Hochschulforum Digitalisierung

DISKUSSIONSPAPIER NR. 42 / NOVEMBER 2026

Deskilling revisited in der Hochschulbildung

Begriff, Formen und Befunde zu Deskilling in Zeiten generativer KI

Drei Jahre nach einem ersten Diskussionspapier nimmt der Beitrag den Begriff Deskilling im Kontext generativer KI erneut in den Blick. Er bestimmt Deskilling als Beeinträchtigung von Kompetenz, Expertise und Urteilskraft, unterscheidet Nicht-Lernen, Verlernen und Fehllernen sowie eine individuelle und kollektive Ebene und sichtet exemplarisch empirische Befunde. Diese belegen Deskilling vor allem als Nicht-Lernen, zeigen aber auch, dass es nicht zwangsläufig eintritt, und lassen Forschungslücken erkennen. Abschließend skizziert er Folgerungen für Studium und Lehre.

Autorin

Prof. Dr. Gabi Reinmann, Universität Hamburg

1. Ausgangspunkt: Deskilling als Thema der Hochschuldidaktik

1.1. Anlass und Einordnung

Im Oktober 2023 habe ich in einem Diskussionspapier die Frage gestellt, ob „Deskilling" durch Künstliche Intelligenz (KI) ein Thema der Hochschuldidaktik sein sollte (Reinmann, 2023). Anlass war die Stellungnahme des Deutschen Ethikrats (2023), der das Risiko individueller und kollektiver Kompetenzverluste auf diese knappe Formel gebracht hatte. Die Debatte, die mit der Verbreitung von ChatGPT einsetzte, kreiste dagegen vor allem um die Frage, welche neuen Kompetenzen für den Umgang mit KI aufzubauen seien. Dass Kompetenzen auch verloren gehen könnten, spielte damals national wie international kaum eine Rolle. Mein Fazit fiel entsprechend vorsichtig aus; Kompetenzverluste durch generative KI in Studium, Lehre und Forschung schienen theoretisch möglich. Empirie dazu aber gab es kaum und offen blieb, ob der Begriff Deskilling geeignet ist, das Interesse an diesem Phänomen auch im Hochschulkontext zu wecken.

Rund drei Jahre später stellt sich die Situation anders dar. Seit 2023 sind zahlreiche Befragungsstudien zur Nutzung generativer KI im Studium entstanden, in Deutschland wie international (z.B. Chan & Hu, 2023; von Garrel & Mayer, 2023), und sie werden fortgeführt, etwa in der Schreibdidaktik (Hoffmann et al., 2026). Sie geben Auskunft darüber, wie Studierende und Lehrende KI nutzen und wie sie deren Folgen selbst einschätzen. Inzwischen gibt es auch Experimente, die den Umgang mit KI nicht nur erfragen, sondern Effekte direkt untersuchen (z.B. Darvishi et al., 2024), und erste Design-Based Research-Studien, in denen mit Interventionen gestaltend geforscht wird (z.B. Preiß, Bartels et al., 2025). Die Befunde sind nicht einheitlich, was bei einem jungen Forschungsfeld kaum überrascht. Einige Studien zeigen Deskilling, andere eher verwandte Phänomene wie eine nachlassende Selbststeuerung beim Lernen oder eine Überschätzung des eigenen Könnens, wieder andere Lerngewinne. Deutlich wird gleichwohl: Deskilling durch generative KI ist nicht nur eine theoretische Möglichkeit, sondern empirisch nachweisbar (siehe Abschnitt 4).

Ausdifferenziert hat sich auch die Begriffslandschaft. In der medizinischen Ausbildungsforschung unterscheiden Abdulnour et al. (2025) Deskilling als Verlust bereits erworbener Fähigkeiten, *never-skilling* als ausbleibende Entwicklung von Kompetenzen und *mis-skilling* als Verfestigung falschen Verhaltens durch Fehler oder Verzerrungen infolge von KI.[1] Lindebaum et al. (in Druck) führen den Begriff *epistemic deskilling* (Verlust praktischer Urteilskraft) ein. Andere Autoren wählen Begriffe, die Deskilling umschreiben oder zu erklären versuchen: Fan et al. (2025) sprechen von *metacognitive laziness* und meinen damit die Abgabe der Steuerung und Überwachung des eigenen Lernens an die KI mit Konsequenzen für die Kompetenzentwicklung; Kosmyna et al. (2025) verwenden den Begriff *cognitive debt*, um den sich anhäufenden Folgekosten einen Namen zu geben, wenn Denkarbeit wiederholt an KI delegiert wird.

Die Frage nach möglichen Kompetenzverlusten ist inzwischen in der Hochschulbildung angekommen und ergänzt die nach KI-Kompetenzen: Diskussionspapiere greifen sie auf (z.B. Münzer et al., 2026),

[1] Begriffe wie Deskilling, Upskilling oder Future Skills, die im deutschsprachigen Diskurs eingeführt sind, verwende ich ohne Hervorhebung. Neuere Begriffe aus der englischsprachigen Literatur gebe ich kursiv und in der Originalschreibung wieder und biete beim ersten Vorkommen eine deutsche Umschreibung an, weil sich viele von ihnen nicht ohne Bedeutungsverschiebung einfach übersetzen lassen.

und der Wissenschaftsrat (2026) nähert sich ihr in seinen Empfehlungen von der anderen Seite: Er stellt die intellektuelle Souveränität ins Zentrum, also das, was vor Deskilling zu schützen ist. Ob der Begriff Deskilling Interesse weckt, 2023 als offene Frage formuliert, lässt sich damit zumindest vorläufig bejahen. Ob er die beobachtbaren Phänomene angemessen erfasst und was davon sich auch empirisch zeigt, lässt sich hingegen noch nicht eindeutig beantworten.

1.2. Anliegen und Ziel des Beitrags

Der vorliegende Text knüpft an das Diskussionspapier von 2023 an und entwickelt dessen Gedanken weiter. Seit 2023 bin ich dem Thema in mehreren Beiträgen, allein und mit anderen, direkt und indirekt weiter nachgegangen: zum Beispiel in Überlegungen zu Kompetenz-, Kontroll- und Sozialverlusten als Risiken für selbstbestimmtes Handeln durch KI (Reinmann et al., 2025), zu Nutzungsmodi im Umgang mit Dialogmaschinen (Herzberg & Reinmann, 2025), zur Bedeutung fachlichen Wissens für kritisches Denken (Reinmann, 2026a), zum akademischen Üben (Reinmann, in Druck). Diese Fäden führe ich hier zusammen und verbinde sie mit der Entwicklung des Diskurses seit 2023. Auf diese Weise prüfe ich, was sich an meinem damaligen Verständnis bewährt hat, was zu präzisieren ist und wo ich meine Einschätzung revidieren muss.

Dazu gehe ich zunächst der Frage nach, wie sich die Verwendung des Begriffs Deskilling verändert hat und welche verwandten Begriffe hinzugekommen sind. Mein Fokus liegt auf der Bedeutung, die der Begriff heute im Bildungskontext meistens hat und die für die Hochschulbildung besonders relevant ist: dass Menschen Kompetenzen verlieren oder gar nicht erst aufbauen. Die ursprüngliche, soziologische Bedeutung, wonach Arbeitsplätze geringere Qualifikationen erfordern, ist keineswegs unwichtig, ich verfolge sie hier aber nicht weiter. Schon 2023 schien mir der Begriff einerseits geeignet, auf ein wichtiges Risiko generativer KI aufmerksam zu machen, und andererseits als zu vereinfachend angesichts der Tragweite des damit gemeinten Phänomens – nach dem Motto „da gehen ein paar Fertigkeiten verloren“. Heute spreche ich mich dafür aus, Deskilling im Hochschulkontext deutlich weiter zu fassen, als es das Wort skill nahelegt; unterscheiden werde ich daher mehrere Formen und Ebenen, in denen sich Deskilling zeigen kann. Darüber hinaus gebe ich mit dem vorliegenden Text einen exemplarischen Einblick in die empirische Befundlage bis 2026. Theorie und Empirie verstehe ich dabei als komplementär: Die Theorie bestimmt, was Deskilling ausmacht, unabhängig davon, was sich derzeit empirisch erfassen lässt; die Empirie soll vorzugsweise zeigen, was bereits erkannt und was noch nicht untersucht ist und wo Befunde von den theoretischen Überlegungen abweichen oder über sie hinausgehen. Abschließend ziehe ich Folgerungen aus Empirie und Theorie und schließe mit einem Ausblick.

2. Gegenstand: Kompetenz, Expertise und Urteilskraft

Um zu bestimmen, was Deskilling im Hochschulkontext ausmacht, ist zunächst zu klären, was mit skill im Wort Deskilling gemeint ist, was also verloren gehen kann. Ich verstehe darunter Kompetenz und die Expertise, die sich aus ihr entwickelt, und sehe in der Urteilskraft ein damit verbundenes Konstrukt, mit dem Autonomie und der Austausch mit anderen ins Spiel kommen. Darauf geht mein Verständnis von 2023 nur zum Teil ein. Neuere Arbeiten, aber auch Theorien, die ich 2023 noch nicht

herangezogen habe, erlauben es, das Verständnis von Deskilling in diesem Sinne zu entfalten, zu präzisieren und an einigen Stellen zu korrigieren.

2.1. *Skill* als Kompetenz und Expertise

2023 habe ich den Begriff Deskilling als einen beschrieben, der eine soziologische und eine psychologische Seite hat (Reinmann, 2023). Soziologisch verstanden bezeichnet Deskilling die Veränderung von Arbeitsplätzen, wenn Technik anspruchsvolle Aufgaben übernimmt und dadurch der Bedarf an hoch qualifizierten Arbeitskräften sinkt; psychologisch meint es den Verlust von Kompetenzen (vgl. Rafner et al., 2021). Schon damals deutete einiges darauf hin, dass im Zusammenhang mit KI die psychologische Seite von Deskilling besonders interessiert; im Bildungskontext hat sich diese Bedeutung inzwischen weitgehend durchgesetzt. Der Gegenbegriff ist Upskilling – ebenfalls mit einer soziologischen und einer psychologischen Seite: höhere Qualifikationsanforderungen an Arbeitsplätze einerseits, Aufbau neuer oder anspruchsvollerer Kompetenzen andererseits (vgl. Rafner et al., 2021). Wo im vorliegenden Text von Upskilling die Rede ist, ist wie beim Deskilling vor allem die psychologische Seite gemeint.

Die Gleichsetzung des englischen Wortes *skill* mit dem deutschen Begriff Kompetenz wird allerdings nicht in allen Diskursen geteilt. Skills sind (durchaus ähnlich wie Kompetenzen) semantisch vieldeutig, werden aber in der durch KI beförderten Debatte um Future Skills tendenziell als einzelne, abgrenzbare und trainierbare Einheiten verstanden (Kalz & Reinmann, 2024). Für die Hochschule halte ich diese Lesart für ungeeignet. Ein wissenschaftliches Studium soll auf berufliche und gesellschaftliche Praxis vorbereiten, in eine Wissenschaft einführen und die Entwicklung der Persönlichkeit ermöglichen (Huber, 1983). Diese Ziele bilden den normativen Rahmen dafür, was im Studium als Verlust gelten kann. Gemessen an ihnen stehen nicht in erster Linie einzelne Fertigkeiten auf dem Spiel, deren Verlust gegebenenfalls wenig ins Gewicht fällt (vgl. Ferdman, 2026), sondern Expertise in einem Fach und die Fähigkeit, wissenschaftlich, und damit auch kritisch, zu denken und zu handeln. Naheliegend ist daher ein umfassender Kompetenzbegriff; als Referenz kann die Definition von Weinert (2001, S. 27 f.) dienen: Danach sind Kompetenzen „die bei Individuen verfügbaren oder durch sie erlernbaren kognitiven Fähigkeiten und Fertigkeiten, um bestimmte Probleme zu lösen, sowie die damit verbundenen motivationalen, volitionalen und sozialen Bereitschaften und Fähigkeiten, um die Problemlösungen in variablen Situationen erfolgreich und verantwortungsvoll nutzen zu können". Etwas vereinfacht und um das Wissen ergänzt, das Weinert nicht eigens nennt, lässt sich Kompetenz auch als Zusammenspiel von Wissen, Können und Haltungen verstehen, wobei Haltung all das beinhaltet, was eine Person als Bereitschaft für ein Handeln mitbringt (Reinmann, 2015).

Was Kompetenz in diesem umfassenden Sinne ausmacht, wird besonders deutlich bei Menschen, die über viele Jahre in einer Domäne oder einem Fach tätig sind und als Expertinnen und Experten gelten. Die vorwiegend empirisch ausgerichtete Expertiseforschung zeigt übereinstimmend, dass solche Personen über umfangreiches, strukturiertes und erfahrungsbasiertes Wissen verfügen und fähig sind, relevante Merkmale komplexer Situationen zu erkennen, ihr Wissen situationsangemessen anzuwenden und auf dieser Basis fundierte Urteile zu fällen (vgl. Boshuizen et al., 2004; Gruber, 2006). Zudem zeichnet sie eine fachlich geprägte Haltung aus: Sie denken kritisch, prüfen Informationen sorgfältig, lassen sich auf Gegenargumente ein, sind bereit, eigene Urteile zu revidieren, und gehen reflektiert mit den Grenzen ihres Wissens um.

Eine ergänzende theoretische Grundlage für diese Erkenntnisse bietet Seilers (2008) Ansatz der Strukturgenese (vgl. Reinmann, 2026a). In der strukturgenetischen Wissenstheorie ist menschliches Wissen das Ergebnis individueller Erkenntnistätigkeit, die leiblich verankert ist und sich in der Auseinandersetzung mit der Umwelt entwickelt. Wissen ist hier mehr als explizit formulierbares Faktenwissen: Es umfasst begrifflich-rationales ebenso wie handlungsbezogenes und intuitives Wissen und ist mit Bewusstsein, Emotion und Motivation verbunden. Wissen in dieser Form ist an die Erkenntnisstrukturen einer Person gebunden. Seiler nennt es personales Wissen; es schließt Kenntnisse, Fertigkeiten und Haltungen ein. Dieses Wissensverständnis ist ähnlich weit gefasst wie der hier verwendete Kompetenzbegriff; ist personales Wissen über viele Jahre in einer Domäne aufgebaut worden, hat es Gemeinsamkeiten mit Expertise, wie sie die kognitionspsychologische Forschung untersucht. Für diesen Beitrag ist Seilers Theorie noch aus zwei weiteren Gründen relevant: Erstens konzipiert sie Wissen weiter als im KI-Diskurs üblich, wo es oft auf abrufbare Fakten reduziert wird. Zweitens stellt sie dem personalen das öffentliche Wissen gegenüber, das sprachlich artikuliert, sozial geteilt und unabhängig von einzelnen Personen verfügbar ist; das eröffnet einen Zugang zur kollektiven Dimension von Wissen und Expertise (siehe Abschnitt 3.3).

2.2. Urteilskraft als Fähigkeit und Bereitschaft

Die Expertiseforschung zeigt, dass Expertinnen und Experten auf der Basis ihres Wissens fundierte Urteile fällen. Die dazu erforderliche Urteilskraft verdient im Zusammenhang mit Deskilling besondere Aufmerksamkeit: Generative KI liefert nicht nur Informationen, sondern zunehmend auch Einschätzungen, Bewertungen und Entscheidungsvorschläge. Wer sich darauf verlässt, urteilt womöglich seltener selbst; für Lindebaum et al. (in Druck) ist das *epistemic deskilling*: der Verlust praktischer Klugheit, die sie in Anlehnung an Aristoteles Phronesis nennen. Wissen, Können und Urteilskraft, soweit sie das wissenschaftliche Erkennen ermöglichen, lassen sich in diesem Sinne auch als epistemische Kompetenzen bezeichnen. Urteilskraft ist nicht nur ein Aspekt von Expertise, sondern zugleich ein Begriff mit langer philosophischer Tradition, die vor allem auf Kant zurückgeht. Kant unterscheidet eine bestimmende Urteilskraft, die einen Fall unter eine gegebene Regel bringt, von einer reflektierenden Urteilskraft, die für einen Fall die passende Regel erst finden muss (vgl. Gerhardt, 2024). Der Deutsche Ethikrat (2023, S. 133) bezieht diese Unterscheidung auf KI: Die bestimmende Urteilskraft lässt sich von Algorithmen übernehmen, die reflektierende dagegen nicht; letztere ähnelt der Phronesis. Lindebaum et al. (in Druck) beschreiben Phronesis als Fähigkeit, in komplexen Situationen kontextspezifische und moralische Urteile zu fällen, die sich im Zuge von Erfahrung entwickelt. Phronesis lässt sich insofern als eine praktische, auf Handeln gerichtete Form reflektierender Urteilskraft verstehen. Wenn im Folgenden von Urteilskraft die Rede ist, ist sie in dem hier entfalteten Sinn gemeint.

Drei Eigenschaften machen Urteilskraft für das Verständnis von Deskilling bedeutsam. Erstens lässt sie sich nicht delegieren: Wer ein Urteil von der KI übernimmt, statt es selbst zu fällen, urteilt nicht. Urteilskraft ist daher immer die Fähigkeit, autonom zu urteilen, und an die Bereitschaft gebunden, diese Fähigkeit zu gebrauchen. Schon Kant hat Unmündigkeit nicht auf einen Mangel an Verstand zurückgeführt, sondern auf einen Mangel an ´Entschließung und Mut´, sich seines Verstandes ohne Leitung eines anderen zu bedienen (vgl. Gerhardt, 2024). Zweitens bildet sich Urteilskraft in sozialen Praktiken aus und muss sich dort bewähren, etwa in einer Fachgemeinschaft, in der Urteile begründet, kritisiert und revidiert werden; sie ist damit auch die Fähigkeit, im Austausch mit anderen zu urteilen, und an die Bereitschaft gebunden, sich auf diesen Austausch einzulassen. Drittens lässt

sich Urteilskraft nicht durch Regeln lehren, sondern nur üben (vgl. Gerhardt, 2024): Sie entwickelt sich dort, wo es Gelegenheiten gibt, selbst zu urteilen.

Mit der Urteilskraft kommt in den Blick, was bei Deskilling neben Wissen und Können verloren gehen kann: die Fähigkeit und Bereitschaft – oder kurz: das Vermögen –, autonom und im Austausch mit anderen zu urteilen. Diese Erweiterung schließt an eine Verlusttrias an, die ich an anderer Stelle mit Kolleginnen und Kollegen beschrieben habe; diese betrifft genau das, worum es hier geht: Wissen und Können, autonomes Urteilen und Urteilen im Austausch mit anderen. Ein unkritischer KI-Einsatz, so die These, kann Kompetenz-, Kontroll- und Sozialverluste befördern und damit selbstbestimmtes Handeln beeinträchtigen (Reinmann et al., 2025). Kompetenzverluste entstehen danach, wenn Menschen wichtiges Wissen und Können nicht mehr pflegen und üben oder gar nicht erst aufbauen; sie fallen unmittelbar unter Deskilling, erfassen aber nur einen Ausschnitt dessen, was hier unter Kompetenz verstanden wird. Kontroll- und Sozialverluste betreffen dagegen zunächst die Bedingungen, unter denen Menschen handeln: Kontrollverluste entstehen etwa, wenn Entscheidungen in Lehre, Studium und Forschung zunehmend auf KI-Empfehlungen beruhen und das eigene, reflektierte Urteil dahinter zurücktritt. Sozialverluste entstehen, wenn individualisierte und auf Effizienz optimierte Angebote Austausch und Zusammenarbeit seltener werden lassen. Diese Verluste sind selbst noch kein Deskilling, können aber dazu führen, dass Menschen das Vermögen verlieren oder gar nicht erst entwickeln, autonom und im Austausch mit anderen zu urteilen.

3. Modellierung: Formen und Ebenen von Deskilling

Skill, Kompetenz, Expertise und Urteilskraft stehen, folgt man der hier vorgeschlagenen Argumentation, in einem bestimmten Verhältnis zueinander. Skills im Sinne einzelner, trainierbarer Einheiten greifen für die Hochschule zu kurz; was im Studium auf dem Spiel steht, ist Kompetenz als Zusammenspiel von Wissen, Können und Haltungen. In entwickelter Form zeigt sie sich als Expertise in einem Fach, die strukturgenetisch als personales Wissen verstanden werden kann. Zu Expertise gehört Urteilskraft als Fähigkeit und Bereitschaft, autonom und im Austausch mit anderen zu urteilen. Damit ist bestimmt, was bei Deskilling im hier definierten Sinne auf dem Spiel steht. Offen ist noch, in welchen Formen und auf welchen Ebenen es auftritt.

3.1. Deskilling als Nicht-Lernen, Verlernen und Fehllernen

Kompetenz, Expertise und Urteilskraft entstehen in Lernprozessen, über lange Zeit, durch Erfahrung und Übung und in der Auseinandersetzung mit Gegenständen und anderen Menschen. Deskilling ist von diesen Lernprozessen her zu verstehen. Das Präfix „de-“ greift dafür eigentlich zu kurz, denn es legt nur nahe, dass etwas bereits Gelerntes verloren geht. Lernen kann aber auch ausbleiben oder in eine falsche Richtung laufen, was die in Abschnitt 1 referierten Begriffe *never-skilling* und *mis-skilling* andeuten (Abdulnour et al., 2025). Eine ähnliche, allerdings nach Personengruppen getrennte Unterscheidung treffen Macnamara et al. (2024) aus kognitionspsychologischer Sicht: Ihre These ist, dass KI-Unterstützung bei Expertinnen und Experten den Abbau von Fähigkeiten beschleunigt, die sie nicht mehr selbst ausüben, und bei Lernenden schon den Erwerb solcher Fähigkeiten erschwert; beides kann von den Betroffenen unbemerkt bleiben. Passlack et al. (2025), die den Einsatz

generativer KI in studentischen Forschungsprojekten untersuchen, zählen zu Deskilling ebenfalls nicht nur den Verlust vorhandener Kompetenzen, sondern auch deren verminderte Entwicklung.

Will man Deskilling als etablierten Dachbegriff beibehalten, liegt es daher nahe, mehrere Modi zu unterscheiden: vor allem Nicht-Lernen, Verlernen und Fehllernen. Beim Nicht-Lernen wird personales Wissen gar nicht erst aufgebaut; beim Verlernen geht vorhandenes personales Wissen verloren; beim Fehllernen lernen Menschen etwas, das sich als falsch oder als etwas anderes als das herausstellt, was gelernt werden sollte. Diese Unterscheidung beschreibt Lernprozesse; auf der Ergebnisseite entsprechen ihnen Nicht-Aufbau, Abbau und Fehlaufbau personalen Wissens.

Im Diskussionspapier von 2023 waren zwei dieser Modi noch an die Ebene gekoppelt, auf der Deskilling auftritt, also daran, ob es Einzelne oder Gemeinschaften betrifft. Einen individuellen Kompetenzverlust nahm ich an, wenn Menschen über Kompetenzen verfügen, diese aber mangels Ausübung verlieren, einen kollektiven, wenn Kompetenzen gar nicht mehr aufgebaut werden. Individuell hieß also Verlernen, kollektiv hieß Nicht-Lernen. Diese Kopplung halte ich nicht mehr für passend: Nicht-Lernen und Verlernen können, ebenso wie Fehllernen, theoretisch auf beiden Ebenen vorkommen. Individuen können Kompetenzen gar nicht erst aufbauen oder sie verlernen, und auch in einer Fachgemeinschaft kann verloren gehen, was einmal etabliert war, etwa wenn sie Praktiken nicht mehr pflegt und weitergibt; ebenso können sich Einzelne wie Gemeinschaften Falsches aneignen, etwa wenn sich fehlerhafte KI-Ausgaben unbemerkt in ihrer Wissenspraxis festsetzen. Ebene und Modus sind deshalb zwei voneinander unabhängige Dimensionen. Von den drei Modi zu unterscheiden ist schließlich ein Phänomen, das ich Scheinlernen nenne und im nächsten Abschnitt erläutere.

3.2. Deskilling auf der individuellen Ebene

Kompetenz bezeichnet etwas, über das eine Person verfügt, nicht das, was sie in einer bestimmten Situation tut.[2] Im Kompetenzdiskurs wird dieser Unterschied mit dem Begriffspaar Disposition und Performanz gekennzeichnet (vgl. Blömeke et al., 2015). Eine Disposition lässt sich nicht direkt beobachten, sie zeigt sich nur in Performanz[3]. Deskilling bezeichnet die Veränderung der Disposition, nicht die der Performanz, auch wenn es sich nur an der Performanz erkennen lässt: Wer Kontrolle an eine KI abgibt oder auf den Austausch mit anderen verzichtet, verhält sich zunächst nur anders; zu Deskilling wird das erst, wenn sich auch die Disposition verändert. Ebenso ist eine mit KI gesteigerte Performanz noch kein Upskilling. Die Übergänge sind allerdings fließend: Eine Disposition zeigt sich nicht nur in Performanz, sie bildet sich auch durch sie, worauf jedes Üben beruht (vgl. Reinmann, in Druck). Wer etwas immer wieder selbst tut, baut die dafür nötige Kompetenz auf oder erhält sie; wer es dauerhaft einer KI überlässt, kann sie verlieren oder gar nicht erst entwickeln. Trennscharf ist die Unterscheidung zwischen Disposition und Performanz nicht; sie soll aber den Blick dafür schärfen, wann aus einer veränderten Praxis eine Veränderung der Person wird. Wie aus einer veränderten

[2] In der Bildungspraxis geht dieses Verständnis oft unter: Mit Kompetenzorientierung soll in der Regel zum Ausdruck kommen, dass Studierende etwas beobachtbar können und nicht nur still für sich etwas wissen. Kompetenz rückt so in die Nähe von Performanz, was zu Missverständnissen führt, etwa wenn aus dem Blick gerät, dass Kompetenz über die einzelne Situation hinausreicht.

[3] In Anlehnung an Erpenbeck et al. (2017) kann man Kompetenzen auch als Dispositionen zum Handeln definieren.

Performanz eine veränderte Disposition werden kann, lässt sich für Wissen und Können ebenso zeigen wie für das Vermögen, selbst und im Austausch mit anderen zu urteilen.

Bei Wissen und Können kann sich ein Zirkel ergeben: Je weniger Novizen selbst Expertise in einem Fach aufbauen (Disposition), desto schlechter können sie KI-Ergebnisse kritisch prüfen; je weniger sie diese prüfen können, desto eher übernehmen sie diese (Performanz), und desto seltener entsteht eigene Expertise (vgl. Reinmann, 2026b). Das gilt auch für kritisches Denken: Als Vollzug in einer konkreten Situation, etwa wenn jemand ein Argument prüft (Performanz), lässt es sich von KI unterstützen und mitunter simulieren, als Fähigkeit und Bereitschaft (Disposition) aber ist es an die Person gebunden (Reinmann, 2026a).

Ähnlich verhält es sich bei der Autonomie und dem damit zusammenhängenden Begriff der Kontrolle, der auf die performative Seite verweist: Kontrolle hat oder verliert man über etwas Bestimmtes, einen Prozess oder ein Ergebnis in einer konkreten Situation. Auf Dauer verloren gehen kann dagegen die Fähigkeit und Bereitschaft, autonom zu urteilen und zu handeln (Disposition). Wie das geschehen kann, lässt sich an einem auch im Hochschulkontext typischen Widerspruch verdeutlichen: KI verspricht Unabhängigkeit von menschlicher Unterstützung, kann aber die Fähigkeit schwächen, selbst zu denken und Urteile zu verantworten; das Mittel zur Steigerung von Autonomie untergräbt dann deren Voraussetzungen (vgl. Reinmann, 2026b).

Entsprechendes gilt für das Urteilen im Austausch mit anderen: Wer gelegentlich auf soziale Korrektur verzichtet (Performanz), verliert damit nicht schon die Fähigkeit und Bereitschaft, im Austausch mit anderen zu urteilen (Disposition), kann sie aber einbüßen, wenn das zur Regel wird. Denn beides bildet sich in sozialen Situationen, zum Beispiel dann, wenn andere einem widersprechen: Wer die eigene Auffassung gegenüber anderen vertreten muss, setzt sich dem Risiko aus, sich zu irren und sich revidieren zu müssen, und lernt gerade daran, Urteile im Austausch zu prüfen. Im Dialog mit einer KI fehlt dieses Risiko; sie hat keine eigenen Überzeugungen, für die sie einsteht, und ihren Einwand kann man folgenlos übergehen oder sich eine andere Antwort erzeugen lassen; es steht also nichts auf dem Spiel (vgl. Callard, 2025).

Am deutlichsten fallen Performanz und Disposition beim Scheinlernen auseinander. Gemeint ist, dass jemand mit KI eine gute Leistung erbringt (Performanz) und daraus schließt, nun entsprechend kompetent zu sein (Disposition), obwohl das nicht der Fall ist; die Person unterliegt damit einer Illusion. Solche Kompetenzillusionen (*illusion of competence*) zeigen sich etwa bei Studierenden, die mit KI programmieren lernen: Gerade diejenigen, die Schwierigkeiten haben, überschätzen am Ende ihre Leistung (Prather et al., 2024). Für die Forschung mit KI sind entsprechende Illusionen des Verstehens (*illusions of understanding*) beschrieben: Man glaubt, eine Sache besser zu durchdringen, als es tatsächlich der Fall ist (Messeri & Crockett, 2024). Scheinlernen ist damit kein vierter Deskilling-Modus, sondern Nicht-Lernen, das durch Performanz verdeckt wird, und eine Bedingung, unter der Deskilling unbemerkt bleibt.

3.3. Deskilling auf der kollektiven Ebene

Performanz und Disposition sind Begriffe für Individuen. Auf Gemeinschaften lassen sie sich nicht ohne Weiteres übertragen, denn eine Fachgemeinschaft zum Beispiel hat keine Disposition im selben Sinne wie eine lernende oder forschende Person. Für die kollektive Ebene braucht es deshalb eigene Begriffe. Hier lässt sich erneut das strukturgenetische Wissensverständnis von Seiler (2008) heranziehen, der neben das personale Wissen das öffentliche Wissen stellt. Öffentliches Wissen ist

materialisiertes, objektiviertes Wissen, wie es sich in Texten, Artefakten und anderen Wissensbeständen zeigt. Es entsteht, wenn personales Wissen aufgeschrieben, kodifiziert oder formalisiert und heute vor allem digitalisiert wird; auf diese Weise kann es zwischen Personen geteilt, vermittelt, gemeinsam weiterentwickelt und maschinell verarbeitet werden. Umgekehrt wird öffentliches Wissen erst dann zu personalem Wissen, wenn Personen es sich in eigener Lern- und Erkenntnistätigkeit aneignen.

Personales und öffentliches Wissen bilden einen Kreislauf: Aus personalem Wissen, das sich Menschen über lange Zeit erarbeiten, entsteht öffentliches Wissen, und dieses ist wiederum die Grundlage dafür, dass andere, vor allem Novizen, eigenes personales Wissen aufbauen können. Öffentliches Wissen geht durch KI nicht verloren; es wächst eher rasant, verändert sich aber. Sprachmodelle rekombinieren vorhandenes, allgemein zugängliches Wissen fortlaufend, und ihre Erzeugnisse gehen wieder in die öffentlichen Bestände ein; das kann diese Bestände vereinheitlichen und verengen (Messeri & Crockett, 2024). Zudem lassen sich solche synthetisch erzeugten Inhalte im Ergebnis kaum von öffentlichem Wissen unterscheiden, das aus personalem Wissen hervorgegangen ist. Problematisch wird das vor allem dann, wenn Menschen kein eigenes personales Wissen mehr aufbauen, sondern sich darauf beschränken, KI-generierte Inhalte zu prüfen und KI bei der Aufgabenbearbeitung zu beaufsichtigen (vgl. Lee et al., 2025). Der Kreislauf kann an zwei Stellen ins Stocken geraten: Es fließt weniger personales Wissen in öffentliche Bestände ein, und Menschen eignen sich öffentliches Wissen nicht mehr selbst an, sodass ihnen das personale Wissen fehlt, das nötig wäre, um KI-generierte Inhalte prüfen zu können. Wenn kollektiv etwas verloren geht, dann also nicht in erster Linie Wissensbestände, sondern eher die Vermittlung zwischen öffentlichem und personalem Wissen; deren Erosion ließe sich als kollektives Deskilling bezeichnen.

Wo und wie diese Vermittlung stattfindet, lässt sich mit Ludwik Fleck (1935/1980) genauer beschreiben. Am Beispiel der Medizin zeigt er, dass wissenschaftliches Erkennen nicht allein eine Leistung Einzelner, sondern immer auch sozial bedingt ist: Es vollzieht sich in Denkkollektiven, also in Gemeinschaften von Menschen, die Gedanken austauschen und dadurch einen gemeinsamen Denkstil ausbilden. Ein Denkstil legt fest, was als Problem gilt, was man wahrnimmt, wie man Wahrgenommenes deutet und was als Lösung anerkannt wird. In einen Denkstil wachsen Menschen hinein, indem sie am Austausch eines Denkkollektivs teilnehmen. Diese Sicht passt zum hier vorgeschlagenen Verständnis kollektiven Deskillings, weil sie beide Richtungen der Vermittlung sozial verortet: Öffentliches Wissen geht aus dem Austausch im Denkkollektiv hervor, und individuell angeeignet wird es in vieler Hinsicht durch Teilhabe an diesem Austausch.

Für die Hochschule lässt sich dieses Hineinwachsen mit Huber (1983) als Sozialisation in ein Fach verstehen: Ein Studium führt in den Denkstil einer Disziplin ein; das geschieht in Lehrveranstaltungen, bei der Begleitung von Projekten und Abschlussarbeiten und in der Zusammenarbeit mit Lehrenden und Mitstudierenden. Werden solche Gelegenheiten seltener, etwa weil Studierende sich Wissen vorwiegend mit KI erschließen oder Forschende den mühsamen Austausch untereinander durch KI ersetzen (Nowotny, 2025), kann sich die Vermittlung zwischen öffentlichem und personalem Wissen abschwächen. Ob es Gelegenheiten zur fachlichen Sozialisation und zum Austausch gibt, hängt von den Rahmenbedingungen ab: im Studium etwa von Prüfungsformen und Betreuungsrelationen, in der Forschung zum Beispiel von Anreizsystemen und Förderstrukturen. Sie können die Einführung in einen Denkstil und den Austausch in einem Denkkollektiv begünstigen oder behindern. Umgebungen, die es erschweren, bestimmte Aktivitäten auszuüben und entsprechende Kompetenzen auszubilden, lassen sich durch die Anstrengung Einzelner kaum ausgleichen; Deskilling ist insofern auch ein strukturelles Problem (Ferdman, 2026).

Weniger Gelegenheiten zur Sozialisation und zum Austausch sind allerdings erst eine Bedingung kollektiven Deskillings, ähnlich wie auf der individuellen Ebene eine veränderte Performanz noch keine veränderte Disposition bedeuten muss. Von kollektivem Deskilling lässt sich erst sprechen, wenn die Vermittlung zwischen öffentlichem und personalem Wissen in der Folge tatsächlich erodiert, wenn sich also in einem Fach immer weniger Menschen öffentliches Wissen aneignen, es prüfen und erneuern.

4. Sichtung: Empirische Befunde zu Deskilling

Nach den Überlegungen in den Kapiteln 2 und 3 ist der Begriff Deskilling im Hochschulkontext umfassender zu konzeptualisieren, als ich es in meinem Text von 2023 getan habe (Reinmann, 2023): Deskilling beschreibt eine Beeinträchtigung von Kompetenz und Expertise, einschließlich des Vermögens, selbst und im Austausch mit anderen zu denken und zu urteilen; es tritt vor allem als Nicht-Lernen, Verlernen und Fehllernen auf. Auf individueller Ebene besteht es in einer Veränderung der Disposition, auf kollektiver Ebene in einer Erosion der Vermittlung zwischen öffentlichem und personalem Wissen. Diese theoretische Bestimmung nutze ich im Folgenden, um die empirische Befundlage zu sichten: Ich frage, welche dieser Aspekte bislang untersucht sind, ob die Studien eher Performanz oder Disposition, eher Bedingungen oder das Phänomen selbst erfassen und wo Lücken bleiben.

4.1. Auswahl und Lesart der Studien

Die Sichtung ist exemplarisch angelegt, nicht als systematisches Review: An ausgewählten Beispielen lässt sich vorläufig zeigen, welche Aspekte von Deskilling bislang untersucht sind, was die Studien erfassen und wo Lücken bleiben. Gesucht habe ich nach Studien, die für einzelne Gruppen oder Modi beispielhaft stehen: Studien zu Studierenden als Novizen, zu Lehrenden und zu Forschenden – Letztere, weil auch Forschung eine für die Hochschulbildung relevante Praxis ist, in der Deskilling auftreten kann. Einbezogen sind auch Studien, die statt Deskilling Upskilling oder keine Effekte finden, weil sie Hinweise geben, unter welchen Bedingungen Deskilling ausbleibt. Für die hier entwickelten begrifflichen Unterscheidungen gibt es keine eingeführten englischen Entsprechungen. Die Suche stützt sich deshalb neben deutschen auf englischsprachige Begriffe, die ihnen nahekommen, etwa *never-skilling* für Nicht-Lernen, *skill decay* (Abbau von Fähigkeiten) für Verlernen, *mis-skilling* für Fehllernen, *illusion of competence* für Scheinlernen sowie *automation bias* (übermäßiges Vertrauen in automatisierte Systeme) für das unkritische Übernehmen von KI-Empfehlungen.

Studien finden sich vor allem zu Studierenden; sie geben Aufschluss über deren Wissen und Können, Hinweise auf deren Fähigkeit, autonom zu urteilen, und – allerdings nur indirekt – auf deren Bereitschaft, selbst zu denken und zu urteilen, nicht aber auf das Urteilen im Austausch. Dazu kommen Studien auf der kollektiven Ebene, insbesondere zu Forschenden. Viele empirische Befunde zu Deskilling stammen aus der Medizin. Kaum fündig wird man bei Lehrenden und Forschenden auf der individuellen Ebene. Unter den Modi scheint Verlernen kaum untersucht zu sein; ob aus Fehlern während der Arbeit mit KI dauerhaftes Fehllernen wird, prüft keine der hier gesichteten Studien. Auch Untersuchungen über längere Zeiträume fehlen weitgehend.

Für die Deutung der Ergebnisse ist vor allem entscheidend, *was* eine Studie erfasst: Über eine veränderte Disposition gibt sie nur Auskunft, wenn sie die Leistung ohne KI erhebt, nachdem zuvor mit KI gearbeitet wurde, am besten mit zeitlichem Abstand; eine Studie, die nur die Leistung mit KI erfasst, untersucht Performanz; Selbstauskünfte zeigen, wie Befragte ihr eigenes Wissen und Können und ihren Umgang mit KI einschätzen. Das gilt für Studien zu Deskilling ebenso wie für solche zu Upskilling. Bedeutsam ist zudem, ob eine Studie nur Wissen und Können erfasst oder auch die Fähigkeit und Bereitschaft, autonom und im Austausch mit anderen zu urteilen. Die folgenden Beispiele machen deutlich, dass speziell die Unterscheidung von Performanz und Disposition für die empirische Forschung offenbar eine Herausforderung ist – eine Unterscheidung, die sich als theoretisch zwingend erweist und praktisch bedeutsam ist. Schließlich zeigen alle Befunde nur Tendenzen an, die an bestimmte Bedingungen gebunden sind.

Geordnet sind die Befunde nach den beiden Ebenen, die ich in Kapitel 3 unterschieden habe. Die Studien zu Studierenden auf der individuellen Ebene gliedere ich danach, was nach Kapitel 2 von Deskilling betroffen sein kann: Wissen und Können, die Fähigkeit, autonom zu urteilen, und die Bereitschaft, selbst zu denken und zu urteilen; zum Urteilen im Austausch mit anderen auf der individuellen Ebene konnte ich keine Studie finden. Ob eine Studie auf Nicht-Lernen oder Fehllernen hindeutet und ob sie Performanz oder Disposition erfasst, klärt dann die Einordnung der einzelnen Studie. Die Studien auf der kollektiven Ebene erfassen vor allem Bedingungen kollektiven Deskillings.

4.2. Empirie zu Deskilling auf der individuellen Ebene

Zu Studierenden liegen inzwischen zahlreiche Studien vor; viele davon sind Befragungen, die erheben, wie Studierende KI nutzen und welche Folgen sie selbst wahrnehmen. Solche Selbstauskünfte über Wissen, Können und Urteilen sagen etwas darüber, wie Studierende die Folgen wahrnehmen, belegen Deskilling aber nicht. Auf der Suche nach anderen Studientypen trifft man vor allem auf Experimente, die eigene Grenzen haben (z.B. eine eingeschränkte ökologische Validität). Weil sie die Leistung erfassen, teils auch ohne KI, habe ich für die beiden folgenden Abschnitte zu Wissen und Können und zum autonomen Urteilen trotzdem vor allem experimentelle Studien ausgewählt; sie erheben die Leistung allerdings meist unmittelbar oder kurz nach der Arbeit mit KI und geben über dauerhafte Veränderungen, also über Dispositionen, daher nur begrenzt Auskunft. Befragungen ziehe ich dort heran, wo es um die Bereitschaft geht, selbst zu denken und zu urteilen, weil sich Bereitschaft kaum anders als über Selbstauskünfte und beobachtetes Verhalten erfassen lässt.

4.2.1. Wissen und Können

Auf Nicht-Lernen deutet eine Studie von Darvishi et al. (2024) hin. Studierende erstellen Lernmaterialien und begutachten die ihrer Peers; vier Wochen lang markiert eine KI wenig gelungene Rückmeldungen. Danach arbeiten die Studierenden vier Wochen lang, zufällig verteilt, mit oder ohne diese Hinweise, mit einer Checkliste zur Selbstkontrolle oder mit beidem. Wer ohne die KI-Hinweise weiterarbeitet, gibt schwächere Rückmeldungen als diejenigen, die sie weiter erhalten. Dies legt nahe, dass sich die Studierenden eher auf die KI verlassen haben, als von ihr zu lernen. Die Checkliste gleicht das nur teilweise aus und bringt zusammen mit der KI keinen zusätzlichen Nutzen. Da die Studie die Leistung nach Wegfall der KI erfasst, lässt sich der Befund als Hinweis auf die Disposition

lesen: Die Fähigkeit, gute Rückmeldungen zu geben, hat sich mit KI-Unterstützung offenbar kaum aufgebaut.

Ob KI das Lernen behindert, hängt nach einer Studie von Lehmann et al. (2025) zum Programmieren im Masterstudium davon ab, wie sie genutzt wird. In zwei Laborexperimenten wirken Sprachmodelle insgesamt weder positiv noch negativ auf das Lernergebnis, das in einem anschließenden Test ohne Sprachmodell erhoben wird. Ergänzende explorative Analysen und eine Feldstudie differenzieren diesen Befund: Wer sich vom Sprachmodell Lösungen erstellen lässt und damit eigene Lernaktivitäten ersetzt, bearbeitet mehr Themen, versteht sie aber schlechter; wer es nutzt, um sich Erklärungen geben zu lassen, und damit das eigene Lernen unterstützt, bearbeitet nicht mehr Themen, versteht sie aber besser. Zudem nützen Sprachmodelle Studierenden mit viel Vorwissen und schaden denen mit wenig. Nach diesen Befunden begünstigt es Nicht-Lernen, wenn KI eigene Lernaktivitäten ersetzt; unterstützt sie diese, ist Upskilling möglich.

In eine vergleichbare Richtung weist ein bislang nur als Diskussionspapier veröffentlichtes Experiment von Contractor und Reyes (2026). Studierende erarbeiten sich mit oder ohne KI ein unbekanntes Thema und schreiben dazu einen Essay. Wer mit KI gearbeitet hat, schneidet in einem anschließenden Wissenstest ohne KI etwas besser ab, auch noch nach einer Woche. Bei den Essays selbst deutet sich ebenfalls ein Lerngewinn an, aber verzögert: Die mit KI verfassten Essays sind zwar kaum besser, eine Woche später aber schreibt die KI-Gruppe ohne KI klarer und näher an der Fragestellung, mit Ausnahme derjenigen, die sich von der KI nicht unterstützen, sondern Text schreiben ließen. Die Disposition wächst also, ohne dass die Performanz mit KI dies anzeigt: gewissermaßen eine Umkehrung des Scheinlernens, die sich in keiner der anderen hier betrachteten Studien findet.

Auf Scheinlernen dagegen weisen zwei Autorenteams hin, die in ihren Studien neben der Leistung auch die Selbsteinschätzung erfassen. Prather et al. (2024) beobachten Novizen im Programmieren beim Lösen einer Aufgabe mit KI. Fast alle kommen zu einer Lösung, aber auf unterschiedlichen Wegen: Leistungsstarke nutzen die KI für Code, den sie ohnehin geplant hatten, und ignorieren unbrauchbare Vorschläge; bei Leistungsschwachen verstärkt die KI die Schwierigkeit, das eigene Vorgehen zu überblicken und zu steuern, etwa weil die Vorschläge der KI den Gedankengang unterbrechen oder in die Irre führen. Gerade die Leistungsschwachen überschätzen ihre Leistung und beenden die Aufgabe mit einer Kompetenzillusion. Ähnliches zeigt sich bei Lehmann et al. (2025): Wer in der Lernphase ein Sprachmodell nutzen konnte, hält den eigenen Lernzuwachs für größer, als er im Test ohne Sprachmodell tatsächlich ist. Beide Studien zeigen, dass Selbsteinschätzung und tatsächliches Wissen und Können auseinanderfallen können, was begünstigt, dass Nicht-Lernen unbemerkt bleibt.

Zusammengenommen deuten die Studien auf zwei Bedingungen hin, unter denen die Nutzung von KI im Studium eher zu Nicht-Lernen als zu Upskilling führt: wenn die KI Lernaktivitäten ersetzt, statt sie zu unterstützen, und wenn das Vorwissen gering ist. Nutzen Studierende KI dagegen, um sich etwas erklären zu lassen, sind auch Lerngewinne möglich. Hinzu kommt, dass Studierende ihre Leistung mit KI überschätzen können und übersehen, dass sie eigentlich nicht gelernt haben. Die Befunde bleiben dennoch Tendenzen: Die meisten Studien erfassen die Leistung zwar auch ohne KI, aber nur unmittelbar danach oder nach wenigen Wochen.

4.2.2. Fähigkeit, autonom zu urteilen

Wie gut Studierende ihr Urteil begründen, wenn sie mit KI recherchieren, untersuchen Stadler et al. (2024) in einem randomisierten Experiment. Die Studierenden sollen zu einer gesellschaftlich umstrittenen wissenschaftlichen Frage eine Empfehlung abgeben; ein Teil recherchiert dafür mit ChatGPT, der andere mit einer Suchmaschine. Die Gruppe mit ChatGPT gibt eine deutlich geringere kognitive Belastung bei der Aufgabenbearbeitung an, argumentiert in ihren Empfehlungen aber schwächer. Da die Studie nur die Leistung während der Aufgabe erfasst, sagt sie nichts über dauerhafte Veränderungen aus; sie deutet aber darauf hin, dass die Entlastung durch KI mit schwächerem Urteilen einhergehen kann.

Um die Übernahme falscher KI-Empfehlungen geht es in einem Experiment von Ren (2026) mit Aufgaben zum Schlussfolgern und zum Bewerten von Informationen. Mit ChatGPT übernehmen die Studierenden falsche Empfehlungen in fast zwei Dritteln der Fälle und sind sich ihrer Antworten sicherer als ohne KI. Ein kurzer Impuls, das eigene Vorgehen zu reflektieren, senkt die Übernahme falscher Empfehlungen deutlich; richtige Empfehlungen übernehmen die Studierenden weiterhin. Erfasst ist auch hier nur das Urteil in der Situation; ob das übernommene Falsche darüber hinaus bestehen bleibt und damit Fehllernen vorliegt, zeigt die Studie nicht.

Auch in der Medizin folgen Studierende mitunter falschen KI-Empfehlungen. In einer Studie, über die Ong et al. (2026) berichten, stellen Studierende in den ersten Studienjahren zu Fallvignetten Diagnosen und erhalten dazu Erklärungen einer KI. Sind diese Erklärungen irreführend, aber plausibel, stellen sie deutlich häufiger falsche Diagnosen; ihre Fehler folgen meist dem, was die KI nahelegt; dennoch bleiben sie sich ihres Urteils sicher. Anders bei Kıyak et al. (2026): Hier stellen Studierende im vierten Studienjahr zu mehrdeutigen Fällen zunächst selbst eine Diagnose und erhalten dann ein als ChatGPT-Antwort ausgegebenes Feedback, das ihrer Diagnose widerspricht. Die meisten bleiben bei ihrem eigenen Urteil, ob sie von ChatGPT auf mögliche Fehler hingewiesen werden oder nicht; das Autorenteam vermutet, dass sie der KI ohnehin wenig trauen. Ob Studierende KI-Empfehlungen folgen, hängt also möglicherweise vom Ausbildungsstand ab, aber auch von der Aufgabe und davon, für wie glaubwürdig sie die KI einschätzen.

Keine dieser Studien ist explizit als Untersuchung autonomen Urteilens angelegt, und alle erfassen das Urteil nur, während Studierende mit KI arbeiten. Sie zeigen, dass KI das Begründen schwächen kann und Studierende falsche Empfehlungen nicht selten übernehmen, ohne an ihrem Urteil zu zweifeln. Ob Studierende falsch Übernommenes später auch ohne KI für richtig halten, ob also Fehllernen vorliegt, untersucht keine der Studien.

4.2.3. Bereitschaft, selbst zu denken und zu urteilen

Die Bereitschaft, selbst zu denken und zu urteilen, lässt sich kaum direkt beobachten. Die Studien, die ich hier heranziehe, erfassen sie nur indirekt: über das Verhalten in einer Lernsituation oder über das, was Studierende selbst berichten.

Ein Beispiel für den ersten Zugang ist ein Experiment von Fan et al. (2025). In einer Schreibaufgabe setzen sich Studierende mit einem fachlichen Thema auseinander und überarbeiten ihren Text mit unterschiedlicher Unterstützung: mit ChatGPT, durch Personen mit Expertise, über ein Programm, das den Text automatisch auswertet und Rückmeldung gibt, oder ohne zusätzliche Hilfe. Erfasst wird

zum einen die Qualität der Texte. Zum anderen wird mit Tests vor und nach der Aufgabe geprüft, was die Studierenden über das Thema gelernt haben und ob sie es auf neue Aufgaben übertragen können. Mit ChatGPT verbessern sich die Texte am stärksten; beim Wissenszuwachs und beim Transfer zeigt sich jedoch kein Unterschied zu den anderen Gruppen. Zugleich steuern und überwachen die Studierenden mit ChatGPT ihr Lernen weniger, obwohl sie nicht weniger motiviert sind. Fan et al. sehen darin ein Anzeichen für *metacognitive laziness*. In der hier verwendeten Begrifflichkeit fehlt es vor allem an der Bereitschaft, das eigene Lernen selbst zu steuern, wenn die KI es ihnen abnehmen kann.

Für den zweiten Zugang, die Selbstauskunft, steht eine Befragung von Hoffmann et al. (2026): Rund 4000 Studierende der Goethe-Universität Frankfurt geben Auskunft darüber, wie sie beim wissenschaftlichen Schreiben KI nutzen und welche Folgen sie an sich wahrnehmen. Die allermeisten Befragten verwenden KI. Gut die Hälfte hat das Gefühl, weniger selbst geleistet zu haben, und knapp die Hälfte befürchtet, kritisches Denken zu verlernen. Nur etwa ein Zehntel lehnt KI ab, knapp ein Fünftel nutzt sie als ‚Partnerin' oder ‚Tutorin', und mehr als zwei Drittel lassen sie auch Teilaufgaben ganz übernehmen. Ein ähnliches Bild ergibt sich in Interviews von Passlack et al. (2025) mit zwölf Studierenden, die generative KI seit mehr als einem halben Jahr in Forschungsprojekten nutzen. Sie berichten von Gewinnen, etwa bei der Kommunikation und im Fachwissen, aber auch von Verlusten bei Kreativität, kritischer Reflexion und Konzentration. Kritische Reflexion gilt ihnen zugleich als Voraussetzung für eine gute Nutzung von KI und als das, was sie nach eigener Wahrnehmung durch diese Nutzung verlieren.

Zusammengenommen deuten die Befunde darauf hin, dass die Bereitschaft, selbst zu denken und zu urteilen, im Umgang mit KI unter Druck gerät: Die Selbstauskünfte lassen zudem eine Lücke zwischen dem eigenen Anspruch und dem tatsächlichen Umgang mit KI erkennen. Ob die Bereitschaft auch dauerhaft schwindet, sich also die Disposition verändert, lässt sich mit diesen Studien nicht beantworten, weil keine von ihnen Studierende über längere Zeit begleitet.

4.3. Empirie zu Deskilling auf der kollektiven Ebene

Kollektives Deskilling läge nach Kapitel 3 dann vor, wenn die Vermittlung zwischen öffentlichem und personalem Wissen erodiert, wenn sich also in einem Fach immer weniger Menschen öffentliches Wissen aneignen, es prüfen und erneuern. Eine Studie, die das untersucht, ist mir bislang nicht bekannt. Es gibt aber Studien, die erfassen, wie sich öffentliches Wissen und der Austausch unter Forschenden verändern, wenn KI genutzt wird. Sie stammen aus der empirisch-quantitativen Wissenschaftsforschung und werten große Mengen an Publikationen aus.

Hao et al. (2026) analysieren gut 41 Millionen naturwissenschaftliche Publikationen. Ob die Forschenden KI genutzt haben, wird nicht erfragt, sondern mithilfe eines Sprachmodells aus den Publikationen erschlossen. KI umfasst hier nicht nur generative KI, sondern auch ältere Verfahren des maschinellen Lernens. Die Befunde sind korrelativ und weisen für Individuen und die Wissenschaft in entgegengesetzte Richtungen. Einzelne Forschende veröffentlichen mit KI deutlich mehr, werden häufiger zitiert und leiten früher Projekte als Forschende ohne KI, was allerdings nur etwas über ihre Performanz aussagt. Für die Wissenschaft zeigt sich dagegen eine Verengung: Die Breite der bearbeiteten Themen nimmt leicht ab, der wechselseitige Bezug der Forschenden aufeinander sinkt stärker, nämlich um gut ein Fünftel, und KI-gestützte Forschung verlagert sich in Gebiete, in denen viele Daten verfügbar sind. Auf kollektiver Ebene lassen sich die engere

Themenbreite und der geringere Austausch als Bedingungen deuten, unter denen die Vermittlung zwischen öffentlichem und personalem Wissen schwächer werden kann.

Kusumegi et al. (2025) werten über zwei Millionen Preprints aus und erschließen die Nutzung von Sprachmodellen aus KI-typischen Formulierungen in den Abstracts. Demnach veröffentlichen Forschende, die Sprachmodelle nutzen, mehr als andere und zitieren breiter, also auch Bücher und weniger beachtete Arbeiten; dieser Zusammenhang ist korrelativ. Für die kollektive Ebene ist vor allem ein zweiter Befund aufschlussreich: Ohne erkennbare KI-Nutzung erhöht eine komplexe Sprache die Chance, dass ein Preprint später in einer Fachzeitschrift erscheint; mit KI ist es umgekehrt. Ähnliches zeigt sich in Gutachten zu einer Informatik-Konferenz. Das Autorenteam vermutet, dass KI auch inhaltlich schwachen Texten eine anspruchsvolle Sprache verleiht. Verweist Sprache nicht mehr verlässlich auf Qualität, wie es diese Befunde nahelegen, wird es schwieriger, öffentliches Wissen zu prüfen. Auch das ist eine Bedingung kollektiven Deskillings, nicht das Phänomen selbst.

Ob KI die Vielfalt von Ideen verringert, untersuchen Moon et al. (2025) an Bewerbungsessays für ein Studium. Sie vergleichen von Menschen verfasste Essays mit solchen, die GPT-4 erzeugt, und erfassen, wie viele neue Ideen jeder weitere Essay hinzufügt. Von Menschen verfasste Essays tragen jeweils mehr neue Ideen bei, und der Abstand wächst, je mehr Essays einbezogen werden; auch veränderte Prompts gleichen das nicht aus. Da hier menschliche und maschinelle Texte verglichen werden und nicht die tatsächliche Nutzung von KI, deutet der Befund auf eine Bedingung kollektiven Deskillings hin: Übernehmen viele ihre Ideen aus denselben Sprachmodellen, verringert sich die Vielfalt an Ideen, auf die eine Gemeinschaft zurückgreifen kann.

Die Studien auf kollektiver Ebene ergeben ein uneinheitliches Bild. Engere Themen, weniger wechselseitiger Bezug und weniger verlässliche Qualitätssignale im Zusammenhang mit der Nutzung von KI sowie eine geringere Vielfalt an Ideen in KI-generierten Texten weisen auf Bedingungen hin, die kollektives Deskilling begünstigen können; gegen eine allgemeine Verengung spricht allerdings, dass breiter zitiert wird. Ebenfalls gegen eine Verengung spricht ein Nebenbefund der Studie von Stadler et al. (2024) mit Studierenden: Die Begründungen derjenigen, die mit ChatGPT recherchieren, ähneln einander nicht stärker als die Begründungen der Gruppe mit einer Suchmaschine. Ob sich in einem Fach tatsächlich weniger Menschen öffentliches Wissen aneignen, es prüfen und erneuern, erfassen die Studien nicht; auch das Urteilen im Austausch mit anderen zeigt sich nur indirekt, im geringeren Bezug der Forschenden aufeinander.

5. Folgerungen: Befunde, Begriff und Revision

Was lässt sich nach all dem über Deskilling in Zeiten generativer KI sagen? Mit dieser Frage greife ich noch einmal das Ziel des Textes auf, zu prüfen, was sich an meinem Verständnis von 2023 bewährt hat, was zu präzisieren ist und wo ich meine Einschätzung revidieren muss.

5.1. Folgerungen aus der Sichtung der Empirie

Die empirische Befundlage scheint sich seit 2023 vergrößert zu haben, sie wirkt aber lückenhaft und ist nicht leicht zu deuten. Weil die Sichtung nur exemplarisch angelegt ist, bleibt dieser Eindruck vorläufig; systematische Reviews könnten bestehende Lücken gezielt aufgreifen und prüfen, wie belastbar er ist.

Vergleicht man die Befunde mit den theoretischen Erkenntnissen zu den Modi von Deskilling, findet vor allem Nicht-Lernen empirische Stützung, ebenso Scheinlernen als Bedingung, unter der Nicht-Lernen unbemerkt bleibt. Zugleich machen die ausgewählten empirischen Resultate deutlich, dass Deskilling bei der Nutzung von KI nicht zwangsläufig eintritt: Unter bestimmten Bedingungen zeigen sich Lerngewinne, vereinzelt erst verzögert und ohne KI; zudem folgen Studierende KI-Empfehlungen keineswegs immer unkritisch. Für das Urteilen deuten die hier referierten Studien darauf hin, dass KI das Begründen schwächen und die Bereitschaft, selbst zu denken und zu urteilen, unter Druck setzen kann; ob sich damit auch die Disposition verändert, bleibt offen. Auf der kollektiven Ebene zeigen sich vor allem Bedingungen, die Deskilling begünstigen können, aber auch Hinweise, die gegen eine allgemeine Verengung des Wissens sprechen.

Lernen hängt von vielen, kaum überschaubaren Faktoren ab, und das gilt auch für die Frage, wie KI es verändert; uneinheitliche Ergebnisse überraschen daher nicht. In den Studien kehren aber drei Bedingungen wieder, die mitbestimmen, wie sich KI auf Lernen und Urteilen auswirkt: Ersetzt KI das eigene Tun, deutet vieles auf Nicht-Lernen hin; unterstützt sie es, zeigen sich eher Lerngewinne. Wer wenig Vorwissen oder einen geringen Ausbildungsstand mitbringt, profitiert weniger von KI und folgt falschen KI-Empfehlungen eher. Und eine Gestaltung der KI-Anwendung, die etwa zur Reflexion auffordert, kann verringern, dass falsche Empfehlungen übernommen werden.

Lücken zeigen sich in dreierlei Hinsicht. Erstens fehlen Studien zu bestimmten Gruppen und Fächern: Bei Lehrenden an Hochschulen ist mir keine aussagekräftige Studie zu Deskilling bekannt. Das ist bemerkenswert, denn in der wissenschaftlichen Literatur wird durchaus thematisiert, dass Lehrende beginnen, KI in der Lehre für didaktische Kernaufgaben zu nutzen (vgl. Hiele et al., 2026); Deskilling könnte also auch bei Lehrenden eine Rolle spielen. In den Studien zu Deskilling dominiert die Medizin, vermutlich, weil Fehlurteile dort besonders schwere Folgen haben; auf Fächer, in denen andere Formen des Urteilens relevant sind, lassen sich ihre Befunde nicht ohne Weiteres übertragen. Zweitens sind die Modi ungleich untersucht: Hinweise finden sich vor allem auf Nicht-Lernen; für Fehllernen zeigt sich nur eine Bedingung, nämlich dass Studierende während der Arbeit mit KI falsche Empfehlungen übernehmen, und zu Verlernen, das vor allem Lehrende und Forschende beträfe, liegen kaum Studien vor. Drittens gibt es Lücken im methodischen Zugang: Viele Studien erfassen die Leistung nur mit KI; wo sie ohne KI erhoben wird, erfolgt das mit geringem zeitlichem Abstand. Verlernen und dauerhafte Veränderungen der Bereitschaft aber lassen sich nur über längere Zeiträume erfassen. Allerdings sind Längsschnittstudien in der Hochschulbildungsforschung generell selten; dazu kommt, dass generative KI noch nicht allzu lange breit verfügbar ist.

5.2. Folgerungen aus der theoretischen Betrachtung

Erkenntnisse für die Hochschulbildung liefert nicht allein die Empirie. Geschärfte Begriffe und begründete Kategorien, wie sie in den Kapiteln 2 und 3 entwickelt sind, haben einen eigenen Erkenntniswert: Sie machen ein Problem genau beschreibbar und erlauben es, empirische Befunde sinnvoll zu deuten. Die Unterscheidung der Deskilling-Modi etwa macht sichtbar, dass Verlernen bislang kaum untersucht ist; die Bestimmung der Urteilskraft als Fähigkeit und Bereitschaft lenkt den Blick darauf, dass mit KI nicht nur Wissen und Können, sondern auch das Vermögen schwinden kann, selbst und im Austausch mit anderen zu denken und zu urteilen.

Die theoretisch herausgearbeitete Unterscheidung von Performanz und Disposition erklärt, warum Deskilling empirisch schwer zu fassen ist: Deskilling bezeichnet eine Beeinträchtigung von Kompetenz und damit (per definitionem) von Dispositionen, nicht eine Veränderung der momentanen Leistung. Dispositionen lassen sich jedoch nicht direkt beobachten, sondern nur über Performanz erschließen. Studien zu Deskilling müssten daher Indikatoren in der Performanz finden, die begründete Schlüsse auf veränderte Dispositionen erlauben: Sie müssten die Leistung ohne KI erheben und Veränderungen über längere Zeit verfolgen. Für Verlernen braucht es den Vergleich mit dem, was jemand zuvor konnte, für Nicht-Lernen den Vergleich mit Gruppen, die ohne KI gelernt haben; ob übernommene Fehler zu Fehllernen werden oder die Bereitschaft, selbst zu denken und zu urteilen, nachlässt, zeigt sich ohnehin erst über längere Zeit. Solche Studien sind aufwendig und, soweit die Sichtung in Kapitel 4 erkennen lässt, bislang kaum vorhanden.

Hinzu kommt eine Frage, die sich empirisch nicht beantworten lässt: Was *sollten* Menschen in Zeiten von KI noch wissen und können, und wozu sollten sie bereit sein, auch wenn sie es dank KI nicht mehr müssten? Um Befunde als Deskilling bewerten und einordnen zu können, braucht es einen normativen Rahmen. Ich lege dafür eine humanistische Wertebasis zugrunde, in deren Zentrum die Würde des Menschen und seine Fähigkeit zu Vernunft und Selbstbestimmung stehen (Deutscher Ethikrat, 2023; Reinmann & Vohle, in Druck); an anderer Stelle habe ich ausgeführt, was daraus für die Hochschulbildung folgt (Reinmann, 2023b, 2026c). Auf diese Wertebasis lassen sich auch die in Abschnitt 2.1 genannten Ziele eines wissenschaftlichen Studiums beziehen. Zugleich bietet sie eine Grundlage für Bildungs- und Lernziele, die aus rein praktischen Gründen verzichtbar erscheinen mögen, weil KI die damit verbundenen Leistungen schneller und scheinbar zuverlässiger erbringt. Ziele auf diese Weise normativ zu begründen, ist weder vorwissenschaftlich noch bloßer Hintergrund der Forschung, sondern Teil der Erkenntnisarbeit: Hochschulbildungsforschung lässt sich ohne theoretisches Forschen zu Normen nicht sinnvoll betreiben; es steht gleichrangig neben dem empirischen Forschen.

Die kollektive Ebene liefert ein weiteres Argument dafür, Bildungs- und Lernziele nicht allein vom individuellen Nutzen her zu bestimmen. Was für Einzelne verzichtbar erscheinen mag, ist es für eine Gemeinschaft nicht unbedingt: Büßen viele Einzelne epistemische Kompetenzen ein oder bauen sie gar nicht erst auf, kann das die Vermittlung zwischen öffentlichem und personalem Wissen schwächen und langfristig die Qualität von Wissenschaft beeinträchtigen, etwa weil sich Wissensbestände verengen und Illusionen des Verstehens zunehmen (Messeri & Crockett, 2024), weil der für Wissenschaft notwendige Austausch in Expertennetzwerken durch KI überflüssig zu werden scheint (Nowotny, 2025) oder weil praktische Urteilskraft verloren geht (Lindebaum et al., in Druck).

5.3. Abgleich mit der Einschätzung von 2023

Meine Einschätzung von 2023 hat sich in einem zentralen Punkt bestätigt: Deskilling ist ein ernstzunehmendes Risiko generativer KI in der Hochschulbildung, das sich nicht auf den Verlust einzelner Fertigkeiten reduzieren lässt. In meinem damaligen Beitrag hatte ich Deskilling als theoretisch möglich bestimmt und die Frage, ob und in welchem Maß es auftritt, an die Empirie verwiesen; die inzwischen vorliegenden Studien sprechen dafür, dass Deskilling zumindest als Nicht-Lernen vorkommt, das durch Scheinlernen leicht unbemerkt bleibt. Weiterhin tragfähig erscheinen mir auch die beiden Gegenmaßnahmen, die ich damals vorgeschlagen habe: eine KI-unabhängige Kompetenzentwicklung und eine beziehungsreiche Bildung, die soziale Orte für das Lernen schafft. Zu präzisieren und zu erweitern ist heute allerdings der Begriff selbst: Deskilling umfasst neben Wissen und Können auch das Vermögen, selbst und im Austausch mit anderen zu denken und zu urteilen; es tritt in drei Modi auf, betrifft die Disposition und nicht die Performanz und hat eine kollektive Ebene, die sich nicht in der Summe individueller Verluste erschöpft. Die erneute Betrachtung, die der Titel ankündigt, führt damit zu einer neuen Rahmung: Deskilling ist hier nicht nur *revisited*, sondern auch *reframed.*

Revidieren muss ich meine Einschätzung zur *hybriden Intelligenz* aufgrund von Empirie und Theorie gleichermaßen. 2023 habe ich dieses Konzept von Rafner et al. (2021) aufgegriffen, wonach Mensch und KI-System so zusammenarbeiten können, dass sie voneinander lernen. Für Expertinnen und Experten wie Lehrende habe ich darin eine Möglichkeit gesehen, nicht nur Deskilling zu vermeiden, sondern auch Upskilling zu fördern; Studierende, so meine Annahme, bräuchten dazu mehr Unterstützung, weil sie die fachlichen Kompetenzen, die Lehrende noch ohne KI erworben haben, erst aufbauen müssen (Reinmann, 2023a). Genau genommen aber lässt der Begriff der hybriden Intelligenz zwei Lesarten zu. In der Lesart von Rafner et al., auf die ich mich damals bezogen habe, unterstützt KI den Lernprozess, etwa indem sie erklärt und so das Verstehen fördert. Dafür sprechen die Befunde zur unterstützenden KI-Nutzung; allerdings ist die Grenze zum Ersetzen fließend, und von Abkürzungen profitieren gerade Novizen am wenigsten. Die Bezeichnung selbst legt jedoch eine zweite Lesart in Richtung Performanz nahe: Hybride Intelligenz bezeichnet dann, wie Mensch und KI gemeinsam ein Problem lösen; in diesem Fall interessiert die Leistung dieses Zusammenspiels. Für die Frage, ob eine Person bei der Arbeit mit KI Dispositionen ausbildet, ist der Begriff in dieser Lesart wenig brauchbar, denn Wissen, Können und Urteilskraft als Fähigkeit und Bereitschaft sind an die Person gebunden, nicht an ein hybrides System.

Für Novizen im Bildungskontext, in dem vor allem die Ausbildung von Dispositionen zählt, halte ich das Konzept der hybriden Intelligenz deshalb heute für wenig geeignet: Ihre Kompetenzentwicklung ist am stärksten gefährdet, wenn sie KI für Abkürzungen nutzen und Aktivitäten abgeben, die eigentlich Gelegenheiten sind, Wissen, Können und Urteilskraft auszubilden. Naheliegender ist für Novizen, in einem ersten Schritt auf KI zu verzichten: also, erst ohne KI Wissen und Können aufbauen und dann gegebenenfalls mit KI arbeiten. Für Expertinnen und Experten, die über diese Dispositionen bereits verfügen, kann hybride Intelligenz dagegen vorteilhaft sein. Lindebaum et al. (in Druck) etwa halten für Führungskräfte, deren bereits ausgebildete praktische Urteilskraft auf Erfahrung beruht, sogar ein *epistemic up-skilling* (Zugewinn an epistemischen Kompetenzen) für möglich, wenn KI als Anlass zur Reflexion dient und sie ihre Entscheidungen selbst begründen und verantworten müssen. Ein solches Upskilling, auch in Richtung Urteilskraft, setzt allerdings ein bereits vorhandenes Maß an Wissen, Erfahrung und Expertise voraus.

6. Ausblick

Als Hochschuldidaktikerin liegt mir besonders daran, in aller Kürze zu fragen, was aus all dem für die Gestaltung von Studium und Lehre folgt. Ich greife dafür vor allem auf eigene Arbeiten der letzten Jahre zurück, weil in ihnen Gedanken angelegt sind, die sich für das Thema KI fruchtbar machen lassen; hier will ich sie allerdings nur skizzieren. Eine Richtung zeichnet sich bereits ab: Es braucht im Studium Gelegenheiten, in denen sich Studierende einen Gegenstand zunächst ohne KI erschließen. Der Wissenschaftsrat (2026) spricht in diesem Zusammenhang von KI-freien Räumen und betont zugleich, dass sich Hochschulbildung wesentlich in sozialer Interaktion vollzieht. Daran anknüpfend habe ich an anderer Stelle vorgeschlagen, KI-freie Räume auf der didaktischen Mikroebene als soziale Räume zu gestalten, in denen Studierende gemeinsam lesen, schreiben und streiten (Reinmann, 2026b): Sie erschließen sich etwa einen schwierigen Text zu zweit Absatz für Absatz, lassen eigene Entwürfe von anderen kommentieren oder vertreten eine Position und danach die Gegenposition. KI kann anschließend hinzukommen, zum Beispiel um die eigene Rekonstruktion mit einer KI-Zusammenfassung zu vergleichen; entscheidend ist die Reihenfolge: erst die eigene Auseinandersetzung, dann – vielleicht – die KI. Solche Räume zielen nicht nur auf Wissen und Können, sondern auch auf das Vermögen, selbst und im Austausch mit anderen zu denken und zu urteilen.

Solche Formen lassen sich auf der Mikroebene unmittelbar umsetzen: Dafür braucht es weder eine neue Prüfungsordnung noch ein neues Modulhandbuch, sondern Lehrende, die sich dafür entscheiden, und Studierende, die sich darauf einlassen. Auf der Mesoebene braucht es dennoch Absprachen und Regelungen: Kollegien könnten sich zum Beispiel darauf verständigen, ob die ersten Semester vor allem der eigenen Auseinandersetzung mit dem Gegenstand gehören sollen; und solange in einem Studiengang vor allem Prüfungsleistungen zählen, bei denen KI erlaubt ist, bleibt ein KI-freier Raum eine Insel (Reinmann, 2026b). Vor allem aber sollte die Zahl summativer Prüfungen deutlich sinken: Erst dann werden Ressourcen frei für Situationen, in denen Studierende etwas versuchen, Rückmeldung erhalten und es erneut erproben können, ohne dass der erste Versuch bereits abschließend bewertet wird (Reinmann, 2022). Mit einem formativen Assessment dieser Art können KI-freie Räume zu Übungsräumen für intellektuelle Souveränität werden (Reinmann, in Druck). Ob solche Maßnahmen Deskilling vorbeugen, wäre wiederum empirisch zu prüfen, am besten mit Längsschnittstudien, die bislang fehlen. Welche Kompetenzen es zu schützen gilt, bleibt dagegen eine normative, theoretisch zu bearbeitende, Frage, die sich mit jeder Entwicklung von KI neu stellen dürfte.

Offen ist für mich schließlich nach wie vor, ob Deskilling der passende Begriff für das hier im Interesse stehende Phänomen ist. Zwar ist er in der hochschuldidaktischen Debatte angekommen, hat dazu angeregt, die Kompetenzentwicklung im Zusammenhang mit KI auch von möglichen Verlusten her zu durchdenken, und hat Studien angestoßen, deren Befunde wichtig, wenn auch nicht eindeutig sind – unter anderem, weil es noch an einer gemeinsamen und theoretisch belastbaren Sprache fehlt. Und doch wäre zu fragen, warum man in der deutschsprachigen Diskussion nicht auf das humanistische Bildungsverständnis zurückgreift, mit dem sich ebenso gut analysieren ließe, welche Risiken ein unbedachter Umgang mit KI vor allem für Novizen birgt, die erst auf dem Weg zur Expertise sind. Wie sinnvoll ist es, die Begriffe Skill und Skilling über Kompetenz, Expertise und Urteilskraft neu zu rahmen, anstatt auf den Begriff Bildung zurückzugehen? Gegen den Bildungsbegriff spricht wohl, dass er sich kaum ins Englische übersetzen lässt und nicht selten als individualistisches Konzept missverstanden wird, obwohl sich Bildung in der Wechselwirkung von Ich und Welt vollzieht. Demgegenüber finden Skill und Deskilling leichter Gehör, sind international anschlussfähig und

lassen sich auf die individuelle wie die kollektive Ebene beziehen – allerdings nur, wenn man sie, wie hier, semantisch erweitert und damit auch umdeutet.

7. Literatur

Abdulnour, R.-E. E., Gin, B. & Boscardin, C. K. (2025). Educational strategies for clinical supervision of artificial intelligence use. *New England Journal of Medicine, 393*(8), 786-797. https://doi.org/10.1056/NEJMra2503232

Blömeke, S., Gustafsson, J.-E. & Shavelson, R. J. (2015). Beyond dichotomies: Competence viewed as a continuum. *Zeitschrift für Psychologie, 223*(1), 3-13. https://doi.org/10.1027/2151-2604/a000194

Boshuizen, H. P. A., Bromme, R. & Gruber, H. (Eds.). (2004). *Professional learning: Gaps and transitions on the way from novice to expert*. Kluwer Academic Publishers.

Callard, A. (2025). *Open Socrates: The case for a philosophical life*. W. W. Norton.

Chan, C. K. Y. & Hu, W. (2023). Students' voices on generative AI: Perceptions, benefits, and challenges in higher education. *International Journal of Educational Technology in Higher Education, 20*, article 43. https://doi.org/10.1186/s41239-023-00411-8

Contractor, Z. & Reyes, G. (2026). Experimental Evidence on the Learning Impact of Generative AI. *IZA Discussion Paper*, 18792.

Darvishi, A., Khosravi, H., Sadiq, S., Gašević, D. & Siemens, G. (2024). Impact of AI assistance on student agency. *Computers & Education, 210*, Artikel 104967. https://doi.org/10.1016/j.compedu.2023.104967

Deutscher Ethikrat. (2023). *Mensch und Maschine – Herausforderungen durch Künstliche Intelligenz* (Stellungnahme). Berlin: Deutscher Ethikrat.

Erpenbeck, J., von Rosenstiel, L., Grote, S. & Sauter, W. (2017). Einführung. In J. Erpenbeck, L. von Rosenstiel, S. Grote & W. Sauter (Hrsg.), *Handbuch Kompetenzmessung* (S. IX–XXXVIII). Schäffer-Poeschel.

Fan, Y., Tang, L., Le, H., Shen, K., Tan, S., Zhao, Y., Shen, Y., Li, X. & Gašević, D. (2025). Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance. *British Journal of Educational Technology, 56*(2), 489-530. https://doi.org/10.1111/bjet.13544

Ferdman, A. (2026). AI deskilling is a structural problem. *AI & Society, 41*, 3001-3013. https://doi.org/10.1007/s00146-025-02686-z

Fleck, L. (1980). *Entstehung und Entwicklung einer wissenschaftlichen Tatsache: Einführung in die Lehre vom Denkstil und Denkkollektiv*. Suhrkamp. (Original erschienen 1935)

Gerhardt, V. (2024). *Immanuel Kant: Vernunft und Leben*. Reclam.

Gruber, H. (2006). Expertise. In D. H. Rost (Hrsg.), *Handwörterbuch Pädagogische Psychologie* (S. 175-180). Beltz PVU.

Hao, Q., Xu, F., Li, Y. & Evans, J. (2026). Artificial intelligence tools expand scientists' impact but contract science's focus. *Nature, 649*(8099), 1237-1243. https://doi.org/10.1038/s41586-025-09922-y

Herzberg, D. & Reinmann, G. (2025). Dialogmaschinen im kommunikativen Beziehungsgeflecht der Hochschulbildung: Idealtypische Nutzungsmodi. *Impact Free 62*. Hamburg.

Hiele, T. M., Hiele, E. M., Hazarika, B., Halibas, A. S. & Ha, Q.-A. (2026). From deskilling to reskilling: Navigating AI integration in academic practice in higher education. *Review of Education*, 14, e70187. https://doi.org/10.1002/rev3.70187

Hoffmann, N., Göbel, H., Rütten, D. & Schmidt, S. (2026*). „Manchmal muss ich mich aktiv zum selbst denken motivieren". Bericht zur Studierendenbefragung 2025 zum akademischen Schreiben mit KI*. Schreibzentrum der Goethe-Universität Frankfurt. https://doi.org/10.21248/gups.97289

Huber, L. (1983). Hochschuldidaktik als Theorie der Bildung und Ausbildung. In L. Huber (Hrsg.), *Ausbildung und Sozialisation in der Hochschule* (Enzyklopädie Erziehungswissenschaft, Bd. 10) (S. 114-138). Klett-Cotta.

Kalz, M. & Reinmann, G. (2024). Erneuerung der Hochschule von außen nach innen oder umgekehrt? Kritische Diskussion und Alternativen zur Future Skills-Bewegung. *Impact Free 57*. Hamburg.

Kıyak, Y. S., Coşkun, Ö. & Budakoğlu, I. İ. (2026). 'ChatGPT can make mistakes' warnings fail: A randomized controlled trial. *Medical Education, 60*(2), 138-142. https://doi.org/10.1111/medu.70056

Kosmyna, N., Hauptmann, E., Yuan, Y. T., Situ, J., Liao, X.-H., Beresnitzky, A. V., Braunstein, I. & Maes, P. (2025). Your brain on ChatGPT: Accumulation of cognitive debt when using an AI assistant for essay writing task. *arXiv*. https://doi.org/10.48550/arXiv.2506.08872

Kusumegi, K., Yang, X., Ginsparg, P., de Vaan, M., Stuart, T. & Yin, Y. (2025). Scientific production in the era of large language models. *Science, 390*, 1240-1243. https://doi.org/10.1126/science.adw3000

Lee, H.-P., Sarkar, A., Tankelevitch, L., Drosos, I., Rintel, S., Banks, R. & Wilson, N. (2025). The impact of generative AI on critical thinking: Self-reported reductions in cognitive effort and confidence effects from a survey of knowledge workers. In *Proceedings of the 2025 CHI Conference on Human Factors in Computing Systems* (article 1121, pp. 1-22). ACM. https://doi.org/10.1145/3706598.3713778

Lehmann, M., Cornelius, P. B. & Sting, F. J. (2025). AI meets the classroom: When do large language models harm learning? *arXiv*. https://doi.org/10.48550/arXiv.2409.09047

Lindebaum, D., Balasubramanian, N., Ashraf, M. & Haack, P. (in press). A process model of managerial phronesis in the age of generative AI. *Academy of Management Review*. https://doi.org/10.5465/amr.2024.0582

Macnamara, B. N., Berber, I., Çavuşoğlu, M. C., Krupinski, E. A., Nallapareddy, N., Nelson, N. E., Smith, P. J., Wilson-Delfosse, A. L. & Ray, S. (2024). Does using artificial intelligence assistance accelerate skill decay and hinder skill development without performers' awareness? *Cognitive Research: Principles and Implications, 9*, article 46. https://doi.org/10.1186/s41235-024-00572-8

Messeri, L. & Crockett, M. J. (2024). Artificial intelligence and illusions of understanding in scientific research. *Nature, 627*, 49-58. https://doi.org/10.1038/s41586-024-07146-0

Moon, K., Green, A. E. & Kushlev, K. (2025). Homogenizing effect of large language models (LLMs) on creative diversity: An empirical comparison of human and ChatGPT writing. *Computers in Human Behavior: Artificial Humans*, 6, article 100207. https://doi.org/10.1016/j.chbah.2025.100207

Münzer, S., Go, S. & Paaßen, B. (2026). *Gefährdet generative KI die digitale Autonomie im Studium?* (Diskussionspapier Nr. 41). Hochschulforum Digitalisierung. https://doi.org/10.5281/zenodo.21414756

Nowotny, H. (2025). Bringing back friction: Reflections on a humanistic culture of AI interdisciplinarity. *Cambridge Forum on AI: Culture and Society, 1*, Artikel e4.

Ong, A. Y., Sui, M., Rosen, K. L. & Kvedar, J. C. (2026). Reconciling how clinical reasoning is learned in the age of artificial intelligence. *npj Digital Medicine, 9*, article 435. https://doi.org/10.1038/s41746-026-02873-2

Passlack, N., Gerholz, K.-H. & Schlottmann, P. (2025). Reskilling me softly: Perceived changes in students' skilling when using GenAI in academic research projects. In T. X. Bui (Eds.), *Proceedings of the 58th Hawaii International Conference on System Sciences* (S. 4924-4932). University of Hawaii.

Prather, J., Reeves, B. N., Leinonen, J., MacNeil, S., Randrianasolo, A. S., Becker, B. A., Kimmel, B., Wright, J. & Briggs, B. (2024). The widening gap: The benefits and harms of generative AI for novice programmers. In *Proceedings of the 2024 ACM Conference on International Computing Education Research* (Vol. 1, pp. 469-486). ACM. https://doi.org/10.1145/3632620.3671116

Preiß, J., Bartels, M., Blüthmann, N. & Reinmann, G. (2025). Förderung von KI-Literacy für das Studium: DBR-Studie zur Entwicklung eines Workshop-Konzepts. *EDeR – Educational Design Research, 9*(3), Artikel 86. https://doi.org/10.15460/eder.9.3.2357

Preiß, J., Freise, F., Bartels, M. & Hartel, F. (2025). *ChatGPT and Me 3.0: Drei Jahre generative KI an der Universität Hamburg*. Digital and Data Literacy in Teaching Lab, Universität Hamburg. https://doi.org/10.25592/uhhfdm.18047

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

Reinmann, G. (2015). Lehrkompetenzen von Hochschullehrern: Kritik des Kompetenzbegriffs in fünf Thesen. In O. Hartung & M. Rumpf (Hrsg.), *Lehrkompetenzen in der wissenschaftlichen Weiterbildung: Konzepte, Forschungsansätze und Anwendungen* (S. 17-36). Springer VS.

Reinmann, G. (2022). Prüfung oder Assessment an Hochschulen? Thesen für einen Wandel der Prüfungskultur. In J. Gerik, A. Sommer & G. Zimmermann (Hrsg.), *Kompetent Prüfungen gestalten: 60 Prüfungsformate für die Hochschullehre* (S. 22-36). Waxmann.

Reinmann, G. (2023a). *Deskilling durch Künstliche Intelligenz? Potenzielle Kompetenzverluste als Herausforderung für die Hochschuldidaktik* (Diskussionspapier Nr. 25). Hochschulforum Digitalisierung.

Reinmann, G. (2023b). Wozu sind wir hier? Eine wertebasierte Reflexion und Diskussion zu ChatGPT in der Hochschullehre. *Impact Free 51*. Hamburg.

Reinmann, G. (2026a). Generative KI in Studium und Lehre: Welche Bedeutung hat fachliches Wissen für kritisches Denken? In U. Dittler & C. Kreidl (Hrsg.), *Hochschulentwicklung der Zukunft* (S. 119-133). Schäffer-Poeschel.

Reinmann, G. (2026b). *Fachwissen und KI-freie Räume: rückwärts- oder vorwärtsgewandt?* Schriftfassung eines Vortrags. https://gabi-reinmann.de/wp-content/uploads/2026/10/KI-Vortrag-Okt-2026-Schriftfassung.pdf

Reinmann, G. (2026c). Wozu? KI, Hochschulbildung und die Frage nach dem Sinn. *Impact Free 73*. Hamburg.

Reinmann, G. (in Druck). Akademisches Üben – Leerstelle und Spezifikum der Hochschuldidaktik. Erschein in P. Tremp (Hrsg.) (2027), *Ein vergleichender Blick auf Hochschullehre und Hochschuldidaktik*. Springer VS.

Reinmann, G. & Vohle, F. (in Druck). Akademische Werte im Zeitalter Künstlicher Intelligenz. In S. Niedermeier, K. Winkler & H. Mandl (Hrsg.), *Pädagogik und Psychologie im digitalen Wandel*. Schäffer-Poeschel.

Reinmann, G., Watanabe, A., Herzberg, D. & Simon, J. (2025). Selbstbestimmtes Handeln mit KI in der Hochschule: Forschungsdefizit und -perspektiven. *Zeitschrift für Hochschulentwicklung, 20*(SH-KI-1), 33-50.

Ren, S. (2026). College students' metacognitive awareness of generative-AI reliance: An experimental study of decision confidence and attribution bias. *Frontiers in Psychology, 17*, article 1926110. https://doi.org/10.3389/fpsyg.2026.1926110

Seiler, T. B. (2008). *Wissen zwischen Sprache, Information, Bewusstsein: Probleme mit dem Wissensbegriff*. MV-Wissenschaft.

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, 160*, article 108386. https://doi.org/10.1016/j.chb.2024.108386

von Garrel, J. & Mayer, J. (2023). Artificial Intelligence in studies – use of ChatGPT and AI-based tools among students in Germany. *Humanities and Social Sciences Communications, 10*, article 799. https://doi.org/10.1057/s41599-023-02304-7

Weinert, F. E. (2001). Vergleichende Leistungsmessung in Schulen – eine umstrittene Selbstverständlichkeit. In F. E. Weinert (Hrsg.), *Leistungsmessungen in Schulen* (S. 17-31). Beltz.

Impressum

Diskussionspapiere des HFD spiegeln die Meinung der jeweiligen Autor:innen wider.
Das HFD macht sich die in diesem Papier getätigten Aussagen daher nicht zu Eigen.



Dieses Werk ist unter einer Creative Commons Lizenz vom Typ Namensnennung - Weitergabe unter gleichen Bedingungen 4.0 International zugänglich. Um eine Kopie dieser Lizenz einzusehen, konsultieren Sie http://creativecommons.org/licenses/by-sa/4.0/. Von dieser Lizenz ausgenommen sind Organisationslogos sowie falls gekennzeichnet einzelne Bilder und Visualisierungen.

ISSN (Online) 2365-7081; 12. Jahrgang

Zitierhinweis
Reinmann, G. (2026). Deskilling revisited in der Hochschulbildung. Begriff, Formen und Befunde zu Deskilling in Zeiten generativer KI. Diskussionspapier Nr. 42. Berlin: Hochschulforum Digitalisierung.

Herausgeber
Geschäftsstelle Hochschulforum Digitalisierung beim Stifterverband für die Deutsche Wissenschaft e.V.
Hauptstadtbüro • Pariser Platz 6 • 10117 Berlin • T 030 322982-520
info@hochschulforumdigitalisierung.de

Layout
Satz: Lena Ackermann
Vorlage: TAU GmbH • Köpenicker Straße 154a • 10997 Berlin

Das 2014 gegründete Hochschulforum Digitalisierung ist eine gemeinsame Initiative des Stifterverbandes, des CHE Centrums für Hochschulentwicklung und der Hochschulrektorenkonferenz (HRK). Gefördert wird es vom Bundesministerium für Forschung, Technologie und Raumfahrt (BMFTR).

www.hochschulforumdigitalisierung.de

STIFTERVERBAND
CHE Centrum für Hochschulentwicklung
HRK Hochschulrektorenkonferenz
Gefördert durch: Bundesministerium für Forschung, Technologie und Raumfahrt