



RS

Use Case: Lernbedarfsanalyse mit KI: Daten strukturieren,
Entscheidungen bewusster treffen

Wie KI Lehrende dabei unterstützt, Lernbedarfe systematisch zu erfassen – ohne pädagogische Verantwortung zu übernehmen. Die Technologie macht Muster sichtbar, während die Interpretation und Umsetzung beim Menschen bleiben.

I. Ausgangslage

Lehrende stehen heute vor einer doppelten Herausforderung, die sowohl die Effizienz ihrer Arbeit als auch die Legitimation ihrer Lehre betrifft. Einerseits führt der Einsatz von KI zwar zu technischen Unterstützungsmöglichkeiten, doch verschiebt sich die Arbeitsbelastung oft nur: Statt Zeit für Planung und Reflexion zu gewinnen, verbringen viele Lehrende wertvolle Ressourcen damit, generische und didaktisch unausgereifte KI-Vorschläge manuell nachzubessern. Dieser „Re-Work-Effort“ bindet Kapazitäten, die für die eigentliche pädagogische Arbeit fehlen, und führt nicht selten dazu, dass die Ergebnisse dennoch am eigentlichen Bedarf der Lerngruppe vorbeigehen.

Andererseits gerät die Präsenzlehre zunehmend in eine Legitimationskrise. Wenn Lehrveranstaltungen lediglich Inhalte wiederholen, die Studierende ohnehin digital abrufen können, stellt sich unweigerlich die Frage: „Warum soll ich überhaupt kommen?“ Diese Frage steht heute in jedem Hörsaal – oft unausgesprochen, aber umso drängender. Ohne präzise Kenntnis der individuellen Lernbedarfe, Vorerfahrungen und Motive der Studierenden vor Ort droht eine kognitive Fehlsteuerung: Die Lehre bewegt sich zwischen Unterforderung durch bloße Wiederholung und Überforderung durch unpassende methodische Ansätze. Der Mehrwert der Präsenzlehre muss daher heute aktiv durch eine **adaptive Planung** erwiesen werden, die den physischen Raum gezielt für echte Interaktion und die Entwicklung von Kompetenz nutzt.

„Wir müssen aufhören, die Zeit unserer Studierenden mit der Vermittlung von Inhalten zu verschwenden, die sie in Sekunden ergoogeln können. Die wahre Aufgabe der Lehre ist es heute, den Kontext zu gestalten, in dem Wissen zu Kompetenz wird. Das erfordert eine radikale Hinwendung zu dem Menschen, der vor uns sitzt.“¹

¹ Frei übersetzt nach Dr. Sabba Quidwai in „Beyond the Basics: Designing AI Enhanced Learning Experiences“ unter <https://www.linkedin.com/learning/beyond-the-basics-designing-ai-enhanced-learning-experiences/be-irreplaceable-as-a-learning-designer>



RS

2. Strategischer Ansatz

Um die Legitimationskrise der Lehre zu überwinden und die ineffiziente Nachbearbeitung generischer KI-Vorschläge zu vermeiden, setzen wir auf eine **systematische, datengestützte Analyse** als Grundlage für adaptive Lernarchitekturen. Statt Zeit in die manuelle Überarbeitung von KI-generierten Inhalten zu investieren, nutzen wir die Technologie gezielt als **Werkzeug zur strukturierten Auswertung** von Lernbedarfen. Die KI übernimmt dabei die Aufgabe, Daten zu sammeln, zu verdichten und Muster sichtbar zu machen – immer unter der Prämisse, dass die **pädagogische Verantwortung und Entscheidungshoheit** beim Menschen verbleibt.

Der Ansatz basiert auf drei zentralen Prinzipien:

1. **Skalierbare Empathie:** Die KI erfasst individuelle Lernbedarfe und macht Muster sichtbar, die im klassischen Lehrsetting oft verborgen bleiben – wertvolle Informationen, um die Vielfalt der Lerngruppe präzise abzubilden.
2. **Strukturierendes Werkzeug:** Die KI filtert und analysiert Rohdaten basierend auf dem Teaching Statement und liefert datenbasierte Entscheidungsgrundlagen, während die Lehrkraft die pädagogische Architektur steuert.
3. **Adaptive Planung:** Der physische Raum wird gezielt für Interaktion und Kompetenzentwicklung genutzt, indem die Lehre sich dynamisch an die Gruppe anpasst – Theorie dort vertieft wird, wo Vorwissen vorhanden ist, und Praxisraum dort entsteht, wo die Daten es nahelegen.

Unser Ansatz setzt bewusst am ersten und entscheidenden Schritt des ADDIE-Modells an: der Analysephase. Viele Lehrende springen heute direkt zur Inhaltserstellung („Development“), ohne das Fundament einer soliden Datenbasis zu legen. Doch eine adaptive Lernarchitektur steht und fällt mit der Qualität der zugrundeliegenden Daten. Indem wir die Analysephase durch KI-gestützte Clusterung von Vorwissen, Motiven und Kontexten stärken, stellen wir sicher, dass die anschließende Planung nicht am eigentlichen Bedarf vorbeigeht, sondern zielgerichtet und wirksam erfolgt.



RS

3. Werkzeug(e)

Der Prozess nutzt eine datengestützte Sensorik-Schleife: Die Lehrkraft erhebt über ein strukturiertes Formular die individuellen Kontexte der Studierenden und lässt diese durch eine trainierte KI auswerten und zu einer adaptiven Lernmatrix prozessieren.

1. Der Sensor (Google Forms o.Ä.): Ein strukturiertes Erfassungstool, das über reine Wissensfragen hinausgeht. Es dient als Brücke zur studentischen Realität. (Live-Beispiel: <https://forms.gle/n164hbxZt1kW5hNCA>)
2. Die Schnittstelle (CSV/PDF): Anonymisierter Export der Antworten, um Datenschutz zu gewährleisten und die Daten für die KI prozessierbar zu machen.
3. Das Gehirn (Custom KI / Analyse-Architekt): Eine spezialisierte KI-Konfiguration, die mit deinem Teaching Statement und der Datenauswertung gefüttert wird.

Beispielfragen für das Umfrageformular

Die Wirksamkeit der Analyse-Architektur beruht auf der gezielten Abfrage von Lernpräferenzen und Hürden. Hier sind einige Fragen aus dem Live-Beispiel unter diesem Link: <https://forms.gle/n164hbxZt1kW5hNCA>

- Informationsaufnahme: „Wie nimmst du komplexe Informationen am besten auf?“ (Fokus auf Medientypen wie Video, Audio oder Text).
- Verständnis-Anker: „Was hilft dir mehr, um komplexe Zusammenhänge zu verstehen?“ (z. B. Beispiele vs. abstrakte Modelle).
- Lernumgebung: „Wo und wie lernst du primär?“ (Stationär am Schreibtisch vs. mobil unterwegs).
- Einstiegs-Präferenz: „Wenn du dich in ein neues Thema einarbeitest, bevorzugst du...“ (z. B. erst Überblick gewinnen vs. direkt ins Detail gehen).
- Soziales Setting: „In welchem Setting erzielst du die besten Ergebnisse?“ (Einzelarbeit vs. Austausch in der Gruppe).
- Angst-Faktoren: „Welcher Begriff aus der Modulbeschreibung löst bei dir aktuell das größte ‚flaue Gefühl‘ aus?“ (Identifikation von kognitiven Barrieren).
- Sicherheits-Anker: „Was gibt dir die größte Sicherheit im Lernprozess?“ (z. B. klare Struktur, Feedback-Schleifen oder Musterlösungen).

Der Analyse-Prompt für dein CustomGPT; Gem, oder ähnliches:

Erstelle eine individuelle KI-Instanz (z. B. in ChatGPT, Gemini oder einem vergleichbaren System). Nach der Festlegung von Name und Beschreibung kannst du die Arbeitsweise und Aufgaben der KI definieren – bei Gemini unter „Anleitung“, bei ChatGPT in der Pro-Version unter „Hinweise“. Lade zusätzlich dein Teaching Statement (siehe Use Case „Teaching Statement“) als Wissensbasis hoch, damit die KI darauf zugreifen kann.



RS

Diesen Prompt kopierst du direkt in die System-Anweisungen deines Gerns, um es als Analyse-Werkzeug vorzubereiten:

Rolle & Identität: Du bist ein Analyse-Werkzeug meines Lehr-Teams. Deine Aufgabe ist es, die hochgeladenen Daten meiner Studierenden mit meinem Teaching Statement abzugleichen und Muster sichtbar zu machen. Du triffst keine Entscheidungen, sondern lieferst strukturierte Übersichten für meine pädagogische Einordnung.

Deine Arbeitsgrundlage: Nutze das hochgeladene Teaching Statement als didaktischen Kompass. Dein Ziel ist es, mir zu helfen, die Perspektiven aller Lernenden zu verstehen und diese Informationen in strategische Handlungsoptionen zu übersetzen.

Analyse-Schritte:

- Herausforderungen identifizieren: Ermittle die häufigsten Lernhindernisse und gib an, wie viele Studierende davon betroffen sind.
- Lernpräferenzen erfassen: Zeige wiederkehrende Muster zu bevorzugten Lernmethoden und -umgebungen auf (inkl. der drei häufigsten Aktivitäten).
- Daten aufbereiten: Stelle die Ergebnisse in einer Tabelle dar (Herausforderung | Häufigkeit | Handlungsmöglichkeit).
- Reflexionsimpuls: Weise auf mögliche Datenlücken hin, die für eine bessere Planung relevant wären.

Strategische Empfehlungen:

- Unterstützungsbedarf: Zeige auf, wo zusätzliche Struktur oder Führung nötig ist, um Überforderung zu vermeiden.
- Raumnutzung: Schlage vor, wie der physische Lehrraum so gestaltet werden kann, dass er den Bedarfen der Gruppe entspricht – z. B. durch Methoden, die zu den erkannten Präferenzen passen.
- Motivationsbrücke: Formuliere einen Einstiegssatz für die erste Sitzung, der die Ziele der Studierenden mit den Modulinhalten verknüpft.

Interaktionsregel: Falls Daten unvollständig sind (z. B. fehlende Angaben zu Studiengang oder Semester), frage aktiv nach, bevor du die Analyse abschließt.



RS

4. Architektur

Die Architektur dieses Prozesses sorgt dafür, dass die Analyse nicht als isoliertes Dokument endet, sondern direkt in die Gestaltung der Lehre einfließt. Der Ablauf folgt vier klaren Phasen, die sicherstellen, dass aus Daten konkrete pädagogische Handlungsoptionen werden:

1. Datenerhebung (Erfassungsphase): Die Studierenden teilen über ein strukturiertes Umfrage-Tool (z. B. Google Forms) ihre individuellen Lernkontexte mit – dazu zählen Motive, persönliche Hürden und zeitliche Präferenzen. Diese Phase bildet das Fundament, um die Vielfalt der Lerngruppe systematisch zu erfassen.

2. Datenaufbereitung (Schnittstellenphase): Die anonymisierten Antworten werden exportiert und in die Analyse-KI hochgeladen. Dort werden sie mit deinem Teaching Statement und weiteren didaktischen Rahmenbedingungen abgeglichen. Dieser Schritt stellt sicher, dass die Daten zielgerichtet und kontextbezogen ausgewertet werden können.

3. Analyse und Mustererkennung (Auswertungsphase): Die KI führt die vordefinierten Analyseschritte aus: Sie identifiziert wiederkehrende Muster, quantifiziert Herausforderungen (z. B. in Tabellenform) und weist auf mögliche blinde Flecken in der Planung hin. Das Ergebnis ist eine strukturierte Übersicht, die als Grundlage für die nächste Phase dient.

4. Didaktische Anpassung (Umsetzungsphase): Auf Basis der Analyse-Matrix passt die Lehrkraft die methodische und inhaltliche Architektur des Kurses an. Dies kann die Intensität der Lernbegleitung, die Auswahl passender Präsenzmethode oder die Schwerpunktsetzung in den Sitzungen umfassen. Die KI liefert dabei datenbasierte Entscheidungsgrundlagen – die finale Gestaltung obliegt jedoch der pädagogischen Expertise der Lehrkraft.

Ziel des Prozesses: Die Lehre wird evidenzbasiert und adaptiv – ohne dass die KI pädagogische Verantwortung übernimmt. Statt generischer Inhalte entstehen maßgeschneiderte Lernangebote, die den Bedarfen der Gruppe gerecht werden.



RS

5. Mehrwert & Reflexion

Effizienz durch Präzision: Der Einsatz dieser Analyse-Architektur reduziert didaktischen Leerlauf, indem Planung nicht mehr auf Vermutungen, sondern auf einer objektiven Datenbasis fußt. Die KI liefert eine klare Übersicht der studentischen Realität – Lernhürden werden frühzeitig erkennbar, noch bevor sie zu Frustration führen. Dies minimiert den Aufwand für nachträgliche Anpassungen und steigert die Effizienz der Vorbereitung. Gleichzeitig gewinnt die Präsenzlehre an Legitimation, weil sie dort ansetzt, wo die Gruppe konkreten Bedarf hat. Das spart nicht nur Zeit, sondern erhöht auch die Motivation – sowohl bei Lehrenden als auch bei Lernenden.

Verantwortungsvolle Nutzung: Die KI fungiert hier als „Empathie-Verstärker“, der es ermöglicht, die Perspektiven vieler Studierender gleichzeitig zu erfassen. Doch sie bleibt ein Werkzeug: Die Technologie liefert Daten und Muster – die pädagogische Einordnung und Entscheidung obliegt allein der Lehrkraft. Ihre Rolle besteht darin, die KI-Ergebnisse kritisch mit dem eigenen Teaching Statement abzugleichen und mit pädagogischem Urteilsvermögen zu handeln – nicht mit blindem Vertrauen in die Daten, sondern mit reflektierter Souveränität.

Grenzen und ethische Reflexion:

Datenqualität: Die Aussagekraft der Analyse hängt maßgeblich von der Offenheit und Beteiligung der Studierenden ab. Unvollständige oder oberflächliche Angaben schränken die Aussagekraft ein.

Inklusion: KI-Systeme tendieren dazu, Mehrheitsmeinungen stärker zu gewichten und Randperspektiven zu übersehen. Hier ist die Lehrkraft gefordert, manuell nachzujustieren, um alle Stimmen gleichberechtigt zu berücksichtigen.

Kontinuität: Die hier beschriebene Erhebung ist eine Momentaufnahme (z. B. zu Semesterbeginn). Ein laufender Feedback-Prozess wäre ideal, um dynamisch auf Veränderungen reagieren zu können.

Zentrale Erkenntnis: Dieser Ansatz zeigt, wie KI unterstützend wirken kann – ohne die pädagogische Verantwortung zu ersetzen. Die Technologie schafft Transparenz, doch die Gestaltung der Lehre bleibt eine menschliche Aufgabe.