J. F. (2023). The effectiveness of artificial intelligence on learning achievement and learning perception: A meta-analysis. *Interactive Learning Environments, 31*(9), 5650-5664. https://doi.org/10.1080/10494820.2021.2015693

Zou, B., Du, Y., Wang, Z., Chen, J., and Zhang, W. (2023). An investigation into artificial intelligence speech evaluation programs with automatic feedback for developing EFL learners' speaking skills. *SAGE Open, 13*. https://doi.org/10.1177/21582440231193818

7. Weiterführende Literatur und Informationen

Einführung in KI und maschinelles Lernen:
https://link.springer.com/book/10.1007/978-3-658-26763-6

KI in der Schule:
https://ki-macht-schule.de/

Unterrichtsmaterialien zu Bias in Künstlicher Intelligenz:
https://www.dguv-lug.de/sekundarstufe-ii/medienkompetenz/bias-wie-objektiv-ist-ki/

Weiterführende Informationen zu Bias in Künstlicher Intelligenz:
https://bias-and-fairness-in-ai-systems.de/

Leitfaden für die datenschutzkonforme Auswahl und Nutzung von Apps (BW):
https://it.kultus-bw.de/site/pbs-bw-new/get/params_Dattachment/4695616/Handreichung-Auswahl-Apps.pdf

Lehrerhandout "Datenschutz geht zur Schule":
https://www.bvdnet.de/datenschutz-geht-zur-schule/lehrerhandout/

KI-Campus:
https://ki-campus.org/
(Überblick über Angebote für Lehrkräfte:
https://ki-campus.org/sites/default/files/2023-01/2023_KI-Campus_Lehrkr%C3%A4fte.pdf)

Kultusministerkonferenz (2024, 10. Oktober). *Handlungsempfehlung für die Bildungsverwaltung zum Umgang mit Künstlicher Intelligenz in schulischen Bildungsprozessen*.
https://www.kmk.org/fileadmin/veroeffentlichungen_beschluesse/2024/2024_10_10-Handlungsempfehlung-KI.pdf

Ständige Wissenschaftliche Kommission der Kultusministerkonferenz (2024): Large Language Models und ihre Potenziale im Bildungssystem. Impulspapier der Ständigen Wissenschaftlichen Kommission (SWK) der Kultusministerkonferenz.
https://doi.org/10.25656/01:28303

Virtuelles Kompetenzzentrum: Künstliche Intelligenz und wissenschaftliches Arbeiten (VK-KIWA):
https://www.vkkiwa.de/