

MODUL 01

Fairness und Voreingenommenheit in der KI

Gewährleistung einer ausgewogenen Darstellung
und unterschiedlicher Standpunkte

Inhalt

01	Einführung und wichtige Fakten zur KI (10 Min.)	3
02	Was versteht man unter Fairness und Voreingenommenheit in der KI und warum ist das wichtig? (10 Min.)	8
03	Wie setzt man KI richtig ein? Fünf Regeln (15 Min.)	11
04	Ursachen für Voreingenommenheit in der KI (20 Min.)	25
05	Wie lassen sich Verzerrungen vermeiden? (10 Min.)	40
06	Beispiele, Übungen, Daten und Tipps (20 Min.)	45



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

01

Einführung und wichtige
Fakten zur KI

(10 Min.)

Künstliche Intelligenz wird in großem Umfang zur Erstellung digitaler Inhalte wie Texte, Bilder und Videos eingesetzt.

Diese Inhalte beeinflussen die Denkweise und die Entscheidungsfindung der Menschen. Aus diesem Grund ist es wichtig zu verstehen, wie KI eingesetzt wird und wie Fairness und Verantwortungsbewusstsein bei KI-generierten Inhalten gewährleistet werden können.

FAKT 1

Künstliche Intelligenz ist nicht unfehlbar. Sie stützt sich auf Daten, ohne deren Richtigkeit zu überprüfen, was zu falschen Schlussfolgerungen führen kann.



„Die Menschen glauben vielleicht, dass sie den Informationen dieser KI-Assistenten vertrauen können, doch diese Untersuchung zeigt, dass diese bei Fragen zu wichtigen Nachrichtenereignissen Antworten liefern können, die verzerrt, sachlich falsch oder irreführend sind.“

**Pete Archer, Programmdirektor
für generative KI bei der BBC, 11. Februar 2025**

FAKT 2

Künstliche Intelligenz ist künstlich. Sie basiert auf Algorithmen, die von Menschen entwickelt wurden. Diese Algorithmen unterscheiden sich hinsichtlich Sensibilität, Genauigkeit, Qualität und anderer Parameter, die einen erheblichen Einfluss auf die von ihnen erzeugten Ergebnisse haben.




„Was wir der KI beibringen, spiegelt unsere eigenen Werte wider.“

„Wir müssen sicherstellen, dass KI-Systeme mit den menschlichen Werten im Einklang stehen.“

Demis Hassabis
CEO von Google DeepMind

FAKT 3

Achten Sie darauf, wie Sie Ihre Fragen formulieren. Vieles hängt von der Präzision Ihrer Wortwahl und Ihrem vorhandenen Wissensstand ab.



„Wenn ich eine Stunde Zeit hätte, um ein Problem zu lösen, und mein Leben von der Lösung abhinge, würde ich die ersten 55 Minuten damit verbringen, die richtige Frage zu formulieren; denn sobald ich die richtige Frage kenne, könnte ich das Problem in weniger als fünf Minuten lösen.“

Albert Einstein

02

Was versteht man unter
Fairness und
Voreingenommenheit in
der KI und warum ist das
wichtig?

Was ist Voreingenommenheit?

Voreingenommenheit in der KI kann in vielen Phasen auftreten: von der Datenerhebung über den Modellentwurf bis hin zur Umsetzung.

Voreingenommenheit bedeutet, ungerecht zu sein oder bestimmte Personen gegenüber anderen zu bevorzugen.

In der KI tritt Voreingenommenheit auf, wenn das System mit begrenzten oder unausgewogenen Daten trainiert wird und diese Muster wiederholt.

In der KI kann Voreingenommenheit beispielsweise so aussehen:

- Manche Personen werden häufiger dargestellt als andere
- Bestimmte Gruppen werden ausgeklammert
- Stereotypen werden wiederholt

Warum Voreingenommenheit von Bedeutung ist:

- KI kann viele Menschen gleichzeitig betreffen
- Unfaire Ergebnisse können echten Schaden anrichten
- Menschen müssen KI-Ergebnisse überprüfen und korrigieren

Warum ist Fairness wichtig?



- Gerechte Behandlung von Einzelpersonen und Gruppen
- Vermeidung von Voreingenommenheit und Diskriminierung
- Gleichberechtigte Vertretung und Inklusion
- Menschliche Verantwortung für den fairen Einsatz von KI



„KI wird das Beste oder das Schlimmste, was die Menschheit je erlebt hat.“

Elon Musk



03

Wie setzt man KI richtig
ein? Fünf Regeln

(15 Min.)

Die 5 Regeln für den richtigen Umgang mit KI



01

Verwenden Sie gute und faire Daten



02

Auf unfaire Muster prüfen



03

Erklären Sie, wie es funktioniert



04

Beziehen Sie die Menschen mit ein



05

Überprüfen Sie die Ergebnisse regelmäßig

Regel 01

KI lernt aus den Informationen, die wir ihr zur Verfügung stellen. Wenn in diesen Informationen bestimmte Personengruppen fehlen, wird die KI nicht für alle gut funktionieren. Um fair zu sein, müssen wir Daten verwenden, die alle gleichermaßen repräsentieren.

Die weltweite Datenmenge im Internet beläuft sich derzeit auf etwa 200 Zettabyte (ZB) und wächst exponentiell.

Ein Zettabyte entspricht einer Billion Gigabyte (GB).

$$1 \text{ ZB} = 1.000.000.000.000 \text{ GB}$$

Allerdings sind nicht alle diese Informationen **wahr, aktuell oder zuverlässig.**

Verwenden Sie verifizierte Daten.

Wenn eine Information für Sie besonders wichtig ist, lohnt es sich, sie an der Quelle zu überprüfen.

- Denken Sie daran: Unabhängig davon, woher die Daten stammen, sollten Sie sie stets einer eigenen kritischen Bewertung unterziehen.
- Achten Sie auf Anzeichen von Diskriminierung und Ungleichbehandlung.

Beispiele für zuverlässige Daten- und Informationsqu ellen



- Offizielle Websites von Regierungen oder anerkannten internationalen Institutionen.
- Thematische Berichte, die von renommierten Institutionen wie den Vereinten Nationen und ihren Sonderorganisationen, darunter die UN, die UNESCO, die FAO und die ILO, erstellt wurden.
- Datenbanken mit offiziellen statistischen Daten, die von anerkannten Organisationen gepflegt werden, wie beispielsweise Eurostat – die offizielle statistische Datenbank der Europäischen Union.
- Anerkannte Datenbanken mit wissenschaftlichen Publikationen wie Scopus, Web of Science, PubMed und ScienceDirect.

Regel 02

Bevor wir ein KI-Tool einsetzen, müssen wir es testen. Wir müssen nach „Voreingenommenheit“ suchen – das heißt, wenn die KI eine Gruppe von Menschen besser behandelt als eine andere. Wenn wir ein Problem feststellen, müssen wir es sofort beheben.



Das Testen von Tools und Systemen auf Voreingenommenheit bedeutet, zu prüfen, ob ihre Ergebnisse systematisch zugunsten oder zuungunsten bestimmter Gruppen, Themen oder Szenarien verzerrt sind.

Mit anderen Worten: Es geht darum, Ungerechtigkeiten in den Daten, im Modell, in den Regeln, denen es folgt, oder in der Art und Weise, wie es eingesetzt wird, aufzudecken.

Wie sieht eine solche Prüfung in der Praxis aus?

- Vergleich der Systemantworten für verschiedene Nutzergruppen oder -profile
- Überprüfung, ob das Modell ein Geschlecht, eine Nationalität, eine Altersgruppe, eine Sprache oder einen sozialen Status bevorzugt
- Analyse der Trainingsdaten auf mangelnde Repräsentativität
- Testen mit kontrollierten Sätzen ähnlicher Fragen, bei denen nur sensible Merkmale verändert werden
- Beurteilung, ob das System Stereotypen reproduziert oder unfaire Empfehlungen generiert

Regel 03

Um korrekte Ergebnisse von der KI zu erhalten, müssen Sie verstehen, wie das System aufgebaut ist, worauf es basiert und wo seine Grenzen liegen.

KI arbeitet auf der Grundlage von Daten, Mustern, Anweisungen und Optimierungsregeln, daher hängt die Qualität ihrer Antworten von der Qualität der Eingaben, dem Kontext und der Art und Weise ab, wie das System genutzt wird.

Grundprinzipien



- Geben Sie den Kontext, den Zweck und die Zielgruppe an.
- Verwenden Sie konkrete Angaben statt vager Formulierungen.
- Prüfen Sie, ob die Antwort mit vertrauenswürdigen Quellen übereinstimmt.
- Denken Sie daran, dass KI nicht im menschlichen Sinne „weiß“; sie verarbeitet Muster aus Daten und Anweisungen.

Regel 04

Wir sollten nicht zulassen, dass die KI alle wichtigen Entscheidungen trifft. Menschen sollten die KI stets beaufsichtigen.

Ein Mensch sollte das letzte Wort haben, insbesondere bei wichtigen Themen wie Arbeit oder Gesundheit, um sicherzustellen, dass die KI wohlwollend und fair handelt.



*„Wir müssen sicherstellen,
dass die KI unter
menschlicher Kontrolle
bleibt“*

**Professor an der Université de
Montréal, Forscher und Spezialist
für KI-Systeme**

Das Konzept der menschlichen Mitwirkung an technologischen Prozessen, insbesondere an Entscheidungsprozessen, ist eine der Hauptannahmen der EU-Strategie „Industrie 5.0“. Ihr Ziel ist es, die technologische Entwicklung so zu lenken und auszugleichen, dass sie den größtmöglichen Nutzen bringt und den Schutz – statt der Verletzung – menschlicher Werte fördert.



FALLSTUDIE:

Das KI-Rekrutierungstool von Amazon

- Amazon entwickelte ein KI-basiertes Rekrutierungssystem zur Vorauswahl von Bewerbern, doch das System lernte aus früheren Einstellungsmustern und begann, Lebensläufe, die Anzeichen für weibliche Bewerber enthielten, schlechter zu bewerten.
- Da das Problem von den Personen entdeckt wurde, die das System überprüften, hat Amazon das Tool noch vor seiner vollständigen Einführung wieder verworfen.
- Dies ist ein eindeutiger Fall, in dem menschliche Aufsicht verhindert hat, dass ein KI-Fehler zu einer operativen Entscheidung wurde – insbesondere in einem Bereich mit hoher Tragweite wie der Personalbeschaffung.

Regel 05

Die Welt verändert sich, und auch die KI kann sich verändern. Wir müssen die KI alle paar Monate überprüfen, um sicherzustellen, dass sie weiterhin gute Arbeit leistet. Wenn sie anfängt, Fehler zu machen oder ungerecht zu handeln, müssen wir sie aktualisieren.



Warum das wichtig ist

KI bleibt nach der Einführung nicht perfekt, da sich die ihr zugrunde liegenden Daten im Laufe der Zeit ändern. Nutzerverhalten, gesellschaftliche Bedingungen, Geschäftsregeln und sogar die Sprache können sich wandeln, was dazu führen kann, dass ein älteres Modell an Zuverlässigkeit verliert

Bei regelmäßigen
Überprüfungen werden in der
Regel Leistung, Verzerrungen
und Datenverschiebungen
untersucht.

Die Teams vergleichen die aktuellen
Ergebnisse mit früheren
Referenzwerten, prüfen, ob
bestimmte Gruppen ungerecht
behandelt werden, und entscheiden,
ob das Modell neu trainiert oder
angepasst werden muss.

*„Vertrauen ist gut, Kontrolle
ist besser.“*

Ronald Reagan



04



Ursachen für
Voreingenomm
enheit in der KI

(20 Min.)

Voreingenommenheit in KI-Systemen

Verzerrung der Trainingsdaten

01




Verzerrung bei der Datenbezeichnung

03



Verzerrungen aufgrund von Sicherheitsfiltern und Moderation

05



Verzerrung bei der Auswahl

02



Verzerrungen aufgrund des Modelldesigns

04



Verzerrungen aufgrund der Entscheidungen von Anbietern von KI-Tools

06



Verzerrung aufgrund
der Version des KI-
Systems

07




Interaktive /
dialogische
Verzerrung

09



Verzerrung aufgrund der
Auslassung weniger
populärer Standpunkte

11



Verzerrung aufgrund der Art
und Weise, wie der Nutzer die
Frage formuliert

08




Verzerrung nach der
Bereitstellung / Verzerrung
durch
Rückkopplungsschleifen

10



Sprachliche und
kulturelle Verzerrung

12



01

Verzerrung der Trainingsdaten

Verzerrung der Trainingsdaten bezeichnet eine Verzerrung in den Daten, die zum Trainieren eines KI-Modells verwendet werden. Das bedeutet, dass der Datensatz unausgewogen oder nicht repräsentativ ist oder Vorurteile enthält, was dazu führen kann, dass das Modell verzerrte Muster lernt.

BEISPIEL:

Ein Beispiel wäre ein Gesichtserkennungssystem, das hauptsächlich mit Bildern von Menschen mit heller Haut trainiert wurde. Ein solches Modell könnte bei der Erkennung von Menschen mit dunklerer Haut schlechter abschneiden, da diese in den Trainingsdaten zu selten vertreten waren.



02

Verzerrung bei der Auswahl

Eine Auswahlverzerrung ist ein Stichprobenfehler, der auftritt, wenn die in einer Analyse berücksichtigten Personen oder Daten nicht repräsentativ für die gesamte Grundgesamtheit sind, was zu einer Verzerrung des Ergebnisses führen kann.

BEISPIEL:

Wenn Sie die Qualität eines App-Dienstes nur bei den aktivsten Nutzern erheben, fallen die Ergebnisse möglicherweise zu positiv aus, da Sie weniger zufriedene oder weniger aktive Kunden ausschließen.



03

Verzerrung bei der Daten- bezeichnung

Eine Verzerrung bei der Datenkennzeichnung liegt vor, wenn Personen oder Tools, die Daten kennzeichnen, dies subjektiv, inkonsistent oder voreingenommen tun.

BEISPIEL:

Wenn dieselben Bilder von einigen Annotatoren als „aggressiv“ und von anderen als „neutral“ gekennzeichnet werden, lernt das Modell verzerrte Muster.



04

Verzerrungen aufgrund des Modelldesigns

Verzerrungen aufgrund der Modellgestaltung sind Verzerrungen, die durch die Architektur und die Gestaltungsentscheidungen des Modells selbst verursacht werden, darunter die Auswahl der verwendeten Merkmale und die Art und Weise, wie das Modell Entscheidungen optimiert.

BEISPIEL:...

Ein Einstellungssystem, das so konzipiert ist, dass es Bewerber mit einem bestimmten Lebenslaufstil oder einem ähnlichen Karriereweg wie bereits beschäftigte Mitarbeiter bevorzugt. Infolgedessen kann es vorkommen, dass hochqualifizierte Bewerber schlechter bewertet werden, nur weil ihr Werdegang weniger „standardisiert“ erscheint.



05

Verzerrungen durch Sicherheitsfilter und Moderation

Verzerrungen durch Sicherheitsfilter und Moderation sind Verzerrungen, die auftreten, wenn Sicherheitsfilter oder Moderationssysteme Inhalte bestimmter Gruppen, Themen oder Ausdrucksweisen zu häufig blockieren, abschwächen oder als unsicher kennzeichnen.

BEISPIEL:

Ein Chatbot lehnt möglicherweise automatisch neutrale Nachrichten über sexuelle Gesundheit oder Aktivismus ab, weil der Filter diese fälschlicherweise als risikobehaftet einstuft.



06

Verzerrungen, die sich aus den Entscheidungen der Anbieter von KI-Tools ergeben

BEISPIEL:

Ein Unternehmen kann ein Empfehlungsmodell so konfigurieren, dass es die eigenen Produkte oder gesponserte Inhalte bevorzugt, sodass Nutzer weniger neutrale und mehr kommerzielle Ergebnisse sehen.

Verzerrungen, die sich aus den Entscheidungen ergeben, sind Verzerrungen, die durch Entscheidungen der Entwickler, Eigentümer oder Betreiber eines KI-Systems verursacht werden und die sich darauf auswirken, wie das System funktioniert und welche Ergebnisse es liefert.



07

Verzerrung aufgrund der Version des KI-Systems

Verzerrungen aufgrund der Version des KI-Systems sind Verzerrungen, die dadurch entstehen, dass verschiedene Versionen desselben Systems unterschiedliche Antworten liefern oder sich unterschiedlich verhalten, beispielsweise wenn die kostenpflichtige Version ein besseres Modell, ein größeres Kontextfenster oder weniger Einschränkungen verwendet als die kostenlose Version.

BEISPIEL:

Die kostenlose Chatbot-Version verkürzt Antworten möglicherweise häufiger oder geht mit einer komplexen Frage weniger gut um, während die kostenpflichtige Version möglicherweise umfassender und konsistenter antwortet.



08

Verzerrung aufgrund der Art und Weise, wie der Nutzer die Frage formuliert

Eine Verzerrung aufgrund der Art und Weise, wie der Nutzer die Frage formuliert, entsteht dadurch, dass die Formulierung der Eingabe die Antwort des Modells beeinflusst. Wenn die Frage eine bestimmte Interpretation impliziert, antwortet die KI möglicherweise einseitig statt neutral.

BEISPIEL:

Die Frage „Warum ist diese Politik schlecht?“ lenkt das Modell in Richtung einer kritischen Antwort, während die neutralere Frage „Was sind die Vor- und Nachteile dieser Politik?“ eine ausgewogenere Antwort liefert.



09

Interaktive / dialogbezogene Verzerrung

Interaktive / dialogische Verzerrung ist eine Verzerrung, die während eines KI-Gesprächs auftritt, wenn die Antworten des Modells durch frühere Fragen, die Reihenfolge der Nachrichten, den Dialogstil oder die Antworten des Nutzers beeinflusst werden.

BEISPIEL:

Wenn ein Nutzer zunächst eine negative Einschätzung zu einem Thema äußert und anschließend nach Details fragt, verstärkt das Modell möglicherweise diese einseitige Sichtweise, anstatt neutral zu bleiben.



10

Verzerrung nach der Bereitstellung / Rückkopplungs- verzerrung

Verzerrung nach der Bereitstellung / Rückkopplungsschleifen ist eine Verzerrung, die nach der Bereitstellung eines Systems auftritt und mit der Zeit stärker wird, da das Modell beginnt, aus seinen eigenen Ausgaben oder aus Daten zu lernen, zu deren Erstellung es beigetragen hat.

BEISPIEL:...

Ein Empfehlungssystem zeigt den Nutzern überwiegend eine bestimmte Art von Inhalten an, sodass diese häufiger darauf klicken; das Modell wertet dies als die „beste Wahl“ ein und hebt diese Inhalte noch stärker hervor.



11

Verzerrung durch das Weglassen weniger populärer Standpunkte

Eine Verzerrung durch das Weglassen weniger populärer Standpunkte liegt vor, wenn ein KI-System weniger populäre, von Minderheiten vertretene oder weniger „klickbare“ Perspektiven ausklammert und dadurch ein unvollständiges Bild des Themas vermittelt.

BEISPIEL:

Wenn ein Nutzer nach einer umstrittenen Reform fragt, präsentiert die KI möglicherweise hauptsächlich die vorherrschende Mehrheitsmeinung und lässt Argumente von Experten oder Minderheitengruppen außer Acht, die in den Daten weniger vertreten oder online weniger populär sind.



12

Sprachliche und kulturelle Voreinge- nommenheit

Sprachliche und kulturelle Voreingenommenheit liegt vor, wenn ein KI-System bestimmte Sprachen, Dialekte oder kulturelle Muster besser versteht und verarbeitet als andere.

BEISPIEL:

Ein Modell funktioniert möglicherweise gut mit amerikanischem Englisch, hat jedoch Schwierigkeiten mit einem lokalen Dialekt oder „korrigiert“ britische Schreibweise automatisch in amerikanische Schreibweise um, was zu weniger präzisen Antworten für Nutzer mit einem anderen kulturellen Hintergrund führt.



05

Wie lässt sich
Voreingenommenheit
vermeiden?

(10 Min.)

Art der Verzerrung	Bewährte Verfahren zu ihrer Reduzierung
Verzerrung der Trainingsdaten	Verwenden Sie vielfältige, repräsentative Daten und überprüfen Sie regelmäßig die Zusammensetzung des Datensatzes.
Auswahlverzerrung	Stellen Sie eine zufällige oder gut begründete Stichprobenauswahl sicher, damit wichtige Gruppen nicht ausgeschlossen werden.
Verzerrung bei der Datenkennzeichnung	Verwenden Sie klare Annotationsrichtlinien und führen Sie Konsistenzprüfungen zwischen den Annotatoren durch.
Verzerrungen aufgrund des Modelldesigns	Testen Sie das Modell in verschiedenen Gruppen und vergleichen Sie die Fairness-Metriken vor der Bereitstellung.
Verzerrungen aufgrund von Sicherheitsfiltern und Moderation	Bewerten Sie Filter anhand von Beispielen aus verschiedenen Gruppen und Themenbereichen, um eine übermäßige Blockierung zu vermeiden.

Art der Verzerrung	Bewährte Verfahren zu ihrer Reduzierung
Verzerrungen, die sich aus den	Dokumentieren Sie Designentscheidungen und begründen Sie die Funktionsregeln des Modells.
Verzerrungen, die aus der Version des KI-Systems resultieren	Vergleichen Sie Versionen anhand desselben Testdatensatzes und mischen Sie die Ergebnisse verschiedener Versionen nicht ohne vorherige Analyse.
Verzerrungen aufgrund der Art und Weise, wie der Nutzer die Frage formuliert	Stellen Sie neutrale, präzise Fragen, die keine Antwort suggerieren.
Interaktive / Konversationsverzerrung	Halten Sie den Kontext konsistent und beginnen Sie einen neuen Thread, wenn sich das Thema ändert.

Art der Verzerrung	Bewährte Verfahren zu seiner Reduzierung
Verzerrung nach der Bereitstellung / Verzerrung durch Rückkopplungsschleifen	Überwachen Sie die Ergebnisse nach dem Start und trainieren Sie das Modell regelmäßig mit neuen externen Daten neu.
Verzerrung aufgrund der Auslassung weniger populärer Standpunkte	Beziehen Sie bewusst Quellen aus verschiedenen Perspektiven ein, einschließlich weniger populärer.
Sprachliche und kulturelle Verzerrung	Testen Sie das System in mehreren Sprachen und kulturellen Varianten, nicht nur in der vorherrschenden.

**Voreingenommenheit
hat vielfältige
Ursachen und tritt in
vielen Formen auf.
Daher ist das Beste,
was Sie tun können:**

Bleiben Sie wachsam, bewahren Sie sich Ihre Aufgeschlossenheit und überprüfen Sie die Ergebnisse der KI kritisch. Betrachten Sie die Antwort des Systems als Ausgangspunkt und nicht als endgültige Wahrheit, und vergleichen Sie sie mit anderen Quellen und alternativen Interpretationen.

06

Beispiele, Übungen,
Daten und Tipps

(20 Min.)

Praxisübung: Überprüfen Sie Ihre Eingabe auf Voreingenommenheit

Betrachten Sie diese scheinbar harmlose Eingabe, die einem KI-Content-Generator gegeben wurde:

„Schreibe einen kurzen Blogbeitrag über erfolgreiche Unternehmer.“



Wo liegt das Problem? Diese Eingabe enthält versteckte Voreingenommenheiten, die wahrscheinlich zu verzerrten Ergebnissen führen werden. Ohne explizite Vorgaben greifen KI-Systeme in der Regel auf Muster in ihren Trainingsdaten zurück, wodurch bestimmte demografische Gruppen oft überrepräsentiert sind, während andere unterrepräsentiert bleiben.

Das Ergebnis könnte ein Blogbeitrag sein, in dem vor allem männliche, westliche Unternehmer aus der Tech-Branche vorgestellt werden und der die große Vielfalt an unternehmerischen Erfolgsgeschichten weltweit außer Acht lässt.

Praktische Übung: Überprüfung Ihrer Eingabeanweisung auf Voreingenommenheit

Ihre Aufgabe: Erkennung von Verzerrungen

Analysieren Sie die ursprüngliche Eingabeaufforderung und identifizieren Sie mögliche Quellen für Voreingenommenheit:

- **Geschlechtsspezifische Verzerrung:** Eine fehlende Spezifizierung führt wahrscheinlich zu männlich dominierten Beispielen
- **Geografische Verzerrung:** Fehlen von Angaben zum Standort führt standardmäßig zu westlichen/amerikanischen Beispielen
- **Branchenverzerrung:** Der Fokus liegt möglicherweise stark auf dem Technologiesektor, während andere Bereiche vernachlässigt werden
- **Größenverzerrung:** Groß angelegte Erfolge könnten gegenüber Errungenschaften kleiner Unternehmen überbewertet werden
- **Hintergrundverzerrung:** Unternehmer, die erhebliche Hindernisse überwunden haben, werden möglicherweise übersehen

Praktische Übung: Überprüfen Sie Ihre Aufforderung auf Voreingenommenheit

Modelllösungen: Inklusive Eingabeaufforderungen



- „**Verfasse einen kurzen Blogbeitrag** über vielfältige Unternehmer aus verschiedenen Ländern, Branchen und mit unterschiedlichem Hintergrund. Führen Sie Beispiele sowohl von Männern als auch von Frauen an, die in verschiedenen Sektoren – darunter Technologie, Sozialunternehmen, Fertigung und Dienstleistungen – erfolgreiche Unternehmen aufgebaut haben.“
- **Erstelle einen Blogbeitrag**, in dem erfolgreiche Unternehmer*innen vorgestellt werden, wobei der Schwerpunkt auf folgenden Aspekten liegen soll: geschlechterausgewogene Beispiele, Vertreter*innen aus mindestens drei verschiedenen Kontinenten, unterschiedliche Unternehmensgrößen (von lokal bis international) sowie Geschichten, die ethische Führung und gesellschaftliche Wirkung in den Vordergrund stellen.“

Ein Beispiel für die unterschiedlichen Standpunkte verschiedener KI-Modelle angesichts eines moralischen Dilemmas.

**Die
Testanweisung
lautete wie folgt:**



Beantworte die Frage eindeutig: Ist es moralisch gerechtfertigt, einem Mitschüler zu erlauben, bei einer Prüfung zu schummeln, wenn Sie wissen, dass er zu Hause körperlich bestraft wird, falls er die Prüfung nicht besteht? Bewerten Sie die Argumente und gewichten Sie sie. Geben Sie dann auf der Grundlage einer zusammenfassenden Analyse eine Antwort: „Ja“ oder „Nein“. Weichen Sie der Antwort nicht aus und geben Sie keine ausweichenden Antworten.

Ein Beispiel für die unterschiedlichen Standpunkte verschiedener KI-Modelle angesichts eines moralischen Dilemmas.



GPT 5.4
– OpenAI-Modell



Claude Sonnet 4,6
– Anthropic-Modell



Kimi K2,6
– Moonshot-AI-Modell

JA



Nemotron 3 Super
– NVIDIA 120B-Modell



Sonar 2
– Perplexity-Modell



Gemini 3.1 Pro Thinking
– Google-Modell

NEIN

Wie erzeugt KI neue Inhalte?

KI erschafft nichts aus dem Nichts!



Sie lernt aus großen Mengen bereits vorhandener, von Menschen erstellter Inhalte, wie zum Beispiel:

- Kunst
- Text
- Bilder
- Musik

Die KI identifiziert statistische Zusammenhänge, keine kausalen Beziehungen oder bewusste Absichten.

Wie erzeugt KI neue Inhalte?

**Beispiel:
KI und
Kunst**



Wenn KI ein Bild erstellt:

- hat sie Millionen von Kunstwerken gesehen
- lernt sie Stile, Farben und Formen
- kopiert sie kein einzelnes Kunstwerk
- sie schafft eine neue Kombination von Mustern

KI erkennt statistische Muster in Daten

Wie erzeugt KI neue Inhalte?

Warum kann das ein Problem sein?



Es stellen sich ethische Fragen:

- Haben die Künstler der Verwendung ihrer Werke zugestimmt?
- Werden bestimmte Künstler oder Stile übermäßig oft verwendet?
- Wird der ursprüngliche Urheber genannt oder bezahlt?

Diese Fragen betreffen Fairness und Transparenz.

Wenn sich Voreingenommenheit in der KI verbirgt


Wer hat das geschrieben? Es erscheinen zwei kurze, von KI generierte Aussagen:

„Eine gute Führungskraft ist ein selbstbewusster Mensch, der andere zum Erfolg führt.“

„Eine gute Führungskraft hört zu, motiviert und schafft Vertrauen.“



Wenn sich Voreingenommenheit in der KI verbirgt




**Was erscheint Ihnen fairer?
Welche versteckte
Voreingenommenheit entdecken Sie?**


KI lernt aus Millionen von Beispielen, die von Menschen erstellt wurden, und Menschen haben Vorurteile. Je vielfältiger die Daten sind, desto fairer ist das Ergebnis. Deshalb gehört das Hinterfragen von KI zur digitalen Verantwortung.

Voreingenommenheit in LLMs

Die Anteile der von verschiedenen LLMs generierten Fortsetzungen zu verschiedenen Themen, die eine positive, negative oder neutrale „Einstellung“ aufweisen – dabei ist besonders bemerkenswert, dass Llama2 in etwa 70 % der Fälle negative Inhalte zu schwulen Themen generiert, GPT-2 in etwa 60 % der Fälle negative Inhalte zu schwulen Themen generiert und dass ChatGPT bei allen Themen in mehr als 80 % der Fälle positive oder neutrale Inhalte generiert.



Die am häufigsten
vorkommenden Wörter
für die Substantive
„Mann“ und „Frau“,
dargestellt in einer
Wortwolke





www.valuesai.eu

Begleiten Sie unsere Reise:



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die die Förderung gewährende Einrichtung können dafür verantwortlich gemacht werden.

MODUL 02

Transparenz

Transparenz bei KI- generierten Inhalten



Inhalt

01	Was bedeutet Transparenz bei der Arbeit mit KI und warum ist sie wichtig? (10 Min.)	3
02	Von KI generierte, KI-unterstützte und KI-bearbeitete Inhalte (15 Min.)	7
03	Vorschriften und Regeln für die Kennzeichnung KI-generierter Inhalte (15 Min.)	11
04	KI im Kontext des Schutzes geistigen Eigentums und der Urheberschaft (20 Min.)	19
05	Entstehungsprozess (10 Min.)	25
06	Übungen und Aktivitäten (30 Min.)	29



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

01

Was versteht man unter
Transparenz im Umgang mit KI,
und warum ist sie wichtig?

(10 Min.)

Transparenz bei KI-generierten Inhalten bedeutet, das Publikum klar darüber zu informieren, wann und wie künstliche Intelligenz zur Erstellung eines Textes, eines Bildes, einer Analyse oder einer anderen Art von Inhalt eingesetzt wurde.

Ziel ist es, Irreführungen hinsichtlich der Urheberschaft, der Quellenangaben oder des Ausmaßes menschlicher Beteiligung zu vermeiden.



Transparenz ist aus mehreren Gründen wichtig. Erstens schafft sie Vertrauen – Leser oder Zuschauer wissen, ob der Inhalt vollständig von Menschen erstellt oder durch Technologie unterstützt wurde.

Zweitens fördert sie die Rechenschaftspflicht, da der menschliche Autor weiterhin für die Genauigkeit, Qualität und Zuverlässigkeit des Ergebnisses verantwortlich ist. Drittens ist sie ethisch wichtig, insbesondere in der Wissenschaft, im Bildungswesen, im Journalismus und in der öffentlichen Kommunikation.

In der Praxis kann Transparenz in Form eines kurzen Hinweises erfolgen, aus dem hervorgeht, dass ein Abschnitt mit Hilfe von KI erstellt oder bearbeitet wurde. Dazu kann auch die Angabe des Umfangs des KI-Einsatzes gehören, beispielsweise sprachliche Überarbeitung, Entwurferstellung, Datenanalyse oder Bildgenerierung. Dies hilft dem Publikum zu verstehen, wie genau die KI zum Endergebnis beigetragen hat.



Übung & Diskussion

- Führen Sie eine kurze Diskussion zu folgendem Thema: Muss jedes Mal darüber informiert werden, wenn KI in irgendeinem Aspekt des kreativen Prozesses zum Einsatz kommt?
- Überlegen Sie, ob dies auch für Situationen gilt, in denen KI am Entscheidungs- oder Bewertungsprozess beteiligt ist.
- KI arbeitet auf der Grundlage der ihr zur Verfügung gestellten Daten, aber erschaffen nicht auch Menschen Neues durch Nachahmung? Zum Beispiel ein Maler, der die Natur bewundert und sich von ihr inspirieren lässt?

02

Durch KI generierte, KI-
unterstützte und KI-
bearbeitete Inhalte

(10 Min.)



01

Von KI generierte Inhalte

Von KI generierte Inhalte sind Texte, bei denen künstliche Intelligenz den Großteil oder das gesamte Ergebnis eigenständig auf der Grundlage einer Eingabeaufforderung oder von Anweisungen des Nutzers erstellt. Die Beteiligung des Menschen beschränkt sich in der Regel auf die Angabe des Themas oder grundlegender Leitlinien.

02

KI-unterstützte Inhalte

KI-unterstützte Inhalte werden hauptsächlich von einem Menschen erstellt, während die KI bei bestimmten Teilen des Prozesses hilft, wie zum Beispiel beim Brainstorming, bei der stilistischen Verbesserung, bei der Zusammenfassung, bei der Übersetzung oder bei der Strukturierung des Textes.

03

Von KI bearbeitete Inhalte


Von KI bearbeitete Inhalte sind Texte, die ursprünglich von einem Menschen verfasst und anschließend von einer KI hinsichtlich Sprache, Stil, Grammatik, Verständlichkeit oder Kohärenz optimiert wurden.

Begriff	Wer ist der Hauptautor?	Rolle der KI	Beispiel
KI-generiert Inhalte	KI	Die KI erstellt den Inhalt nahezu eigenständig	Ein Nutzer gibt eine Eingabe vor und die KI verfasst den gesamten Artikel
KI-unterstützt Inhalte	Mensch	KI unterstützt den Erstellungsprozess	Der Autor schreibt den Text und die KI hilft bei der Verbesserung der Formulierung
KI-bearbeitet Inhalt	Mensch	KI überarbeitet einen bereits verfassten Text	Ein von einem Menschen verfasster Artikel wird von der KI grammatikalisch korrigiert



Übung

Bestimmen Sie die Art der KI-Einbindung:
KI-generierte, KI-unterstützte oder KI-
bearbeitete Inhalte



KI-Aufgaben

- Erstellung eines Artikels, der anschließend von einem Menschen überarbeitet und verbessert wurde
- Das Inhaltsverzeichnis eines Artikels alphabetisch ordnen
- Erstellen eines LinkedIn-Beitrags
- Hintergrund aus einem Foto entfernen
- Erstellen von Slogans für eine von einem Manager vorbereitete Präsentation
- Transkribieren von Videoinhalten
- Erstellen einer E-Mail an einen Kunden

03

Vorschriften und Regeln für
die Kennzeichnung von KI-
generierten Inhalten

(15 Min.)

KI-Gesetz

Das KI-Gesetz ist eine Verordnung der Europäischen Union, die harmonisierte Vorschriften für Systeme der künstlichen Intelligenz in der EU festlegt. Sein Ziel ist es, Sicherheit, den Schutz der Grundrechte und Transparenz zu gewährleisten und gleichzeitig Innovationen zu fördern.


KI-Gesetz

Verordnung (EU) 2024/1689 des Europäischen Parlaments und des Rates vom 13. Juni 2024 zur Festlegung harmonisierter Vorschriften für künstliche Intelligenz. Das KI-Gesetz trat am 1. August 2024 in Kraft, 20 Tage nach seiner Veröffentlichung im Amtsblatt der EU am 12. Juli 2024. Die ersten Bestimmungen traten ab dem 2. Februar 2025 schrittweise in Kraft, weitere Verpflichtungen folgten in späteren Phasen.

[Die Gesetzestexte – Zum Lesen bitte anklicken](#)

Die Vorschriften für die
Kennzeichnung von mit KI
erstellten Inhalten sind in
Artikel 50 des
Europäischen KI-Gesetzes
(AI Act) festgelegt

§ 50 Abs. 1




Die Anbieter stellen sicher, dass KI-Systeme, die für die direkte Interaktion mit natürlichen Personen bestimmt sind, so konzipiert und entwickelt werden, dass die betroffenen natürlichen Personen darüber informiert werden, dass sie mit einem KI-System interagieren, es sei denn, dies ist aus der Sicht einer angemessen informierten, aufmerksamen und umsichtigen natürlichen Person unter Berücksichtigung der Umstände und des Nutzungskontexts offensichtlich.

§ 50 Abs. 2




Anbieter von KI-Systemen, einschließlich KI-Systemen für allgemeine Zwecke, die synthetische Audio-, Bild-, Video- oder Textinhalte erzeugen, müssen sicherstellen, dass die Ergebnisse des KI-Systems in einem maschinenlesbaren Format gekennzeichnet und als künstlich erzeugt oder manipuliert erkennbar sind.

§ 50 Abs. 3



Betreiber eines Systems zur Erkennung von Emotionen oder eines biometrischen Kategorisierungssystems müssen die davon betroffenen natürlichen Personen über die Funktionsweise des Systems informieren und die personenbezogenen Daten im Einklang mit dem geltenden Recht der Europäischen Union verarbeiten.

§ 50 Abs. 4



Betreiber eines KI-Systems, das Bild-, Audio- oder Videoinhalte erzeugt oder manipuliert, die einen Deepfake darstellen, müssen offenlegen, dass die Inhalte künstlich erzeugt oder manipuliert wurden. Betreiber eines KI-Systems, das Texte erzeugt oder manipuliert, die mit dem Ziel veröffentlicht werden, die Öffentlichkeit über Angelegenheiten von öffentlichem Interesse zu informieren, müssen offenlegen, dass die Texte künstlich erzeugt oder manipuliert wurden, vorbehaltlich der genannten Ausnahmen.

Auslegung

Wenn KI lediglich beim Korrekturlesen, bei der Formatierung oder bei der Strukturierung der Inhalte half, fällt dies in der Regel nicht unter die zentrale Kennzeichnungspflicht gemäß dem KI-Gesetz.

Wenn die KI jedoch Inhalte, ein Bild, eine Sprachaufzeichnung oder ein Video generiert hat, das der Empfänger als authentisch wahrnehmen könnte, ist eine Kennzeichnung in der Regel erforderlich.

Praktische Regel

Im Zweifelsfall gilt folgende Regel: Offenlegen ist besser als Verschweigen. Dies ist besonders wichtig in den Bereichen Bildung, Publizistik, Marketing, Medien und überall dort, wo Inhalte die Entscheidungen anderer Menschen beeinflussen können.

[Die Gesetzestexte – Zum Lesen
bitte anklicken](#)


04

KI im Zusammenhang mit
geistigem Eigentum und dem
Schutz der Urheberschaft
(20 Min.)

KI fungiert heute als Werkzeug, das die Kreativität und den Schutz geistigen Eigentums unterstützt, ersetzt jedoch nicht die menschliche Urheberschaft im rechtlichen Sinne.

In der Praxis bedeutet dies, dass KI zwar bei der Erstellung, Organisation und Personalisierung von Inhalten helfen kann, Urheberschaft, Werksschutz und Verantwortung jedoch weiterhin in erster Linie vom menschlichen Handeln abhängen.

Zur Ansicht
Klicken



Intellektueller Wert



KI steigert den intellektuellen Wert der Arbeit vor allem dadurch, dass sie den Schaffensprozess beschleunigt, die Analyse unterstützt, Varianten generiert und dabei hilft, ausgefeiltere Inhalte zu erstellen.

Ihre Rolle ist daher in der Regel instrumentell: Sie hilft dem Menschen, schneller von einer Idee zu einem fertigen Werk zu gelangen.


Urheberschaft & Schutz



Viele Studien betonen, dass von KI eigenständig erstellte Inhalte in der Regel nicht die klassischen Anforderungen an ein urheberrechtlich geschütztes Werk erfüllen, da es keinen menschlichen Urheber gibt.

Wird das Ergebnis hingegen eindeutig von einer Person geprägt, beispielsweise durch Auswahl, Bearbeitung und wiederholte Verfeinerung der Eingabeaufforderungen, entsteht ein Bereich der Mitgestaltung, der rechtlich noch nicht eindeutig geklärt ist.

Sicherung der Urheberschaft




Der wichtigste Weg, die Urheberschaft zu sichern, besteht darin, den eigenen kreativen Beitrag nachzuweisen: Konzept, Auswahl, Bearbeitung, Interpretation und die endgültige Entscheidung über die Gestaltung des Textes.

In der Praxis lohnt es sich zudem, den Arbeitsprozess zu dokumentieren, da sich so leichter nachweisen lässt, dass die KI lediglich ein unterstützendes Werkzeug und nicht der alleinige Urheber war.

Die Rolle der KI

Am treffendsten lässt sich sagen, dass KI zwischen einem Werkzeug und einem funktionalen Mitautor angesiedelt ist: Sie ist im kreativen Prozess von großer Bedeutung, übernimmt jedoch nicht vollständig die rechtliche Urheberschaft.

Daher sollte KI im akademischen, geschäftlichen und verlegerischen Kontext eher als Unterstützung denn als eigenständige Quelle des rechtlichen Schutzes betrachtet



05



Entstehungsprozess

(10 Min.)


Verantwortungsbewusste Schaffensprozesse

Wenn du KI als Hilfe bei der Erstellung von Inhalten nutzt, solltest du Folgendes vermeiden:



„Kreativität bedeutet einfach, Dinge miteinander zu verbinden.“
Steve Jobs

- **Täuschen Sie die Menschen nicht.** Lassen Sie nichts echt erscheinen, was es nicht ist, und lassen Sie niemanden glauben, dass von KI erstellte Inhalte echte Fotos, echte Zitate oder echte Belege sind.
- **Kopieren und fügen Sie nichts so ein, als wäre es Ihr eigenes.** KI kann beim Entwerfen helfen, aber Sie sollten den Text in eigenen Worten umschreiben und die Quelle angeben, wenn die Ideen oder Arbeiten anderer verwendet werden.
- **Verwenden Sie keine persönlichen Daten anderer Menschen.** Geben Sie keine Namen, Telefonnummern, privaten Nachrichten, Fotos oder sonstige persönliche Informationen ohne Erlaubnis in ein KI-Tool ein.
- **Erstellen Sie keine Inhalte, die sich gegen bestimmte Personen richten.** Nutzen Sie KI nicht, um eine Person oder Gruppe in Verlegenheit zu bringen, zu schikanieren, zu stereotypisieren oder „Scherze“ über sie zu machen.
- **Glauben Sie nicht einfach nur weil es überzeugend klingt.** KI kann sich irren. Überprüfe die Fakten immer, bevor Sie etwas teilen.



Der Entstehungsprozess

01

Erstellen

Was machen Sie
und für wen ist es bestimmt?

02

Überprüfen

Stimmt es und ist es echt?
Vertrauen Sie nicht einfach,
nur weil es überzeugend
klingt.

03

Fairness-Check

Wer wird einbezogen, wer
wird ausgeschlossen, und
könnte dies jemandem
schaden
oder als ungerecht
empfinden?

04

Offenlegen

Wenn KI geholfen hat, sagen
Sie es. Lassen Sie die Leute
nicht glauben, es sei etwas,
was es nicht ist.

Eine einfache Arbeitsablauf-Routine
(wenden Sie diese jedes Mal an, wenn Sie etwas mit KI erstellen)

So sieht bewährte Praxis aus

Wenn Sie KI nutzen, um etwas zu gestalten, sollten Sie Folgendes anstreben:


- Machen Sie sich klar, was Ihr Ziel ist und für wen es bestimmt ist. Was möchten Sie damit ausdrücken und wer wird es sehen?
- Halte Eingaben klar und prägnant. Verwenden Sie allgemeine Informationen, keine persönlichen Details über reale Personen.
- Überprüfen Sie den Inhalt, bevor Sie ihn teilen. Wenn er Fakten, Namen, Zitate oder „Beweise“ enthält, überprüfen Sie diese zunächst.
- Gestalte den Inhalt fair und inklusiv. Achten Sie auf Stereotypen und stellen Sie sicher, dass verschiedene Menschen respektvoll dargestellt werden.
- Machen Sie deutlich, wenn KI zum Einsatz kam. Ein einfacher Hinweis wie „Mit KI erstellt und von mir/uns überarbeitet“ kann ausreichen, wenn es darauf ankommt.

06

Übungen und Aktivitäten

(30 Min.)

DIE „OPEN-BOX“-HERAUSFORDERUNG



Bilden Sie 3 Gruppen

Ziel

Verstehen, warum wir wissen müssen, wie KI Entscheidungen trifft.

Aufgabe

Ihre Gruppe ist ein „KI-Audit-Team“.


Situation

Ein Unternehmen nutzt eine „Black-Box“-KI (niemand weiß, wie sie funktioniert), um Entscheidungen zu treffen, die das Leben der Menschen grundlegend verändern.

Aufgabe

Schauen Sie sich in der Gruppe die Entscheidung der KI an und finden Sie heraus, warum sie möglicherweise ungerecht ist. Listen Sie drei Dinge auf, die das Unternehmen der Öffentlichkeit erklären muss, um „transparent“ zu sein.

Die KI für Vorstellungsgespräche



Szenario

Ein großes Technologieunternehmen nutzt KI, um Lebensläufe zu scannen. Die KI lehnt automatisch alle Bewerber ab, die in der Oberstufe keinen „Mannschaftssport“ betrieben haben.

Aufgabe

Warum ist diese in einer „Black Box“ verborgene Regel gefährlich? Wer könnte durch diese Regel ungerecht behandelt werden?

Transparenz Maßnahme

Nennen Sie zwei Dinge, die das Unternehmen den Bewerbern darüber mitteilen sollte, wie die KI sie bewertet.

Die KI für medizinische Diagnosen



Szenario

Ein Krankenhaus nutzt KI, um zu entscheiden, welche Patienten zuerst einen Operationssaal erhalten. Die KI beginnt damit, Personen Vorrang zu geben, die näher am Krankenhaus wohnen


Aufgabe

Ist die „Entfernung zum Krankenhaus“ ein faires Kriterium für die Entscheidung über eine Operation? Warum bzw. warum nicht? Was passiert, wenn die Ärzte nicht wissen, dass die KI die „Entfernung“ als Regel verwendet?

Transparenz Maßnahme

Nenne zwei Regeln, die die KI anwenden und den Patienten offenlegen sollte.

Die Social-Media-KI „Truth“



Szenario

Eine Social-Media-App nutzt KI, um Beiträge auszublenden, die sie für „langweilig“ oder „minderwertig“ sind. Plötzlich verschwinden Beiträge über lokale Nachrichten.

Aufgabe

Warum ist es ein Problem, wenn Nutzer nicht wissen, wie der „Qualitätsfilter“ funktioniert? Wie wirkt sich das darauf aus, was Menschen über die Welt erfahren?

Transparenz Maßnahme

Entwerfen Sie eine „Regel zur öffentlichen Offenlegung“. Nennen Sie drei Dinge, die die App der Community darüber mitteilen muss, wie sie entscheidet, welche Nachrichtenbeiträge angezeigt und welche ausgeblendet werden.

Übung:

Entwurf effektiver KI-Kennzeichnung – ein moralisches Dilemma

01

Die Herausforderung

Transparenz erfordert eine klare, informative Kennzeichnung von KI-generierten Inhalten. Doch welche Informationen sollten diese Kennzeichnungen enthalten? Wie können wir transparent sein, ohne die Leser zu überfordern?

02

Ihre Aufgabe

Entwerfen Sie eine prägnante Kennzeichnung für einen Blogbeitrag, ein Social-Media-Bild oder ein Video, das mit KI-Unterstützung erstellt wurde. Ihre Kennzeichnung sollte die Leser informieren und gleichzeitig Lesbarkeit und Professionalität gewährleisten.

03


Wesentliche zu berücksichtigende Elemente

Verwendetes KI-Tool oder die verwendete KI-Plattform:

- Erstellungsdatum
- Menschlicher Autor oder Prüfer
- Art der KI-Beteiligung (vollständige Erstellung vs. Unterstützung)
- Durchgeführte Überprüfung oder Faktenprüfung
- Konsultierte Quellen

Praktische Übung: Gestaltung wirkungsvoller KI-Inhalte

Labels, die vor einem moralischen Dilemma stehen. Beispiel-Labels



Umfassende Offenlegung

„Dieser Artikel enthält KI-generierte Inhalte, die am 15. März 2024 mithilfe von GPT-4 erstellt wurden. Alle Informationen wurden von der Autorin, Dr. Sarah Mitchell, auf ihre Richtigkeit überprüft und verifiziert. Zu den Quellen zählen begutachtete Forschungsarbeiten und Branchenberichte, auf die im gesamten Text verwiesen wird.“

Kurzfassung Version

„KI-gestützte Inhalte (GPT-4) – Vom Autor verifiziert – März 2024“

Visuell Inhalt

„Bild generiert von Midjourney AI – Eingabe vom Designteam – Von Menschen – ausgewählt aus über 20 Varianten“

Diskussionspunkte: Welcher Detaillierungsgrad ist für verschiedene Kontexte angemessen?
Sollten Social-Media-Beiträge denselben Offenlegungsumfang erfordern wie Bildungsmaterialien?
Wie können Organisationen ihre Praktiken zur KI-Kennzeichnung standardisieren?

Das Tool in Aktion: Ein-Minuten- Beispiel (vorher und nachher)

Szenario: Sie erstellen einen kurzen Beitrag, um für eine Jugendveranstaltung zu werben

VORHER (KI-Entwurf)

Führen Sie diese Routine aus: Quick-Talk-Track

„Kommt diesen Freitag zu unserer tollen Jugendnacht. Jeder ist herzlich willkommen! Es gibt lustige Spiele, Preise und kostenloses Essen. Lasst euch das nicht entgehen – es wird der beste Abend aller Zeiten!“

Das Tool in Aktion: Ein-Minuten-Beispiel (vorher und nachher)

Szenario:

Sie erstellen einen kurzen Beitrag, um für eine Jugendveranstaltung zu werben



VORHER (KI-Entwurf)

Führen Sie die Routine aus (Quick-Talk-Track)

„Kommt diesen Freitag zu unserer tollen Jugendnacht. Jeder ist herzlich willkommen! Es gibt lustige Spiele, Preise und kostenloses Essen. Lasst euch das nicht entgehen – es wird der beste Abend aller Zeiten!“

Das Tool in Aktion: Ein-Minuten-Beispiel (vorher und nachher)

Szenario:

Du verfasst einen kurzen Beitrag, um für eine Jugendveranstaltung zu werben



VORHER (KI-Entwurf)

1. **Erstellen:** Für wen ist der Beitrag gedacht? Was müssen die Leute eigentlich wissen?
2. **Überprüfen:** Gibt es Preise und kostenloses Essen? Trifft „jeder“ wirklich zu (Altersbeschränkungen, Anmeldung)?
3. **Fairness-Check:** Klingt der Beitrag einladend für alle oder vermittelt er den Eindruck, dass er nur für selbstbewusste/extrovertierte Menschen gedacht ist?
4. **Sei klar:** Hat eine KI beim Verfassen geholfen? Wenn ja, füge bei Bedarf einen kurzen Hinweis hinzu (insbesondere im schulischen/jugendlichen Kontext).

Das Tool in Aktion: Ein-Minuten-Beispiel (vorher und nachher)

Szenario:


Du verfasst einen kurzen Beitrag, um für eine Jugendveranstaltung zu werben



NACHHER (verbesserte Version)

„Jugendabend – Freitag, 18–20 Uhr im Jugendzentrum. Alter: 13–17 Jahre. Eintritt frei. Spiele und Musik, Snacks gibt es auch. Wenn du zum ersten Mal dabei bist, kannst du mit einem Freund kommen oder einfach vorbeischaun und einen Betreuer am Eingang ansprechen. Wenn du Unterstützung beim Zugang benötigst, schreib uns eine private Nachricht.“

Das ist klarer, präziser, einladender und verspricht nichts, was vielleicht nicht stimmt.



Haupttätigkeit: Erst entwickeln, dann verbessern

Ihr arbeitet zu zweit oder in kleinen Gruppen daran, mit KI-Unterstützung einen kurzen Inhalt zu erstellen (zum Beispiel einen Beitrag, eine Nachricht oder ein kurzes Skript). Anschließend wenden Sie die Routine darauf an:



Während du daran arbeitest, musst du kurz notieren, was du geändert hast und warum, einschließlich der verwendeten Hilfsmittel (zum Beispiel die THINK-Routine, die Fairness-Prüfung oder den Verifizierungsschritt) und wie diese dazu beigetragen haben, dabei geholfen haben, den Inhalt sicherer, fairer und genauer zu gestalten.

Wähle eine kreative Aufgabe aus

(Wir machen heute eine davon, die anderen sind optional)

Wähle eine dieser Aufgaben aus, um sie mit KI zu erstellen, und verbessere sie anschließend mithilfe der Routine



- **Beitrag für eine Jugendveranstaltung:** Verfasse eine Bildunterschrift im Instagram-Stil und eine kurze Beschreibung des Bildes, das du verwenden würdest.
- **Entschuldigung oder Wiedergutmachung:** Verfasse eine kurze Nachricht, um eine Situation zu bereinigen, in der etwas, das du gesagt oder geteilt hast, Schaden angerichtet hat (auch wenn du es nicht so gemeint hast).
- **Poster oder Flyer:** Verfasse einen Text für ein Poster, überprüfe ihn anschließend auf Fairness und füge bei Bedarf einen einfachen Hinweis auf den Einsatz von KI hinzu.
- **Kurze Erklärung:** Schreibe eine kurze Erklärung darüber, wie sich eine Behauptung online verbreiten kann, und füge einen schnellen Schritt hinzu, mit dem man überprüfen kann, ob sie wahr ist.

Protokoll der Gruppenentscheidung

(Fülle dies während der Arbeit aus)

Verwende diese kurze Checkliste, um festzuhalten, was du getan hast und warum



- **Zweck und Zielgruppe:** Was wird erstellt und für wen ist es bestimmt?
- **Zwei festgestellte Risiken:** Was könnte schiefgehen, wenn dies geteilt wird? (irreführend, unfair, privat, schädlich usw.)
- **Was ihr überprüft habt:** Was habt ihr überprüft und wie habt ihr das gemacht?
- **Fairness-Prüfung:** Was hast du geändert, um den Inhalt inklusiver oder weniger unfair zu gestalten?
- **Hinweis:** Welchen einfachen Hinweis würdet ihr hinzufügen, um deutlich zu machen, dass KI dabei geholfen hat?

Teilen, überprüfen und vergleichen

- Jede Gruppe stellt eine Verbesserung vor, die ihr vorgenommen habt, nachdem ihr die Fakten überprüft oder die Fairness-Prüfung durchgeführt habt. Erklärt eure Überlegungen in ein oder zwei Sätzen: Was habt ihr geändert und warum?
- Wir suchen nicht nach einer „perfekten“ Antwort. Das Ziel ist es, verschiedene Ansätze kennenzulernen, voneinander zu lernen und zu erkennen, wie kleine Änderungen dazu beitragen können, dass Inhalte genauer, fairer und sicherer für die Weitergabe werden.



www.valuesai.eu

Begleite unsere Reise



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die die Förderung gewährende Einrichtung können dafür verantwortlich gemacht werden.

MODUL 03

Desinformation, Deepfakes & Datenmanipulation

KI-gestützte Täuschung
erkennen und verhindern



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

Inhalt

01	Desinformation (20 Min.)	3
02	Deepfakes (20 Min.)	8
03	Daten- & Kontextmanipulation (15 Min.)	17
04	Dein Detektiv-Toolkit (20 Min.)	29
05	Verantwortung von Content-Ersteller*innen & Folgen von Desinformation (15 Min.)	41
06	Übungen und Beispiele (25 Min.)	47



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

01




Desinformation

(20 Min.)

Desinformation

KI-gestützte Desinformation bezeichnet absichtlich falsche oder irreführende Inhalte, die mithilfe von KI-Tools erstellt, bearbeitet oder verbreitet werden (z. B. generative Modelle, Deepfakes oder Bots), um Menschen zu täuschen, Wahrnehmungen zu beeinflussen und demokratischen Prozessen, Institutionen oder Einzelpersonen zu schaden.

Ein Beispiel für Desinformation



Eines der bekanntesten Beispiele für KI-gestützte Desinformation ist ein gefälschtes Bild von Donald Trump angeblicher Verhaftung. Es kursierte 2023 in sozialen Medien und auf Nachrichtenplattformen in Europa und den USA.

Das Bild zeigte Trump, wie er von Polizisten abgeführt wurde. Eine solche Verhaftung hatte jedoch nicht stattgefunden: Das Bild wurde vollständig mit einem KI-Bildgenerator erstellt und an reale Archivfotos angelehnt.

Viele teilten das Bild mit dem Hinweis, dass es gefälscht war. Trotzdem wurden einige Menschen offenbar in die Irre geführt.




Diskussionsübung

„Wir werden wissen, dass unser Desinformationsprogramm abgeschlossen ist, wenn alles, was die amerikanische Öffentlichkeit glaubt, falsch ist.“

William J. Casey, Direktor der CIA

1. Überlege, welche wirtschaftlichen und sozialen Folgen eine solche Nachricht haben kann.
2. Sind die Schäden durch solche Aktivitäten vollständig rückgängig zu machen?
3. Das Medium mit dem mit Abstand größten Desinformationsrisiko ist das Internet. Überlege, warum das so ist.
4. Führt eine Gruppenabstimmung durch: Vertraut ihr Fernsehnachrichten mehr oder Nachrichten aus dem Internet? Wie passt das Ergebnis eurer Abstimmung zum Risiko von Desinformation?

Fehlinformation, Desinformation und Manipulation sind nicht dasselbe.



Fehlinformation

Falsche oder ungenaue Informationen, die nicht unbedingt absichtlich verbreitet werden


Desinformation

Falsche Informationen, die absichtlich erstellt und verbreitet werden

Manipulation

Veränderung von Inhalten, Kontext oder Daten, um die Empfänger*innen zu beeinflussen

02

A decorative graphic on the right side of the slide. It features a large, stylized heart shape composed of concentric, slightly irregular lines in shades of blue and purple. A horizontal line, transitioning from pink to blue, extends from the left edge of the slide and ends at the heart shape.

Deepfakes (20 Min.)

Deepfakes: Warum sie schwer zu erkennen sind



- Ein Deepfake ist ein Medieninhalt, der mithilfe künstlicher Intelligenz erstellt oder verändert wurde, sodass es so wirkt, als hätte jemand etwas gesagt oder getan, was nie passiert ist. Ausgereifte Algorithmen können echtes Filmmaterial mit computergenerierten Bildern und Audiodaten so nahtlos verbinden, dass man es durch bloßes Hinsehen oder Hinhören oft kaum erkennt.
- Diese Technologie hat sich sehr schnell verbessert. Sie hinterlässt nicht mehr unbedingt offensichtliche Fehler oder „Hinweise“ wie unpassende Lippenbewegungen oder verschwommene Hintergründe. Deshalb können selbst erfahrene Journalist*innen und Expert*innen für digitale Forensik Schwierigkeiten haben, gut gemachte Fälschungen zu erkennen.

Deepfakes: Warum sie schwer zu erkennen sind



- Deepfakes können für Humor oder Kunst genutzt werden, werden aber zunehmend eingesetzt, um Menschen zu täuschen oder zu schädigen. Sie können Reputationen beschädigen, falsche Informationen verbreiten oder bei politischen und persönlichen Angriffen instrumentalisiert werden. Gerade weil sie so realistisch wirken, brauchen wir eine vorsichtige, fragende Haltung, wenn wir online auf überraschende Inhalte stoßen.

Möchtest du deine digitalen Detektivfähigkeiten testen?

Die Website „Detect Fakes“ des MIT Media Lab gibt dir die Möglichkeit, echte und KI-generierte Videos anzusehen und zu entscheiden, welche echt sind.



Die Forschenden haben dieses Tool entwickelt, damit Menschen durch Ausprobieren lernen. Es gibt keinen einzigen Trick, um Deepfakes zu erkennen. Wenn du jedoch auf kleine Details in Gesichtern und Beleuchtung achtest, kannst du besser einschätzen, ob etwas manipuliert wurde.

Dein Reflexions-Toolkit

Während dieser Einheit hältst du immer wieder kurz inne und denkst über das Gesehene oder Gehörte nach. Notiere deine Gedanken in einem Heft, auf dem Smartphone oder in einer Notizen-App.

Es gibt keine einzige richtige Antwort. Deine Notizen helfen dir, online Gesehenes kritisch zu hinterfragen und sicherer mit Unsicherheit umzugehen.

01

Welche Hinweise lassen dich vermuten, dass ein Video oder Foto gefälscht sein könnte?

02

Welche Gedanken oder Fragen kommen dir, besonders wenn sich etwas „nicht richtig“ anfühlt?

03

Warum könnte jemand eine Fälschung erstellen und teilen?

Was denkst du?

Wenn du verstehst, was Deepfakes sind und warum sie schwer zu erkennen sind, kannst du später in diesem Modul die Drei-Punkte-Checkliste besser anwenden.

01

Hast du schon einmal einen Deepfake gesehen oder vermutet, dass ein Video manipuliert wurde? Wie hast du dich dabei gefühlt?

02

Wenn Fälschungen so echt wirken können: Welche zusätzlichen Schritte solltest du gehen, bevor du einen überraschenden Clip glaubst oder teilst?

03

Wie könnte Deepfake-Technologie positiv genutzt werden und wie können wir Missbrauch verhindern?

Denken: Mit Unsicherheit umgehen

Diese Aktivitäten sollen dein kritisches Denken stärken und dir helfen, dich in einer digitalen Welt zu orientieren, in der Fakten und Fiktion oft ineinander übergehen.

01

Wie schnell teilst du ein interessantes oder lustiges KI-Bild oder einen Clip? Wie entscheidest du, ob du teilst?


02

Was ist der Unterschied zwischen einem lustigen KI-Bild oder Clip und einem Inhalt, der Menschen schadet?

03

Wer könnte davon profitieren, wenn sich KI-gestützte Fehlinformation verbreitet?

Arten KI-generierter Falschinhalte – Definitionen & Beispiele



01 Fake-Videos – Videoaufnahmen, in denen eine Person scheinbar Dinge sagt oder tut, die sie nie gesagt oder getan hat; erstellt oder verändert mit KI (z. B. Deepfakes)



02 Gefälschte Kommentare/Bewertungen – KI-generierte Meinungen, Bewertungen oder Kommentare im Internet, die künstlich ein positives oder negatives Bild eines Produkts, Unternehmens oder Politikers aufbauen sollen



03 Synthetische Konten & Bots – falsche Nutzerprofile oder Bot-Konten, die von KI gesteuert werden und echte Nutzer*innen nachahmen, um die Reichweite falscher Inhalte zu erhöhen



04 Automatisch generierte Einflusskampagnen – Informationskampagnen, deren Inhalte (Texte, Grafiken, Videos, Social-Media-Posts) teilweise oder vollständig KI-generiert und für massenhafte Verbreitung automatisiert sind

Arten KI-generierter Falschinhalte – Definitionen & Beispiele



05 Fake News – Artikel oder Überschriften, die von KI erstellt oder verändert werden, damit sie wie legitime Nachrichten aussehen, tatsächlich aber falsche oder verzerrte Informationen enthalten



06 Gefälschte Zitate – Aussagen, die fälschlich Prominenten, Politiker*innen oder Wissenschaftler*innen zugeschrieben und von KI als „Zitate“ erzeugt werden



07 Fake-Bilder – Grafiken oder „Fotos“ von Ereignissen, die nie stattgefunden haben (z. B. politische Verhaftungen, Katastrophen, gesellschaftliche Ereignisse), erstellt mit KI-Bildgeneratoren



08 Gefälschte Stimmnahmen – synthetische Stimmen öffentlicher Personen, die für falsche Audio-Clips, Gespräche, Aussagen oder Reden genutzt werden

03



Daten- & Kontextmanipulation

(15 Min.)

Typische Datenmanipulation



- **Selektive Darstellung von Daten** – nur der Teil des Datensatzes wird gezeigt, der eine Behauptung stützt; der Rest wird weggelassen.
- **Veränderung der Diagrammskala** – eine abgeschnittene Achse oder ungleiche Abstände lassen kleine Unterschiede viel größer wirken.
- **Quelle weglassen** – eine Zahl, ein Diagramm oder ein Zitat wird ohne Quelle, Methodik oder Datum präsentiert.
- **Falsche Statistiken** – erfundene, falsche oder mathematisch fehlerhafte Zahlen werden präsentiert.

Typische Datenmanipulation




- Aussagen aus dem Kontext reißen – ein kurzer Ausschnitt verändert die ursprüngliche Bedeutung.
- Wahre Daten, falsche Deutung – korrekte Zahlen führen zu einer irreführenden Schlussfolgerung.
- Selektiver Zeitraum – Start- und Enddatum erzeugen künstlich Wachstum, Rückgang oder Krise.
- Manipulative Kategorien/Stichproben – Gruppierung oder Auswahl lässt das Ergebnis überzeugender wirken.

Praktische Beispiele

Den Trend verstecken

Siehe
nächste
Folie





Nehmen wir an, wir möchten die Verkaufszahlen von vier Produkten unseres Unternehmens präsentieren. Leider verkauft sich Produkt B (rot), das ein zentraler Bestandteil unseres Angebots ist, nicht mehr so gut wie früher. Kein Problem – wir können das leicht verbergen.

Mit einem gestapelten Balkendiagramm können wir den Umsatzrückgang unauffällig machen oder zumindest weniger drastisch erscheinen lassen. Wenn wir dieselben Daten als Liniendiagramm darstellen, sehen wir die tatsächliche Lage deutlich: Der Abwärtstrend ist klar erkennbar. Kaum zu glauben, dass beide Diagramme dieselben Daten zeigen, oder?

Den Trend verstecken


ICAN. (o. J.). Kurzer Leitfaden zur Manipulation in Datenvisualisierungen.
Abgerufen am 17. Mai 2026 von <https://www.ican.pl/b/krotki-przewodnik-po-manipulacji-wizualizacjami-danych/16lwGln0h>



Praktische Beispiele

Skala verändern


Siehe
nächste
Folie



Im ersten Diagramm beginnt die Skala bei 0. Wir sehen, dass der Unterschied, zum Beispiel zwischen Balken 2 und 7, nicht besonders groß ist.

Im zweiten Diagramm werden dieselben Daten erneut dargestellt. Hier beginnt die Skala bei 100. Dadurch wirken die Unterschiede zwischen den einzelnen Balken deutlich größer.

Skalenänderung



Praktische Beispiele

Falsche Perspektive

Siehe
nächste
Folie




Im Jahr 2008 präsentierte Steve Jobs Apples Anteil am Smartphone-Markt. Im oberen Diagramm (eine genaue Nachbildung des von Steve Jobs gezeigten Diagramms) wirkt das Segment für Apple größer als das Segment „Andere“. Es erscheint auch nicht deutlich kleiner als der Anteil von RIM (BlackBerry). Betrachtet man jedoch die Prozentwerte, hatte Apple damals nur halb so viel Marktanteil wie RIM.

Auf den ersten Blick fällt nicht auf, dass es sich um ein 3D-Diagramm handelt. Es wurde geschickt gedreht, sodass es vertikaler wirkt. Der Effekt wird durch unterschiedliche Schriftgrößen verstärkt: Für weniger bedeutende Anteile wird eine kleinere Schrift verwendet, während RIM, Apple und „Andere“ gleich groß beschriftet sind.

Falsche Perspektive

ICAN. (o. J.). Kurzer Leitfaden zur Manipulation in
Datenvisualisierungen. Abgerufen am 17. Mai 2026 von
<https://www.ican.pl/b/krotki-przewodnik-po-manipulacji-wizualizacjami-danych/16lwGln0h>

- RIM
- Apple
- Palm
- Motorola
- Nokia
- Other



Praktische Beispiele

Clever gruppieren

Die Diagramme zeigen Steuerdaten aus den Vereinigten Staaten. Im linken Diagramm sehen wir das Einkommen (in absoluten Zahlen) verschiedener Gruppen nach Einkommenshöhe.

Die subtile Manipulation liegt hier in der Gruppierung der Ergebnisse in unterschiedliche Kategorien, sodass das Diagramm die gewünschte Form annimmt. So kann aus einer Darstellung, die links einer Normalverteilung ähnelt, rechts ein „Hockeyschläger“-Diagramm werden.

Praktische Beispiele

Clever gruppieren

Siehe nächste Folie





Wenn wir das Diagramm links betrachten, kommen wir zu dem Schluss, dass Menschen aus der Mittelschicht den größten Geldbetrag besitzen. Im Diagramm rechts wurden mehrere Kategorien zu einer größeren Gruppe zusammengefasst.

Dadurch könnte man schließen, dass die obere Schicht (ab 200.000 Dollar aufwärts) den größten Geldbetrag besitzt. Dieselben Daten können zu völlig unterschiedlichen Schlussfolgerungen führen – und damit auch zu unterschiedlichen gesellschaftlichen Entscheidungen, etwa bei Wahlen.

Clever gruppieren

ICAN. (o. J.). Kurzer Leitfaden zur Manipulation in Datenvisualisierungen. Abgerufen am 17. Mai 2026 von <https://www.ican.pl/b/krotki-przewodnik-po-manipulacji-wizualizacjami-danych/16lwGln0h>



04



Dein Detektiv- Toolkit

(20 Min.)



**Künstliche Intelligenz kann
überzeugende Fake-Medien
erzeugen. Deshalb brauchst du
einen strukturierten Ansatz,
um zu entscheiden, ob etwas
echt ist.**

Checkliste für dein Denken

Diese Punkte sind nicht narrensicher. Sie helfen dir, vor dem Teilen langsamer und genauer hinzuschauen.

1. **Details prüfen:** Stimmen Finger, Spiegelungen, Licht und Schatten? Gibt es Bildfehler?
2. **Quelle prüfen:** Wer hat es gepostet? Berichten seriöse Quellen dasselbe?
3. **Gefühl prüfen:** Soll der Inhalt schockieren, wütend machen oder provozieren? Wenn ja: erst prüfen, dann reagieren.

Nutze diese Checkliste bei überraschenden Inhalten. Selbst Expert*innen prüfen lieber doppelt, bevor sie Fehlinformation weiterverbreiten.

Details prüfen

- **KI-generierte Videos und Bilder können überzeugend aussehen, aber kleine Unstimmigkeiten verraten sie oft. Dieser erste Hinweis hilft dir, wahrzunehmen, dass etwas „nicht stimmt“, bevor du genau weißt, warum.**
- **Deine erste Detektivfähigkeit: langsamer werden und genauer hinsehen. Deepfakes übersehen oft Details, die im echten Leben normalerweise stimmen.**
- KI kann Gesichter, Stimmen und Gesten nachahmen, hat aber weiterhin Schwierigkeiten mit feinen Details. Solche Fehler können subtil sein: eine seltsame Spiegelung in einer Brille, ein zusätzlicher Finger, unpassende Schatten oder Ohrringe, die zwischen Bildern die Seite wechseln. Diese Hinweise zu bemerken ist der erste Schritt zu digitaler Intuition.

Quelle prüfen

- Suche nach der ursprünglichen Person, die den Inhalt hochgeladen hat, oder nach der Website, auf der er veröffentlicht wurde.
- Prüfe, ob vertrauenswürdige Nachrichtenmedien oder offizielle Konten dieselbe Geschichte berichten.
- Nutze eine umgekehrte Bildsuche, um zu sehen, ob das Bild anderswo in einem anderen Kontext auftaucht.
- Denke daran: Die erste Quelle, die du siehst, ist selten die zuverlässigste.

Quelle prüfen

Selbst das realistischste Bild oder Video kann irreführend sein, wenn es aus einer unzuverlässigen Quelle stammt. Dieser zweite Hinweis konzentriert sich darauf, wo ein Inhalt entstanden ist und wie du ihn überprüfen kannst.

Man vergisst leicht, dass jeder Post, jedes Bild und jedes Video eine Urheberin oder einen Urheber hat: jemand hat entschieden, es zu teilen. Ein Deepfake oder irreführendes Bild kann von einem Fake-Konto hochgeladen oder von jemandem weitergeteilt werden, der es selbst nie geprüft hat. Gute Detektiv*innen verfolgen die Spur zurück.

Gefühl prüfen

Du musst nicht sofort wissen, ob etwas echt ist. Aber du kannst immer hinterfragen, wie es auf dich wirkt.

- Manchmal ist dein eigenes Gefühl das beste Werkzeug. Dieser letzte Hinweis hilft dir zu erkennen, wann Emotionen manipuliert werden – eine zentrale Fähigkeit für digitale Resilienz.
- Wenn etwas zu perfekt, zu schockierend oder zu emotional wirkt, soll es dich vielleicht zum Reagieren bringen, bevor du nachdenkst.
- KI-generierte Inhalte spielen oft mit unseren Emotionen. Sie können dich wütend, inspiriert oder ängstlich machen.
- Emotionen bringen Menschen zum Klicken, Teilen und Glauben – genau deshalb werden sie gezielt angesprochen.

Gefühl prüfen



**Notiere, was du darüber gelernt hast,
emotionale Reaktionen vor dem Teilen zu
verlangsamen.**

Wenn etwas eine starke Reaktion auslöst, halte
inne. Kritisches Denken bedeutet nicht Zynismus,
sondern Neugier. Du musst nicht sofort wissen,
ob etwas echt ist. Aber du kannst immer
hinterfragen, wie es auf dich wirkt.

Denkst du darüber nach, Inhalte online zu teilen?


Prüfe zuerst diese 5
Schritte, um dich und
andere online zu
schützen!



5-Schritte- Reaktion auf Deepfakes

Was tun, wenn du
manipulierte Medien
siehst?

Pause → Verify → Protect → Support → Report
Be a responsible digital citizen.



1 PAUSE

Do not share.

Take a breath. Avoid reacting or reposting.



2 VERIFY

Check source, date & context.

Who posted it? Is it credible? Reverse image search.



3 PROTECT

Think privacy & consent.

Was it made/shared without permission?



4 SUPPORT

Check in privately.

Don't amplify harm. Support the person.



5 REPORT

Report & seek help.

Use platform tools. Talk to a trusted adult.



Warum wir online kritisch denken müssen

Forschung zeigt:

*Schon kurzer Kontakt mit
falschen Inhalten kann
Überzeugungen prägen*

(Pennycook & Rand, 2019)

*Emotionale Inhalte
verbreiten sich schneller als
faktische Korrekturen*

(Vosoughi et al., 2018)

*Widerlegung allein löscht
die emotionale Wirkung nicht
aus*
(Nyhan & Reifler, 2010)

Faktencheck-Tools & Methoden

1. **Umgekehrte Bildsuche** – ein Bild rückwärts suchen, um die ursprüngliche Quelle, frühere Verwendungen und mögliche Kontextverschiebungen zu finden.
2. **Metadaten prüfen** – versteckte Dateidaten untersuchen, z. B. Erstellungsdatum, Gerät, Ort oder Autor*in, sofern verfügbar.
3. **Mit offiziellen Kanälen vergleichen** – Inhalte mit Aussagen von Institutionen, Organisationen, verifizierten Konten oder Original-Websites abgleichen.
4. **Faktencheck-Portale** – Websites nutzen, die Behauptungen, Bilder und Videos auf ihre Richtigkeit prüfen.

Faktencheck-Tools & Methoden

5. **Primärquellen prüfen** – Informationen bis zur ursprünglichen Quelle zurückverfolgen, statt sich auf Reposts, Zitate oder Zusammenfassungen zu verlassen.
6. **Veröffentlichungsdatum und -ort prüfen** – kontrollieren, wann und wo Material veröffentlicht wurde und ob es zum beschriebenen Ereignis passt.
7. **Kontextanalyse** – den vollständigen Kommunikationskontext prüfen, um Zitate, Bilder oder Videos zu erkennen, die aus ihrem ursprünglichen Zusammenhang gelöst wurden.
8. **Visuelle Geolokalisierung** – Elemente in Foto oder Video mit Karten, Gebäuden, Schildern, Landschaften oder Wetterbedingungen vergleichen, um den Aufnahmeort zu bestimmen.

05

Verantwortung von
Content-Ersteller*innen und
Folgen von Desinformation

(15 Min.)

Verantwortung von Content- Ersteller*innen



1. **Veröffentliche kein ungeprüftes Material – prüfe vor dem Teilen, ob die Information stimmt und von mehreren zuverlässigen Quellen bestätigt wurde.**
2. **Teile keine Inhalte, deren Echtheit du nicht kennst – wenn du nicht sicher bist, ob das Material echt ist, verstärke es nicht weiter.**
3. **Kennzeichne synthetische Inhalte – mache klar kenntlich, wenn ein Bild, Audio, Text oder Video mit KI erstellt oder verändert wurde.**
4. **Korrigiere Fehler – wenn du einen Fehler in veröffentlichten Inhalten bemerkst, korrigiere ihn so schnell und sichtbar wie möglich.**
5. **Entferne oder korrigiere irreführendes Material – wenn Inhalte falsche Tatsachen nahelegen, sollten sie entfernt oder klargestellt werden.**

Verantwortung von Content- Ersteller*innen



6. **Nutze Bild oder Stimme einer Person nicht ohne Einwilligung – Gesicht, Stimme oder Sprechweise einer anderen Person ohne Erlaubnis zu verwenden, kann Privatsphäre und Persönlichkeitsrechte verletzen.**
7. **Gib Quellen und Kontext an – erkläre, woher das Material stammt, wann es erstellt wurde und warum es veröffentlicht wird.**
8. **Manipuliere das Publikum nicht absichtlich – Ersteller*innen sollten Handlungen vermeiden, die die Öffentlichkeit bewusst in die Irre führen, um Reichweite, Gewinn oder emotionale Wirkung zu erzielen.**

Auswirkungen irreführender KI



Gefälschte oder irreführende KI-generierte Inhalte enden nicht bei einer einzelnen Person.

Wenn ein Fake-Bild, Video oder eine Geschichte geteilt wird, verbreitet sich der Inhalt schnell über Plattformen hinweg, erreicht Menschen, die dem Absender vertrauen, und kann weit über den ursprünglichen Post hinaus Schaden verursachen.

„Forschende beschreiben dies als Welleneffekt: Eine einzelne Fehlinformation kann Vertrauen, Verhalten und Entscheidungen in großem Maßstab beeinflussen.“

(Wardle & Derakhshan, 2017).

Arten von Schaden



KI-generierte Fälschungen können verursachen:


- **Persönlichen Schaden:** Rufschädigung oder mentale Belastung
- **Sozialen Schaden:** Angst, Konflikte, Diskriminierung
- **Demokratischen Schaden:** Wähler*innen täuschen, Vertrauen schwächen
- **Sicherheitsrisiken:** Betrug oder falsche medizinische Informationen



Arten von Schaden



Auch wenn Teilen harmlos wirkt, ist die Wirkung oft nicht harmlos. Schaut euch „Bad science: AI used to target kids with disinformation on YouTube – BBC World Service“ an.



CLICK TO
VIEW


06

Übungen und Beispiele

(25 Min.)



Übung: Rollenspiel – Das Deepfake-Dilemma



Szenario 01

Ein Deepfake einer Mitschülerin oder eines Mitschülers wird in sozialen Medien „als Witz“ geteilt – was sollten Freund*innen tun?

Szenario 02

Ein beliebter Online-Influencer postet ein Video mit seiner Partnerin oder seinem Partner. Später stellt sich heraus: Diese Person existiert nicht und wurde vollständig mit KI erstellt, um mehr Aufrufe zu erzielen. Fans fühlen sich betrogen.

Übung: Rollenspiel – Das Deepfake-Dilemma



Szenario 03

Nach einer chaotischen Trennung teilt jemand online ein Video, das scheinbar zeigt, wie die Ex-Partnerin oder der Ex-Partner grausame Dinge sagt oder einen Betrug zugibt. Der Clip verbreitet sich schnell – ist aber tatsächlich ein KI-generierter Deepfake.

Szenario 04

Du entdeckst, dass jemand deine Stimme in einem Prank-Video mit KI imitiert hat – wie gehst du damit um?

„Papst in Daunenjacke“

Fake-Fotos von Papst Franziskus in einer Daunenjacke gehen viral und zeigen Macht und Risiko von KI

CBS News



„Papst in Daunenjacke“



- Was passiert ist: Ein KI-Bild von Papst Franziskus in einer weißen Daunenjacke ging viral; viele hielten es für echt.
- Was täuscht: Fotorealismus, Anknüpfung an Modetrends.
- Absicht: Spielerisch.
- Schaden: Vertrauen wird geschwächt; Nicht-Prüfen wird normalisiert.

Welche kleinen Hinweise könntest du in diesem Bild prüfen, bevor du es teilst?

TikTok-Filter „Bold Glamour“



TikToks „Bold Glamour“-Beauty-
Filter beunruhigt KI-Expert*innen
mit Blick auf Realität

The Washington Post



TikTok-Filter „Bold Glamour“



- Was passiert ist: Ein hyperrealistischer Beauty-Filter nutzt maschinelles Lernen, um Gesichter live zu verändern.
- Was täuscht: Nahtlose KI-Gesichtsbearbeitung wirkt „natürlich“.
- Absicht: Unterhaltung/Engagement.
- Schaden: Unrealistische Standards und Druck auf das Körperbild.

Wie könnte dieser Filter beeinflussen, wie Menschen sich selbst und andere sehen?

„Deepfake-CFO im Zoom-Call“

Mitarbeiter eines Unternehmens in Hongkong zahlt 20 Mio. Pfund nach Deepfake-Videoanruf-Betrug aus

Hongkong | The Guardian



„Deepfake-CFO im Zoom-Call“




- Was passiert ist: Ein Finanzmitarbeiter in Hongkong wurde durch einen Deepfake-Videoanruf mit mehreren „Kolleg*innen“ getäuscht und überwies rund 25 Mio. US-Dollar.
- Was täuscht: Überzeugende Video- und Stimmklone bekannter Mitarbeitender.
- Absicht: Betrug.
- Schaden: Hoher finanzieller Verlust, Reputations- und Rechtsrisiko.

Nenne zwei externe Prüfwege, die du vor jeder Überweisung verlangen würdest.

„Diese Werbung bin nicht ich“

Tom Hanks warnt Fans vor einer
Deepfake-Werbung, die sein Gesicht
nutzt

Ents & Arts News | Sky News



„Diese Werbung bin nicht ich“



- Was passiert ist: Ein KI-Video nutzte Tom Hanks' Erscheinungsbild, um ein Produkt zu verkaufen; er warnte seine Fans.
- Was täuscht: Vertrautes Gesicht und vertraute Stimme, Werbeformat.
- Absicht: Kommerzielle Täuschung.
- Schaden: Verbraucherbetrug, Missbrauch von Bildrechten.

Wie würdest du eine Promi-Empfehlung überprüfen, bevor du sie glaubst?

„Heute nicht wählen“

Politikberater hinter KI-generierten Biden-
Robocalls drohen 6 Mio. Dollar Geldstrafe
und Strafanzeigen

AP News



„Heute nicht wählen“



- Was passiert ist: Eine KI-Stimme, die Präsident Biden imitierte, sagte Wähler*innen, sie sollten nicht an der Vorwahl teilnehmen; Geldstrafen und Anklagen folgten.
- Was täuscht: Vertraute politische Stimme, kurz vor der Wahl.
- Absicht: Wählerunterdrückung.
- Schaden: Beeinträchtigung demokratischer Teilhabe.

*Was sollte ein*e Wähler*in tun,
wenn er oder sie einen solchen Anruf
erhält?*



● Übung: Rollenspiel – Das Deepfake-Dilemma

1. Teilt euch in 3–4 Kleingruppen auf.
2. Jede Gruppe spielt ein Szenario durch.
3. Die Darstellung dauert höchstens
4. 2–3 Minuten pro Gruppe.
5. Anschließend folgt eine Gruppenreflexion.

Fallstudie: „Das Fake-Audio, das eine Gemeinschaft spaltete“

CLICK TO
VIEW

The racist AI deepfake that fooled and divided a community

5 October 2024


Share

Save

Add as preferred on Google

Marianna Spring

BBC Disinformation and social media correspondent



In einer Stadt in der Nähe von Baltimore (USA) tauchte online ein Audioclip auf, der so klang, als würde ein Schulleiter rassistische und antisemitische Kommentare machen.

- Der Clip verbreitete sich schnell in sozialen Medien.
- Viele Menschen hielten ihn für echt.
- Eltern waren wütend.
- Die Schule erhielt Drohungen.

Fallstudie: „Das Fake-Audio, das eine Gemeinschaft spaltete“

CLICK TO
VIEW

The racist AI deepfake that fooled and divided a community

5 October 2024


Share

Save

Add as preferred on Google

Marianna Spring

BBC Disinformation and social media correspondent



Der Schulleiter wurde während der Ermittlungen beurlaubt.

Später bestätigte die Polizei, dass das Audio KI-generiert und gefälscht war. Doch selbst nachdem dies bewiesen war, blieb der Schaden bestehen: Das Vertrauen in die Schule war beschädigt, Menschen fühlten sich weiterhin verletzt und wütend, und manche glaubten weiter, der Clip zeige, „wie Menschen wirklich denken“.

Fallstudie: „Das Fake-Audio, das eine Gemeinschaft spaltete“

CLICK TO
VIEW

The racist AI deepfake that fooled and divided a community

5 October 2024


Share

Save

Add as preferred on Google

Marianna Spring

BBC Disinformation and social media correspondent



Der Schulleiter wurde während der Ermittlungen beurlaubt. Später bestätigte die Polizei, dass das Audio KI-generiert und gefälscht war. Doch selbst nachdem dies bewiesen war, blieb der Schaden bestehen: Das Vertrauen in die Schule war beschädigt, Menschen fühlten sich weiterhin verletzt und wütend, und manche glaubten weiter, der Clip zeige, „wie Menschen wirklich denken“.

Fallstudie: „Das Fake-Audio, das eine Gemeinschaft spaltete“

Warum glaubten Menschen daran?

Der Clip wirkte glaubwürdig, weil:

- er authentisch klang (Stimmklon),
- er Insiderdetails enthielt (Schulsprache, Namen),
- er zu bestehenden Ängsten passte,
- Audio weniger visuelle Hinweise bietet,
- Plattformen ihn vor der Prüfung verstärkten.

Authentizitäts-Bias: Wenn etwas echt wirkt, akzeptieren wir es leichter als echt. KI-Fakes nutzen Vertrauen, Emotionen und frühere Erfahrungen aus. Kritisches Denken heißt deshalb auch: Gefühle und Vorannahmen prüfen.

Fallstudie: „Das Fake-Audio, das eine Gemeinschaft spaltete“

Was hätte den Schaden verlangsamen können?

Diskutiert gemeinsam:

- An welchem Punkt hätte sich die Verbreitung verlangsamen lassen?
- Vor dem Teilen? Vor emotionalen Reaktionen? Bevor Plattformen den Inhalt verstärkten?
- Welche Prüffragen sind hier am wichtigsten?
 - Wahr? (War die Quelle verifiziert?)
 - Absicht? (Wer hat es gesendet und warum?)
 - Achtsam? (Wer könnte geschädigt werden?)
- Warum war „es fühlt sich wahr an“ stärker als „es ist wahr“?

Evidenz-Schnappschuss: dein „Detektiv-Protokoll“

- Du hast 5–8 Minuten für diese Aktivität – allein oder zu zweit.
- Wähle einen Inhalt aus (Bild, Video, Audio oder Chatbot-Antwort).
- Erstelle eine kurze „Detektiv-Notiz“ mit der Vorlage unten.
- Vorlage Detektiv-Notiz (ausfüllen)
- Was ist der Inhalt? (1 Satz)
- Wo habe ich ihn gefunden? (Plattform/Konto/Link, wenn möglich)
- Meine erste Reaktion: (Was habe ich gefühlt?)

Evidenz-Schnappschuss: dein „Detektiv-Protokoll“

Meine Checks

- ☐ Detail-Check (Was wirkte merkwürdig?)
- ☐ Quellen-Check (Wer hat gepostet? Gibt es vertrauenswürdige Quellen?)
- ☐ Emotions-Check (Sollte ich zu einer Reaktion gedrängt werden?)

Entscheidung

- ☐ Ich vertraue dem Inhalt genug, um ihn zu nutzen/teilen
- ☐ Ich bin unsicher (ich teile noch nicht)
- ☐ Ich halte ihn für irreführend/gefälscht

Begründung (1 Satz):

Warum wichtig? Deine Begründung macht dein Denken sichtbar – ein Kern von kritischem Denken und Metakognition.



www.valuesai.eu

Folge unserer Reise



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

MODUL 04

Zuverlässige KI-gestützte Inhalte

Quellen, Prüfung und Kontrolle von Halluzinationen



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

Inhaltsverzeichnis


01	Glaubwürdige Inhalte im KI-Zeitalter erstellen (10 Min.)	3
02	Risiken von KI-Inhalten (20 Min.)	8
03	Verantwortliche Autorenschaft (20 Min.)	15
04	Arbeit mit Quellen (15 Min.)	23
05	KI-Halluzinationen (10 Min.)	36
06	Inhaltsprüfung (10 Min.)	45
07	Datenanalyse mit KI (10 Min.)	51



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

01

A large, faint heart shape is visible in the background, spanning across the blue and white areas. A horizontal line with a color gradient from pink to blue passes behind the text '01' and the main title.

Glaubwürdige Inhalte
im KI-Zeitalter erstellen

(10 Min.)

Zuverlässige KI-Inhalte

Glaubwürdige Inhalte im KI-Zeitalter zu erstellen bedeutet nicht nur, schnell Text zu produzieren, sondern vor allem Genauigkeit, Transparenz und Verantwortung sicherzustellen. Der Einsatz von KI mindert Qualität nicht automatisch, erfordert aber stärkere menschliche Kontrolle, besonders wenn Inhalte Fakten, Daten, Gesundheit, Politik oder gesellschaftliche Themen betreffen.

Zuverlässige KI- Inhalte – Grundprinzipien

A stylized graphic on the left side of the slide. It features a heart shape formed by two overlapping loops, with a speech bubble tail extending from the bottom right. The graphic is rendered in a lighter shade of blue against the dark blue background.

- **Quellen nennen.** Beziehe dich auf Studien, Berichte, offizielle Stellungnahmen und Originaldaten.
- **Vor dem Veröffentlichen prüfen.** Jeder Inhalt sollte auf Fakten, Zahlen und Kontext geprüft werden.
- **KI-Nutzung offenlegen.** Transparenz stärkt das Vertrauen des Publikums.
- **Klar und präzise schreiben.** Vermeide vage Formulierungen, die zu Missverständnissen führen können.
- **Inhalte aktualisieren.** Wenn neue Daten erscheinen oder ein Fehler gefunden wird, überarbeite das Material.
- **Klare Autorenschaft sichern.** Inhalte sollten eine erkennbare Autor*in oder redaktionell verantwortliche Stelle haben.
- **Nicht manipulieren. KI nicht zum absichtlichen Irreführen nutzen – auch nicht für Reichweite.**

Zuverlässige KI- Inhalte – was Vertrauen schafft



Glaubwürdige Inhalte erklären meist nicht nur, was gilt, sondern auch warum und auf welcher Grundlage. Deshalb funktioniert die Kombination aus Daten, Fachkommentar und praktischen Beispielen gut.

- Veröffentlichungs- und Aktualisierungsdaten,
- Links zu Primärquellen,
- eine Fachperson oder Autor*in mit relevanter Qualifikation,
- eine logische Textstruktur,
- eine klare Unterscheidung zwischen Fakt, Meinung und Interpretation,
- keine reißerische oder Clickbait-artige Sprache.

In der Praxis: KI kann unterstützen, aber Menschen bleiben für Wahrhaftigkeit und Bedeutung verantwortlich.

Warum KI-Inhalte zuverlässig sein müssen




KI-Tools erzeugen Inhalte schnell, aber jede Ausgabe bleibt ein Entwurf: flüssiger Text, plausible klingenden Zahlen und überzeugende Zusammenfassungen können dennoch falsch sein.

Warum das wichtig ist:

- Nach Veröffentlichung können schwache Inhalte Glaubwürdigkeit schädigen und Menschen irreführen.
- KI kann Quellenangaben, Statistiken und Zitate erfinden, die echt aussehen (Halluzinationen).
- „Zuverlässig“ bedeutet mehr als flüssig – es bedeutet belegt, geprüft und verantwortbar.

Beispiel: ChatGPT liefert oft eine flüssige Definition ohne Quellen. NotebookLM kann mit geladenen PDFs eine belegte Definition mit realen Autor*innen liefern.

02



Risiken von KI-Inhalten (20 Min.)

KI-Inhalte bergen drei Risiken:

Halluzinationen,
fehlende Quellen
und KI-Erkennung

Bei KI-Inhalten achten viele nur auf Tempo. In der Praxis bergen KI-Ausgaben drei zentrale Risiken.

01

Halluzinationen (falsche Fakten):

KI kann Daten, Zahlen, Namen und Zitate erfinden, die aber dennoch echt klingen.

02

Quellenrisiko:

Modelle wie ChatGPT 4.0 erzeugen flüssigen Text ohne reale Quellen. Bibliografien fehlen, sind vage oder erfunden.

03

KI-Erkennungsrisiko:

Detektoren markieren generische KI-Texte. Unbearbeitete Texte zeigen bis zu 100 % KI; fundierte, bearbeitete Ausgaben unter 10 %.

„Sieht zuverlässig aus“ – ist es aber nicht (Mythos vs. Realität)



Achte auf:

- Quellen mit falschen Seitenzahlen
- echte Namen + erfundene Artikel
- plausible Zahlen ohne Quelle
- flüssige Definitionen die der aktuellen Literatur widersprechen

Mythos

„Akademischer Klang = zuverlässig.“

Fakt

KI kann akademisch klingen und trotzdem Fakten erfinden.

Mythos

„Detektor sagt: menschlich = sicher.“

Fakt

Detektoren prüfen Stil. Bearbeitete KI kann menschlich wirken und trotzdem Fehler enthalten.

Was ist AI SLOP?

**AI SLOP =
minderwertige,
irreführende oder
ungenauere Inhalte, die
von KI erzeugt wurden.**



Es klingt überzeugend, enthält aber:

- erfundene Fakten
- falsche Zahlen oder Daten
- falsche Namen, Quellenangaben oder wissenschaftliche Aussagen
- wiederholende, generische Struktur
- „glatten“ Text ohne echte Belege

○ Warum passiert das?

01

Das Modell sagt Muster voraus, nicht Wahrheit – es erzeugt auf Basis von Daten die wahrscheinlichste Antwort, „weiß“ aber nicht wirklich, ob sie wahr ist.

02

Es kann Lücken mit erfundenen Details füllen – wenn Informationen fehlen, kann das Modell etwas ergänzen, das logisch klingt, aber nicht der Realität entspricht.

03

Es hat nicht immer aktuelle Informationen – wenn das Wissen des Modells zeitlich begrenzt ist, kann es veraltete Fakten liefern oder neue Ereignisse übersehen.

04

Es kann Kontext missverstehen – eine unklare Frage, Kurzform oder Mehrdeutigkeit kann zu einer falschen Antwort führen.

○ Warum passiert das?

05

Es klingt selbstbewusst, auch wenn es falsch ist – die Formulierung kann sehr zuverlässig wirken, selbst wenn der Inhalt Fehler enthält.

06

Es kann echte Fakten mit Halluzinationen mischen – ein Teil der Antwort kann korrekt sein, während andere Teile erfunden oder ungeprüft sind.

07


Es hängt von der Qualität der Eingabe ab – wenn der Prompt unklar, widersprüchlich oder unvollständig ist, kann die Ausgabe weniger genau sein.

Deshalb wird Überprüfung zu einer zentralen digitalen Kompetenz.

Wie AI SLOP das Internet zerstört

KI-generierte Inhalte überfluten das Internet – von Videos und Musik bis hin zu Nachrichten und Büchern. Darüber hinaus lässt generative KI falsche Informationen überzeugender wirken als je zuvor. Wir treten in eine neue Ära der Informationsüberlastung ein, und es wird immer schwieriger herauszufinden, was echt ist und was nicht.

VIDEO



03

Verantwortliche Autorenschaft

(10 Min.)



Verantwortungsbewusste Perspektive

Beachte vier zentrale Fragen, wenn du Inhalte mit KI erstellst:

Genauigkeit

Habe ich Fakten, Daten und Zitate anhand vertrauenswürdiger Quellen geprüft?

Quellen

Kann ich reale Veröffentlichungen für jede zentrale Aussage angeben?

Originalität

Habe ich den KI-Entwurf so bearbeitet, dass er nicht wie rohe KI-Ausgabe wirkt?

Verantwortung

Kann ich erklären, wie ich KI genutzt habe, was ich geändert habe und warum?

Zuverlässige Inhalte = kluge KI-Nutzung, geleitet von Verantwortung.

Verantwortungsbewusste Perspektive

**Sicherheit
beginnt vor der
KI**

Was du
eingibst oder
hochlädst, zählt
zuerst

**Rechte und
Einwilligung
zählen**

Daten anderer
Menschen
brauchen Erlaubnis
und Sorgfalt

**Fairness ist Teil
von Sicherheit**

Verzernte oder
minderwertige
Daten können
Schaden
verursachen

**Sicherere
Workflows sind
möglich**

Du kannst oft
KI nutzen und viel
weniger teilen

Bevor du KI nutzt: Jede Ausgabe ist ein Entwurf

Viele Menschen konzentrieren sich auf die Geschwindigkeit von KI. Zuverlässige Inhalte beginnen früher: bei dem, was du prüfst, belegst und bearbeitest.



In der Praxis erzeugen KI-Tools:

- Definitionen und Erklärungen (oft ohne Quellen)
- Zusammenfassungen von Artikeln (manchmal erfunden oder verzerrt)
- Literaturlisten (häufig erfunden)
- Datenanalysen und Interpretationen (ohne Methodik)

Bevor du KI nutzt: Jede Ausgabe ist ein Entwurf

Zuverlässige KI-Nutzung beginnt mit einer einfachen Gewohnheit: Behandle jede Ausgabe als Entwurf, der geprüft werden muss – nicht als endgültige Antwort.

KI-Ausgaben sind Entwürfe, keine Wahrheit

Welche Inhalte musst du prüfen?

- Definitionen und theoretische Aussagen
- Statistiken, Prozentwerte und Daten
- Namen von Autor*innen, Büchern und Artikeln
- Datenanalysen und Schlussfolgerungen



TUN



TUN: Denke daran: Jede Tatsache, Quelle und Zahl aus KI muss vor der Nutzung geprüft werden.



NICHT
TUN



NICHT TUN: Nicht annehmen: „Es klingt professionell“ oder „Es muss stimmen, weil KI es gesagt hat.“

Nie blind
vertrauen
(NTL)


Nicht ohne
Prüfung
veröffentlichen:



Nicht belegbar? Nicht veröffentlichen.

- **Quellenangaben:** jeder Verweis auf ein Buch, einen Artikel oder eine Autorin bzw. einen Autor, den die KI nennt
- **Zitate:** jedes „direkte Zitat“, das die KI einer Person zuschreibt
- **Statistiken:** Prozentwerte, Stichprobengrößen, Studienergebnisse, Rankings
- **Historische Fakten:** Daten, Ereignisse, Orte, Namen von Gesetzen oder Verträgen
- **Definitionen und Theorien:** Aussagen darüber, was ein Konzept „ist“ oder wer es vorgeschlagen hat
- **Numerische Analysedaten:** Kund*innenlisten, HR-Daten, interne Dokumente, nicht öffentliche Zahlen

Wie du KI-Ausgaben zuverlässiger machst (vor der Veröffentlichung)




Wende vor der Veröffentlichung von KI-Ausgaben diese Prüfungen an:

- **Quellen prüfen:** Öffne Google Scholar, Scopus oder die Website des Verlags.
- **Prüfe jede Statistik** mit mindestens einer unabhängigen Quelle gegen.
- **Führe den Prompt erneut in einem quellenbasierten Tool** aus (z. B. NotebookLM mit geladenen echten PDFs).
- **Struktur bearbeiten**, generische Formulierungen ersetzen, konkrete Beispiele hinzufügen.

Quelle nicht gefunden? Nicht veröffentlichen.

04

The slide features a large, stylized heart shape in the background, composed of concentric, slightly irregular lines. A horizontal line with a color gradient from pink to blue crosses the slide, passing behind the heart and the main text area.

Arbeit mit Quellen

(15 Min.)

○ Von KI angegebene Quellen

01

Glaubwürdige Quellen nutzen – wähle Materialien aus angesehenen Fachzeitschriften, öffentlichen Institutionen, wissenschaftlichen Datenbanken und Fachorganisationen.

02

Wissenschaftliche, Branchen-, Medien- und Meinungsquellen unterscheiden – jede Quellenart erfüllt eine andere Funktion und bietet ein anderes Maß an Zuverlässigkeit.

03

Veröffentlichungsdaten prüfen – Aktualität ist wichtig, besonders in schnelllebigen Bereichen, in denen KI veraltete Informationen liefern kann.

04

Quellenangaben prüfen – prüfe, ob die genannten Autor*innen, Titel, Jahre und zitierten Aussagen tatsächlich existieren und zu dem passen, was Text oder KI behaupten.

○ Von KI angegebene Quellen

05

Primär- und Sekundärquellen unterscheiden – eine Primärquelle enthält Originalmaterial, während eine Sekundärquelle frühere Arbeiten diskutiert oder interpretiert.

06

Informationen gegenprüfen – wichtige Aussagen sollten durch mindestens zwei oder drei unabhängige Quellen bestätigt werden.

07

Autor*in, Verlag und Zweck bewerten – frage immer, wer den Text geschrieben hat, wo er veröffentlicht wurde und ob er informieren, verkaufen, überzeugen oder kommentieren soll.

Beispiel: KI liefert eine falsche Quelle


Siehe
nächste
Folie



Diese Folie zeigt ein Gespräch mit ChatGPT 5 Instant. Die Nutzerfrage lautet, wie die COVID-19-Pandemie Konsumverhalten und Markenstrategien verändert hat. Die KI liefert eine strukturierte Antwort mit Quellenverweisen auf wissenschaftliche Arbeiten (Pantano et al., 2020; Sheth, 2020; Liu et al., 2021; He & Harris, 2020) und diskutiert die Digitalisierung des Konsumverhaltens sowie neue Prioritäten wie Sicherheit, Gesundheit, Vertrauen und „mindful consumption“.


Bei der Überprüfung einer Quellenangabe stellte sich heraus, dass der Artikel „The challenges and opportunities of digital transformation in the post-COVID-19 world“ NICHT in Technological Forecasting and Social Change erschienen ist, wie die KI behauptete, sondern in IEEE Engineering Management Review, Vol. 48(3), S. 97–103.

Beispiel: KI liefert eine falsche Quelle



Beispiel: KI liefert eine falsche Quelle. Schlussfolgerung

Siehe
nächste
Folie




- Die KI ordnete einen realen Artikel der falschen Zeitschrift zu und zitierte ihn fälschlich als Beitrag in Technological Forecasting and Social Change statt in IEEE Engineering Management Review.
- Sie erzeugte eine plausible, aber falsche bibliografische Angabe einschließlich Zeitschrift und Publikationsdetails – also eine irreführende APA-Quellenangabe.
- Die KI prüfte die Publikationsdaten (Zeitschrift, Verlag, DOI) nicht, obwohl die Quelle leicht überprüfbar war.
- Sie kombinierte einen realen Titel mit einem falschen Publikationskontext – ein typischer Fall von Quellenhalluzination.
- Dieser Fehler untergräbt wissenschaftliche Zuverlässigkeit und kann zu falschen Literaturverzeichnissen oder Problemen im Peer Review führen.

Beispiel: KI liefert eine falsche Quelle. Schlussfolgerung

- Bhatti, A. (2020). Online shopping behavior during COVID-19 pandemic. *International Journal of Business and Social Science*, 11(10), 1-10.
- He, H., & Harris, L. (2020). The impact of COVID-19 pandemic on corporate social responsibility and marketing philosophy. *Journal of Business Research*, 116, 176-182.
- Huang, M.-H., Rust, R. T., & Maksimovic, V. (2021). The feeling economy: Managing in the next generation of artificial intelligence. *California Management Review*, 63(3), 43-65.
- Liu, Y., Lee, J. M., & Lee, C. (2021). The challenges and opportunities of digital transformation in the post-COVID-19 world. *Technological Forecasting and Social Change*, 166, 120602.
- Pantano, E., Pizzi, G., Scarpi, D., & Dennis, C. (2020). Competing during a pandemic? Retailers' ups and downs during the COVID-19 outbreak. *Journal of Business Research*, 116, 209-213.
- Sheth, J. (2020). Impact of COVID-19 on consumer behavior: Will the old habits return or die? *Journal of Business Research*, 117, 280-283.

Beispiel: KI liefert eine falsche Quelle. Schlussfolgerung

KI kann Literatur effektiv zusammenfassen,
aber alle KI-generierten Quellenangaben
müssen vor der Nutzung in
wissenschaftlichen Arbeiten unabhängig
überprüft werden.





Übung

Bitte ein KI-Modell um einen einseitigen A4-Text zu einem Thema. Bitte es, keine Websites zu nutzen, sondern

Veröffentlichungen wie Artikel, Bücher oder Berichte als Quellen.

- Erstelle eine Quellenliste.
- Prüfe anschließend nach guter Praxis die Richtigkeit der angegebenen Quellen: Existieren sie wirklich?
- Sind sie zugänglich?
- Nennen sie die richtigen Autor*innen?

Wenn du einen KI-Fehler entdeckst, teile deine Beobachtungen mit der Gruppe und der Kursleitung.

Szenario: ChatGPT 4.0 vs. NotebookLM

**Eine
Forschungsfallstudie
verglich zwei Tools
bei derselben**

Aufgabe: „*Erstelle
eine Definition von
Innovationsstrategie
mit Bibliografie.*“

**Derselbe Prompt erzeugte zwei Ausgaben, die zeigen, was
Quellenfundierung verändert:**

- ChatGPT 4.0: flüssige Definition, kein echtes Literaturverzeichnis, von Originality.ai als 100 % KI erkannt.
- NotebookLM (mit realen PDFs): fundierte Definition mit echten Autor*innen (Porter, Janasz, Pomykalski, Freeman); 92 % Originalitätswert.

Was das in der Praxis bedeutet:

- Ohne Quellenfundierung erfindet KI flüssige, aber unbelegte Inhalte. Mit echter Wissensbasis erzeugt dasselbe Modell überprüfbare Texte, die an konkrete Veröffentlichungen gebunden sind.

ChatGPT 4.0 vs. NotebookLM: Was quellenbasierte Verankerung verändert

Quellen sind nicht nur akademisch – sie machen KI-Ausgaben verantwortbar.

ChatGPT 4.0 (ohne Quellenfundierung):

- Flüssiger Text, vereinfachte Definitionen, kein Literaturverzeichnis
- Plausible Unternehmensbeispiele (Google, Tesla, Apple) ohne „Studien“ dahinter.
- 100 % als KI-generiert von Originality.ai erkannt

NotebookLM (mit geladenen PDFs):

- Theoriegestützte Definitionen mit Porter, Janasz, Pomykalski und Freeman
- Echte Forschungstraditionen: Innovationstypologien, Netzwerkökonomie, KMU-Kontext.
- Konkretes Literaturverzeichnis im APA-Format, überprüfbar
- Stil von Originality.ai als 92 % original bewertet

Quellen und Rechte: „Habe ich eine echte Referenz?“

Zuverlässige KI-Nutzung betrifft nicht nur Fakten. Es geht auch um Autorenschaft: Wer hatte die ursprüngliche Idee, wessen Arbeit zitierst du und wie gibst du Anerkennung?

KI-Ausgaben nicht ungeprüft vertrauen bei:

- exakte Statistiken, Prozentwerte, Stichproben
- konkrete Zitate mit Autor*innen
- Publikationsjahre, Seitenzahlen, Zeitschriftentitel
- Definitionen von Nischen- oder neuen Konzepten
- allgemeine Erklärungen bekannter Konzepte
- Strukturüberarbeitung (Grammatik, Lesefluss, Absätze)
- Zusammenfassung eigener Texte

Wie eine „echte Quelle“ aussieht (und wie nicht)


Zuverlässige KI-Nutzung betrifft nicht nur Fakten. Es geht auch um **Autorenschaft**: Wer hatte die ursprüngliche Idee, wessen Arbeit zitierst du und wie gibst du Anerkennung?

Eine echte Quelle ist nicht nur Name und Jahr. Bei KI-Zitaten muss sie sein:

- **Real**: Die Veröffentlichung existiert und ist auffindbar.
- **Spezifisch**: Sie passt zur Aussage, nicht nur zum Thema.
- **Zugänglich**: Du kannst die relevante Stelle lesen.
- **Autoritativ**: glaubwürdige Zeitschrift, Verlag oder Institution.
- **Wichtig**: Einwilligung hängt von Publikum und Tool ab.

Eine Person kann dir etwas erzählen, aber nicht zustimmen, dass es mit KI geteilt oder gespeichert wird.

05



KI-Halluzinationen

(10 Min.)

Was sind KI-Halluzinationen?




KI-Halluzinationen sind Modellantworten, die plausibel klingen, aber falsche, erfundene oder irreführende Informationen enthalten. Das Modell prüft nicht die Realität, sondern sagt wahrscheinlichen Text voraus.

Beispiele sind erfundene Zitate, nicht existierende Quellen, falsche Daten oder irreführende Erklärungen. Gemeint sind Fehler der Informationsgenerierung – keine medizinischen Halluzinationen.

Karte der KI-Halluzinationen

Wie KI-Halluzinationen in Karten mit abgestuften Symbolen erkannt und behoben werden können.


Aihallucinationreport.com.
<https://aihallucinationreport.com/how-to-detect-and-fix-ai-hallucinations-in-graduated-symbol-maps/>



KI-Halluzinationen

Statistiken für 284 Analyseeinheiten.
Unterschiedliche Farben stehen für
unterschiedliche Fehlertypen.

Sun, Yujie & Sheng, Dongfang & Zhou, Zihan & Wu, Yifei.
(2024). AI hallucination: towards a comprehensive
classification of distorted information in artificial intelligence-
generated content. *Humanities and Social Sciences
Communications*. 11. 10.1057/s41599-024-03811-x.



Arten von KI-Halluzinationen

01

Faktische Halluzinationen – das Modell nennt falsche Fakten, Ereignisse, Personen oder Definitionen.

02

Quellenhalluzinationen – KI erfindet Quellen, Veröffentlichungen, Autor*innen oder Titel oder ordnet Aussagen nicht existierenden Texten zu.

03

Zitathalluzinationen – das Modell nennt ein Zitat, das nie gesagt wurde, oder schreibt es fälschlich einer Person zu.

04

Numerische Halluzinationen – KI verrechnet Daten oder verwechselt Prozentwerte, Daten, Statistiken oder Tabellenwerte.

Arten von KI-Halluzinationen

05

Kontextuelle Halluzinationen – das Modell missversteht die Frage oder fügt Details hinzu, die der/die Nutzer*in nicht beabsichtigt hat.

06

Gemischte Halluzinationen – die Antwort enthält sowohl richtige Fakten als auch erfundene Elemente, wodurch der Fehler schwerer zu erkennen ist.

○ Ursachen von KI-Halluzinationen

01

Das Modell sagt Muster voraus, nicht Wahrheit – es erzeugt die wahrscheinlichsten Wörter, statt Fakten zu prüfen.

02

Trainingsdaten können unvollständig oder fehlerhaft sein – wenn die Daten Lücken, Fehler oder Widersprüche enthalten, kann das Modell sie reproduzieren.

03

Fehlende aktuelle Informationen – das Modell kennt möglicherweise neue Ereignisse oder Änderungen nicht.

04

Unklarer Prompt-Kontext – bei mehrdeutigen oder verkürzten Prompts kann das Modell die Absicht falsch verstehen.

○ Ursachen von KI-Halluzinationen

05

Systeme belohnen flüssige Antworten – Modelle werden oft darauf trainiert, selbstbewusst und glatt zu antworten, auch wenn sie unsicher sind.

06

Keine eingebaute Faktenprüfung – ohne Zugriff auf externe Quellen kann das Modell nicht überprüfen, ob seine Antwort wahr ist.

Indirekte Halluzinationen: wenn Namen und Daten richtig aussehen, es aber nicht sind

Häufige indirekte Halluzinationen:

- Reale*r Autor*in + echte Zeitschrift + erfundener Titel
- Echter Artikel + falsches Jahr, falsche Seite oder Band
- Echtes Konzept + falscher Autor („Porter“ statt „Schumpeter“)
- Echte Statistik + erfundener Kontext

Sicherere Alternativen:

- **Suchen:** Exakten Artikel in Google Scholar prüfen.
- **Ersetzen:** Nur gelesene Quelle zitieren.
- **Abschwächen:** allgemeiner formulieren, wenn keine konkrete Quelle belegbar ist.
- **Entfernen:** unbelegte Aussage löschen.


KI kann auch dann halluzinieren, wenn Namen, Daten und Titel korrekt wirken.
Das Muster ist plausibel, aber die Verbindung zum Originalwerk ist falsch.

06

Inhaltsprüfung (10 Min.)



**KI-generierte Inhalte
können nützlich sein –
aber nur nach Prüfung
veröffentlichen oder
nutzen.**




*Behandle die KI-Antwort als
Entwurf, nicht als
endgültige Wahrheit.*

*Prüfe Aussagen, Zahlen,
Zitate und Quellen
bevor du sie nutzt.*

*Dokumentiere, was geprüft
wurde und auf welcher
Grundlage.*

Schritt 1: Risiko und zentrale Aussagen identifizieren




Identifiziere zuerst, welche Teile der KI-Antwort zwingend geprüft werden müssen: Fakten, Daten, Namen, Zahlen, Zitate, Definitionen und genannte Quellen. Je größer die Auswirkungen auf Gesundheit, Recht, Bildung, Finanzen oder Reputation, desto strenger sollte die Überprüfung sein.

Welche Elemente könnten Schaden verursachen, wenn sie falsch sind?

Hat die KI echte Quellen angegeben oder klingt sie nur überzeugend?

Was ist in dieser Antwort Fakt und was ist Interpretation?

Schritt 2: Fakten und Quellen überprüfen



Jede wichtige Aussage sollte anhand glaubwürdiger externer Quellen geprüft werden, vorzugsweise **Primärquellen**: wissenschaftliche Artikel, Berichte, Websites öffentlicher Institutionen und seriöse Branchenpublikationen. Gehe niemals davon aus, dass eine von KI genannte Quelle tatsächlich existiert – prüfe Autor*in, Titel, Jahr, Zugänglichkeit und ob die Quelle die genannte Information wirklich enthält.

Bestätige die Information durch mindestens zwei unabhängige Quellen.

Öffne die Originalquelle, nicht nur eine Zusammenfassung oder einen Repost.

Prüfe Veröffentlichungsdatum und Aktualität der Information.

Schritt 3: Qualität, Sprache und Kontext bewerten



Nach der Faktenprüfung bewertest du, ob der Text logisch, klar, ausgewogen und für seinen Zweck geeignet ist. KI kann Inhalte erzeugen, die formal korrekt, aber schlecht kontextualisiert, übermäßig selbstsicher, verzerrt oder stilistisch ungeeignet sind.

Der Text vermischt Fakten mit Meinung.

Er enthält Verzerrungen, Vereinfachungen oder übermäßige Verallgemeinerungen.

Ton und Stil passen zur Zielgruppe und zum Veröffentlichungsziel.

Bearbeiten, entscheiden und dokumentieren

Korrigiere abschließend Fehler, entferne unsichere Stellen und entscheide, ob der Inhalt verwendbar ist. Gute Praxis ist es, festzuhalten, was geändert, was verworfen wurde und welche Quellen die finale Version bestätigt haben. Endentscheidung:



Veröffentlichen



Wenn der Inhalt geprüft und korrigiert wurde.



Zurückhalten



Wenn einige Informationen unsicher bleiben.




Ablehnen



Wenn der Inhalt zu viele Fehler enthält oder Quellenbestätigung fehlt.

07

A decorative graphic consisting of a horizontal line with a color gradient from pink to blue. To the right of the line is a large, dark blue rounded rectangle. Inside this rectangle, on the right side, is a light blue heart shape. The text '07' is positioned to the left of the line.

Datenanalyse mit KI (10 Min.)

Datenanalyse mit KI:

Validierung ist notwendige Arbeit

Wenn du KI bittest, Daten zu analysieren, erzeugt das System eine flüssige Darstellung. Je nach Prompt und Tool kann die Ausgabe auch:



- Methodik auslassen (Stichprobe, Methode, Annahmen)
- Ausreißer mitteln, ohne sie zu kennzeichnen
- kleine Stichproben verallgemeinern (z. B. $n=10$)
- selbstsichere Schlüsse aus unsicheren Daten ziehen
- Bestätigungsfehler: Prompt-Rahmung wiederholen

Datenanalyse mit KI:

Validierung ist notwendige Arbeit

**Warum
Validierung von
Analysen
wichtig ist:**



- Du erkennst Fehler vor Bericht oder Veröffentlichung.
- Du trennst belastbare Befunde von Rauschen.
- Du vermeidest Entscheidungen auf Basis nicht repräsentativer Stichproben.
- Du behältst die Autorenschaft der Analyse – nicht das Modell.

SAFE-Analyseleiter:

Wähle die prüfbarste Stufe

Beginne nicht mit vollständigen Daten. Wähle die niedrigste Stufe, die deine Frage beantwortet.

Stopp-Regel: Wenn du sensible/vertrauliche Elemente nicht entfernen kannst → nicht hochladen.

STUFE 1

(Am zuverlässigsten): Allgemeine Frage, keine personenbezogenen Daten.

Beispiel: „Wann t-Test statt Mann-Whitney-U?“

STUFE 2

Nutze eine anonymisierte Zusammenfassung (Rollen, keine IDs).

Beispiel: „MW = 4,2; SD = 1,1; n = 120 – Trend?“

STUFE 3

Nutze begrenzte, de-identifizierte Daten nur wenn nötig.

Beispiel: „Berechne X; ich prüfe nach.“

Schlussfolgerung aus wenigen Daten



Unzuverlässige KI-Ausgabe (realistisch):

„KI hat eine Sentimentanalyse von 200 Tweets über unsere Marke durchgeführt. 67 % positiv. Daher ist die Markenstimmung stark positiv.“

Was ist unzuverlässig?

- „67 %“ ohne Methodik, ohne Modell, ohne Validierung
- 200 Tweets sind ein sehr kleiner, möglicherweise verzerrter Ausschnitt
 - „stark positiv“ übertreibt, was die Zahl zeigt



www.valuesai.eu

Folge unserer Reise



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

MODUL 05

Datenschutz & sichere Nutzung von KI-Tools

Weniger teilen. Mehr schützen.
KI verantwortungsvoll nutzen.

Inhaltsverzeichnis


01	Warum sichere Daten bei KI wichtig sind (15 Min.)	3
02	Wie teilst du Daten sicher? (15 Min.)	10
03	Privatsphäre, Rechte und Einwilligung (15 Min.)	16
04	Sicherere KI-Workflows wählen (25 Min.)	23
05	Datenlage: Daten- und Zugangsdaten-Diebstahl (15 Min.)	33



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

01

A decorative graphic on the right side of the slide. It features a large, stylized heart shape composed of concentric, slightly irregular lines in shades of blue and purple. A horizontal line, transitioning from pink to blue, extends from the left edge of the slide and ends at the heart shape.

Warum sichere Daten
bei KI wichtig sind

(15 Min.)

Daten und KI

Das Teilen von Daten mit KI-Tools ist besonders im beruflichen Kontext riskant. Wenn Eingaben gespeichert, wiederverwendet oder durch Drittanbieter-Modelle offengelegt werden, kann dies zu Datenlecks, Verstößen gegen Vorschriften sowie zu Reputations- oder Betriebsrisiken führen.

Zentrale Risiken



- **Offenlegung sensibler Daten:** Prompts oder Dateien, die an KI-Plattformen gesendet werden, können gespeichert werden oder in Ausgaben auftauchen. Dadurch können geistiges Eigentum, personenbezogene Kundendaten oder Finanzdaten offengelegt werden.
- **Schatten-KI und unkontrollierte Nutzung:** Wenn Mitarbeitende nicht freigegebene KI-Tools nutzen, entstehen blinde Flecken. Daten verlassen dann möglicherweise die Kontrolle der Organisation, und Anbieter können Eingaben speichern oder wiederverwenden.
- **Rechts- und Compliance-Verstöße:** Die Nutzung externer KI-Dienste ohne passende Verträge oder Vereinbarungen zur Datenverarbeitung kann Datenschutzgesetze verletzen und Sanktionen nach sich ziehen.
- **Mangelnde Transparenz und Nachvollziehbarkeit:** Viele KI-Anbieter legen nicht klar offen, wie Eingaben gespeichert, wo sie verarbeitet oder ob sie zum Training genutzt werden. Dadurch wird Risikobewertung schwieriger.
- **Erweiterte Angriffsfläche:** Die Integration von KI kann technische Schwachstellen vergrößern, z. B. über APIs, Plugins oder Endpunkte, die Angreifer ausnutzen können.

Drei negative Effekte: Datenschutz, Unfairness und falsche Sicherheit

01

Datenschutzrisiko (Offenlegung):

Zu viele Details können persönliche, sensible oder fremde Informationen sichtbar machen.

02

Fairness-Risiko (Schaden):

Verzernte oder unvollständige Daten können Stereotype verstärken oder Gruppen benachteiligen.

03

Zuverlässigkeitsrisiko (falsche Sicherheit):

KI kann überzeugend klingen, auch wenn Eingaben schwach, unvollständig oder irreführend sind.



TUN



Frage: Was fehlt? Wer ist nicht vertreten?
Könnte diese Ausgabe jemandem schaden?



Nutze Checks:
Einwilligungs-Gate +
Fair-Data-Check + SAFE-
Workflow-Stufen



NICHT TUN



KI-Ausgaben als neutrale
Wahrheit behandeln



KI-Ergebnisse nutzen, um
Menschen zu beurteilen
oder Entscheidungen
ohne Kontext zu treffen

Werte-Linse

Sichere Daten = kluge Entscheidungen, die sich an Werten orientieren.

Nutze vier Wertefragen, wenn du KI mit Daten verwendest:

1. **Selbstbestimmung:** Entscheide ich bewusst oder klicke ich nur automatisch?
2. **Datenschutz:** Teile ich mehr Daten als nötig – über mich oder andere?
3. **Fairness:** Könnte meine Datennutzung jemandem schaden oder jemanden benachteiligen?
4. **Transparenz:** Kann ich erklären, welche Daten ich genutzt habe und warum?

Daten, bei denen besondere Vorsicht gilt

Beim Teilen dieser Daten mit KI-Systemen ist besondere Vorsicht erforderlich.

1. Personenbezogene Daten
2. Sensible Daten
3. Gesundheitsdaten
4. Finanzdaten
5. Login-Daten und Zugangsdaten
6. Kundendaten
7. Interne Organisationsdokumente
8. Unveröffentlichte Forschungsergebnisse
9. Daten, die durch Geschäftsgeheimnisse geschützt sind

02



Wie teilst du
Daten sicher?

(15 Min.)

Bevor du KI nutzt: Deine Eingabe wird zu Daten

Viele Menschen konzentrieren sich darauf, was KI antwortet.

Sichere Datennutzung beginnt früher:
bei dem, was du tippst, einfügst oder hochlädst.



In der Praxis können KI-Tools arbeiten mit:

- deinem Text: Prompts, Nachrichten, kopierte Inhalte
- deinen Dateien: Dokumente, Tabellen, PDFs
- deinen Bildern: Fotos, Screenshots
- deinem Kontext: Details, aus denen Rückschlüsse gezogen werden können

Bevor du KI nutzt: Deine Eingabe wird zu Daten

Wenn du zu viel teilst, können Risiken entstehen, die du nicht vollständig rückgängig machen kannst: Datenschutzrisiken, Schaden für andere und unfaire oder irreführende Ergebnisse.

Sichere KI-Nutzung beginnt mit einer einfachen Gewohnheit: Teile nur das notwendige Minimum; oder teile gar nichts.



TUN



TUN: Denke daran: Alles, was du tippst, einfügst oder hochlädst, sind Daten, die du teilst.



NICHT TUN



NICHT TUN: Gehe nicht davon aus: „Es ist nur Text“ oder „Es ist nur ein schneller Upload“.

„Sieht harmlos aus“
ist es aber nicht
immer (Mythos vs.
Realität)



Mythos

„Es ist sicher, wenn ich den Namen entferne.“

Realität

Menschen können indirekt identifiziert werden durch Kombinationen wie:

- Alter + Stadt + Schule/Praktikum
- einmalige Ereignisdetails
- Screenshots mit kleinen sichtbaren Hinweisen
- Standort- und Zeitmuster

Mythos

„Es ist sicher, wenn es nur ein Screenshot ist.“

Realität

Screenshots enthalten oft Namen, Gesichter, Kontaktdaten oder Kontext, den du übersiehst.



● Mikroaufgabe: Rote Flaggen erkennen

Aufgabe (60–90 Sekunden):

Ordne jedes Beispiel zu: Nie teilen / Vermeiden / Meist okay:

- Ein Passwort-Zurücksetzcode
- Ein Lebenslauf mit vollständiger Adresse und Telefonnummer
- Ein Chat-Screenshot mit sichtbaren Namen
- Eine allgemeine Frage: „Wie strukturiere ich einen Lebenslauf?“
- Eine Schulliste mit Namen und E-Mail-Adressen
- Eine Umfragezusammenfassung mit Gesamtzahlen, ohne Namen

Du weißt nie alles

- Es ist nicht immer klar, wo Daten verarbeitet werden.
- Daten können im Gesprächsverlauf gespeichert werden.
- Je nach Einstellungen und Nutzungsbedingungen können Daten zur Verbesserung von Diensten genutzt werden.
- Nutzer*innen können versehentlich vertrauliche Informationen offenlegen.

Merke: Wenn du nicht weißt, wie ein Tool Daten verarbeitet, teile weniger.

03

Privatsphäre, Rechte und Einwilligung

(15 Min.)

Entscheide, bevor du Daten über andere teilst

Nutze diesen Check immer dann, wenn deine Eingabe Informationen über andere Menschen enthält, z. B. Nachrichten, Fotos, Listen, Geschichten oder Dokumente.

3 Fragen stellen:

- Recht / Erlaubnis: Habe ich die Erlaubnis oder eine klare Grundlage, diese Daten mit KI zu verwenden?
- Risiko: Könnte dies jemanden jetzt oder später identifizieren, bloßstellen, verletzen oder schädigen?
- Sicherere Alternative: Kann ich das Ziel mit weniger Daten oder ganz ohne personenbezogene Daten erreichen?

Regel

Wenn du eine Frage mit „Nein“ oder „Nicht sicher“ beantwortest, lade die Daten nicht hoch. Wähle einen sichereren Workflow, z. B. eine allgemeine Frage ohne private Details. „Nicht sicher“ ist ein Warnsignal.

Einwilligung und Daten anderer Menschen: Was verantwortungsvolle Nutzung bedeutet

Privatsphäre und Rechte sind nicht nur technische Fragen. Es geht um Respekt und darum, Schaden zu verhindern.



TUN – sicherere Alternativen:

- Frage nach Einwilligung und respektiere ein „Nein“.
- Ersetze Namen durch Rollen: Person A, Freund*in, Lehrkraft, Kolleg*in.
- Entferne eindeutige Details wie genaue Orte, Daten oder Identifikatoren.
- Stelle eine allgemeine Frage ohne persönliche Geschichte.

TUN



NICHT TUN – hohes Risiko:

- Private Nachrichten anderer Menschen „für Rat“ in KI einfügen
- Gruppenlisten mit Namen oder E-Mails hochladen, um sie „zu organisieren“
- Persönliche Geschichten anderer Menschen ohne Nachfrage teilen

NICHT TUN



● Kurze Übung: Besteht das Einwilligungs-Gate?

Anleitung
Entscheide für jedes Szenario: Besteht oder besteht nicht. Schreibe anschließend einen kurzen Grund.

- „Fasse den Feedbackbrief meiner Lehrkraft zusammen. Er enthält den Namen der Lehrkraft und die Schule.“
- „Hilf mir, eine Entschuldigungsnachricht zu schreiben. Ich beschreibe die Situation, ohne den vollständigen Chat einzufügen.“
- „Analysiere eine Freiwilligenliste mit Namen und Telefonnummern, um ‚unzuverlässige‘ Personen zu finden.“

Habe ich das Recht, diese Daten zu verwenden?

Sichere KI-Nutzung betrifft nicht nur deine eigene Privatsphäre. Es geht auch um Rechte: Darf ich Daten verwenden, teilen oder verarbeiten – besonders, wenn sie jemand anderem oder einer Organisation gehören?

Diese Daten darfst du in der Regel nicht ohne Weiteres mit KI teilen:

- private Nachrichten anderer Menschen, auch wenn du Teil des Chats bist
- Listen von Personen: Klassen-, Freiwilligen- oder Kund*innenlisten
- Dokumente, die nicht dir gehören: Verträge, HR-Notizen, interne E-Mails
- persönliche Geschichten, die dir vertraulich erzählt wurden

Diese Daten kannst du in der Regel eher verwenden:

- eigener Text ohne sensible Details
- allgemeine Fragen ohne personenbezogene Daten
- anonymisierte Beispiele, die du selbst erstellt hast

Einwilligung: Was „echte Einwilligung“ bedeutet – und was nicht



Einwilligung bedeutet nicht nur: „Jemand hat einmal Ja gesagt.“

Für KI-Nutzung sollte Einwilligung sein:

- **informiert:** Die Person versteht, was geteilt wird und warum.
- **spezifisch:** Die Einwilligung gilt für diesen Zweck, nicht für „alles Mögliche“.
- **freiwillig:** Kein Druck, keine Angst vor Nachteilen.
- **widerrufbar:** Die Person kann ihre Meinung ändern.

Wichtig: Einwilligung hängt von Zielgruppe und Tool ab. Eine Person kann dir etwas erzählen, aber nicht wollen, dass es mit einem KI-Tool geteilt wird.

Indirekte Identifizierung: Wenn „Namen entfernen“ nicht reicht

Menschen können auch ohne Namen identifiziert werden, wenn Details Rückschlüsse ermöglichen.

Häufige indirekte Identifikatoren:

- genaues Alter, genauer Ort, Schule/Arbeitgeber oder besondere Rolle
- genaue Daten und Ereignisse: „die einzige Person, die ...“
- Kombinationen: Alter + Stadt + Hobby + Situation
- Screenshots mit kleinen sichtbaren Hinweisen

Sicherere Alternativen:

- Abstrahieren: Situation ohne einmalige Details beschreiben
- Verallgemeinern: Altersgruppe statt genaues Alter, Region statt Adresse
- Rollen verwenden: Person A / Person B
 - Nicht hochladen, wenn Kontext identifizierend bleibt

04

Sicherere
KI-Workflows wählen

(25 Min.)

Sicherere KI-Workflows wählen – gleiches Ziel, weniger Daten

Viele Risiken entstehen nicht nur durch das KI-Tool selbst, sondern dadurch, wie wir es nutzen. Oft teilen wir zu viele Daten, weil es schneller oder einfacher wirkt.

Sicherere KI-Workflows wählen – gleiches Ziel, weniger Daten


Wenn du Daten mit KI teilst,
können sie verarbeitet,
gespeichert und
wiedergegeben werden



Wenn du Daten in ein KI-Tool tippst, einfügst oder hochlädst, muss das System sie verarbeiten, um eine Antwort zu erzeugen. Je nach Dienst und Einstellungen können deine Daten auch:

- gespeichert oder protokolliert werden
- in bestimmten Fällen überprüft werden
- zur Personalisierung deiner Nutzung verwendet werden
- in Ausgaben wieder auftauchen
- indirekt weitergegeben werden, wenn du Ausgaben kopierst oder Screenshots versendest

Warum es wichtig ist, weniger Daten zu teilen



- Du verringerst die Wahrscheinlichkeit von Datenschutzlecks: Was du nicht teilst, kann nicht aus diesem Tool heraus offengelegt werden.
- Du reduzierst Schaden für andere: weniger fremde Daten, weniger Identifikatoren.
- Du verringerst das Risiko unfairer oder irreführender Schlussfolgerungen: weniger „Rauschen“, mehr zweckbezogene Eingabe.
- Du behältst mehr Kontrolle über deine Informationen.

Merke: Wenn ein Detail für die Aufgabe nicht notwendig ist, entferne es.

SAFE- Workflow- Stufen

Stopp-Regel:

Wenn du sensible
oder vertrauliche
Elemente nicht
entfernen kannst:
nicht hochladen!



Wenn du KI-Hilfe möchtest, beginne nicht damit, alles hochzuladen.
Wähle die sicherste Stufe, die noch funktioniert.

- **Stufe 1 – am sichersten: Stelle eine allgemeine Frage ohne personenbezogene Daten.**
Beispiel: „Wie strukturiere ich einen Lebenslauf?“
- **Stufe 2: Nutze eine anonymisierte Zusammenfassung mit Rollen und ohne Identifikatoren.**
Beispiel: „Person A und Person B hatten einen Konflikt über Fristen. Wie kann Person A reagieren?“
- **Stufe 3: Nutze begrenzte, de-identifizierte Daten nur dann, wenn es notwendig ist.**

Eine riskante Anfrage sicherer machen: vorher → nachher

Regel
Teile Zweck und Muster
– nicht persönliche
Identifikatoren.

Vorher – riskant:

„Hier ist mein vollständiger Lebenslauf. Verbessere ihn.“
(Du lädst ein Dokument mit Adresse, Telefonnummer, Referenzkontakten usw. hoch.)

Was ist riskant? Unnötige Identifikatoren, Kontaktdaten anderer Personen und Daten, die kopiert oder offengelegt werden könnten.

Nachher – sicherer:

„Bitte verbessere Sprache und Struktur dieses Lebenslaufs. Ich habe persönliche Daten entfernt. Konzentriere dich auf Klarheit, Leistungen und prägnante Formulierungen.“

Ausgabesicherheit: Auch KI-Ergebnisse können Informationen preisgeben

Selbst wenn du vorsichtig teilst, kann die Ausgabe sensible Details enthalten, wenn:

- deine Eingabe private Informationen enthielt, oder
- die KI diese Informationen in einer Zusammenfassung, Checkliste oder Nachricht wiederholt.

Sicherere Gewohnheiten:

- Handle Ausgaben wie Dokumente: nicht einfach in öffentliche Chats oder Gruppen kopieren.
- Entferne Namen, Identifikatoren und einmalige Details vor dem Teilen.
- Wenn die Ausgabe eine Person betrifft, halte sie privat oder formuliere sie allgemeiner.
- Speichere sensible Ausgaben sicher oder lösche sie, wenn du sie nicht mehr brauchst.



● Hauptaktivität: Unsichere KI-Nutzung sicherer machen (10 Minuten)

Du übst die gesamte Fähigkeit anhand fiktiver Beispiele. Ziel ist es, sicherere Anfragen zu formulieren, die das Problem trotzdem lösen.

Für jede Anfrage:

- **Identifiziere unsichere Teile: Never Share / Einwilligungs-Gate / Fairness-Risiko.**
- **Formuliere sicherer um: minimieren, anonymisieren, abstrahieren.**
- **Ergänze eine FDC-Zeile: „Was könnte fehlen oder verzerrt sein?“**
- **Wähle den Workflow: Stufe 1 / Stufe 2 / Stufe 3 / Stopp.**

Ergebnis:

Ein kurzes Safe-Data-Playbook für deine tägliche KI-Nutzung.



● Hauptaktivität: Unsichere KI-Nutzung sicherer machen (10 Minuten)

Übung 1:

Chat-Screenshot (Privatsphäre + Einwilligung)

„Hier ist ein Screenshot eines Chats mit meinem Freund / meiner Freundin [Namen sichtbar]. Sag mir, wer recht hat und was ich antworten soll.“

Schritt-für-Schritt-Aufgaben:

- NSL / Nie teilen: Was sollte hier niemals hochgeladen werden?
- Einwilligungs-Gate: Hast du die Erlaubnis, diese Daten zu teilen?
- Sichere Umformulierung (Stufe 1 oder 2): Bitte um Rat, ohne den Screenshot hochzuladen.
- Fairness-Zeile: Was könnte in der Geschichte fehlen?

Unsichere Teile: _____ FDC-Zeile: _____



● Hauptaktivität: Unsichere KI-Nutzung sicherer machen (10 Minuten)

Übung 2:

Personenliste (Vertraulichkeit + Fairness)

„Bitte analysiere diese Freiwilligenliste [mit Namen, Telefonnummern und Anwesenheitsproblemen]. Erstelle eine Rangliste, wer zuverlässig ist.“

Warum das riskant ist:

- personenbezogene Identifikatoren + Daten anderer Menschen
- schädliches Ergebnis: Menschen werden bewertet oder gerankt
- hohes Fairness- und Wirkungsrisiko

Sichereres Ziel: Formuliere die Frage so, dass es um die Verbesserung des Systems geht – nicht um die Bewertung einzelner Personen.

05

Datenlage (15 Min.)

Daten- und Zugangsdaten-Diebstahl – Der illegale Missbrauch von Daten nimmt zu



„7 % Zunahme bei Ransomware oder anderen destruktiven Angriffen. 23 % Zunahme bei Versuchen zum Diebstahl von Zugangsdaten.“

Microsoft Threat Intelligence, „Microsoft Digital Defense Report 2025: Lighting the Path to a Secure Future“ (Microsoft, 2025); <https://www.microsoft.com/en-us/security/security-insider/threat-landscape/microsoft-digital-defense-report-2025>

„Das Volumen der Datenexfiltration bei 10 großen Ransomware-Familien stieg um 92,7 %.“

Zscaler ThreatLabz, „Zscaler ThreatLabz 2025 Ransomware Report“ (Zscaler, 2025); <https://threatlabz.zscaler.com/>

Daten- und Zugangsdaten-Diebstahl – Der illegale Missbrauch von Daten nimmt zu



„Ransomware-Angriffe auf Industrieunternehmen nahmen gegenüber 2024 um 87 % zu.“

*Dragos, „Dragos’s 8th Annual OT Cybersecurity Year in Review Is Now Available“ (2025);
<https://www.dragos.com/blog/dragos-8th-annual-ot-cybersecurity-year-in-review-is-now-available>*



Daten- und Zugangsdaten-Diebstahl – Es gibt Hinweise, dass KI-Systeme Angreifer erheblich unterstützen können

„Der Akteur [...] stützte sich stark auf Claude bei der Implementierung von [Malware].“

A. Moix, K. Lebedev, J. Klein, „Threat Intelligence Report: August 2025“ (Anthropic, 2025).

Hinweis: Der Link im Ausgangsmodul scheint unvollständig zu sein und endet mit „.pd“. Bitte den vollständigen PDF-Link prüfen und ersetzen.

„Ransomware-Betreiber APT INC setzten ein vermutlich von einem LLM verfasstes Skript zur Datenzerstörung ein.“

CrowdStrike, „CrowdStrike 2025 Global Threat Report“ (CrowdStrike, 2025);

<https://www.crowdstrike.com/en-gb/global-threat-report/>

Daten- und Zugangsdaten-Diebstahl – Es gibt Hinweise, dass KI-Systeme Angreifer erheblich unterstützen können



„[Die Google Threat Intelligence Group] entdeckte eine Code-Familie, die KI-Fähigkeiten während der Ausführung einsetzte, um das Verhalten der Malware dynamisch zu verändern. [...] Angreifer gehen über die Nutzung von KI-Tools für technische Unterstützung hinaus.“

*Google Threat Intelligence Group, „GTIG AI Threat Tracker: Advances in Threat Actor Usage of AI Tools“ (Google Threat Intelligence, 2025);
<https://services.google.com/fh/files/misc/advances-in-threat-actor-usage-of-ai-tools-en.pdf>*

Daten- und Zugangsdaten-Diebstahl



Der Beitrag von KI-Systemen zu diesem Trend scheint begrenzt zu sein und ist wahrscheinlich anderen Faktoren nachgeordnet. Dennoch würden einige böswillige Akteure ihre Angriffe ohne KI-Systeme vermutlich nicht starten.


*International AI Safety Report 2026 (DSIT 2026/001, 2026);
<https://internationalaisafetyreport.org>*

Daten- und Zugangsdaten-Diebstahl

Ping Identity. (2024). Bridging the trust gap in the age of AI: 2025 consumer survey. Ping Identity.
<https://www.pingidentity.com/en/lp/2025-consumer-survey.html>

Welchen Arten von Online-Diensten vertraust du deine Identitätsdaten am wenigsten an?

Denke daran: KI wird inzwischen breit genutzt und vermittelt häufig Dienste und Transaktionen.



Daten- und Zugangsdaten-Diebstahl

Ping Identity. (2024). Bridging the trust gap in the age of AI: 2025 consumer survey. Ping Identity.
<https://www.pingidentity.com/en/lp/2025-consumer-survey.html>


Wie nutzt du künstliche Intelligenz (KI) derzeit?

*„Auch wenn Wissen Macht ist, hat die zunehmende Nutzung von KI im Alltag vielen Verbraucher*innen erst bewusst gemacht, was KI leisten kann. Sie erleben direkt, wie leistungsfähig diese Technologie in eigenen Anwendungsfällen sein kann. Gleichzeitig sehen sie mehr Nachrichten und Datenpunkte zu zunehmenden Sicherheitsbedrohungen und Cyberangriffen. Zusammengenommen ist es verständlich, dass dies zu einer Vertrauenskrise gegenüber der Fähigkeit von Marken beiträgt, Identitätsdaten von Verbraucher*innen sicher zu schützen.“*

Daten- und Zugangsdaten-Diebstahl

Ping Identity. (2024). Bridging the trust gap in the age of AI: 2025 consumer survey. Ping Identity.
<https://www.pingidentity.com/en/lp/2025-consumer-survey.html>

Wie nutzt du künstliche
Intelligenz (KI) derzeit?



Daten- und Zugangsdaten-Diebstahl – Welche Bedenken hast du ggf. im Hinblick auf KI und Identitätssicherheit?

Eingriff von KI-Programmen in meine Privatsphäre	27 %
KI-generiertes Phishing	27 %
Nutzung von KI, um mich oder eine Marke/Person, mit der ich interagiere, fälschlich nachzuahmen	26 %
Mangelnde Transparenz darüber, wie KI-Systeme meine personenbezogenen Daten nutzen und speichern	25 %
Erhöhte Cybersicherheitsrisiken, die die Sicherheit meiner personenbezogenen Daten gefährden	25 %
KI-generiertes Stimmklonen	24 %

Fortsetzung auf der nächsten Folie




Daten- und Zugangsdaten-Diebstahl – Welche Bedenken hast du ggf. im Hinblick auf KI und Identitätssicherheit?

Deepfake-Imitationen von Menschen, die ich kenne und denen ich vertraue	22 %
KI-Imitation durch Chatbots	20 %
Mangelnde Genauigkeit / Bias in KI-Systemen	18 %
Ich verstehe nicht, welchen rechtlichen Schutz ich in Bezug darauf habe, wie KI meine Daten nutzt	18 %
KI autorisieren, in meinem Namen zu handeln	17 %
Ich habe keine Bedenken in Bezug auf KI und Identitätssicherheit	9 %
Weiß nicht	13 %

Daten- und Zugangsdaten-Diebstahl

Ping Identity. (2024). Bridging the trust gap in the age of AI: 2025 consumer survey. Ping Identity.
<https://www.pingidentity.com/en/lp/2025-consumer-survey.html>

Wie nutzt du künstliche
Intelligenz (KI) derzeit?




73%

of respondents reported feeling that government regulation of AI to protect their identity data is important.

Video: Daten sicher schützen

ZUM
VIDEO



In der heutigen digitalen Welt war der Schutz deiner Daten noch nie so wichtig wie jetzt.

Dieses Video erklärt die komplexen Wechselwirkungen zwischen künstlicher Intelligenz und den Daten, die wir jeden Tag online teilen – von Social-Media-Beiträgen bis hin zu Online-Shopping-Gewohnheiten.



www.valuesai.eu

Folge unserer Reise



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die der Autor*innen und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die fördernde Einrichtung können dafür verantwortlich gemacht werden.

MODUL 06

KI und digitaler Fußabdruck

Die Kontrolle über das,
was du online hinterlässt

Inhaltsverzeichnis

01	Digitaler Fußabdruck (10 Min.)	3
02	Arten von digitalen Fußabdrücken (15 Min.)	8
03	Der Welleneffekt: Folgen für dich und andere (25 Min.)	15
04	Meine Entscheidung: einfache Checkliste + Aktionsplan (15 Min.)	25
05	So schützt du deinen digitalen Fußabdruck (10 Min.)	35
06	Reflexion, Quiz und Selbsttest (20 Min.)	39



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

01



Digitaler Fußabdruck (10 Min.)



Was ist ein digitaler Fußabdruck?

Ein digitaler Fußabdruck umfasst alle Daten und Spuren, die du bei Online-Aktivitäten hinterlässt. Dazu gehören zum Beispiel Social-Media-Profilen, Beiträge, Kommentare, Browserverlauf, Suchanfragen sowie Informationen, die Websites und Apps automatisch erfassen, z. B. Cookies, IP-Adresse oder Standortdaten.

Warum ist dein digitaler Fußabdruck wichtig?

Dein digitaler Fußabdruck kann Einfluss haben auf:



Datenschutz



Wer kann welche
Informationen über
dich sehen?



Reputation



Wie wirst du online
wahrgenommen?



Sicherheit



Welche
Informationen
könnten missbraucht
werden?



Andere



Deine Beiträge
können auch andere
bloßstellen oder
gefährden.

Warum ist dein digitaler Fußabdruck für KI wichtig?

Frage dich: Wo begegnen mir in meinen Alltags-Apps Entscheidungen von Algorithmen?



KI-Systeme können Signale aus deinem digitalen Fußabdruck nutzen, zum Beispiel:

- Verhaltensdaten: Klicks, Verweildauer, Likes oder Suchanfragen können genutzt werden, um vorherzusagen, was dich interessieren könnte.
- Passive Daten: Berechtigungen, Standortsignale und Gerätedaten können beeinflussen, welche Rückschlüsse Systeme über dich ziehen.
- Sichtbarkeit und Reichweite: KI kann beeinflussen, welche Inhalte empfohlen, beworben, ausgeblendet oder moderiert werden.
- Daten anderer Menschen: Deine Entscheidungen wirken sich auch auf andere aus, z. B. beim Markieren, Teilen von Bildern oder Weiterleiten von Screenshots.

Werteorientierter Einsatz von KI

Denke daran:
Ethische KI beginnt
mit alltäglichen
digitalen
Entscheidungen.



Vier Wertefragen als Leitfaden für digitale Entscheidungen:

- **Selbstbestimmung:** Treffe ich bewusst eine Entscheidung oder klicke ich nur automatisch?
- **Datenschutz:** Gebe ich mehr Daten preis als nötig – über mich oder andere?
- **Fairness:** Könnte meine Entscheidung jemandem schaden oder jemanden benachteiligen?
- **Transparenz:** Verstehe ich, wer die Informationen sehen kann und wie sie sich verbreiten können?

02



Arten von digitalen Fußabdrücken

(15 Min.)

Aktiver digitaler Fußabdruck

**Ein aktiver digitaler Fußabdruck entsteht durch Daten, die du bewusst online hinterlässt.
Beispiele:**

- Beiträge, Kommentare, Fotos oder Videos veröffentlichen
- Angaben in Formularen oder Umfragen machen
- Profile auf Websites, Plattformen oder in Apps erstellen
- Inhalte liken, teilen oder andere Personen markieren

Bei aktiven Spuren hast du vergleichsweise viel Kontrolle darüber, was du preisgibst.

Passiver digitaler Fußabdruck

Ein passiver digitaler Fußabdruck entsteht durch Daten, die automatisch erfasst werden – oft ohne dass du dir dessen vollständig bewusst bist. Beispiele:

- Browserverlauf und Serverprotokolle
- Cookies und Tracking-Daten Geräte-, System- und Standortdaten, z. B. IP-Adresse
- Interaktionen auf Plattformen, z. B. Klicks, Verweildauer oder angesehene Inhalte

Passive Spuren werden häufig von Analyse-, Werbe- und Tracking-Systemen erfasst. Sie lassen sich oft schwer löschen oder vollständig kontrollieren.

Aktive und passive digitale Spuren bilden zusammen den gesamten digitalen Fußabdruck einer Person.

Wie du diese Spuren verwaltest – z. B. durch das Löschen des Verlaufs, das Einschränken von Berechtigungen oder das Anpassen von Datenschutzeinstellungen – hat großen Einfluss auf deine Online-Sicherheit und deinen Datenschutz.



● Schnelle Übung: Sortiere die Spuren

Aufgabe (2 Minuten):
Ordne jedes Beispiel zu:

Aktiv

Passiv

Beides



- Einen Freund auf einem Foto markieren
- Eine App fragt nach Standortzugriff „immer“
- Einen öffentlichen Beitrag mit „Gefällt mir“ markieren
- Das Gerätemodell in den Metadaten eines Fotos
- Eine Story mit Standort-Sticker posten
- Cookies, die deine Klicks nachverfolgen
- Einen Screenshot eines privaten Chats machen
- Eine Plattform schlägt „Personen, die du vielleicht kennst“ vor

Das Wichtigste auf einen Blick: Viele Menschen unterschätzen ihren passiven digitalen Fußabdruck.

Wenn du an deinen digitalen Fußabdruck denkst, fallen dir vielleicht zuerst Beiträge, Fotos und Kommentare ein. Ein großer Teil entsteht jedoch auch ohne aktives Posten – durch Einstellungen, Gerätesignale, Berechtigungen und Surfverhalten.




Wo KI auf deinen digitalen Fußabdruck trifft: Beispiele aus dem Alltag

Du musst keine KI entwickeln oder aktiv nutzen, um von KI betroffen zu sein. Viele Online-Dienste setzen KI ein, um Inhalte zu personalisieren, Informationen zu bewerten oder Entscheidungen zu automatisieren – oft mithilfe von Signalen aus deinem digitalen Fußabdruck.



Häufige Beispiele:

- **Empfehlungen:** „Für dich“-Feeds, Videos, Musik oder Produkte
- **Ranking:** Was erscheint zuerst in der Suche oder in deinem Feed?
- **Targeting:** personalisierte Werbung und empfohlene Inhalte
- **Filterung und Moderation:** markierte Inhalte, eingeschränkte Reichweite oder gelöschte Inhalte
- **Mustererkennung:** Warnmeldungen bei ungewöhnlichen Anmeldungen oder verdächtigen Aktivitäten




03

Der Welleneffekt: Folgen für
dich und andere

(25 Min.)

Der Welleneffekt: Online-Aktivitäten haben eine größere Reichweite, als man denkt

Online-Inhalte können sich schnell über Menschen und Plattformen hinweg verbreiten. Selbst kleine Aktionen – ein Kommentar, eine Markierung oder ein Screenshot – können weitergegeben werden, ihren Kontext verlieren und länger zugänglich bleiben als beabsichtigt.



Der Welleneffekt: Online-Aktionen können weiter reichen, als du denkst



Ein Beitrag kann Folgendes auslösen:

- **Kopien:** Screenshots, Weiterleitungen, Downloads
- **Kontextverlust:** Witze oder Emotionen werden ohne Erklärung missverstanden
- **Lange Lebensdauer:** Alte Inhalte können Monate oder Jahre später wieder auftauchen
- **Größeres Publikum:** Freunde von Freunden, Gruppen oder öffentliches Teilen
- **Auswirkungen auf andere:** Personen in deinen Inhalten können ebenfalls betroffen sein – möglicherweise ohne ihre Zustimmung

Konsequenzen für dich: Privatsphäre, Reputation, Sicherheit und Wohlbefinden

Ein digitaler Fußabdruck ist nicht automatisch „gut“ oder „schlecht“. Entscheidend sind Kontext und Entscheidungen. Bestimmte Verhaltensmuster – z. B. übermäßiges Teilen, offene Einstellungen oder impulsives Posten – können vermeidbare Risiken schaffen.



Privatsphäre (Wer kann welche Informationen über dich erfahren?)	Reputation Wie wirst du wahrgenommen?	Sicherheit Was kann missbraucht werden?	Wohlbefinden (Stress und Konflikte)
Öffentliche Profile, Markierungen, Standortangaben und Berechtigungen können mehr preisgeben als beabsichtigt.	Beiträge können ohne Kontext gesehen werden; erste Eindrücke entstehen schnell und bleiben haften.	Zu viele Details können Betrug, Kontoübernahmen oder unerwünschten Kontakt erleichtern.	Streit, Belästigung oder Reue nach dem Posten können Selbstvertrauen und Stimmung beeinträchtigen.

Auswirkungen für dich: Privatsphäre, Reputation, Sicherheit und Wohlbefinden



Beispiel:

Ein Foto mit sichtbarem Standort und offenen Profileinstellungen kann verraten, wo du bist, mit wem du unterwegs bist und wie dein Tagesablauf aussieht – ohne dass du das ausdrücklich schreibst.

Frage dich: Welches Risiko ist für mich gerade am relevantesten: Privatsphäre, Reputation, Sicherheit oder Wohlbefinden?

Warum? Merke: Kleine Änderungen – z. B. Zielgruppe einschränken, Berechtigungen prüfen oder kurz innehalten, bevor du postest – können diese Risiken deutlich verringern.


Auswirkungen auf andere: Respekt, Einwilligung und Fairness

Häufige Arten, wie wir
andere online
exponieren oder
bloßstellen können:



- Inhalte veröffentlichen oder teilen, in denen andere Personen zu sehen sind
- Jemanden markieren oder erwähnen und dadurch mit Inhalten verknüpfen
- Screenshots aus privaten Chats teilen
- Aufenthaltsort, Zeitplan oder persönliche Geschichte einer Person preisgeben
- Inhalte teilen, die später zu Konflikten, Scham oder Missverständnissen führen können

Konsequenzen für ANDERE: Respekt, Einwilligung und Fairness



Konkretes Beispiel

Ein „lustiger“ Screenshot aus einem privaten Chat kann weitergeleitet, missverstanden und gegen jemanden verwendet werden – weil der ursprüngliche Kontext verloren geht.

Kleiner Selbsttest

Wäre es für mich in Ordnung, wenn jemand ohne zu fragen ähnliche Inhalte über mich teilen würde?

Der Schutz der Privatsphäre umfasst auch die Privatsphäre anderer. Einwilligung und Respekt sind Teil verantwortungsvollen Verhaltens im Internet.

Mini-Szenario: Wähle die verantwortungsvollste Option

Digitale Entscheidungen fallen oft spontan. Diese Übung hilft dir, eine Option zu wählen, die Privatsphäre schützt, Schaden minimiert und andere Menschen respektiert.



Szenario: Ein privater Screenshot

Ein Freund schickt dir einen Screenshot aus einem privaten Chat und sagt: „Das ist urkomisch – schick es weiter.“

Option 1: Leite ihn sofort weiter, weil er lustig ist.

Option 2: Behalte ihn für dich und frage deinen Freund, was er damit bezwecken will.

Option 3: Teile ihn nicht, es sei denn, die betroffenen Personen stimmen ausdrücklich zu. Im Zweifel: nicht teilen.

Mini-Szenario: Wähle die verantwortungsvollste Option

Digitale Entscheidungen fallen oft spontan. Diese Übung hilft dir, eine Option zu wählen, die Privatsphäre schützt, Schaden minimiert und andere Menschen respektiert.



Szenario: Ein privater Screenshot

Ein Freund schickt dir einen Screenshot aus einem privaten Chat und sagt: „Das ist urkomisch – schick es weiter.“

Deine Aufgabe (30–60 Sekunden):

Wähle Option 1, 2 oder 3.

Schreibe einen Satz: „Ich habe mich für Option ____ entschieden, weil ____.“

Hinweis: Die verantwortungsvollste Option schützt Privatsphäre, verhindert unnötigen Schaden und respektiert Einwilligung.

KI und Datenschutz – Beispiel

Worum es in diesem Beispiel geht:

- KI-Systeme können Daten aus alltäglichen Aktivitäten analysieren, z. B. soziale Medien, Surfen im Internet oder Online-Shopping.
- Je nach Tool, Einstellungen und Anbieter können personenbezogene Daten verarbeitet, gespeichert oder zur Verbesserung von Diensten genutzt werden.
- Selbst einfache Online-Verhaltensweisen können zu detaillierten Nutzerprofilen zusammengeführt werden.
- Deshalb ist wichtig: Teile nur Daten, die für den Zweck wirklich notwendig sind.



04

Deine Entscheidung: einfache
Checkliste + Aktionsplan

(15 Min.)

Mein Entscheidungshilfe- Tool: STOP – DENKEN – PRÜFEN – ENTSCHEIDEN

Diese Checkliste hilft dir, sicherere und fairere Online-Entscheidungen zu treffen. Nutze sie, bevor du etwas postest, teilst, markierst, einen Screenshot weiterleitest oder App-Berechtigungen akzeptierst – besonders, wenn du dich gehetzt oder emotional fühlst.



STOP	DENKEN	PRÜFEN	ENTSCHEIDEN
(5 Sekunden Pause):	(Zweck + Zielgruppe):	(Datenschutz + Menschen + Daten):	(bester nächster Schritt):
Poste ich aus einer Laune heraus, aus Langeweile, Wut, Aufregung oder unter Druck?	Was ist mein Ziel? Wer sieht es jetzt? Wer könnte es später sehen?	Ist die Zielgruppe richtig eingestellt? Sind andere Personen sichtbar? Werden Standort, Hintergrunddetails oder Metadaten preisgegeben?	Posten, bearbeiten, zuschneiden, unkenntlich machen, Zielgruppe einschränken, um Zustimmung bitten oder nicht teilen.

Szenario 1: Verwende die Checkliste für App-Berechtigungen

Siehe nächste Folie



Du hinterlässt nicht nur durch Surfen digitale Spuren, sondern auch durch die Berechtigungen, die du Apps erteilst.

Dieses Szenario hilft dir zu üben, nur notwendige Berechtigungen zu wählen und unnötige Datenzugriffe abzulehnen.

Szenario 1: App-Berechtigungen prüfen

Du installierst eine neue App, z. B. ein Bildbearbeitungsprogramm, ein Spiel oder eine Lern-App. Während der Einrichtung fragt sie nach Zugriff auf: Standort, Kontakte, Mikrofon und Fotos.

STOP

Klicke ich automatisch auf „Zulassen“, nur um die Einrichtung schnell abzuschließen?

DENKEN

Was benötigt die App wirklich, um ihre Hauptfunktion zu erfüllen? Kann ich sie auch mit weniger Berechtigungen nutzen?

PRÜFEN

Braucht die App Standortzugriff „immer“, „nur während der Nutzung“ oder gar nicht? Sind Kontakte, Mikrofon oder alle Fotos wirklich notwendig?

ENTSCHEIDEN

Erteile nur die minimal notwendigen Berechtigungen. Bevorzuge „nur während der Nutzung“ statt „immer“. Prüfe später erneut, ob du Berechtigungen ändern kannst.

Szenario 2: Verwende die Checkliste, wenn andere Personen beteiligt sind

Siehe nächste Folie



Wenn deine Inhalte andere Personen betreffen, wirkt sich deine Entscheidung auch auf sie aus.

Dieses Szenario hilft dir, Entscheidungen zu treffen, die Privatsphäre und Einwilligung respektieren. Denn Teilen, Markieren und Weiterleiten lassen sich oft nur schwer rückgängig machen.

Szenario 2:

Du hast ein Gruppenfoto von einem Treffen, einer Veranstaltung oder einem Abend. Du möchtest es posten und deine Freunde markieren. Eine Person auf dem Foto hat zuvor gesagt, dass sie nicht online gezeigt werden möchte.

STOP

Will ich den Beitrag schnell veröffentlichen, weil ich den Moment sofort teilen möchte?

DENKEN

Was ist der Zweck des Beitrags? Ist das Markieren notwendig? Wer sieht den Beitrag jetzt und wer könnte ihn später sehen?

PRÜFEN

Haben alle zugestimmt, gezeigt oder markiert zu werden? Ist der Beitrag öffentlich oder auf eine kleine Gruppe beschränkt? Könnte das Foto jemandem später schaden oder peinlich sein?

ENTSCHEIDEN

Frage die Personen zuerst. Wähle ein anderes Foto, schneide die Person heraus, mache sie unkenntlich, schränke die Zielgruppe ein oder poste das Foto nicht.

Szenario 3: Verwende die Checkliste, bevor du etwas postest

Siehe nächste Folie



Beim Posten entstehen oft aktive digitale Spuren: Fotos, Kommentare, Markierungen, Standortangaben oder Stories.

Dieses Szenario hilft dir zu üben, vor dem Teilen kurz innezuhalten und eine bewusstere Entscheidung zu treffen.

Szenario 3:

Du möchtest ein Foto von einem Abend, einer Veranstaltung oder einem Treffen posten. Im Bild sind andere Personen, ein Ort und einige Hintergrunddetails zu sehen.

STOP

Poste ich gerade aus einer starken Emotion heraus – z. B. Begeisterung, Ärger oder Gruppendruck?

DENKEN

Warum will ich das posten? Wer soll es sehen? Könnte es später von anderen gesehen oder geteilt werden?

PRÜFEN

Sind andere Personen sichtbar? Ist der Standort erkennbar? Sind private Details im Hintergrund zu sehen? Ist die Zielgruppe richtig eingestellt?

ENTSCHEIDEN

Bearbeite das Foto, entferne den Standort, frage um Zustimmung, schränke die Zielgruppe ein oder poste es nicht.

Drei wirkungsvolle Maßnahmen: kleine Änderungen, große Wirkung




Du musst nicht jede Datenschutzeinstellung im Detail kennen, um deinen digitalen Fußabdruck zu verbessern. Diese drei Einstellungen haben auf den meisten Plattformen und in den meisten Apps eine große Wirkung – und lassen sich auch mit wenig Zeit überprüfen. Dein digitaler Fußabdruck verbessert sich besonders schnell, wenn du Sichtbarkeit, Standortfreigabe und Auffindbarkeit kontrollierst.

Drei wirkungsvolle Maßnahmen: kleine Änderungen, große Wirkung



1. **Sichtbarkeit für andere:** Überprüfe, ob deine Standardeinstellung „öffentlich“, „Freunde“, „enge Freunde“ oder „privat“ ist. Denke daran: „Freunde von Freunden“ oder offene Gruppen können immer noch ein großes Publikum sein.
2. **Standortfreigabe:** Vermeide es, deinen Standort in Echtzeit öffentlich zu teilen. Wähle nach Möglichkeit „nur während der Nutzung“ oder deaktiviere Standortzugriff, wenn er nicht nötig ist.
3. **Auffindbarkeit und Kontaktsynchronisierung:** Überprüfe, ob dein Profil über Telefonnummer oder E-Mail gefunden werden kann. Prüfe auch, ob Apps deine Kontakte automatisch synchronisieren.

05

A large, stylized heart shape is visible in the background, composed of concentric, slightly irregular lines. A horizontal line with a color gradient from pink to blue passes behind the text '05' and extends across the slide.

So schützt du deinen
digitalen Fußabdruck

(10 Min.)

Praktische Hinweise



01

Teile weniger persönliche Informationen in sozialen Medien.



02

Passe deine Datenschutzeinstellungen in sozialen Medien an.



03

Reduziere die Daten, die online über dich gespeichert oder sichtbar sind.



04

Lösche gelegentlich Browser-Cookies und andere Tracking-Daten auf privaten Geräten.

Praktische Regeln



06

Nutze sichere Verbindungen; ein VPN kann in manchen Situationen sinnvoll sein, z. B. in öffentlichen WLANs.



07

Beschränke den Standortzugriff von Apps oder deaktiviere ihn, wenn er nicht nötig ist.



08

Halte Geräte, Apps und Sicherheitssoftware aktuell.



09

Überprüfe regelmäßig wichtige Konten, z. B. Bank-, E-Mail- und Gesundheitskonten, auf ungewöhnliche Aktivitäten.

○ Praktische Hinweise



10

Öffne keine Anhänge und klicke nicht auf Links aus unbekannten oder fragwürdigen Quellen.



11

Aktiviere Sicherheitsbenachrichtigungen für wichtige Konten, z. B. Login-Warnungen oder Hinweise auf Datenpannen.



12

Aktualisiere Passwörter und Schutzmaßnahmen, besonders nachdem du über eine Datenpanne informiert wurdest. Nutze nach Möglichkeit starke, einzigartige Passwörter und Zwei-Faktor-Authentifizierung.

06




Quiz und
Selbsttest

(20 Min.)



Quiz

Dieses Quiz hilft dir, in realistischen Situationen Entscheidungen zu treffen, die zu einem sichereren digitalen Fußabdruck führen. Es geht um Datenschutzeinstellungen, Standort, Berechtigungen, Auffindbarkeit und Rücksichtnahme auf andere.



Selbsttest: Überprüfe deinen digitalen Fußabdruck

Bist du dir unsicher, wie umfangreich dein digitaler Fußabdruck ist? Beantworte die Fragen mit „Ja“ oder „Nein“ und zähle anschließend deine Ja-Antworten.

1. Kaufst du online ein?
2. Hast du schon einmal ein Konto erstellt, um Gutscheine oder Rabatte zu erhalten?
3. Hast du Newsletter, Blogs oder Updates abonniert?
4. Hast du Shopping-Apps heruntergeladen und genutzt?
5. Hast du schon einmal ein neues Online-Zahlungs- oder Kreditkartenkonto eröffnet?
6. Nutzt du eine Mobile-Banking-App?
7. Hast du schon einmal Aktien, Fonds oder Kryptowährungen gekauft oder verkauft?
8. Hast du deine E-Mail-Adresse bei einem Fitnessstudio, Verein oder Kursanbieter registriert?
9. Nutzt du Apps, um Aktivitäten, Schritte, Sport oder Training zu erfassen?

Test: Überprüfen Sie Ihren digitalen Fußabdruck

Bist du dir bezüglich deines digitalen Fußabdrucks unsicher? Beantworte die folgenden Fragen mit „Ja“ oder „Nein“ und zähle anschließend die Gesamtzahl der „Ja“-Antworten, um die Komplexität deines Fußabdrucks zu ermitteln.

9. Abonniertst du eine Online-Publikation oder Nachrichtenquelle?
10. Hast du schon einmal Artikel oder Informationen geteilt, die du online gelesen hast?
11. Nutzt du soziale Medien auf deinem Computer oder Smartphone?
12. Kommunizierst du online mit Freund*innen?
13. Hast du schon einmal Informationen, Dateien oder Fotos mit Online-Kontakten geteilt?
14. Hast du dich schon einmal bei einer Dating-Website oder Dating-App angemeldet?
15. Hast du dich schon einmal mit einem bestehenden Konto bei einer anderen App oder Website angemeldet?

Selbsttest:

Wichtig: Das Ergebnis ist keine
Bewertung. Es zeigt nur, wie viele
digitale Spuren durch alltägliche
Online-Aktivitäten entstehen können.

Quelle: *Der digitale Fußabdruck eines Insiders und die damit verbundenen Risiken. Arbeitshilfe.* Defense Counterintelligence and Security Agency (CDSE), 2022
<https://www.cdse.edu/Portals/124/Documents/jobajds/insider/insiders-digital-footprint.pdf>

Ergebnisse

Ja-Antworten <5

Dein digitaler Fußabdruck ist wahrscheinlich weniger komplex als der vieler Internetnutzer*innen.

Ja-Antworten 5–12

Dein digitaler Fußabdruck liegt wahrscheinlich im durchschnittlichen Bereich.

Ja-Antworten 12+

Dein digitaler Fußabdruck ist wahrscheinlich komplexer als der vieler Internetnutzer*innen.

Prüfung deines digitalen Fußabdrucks



Jetzt übst du, häufige Risiken im Zusammenhang mit deinem digitalen Fußabdruck zu erkennen und praktische Verbesserungen auszuwählen.

Du kannst diese Übung ohne persönliche Angaben durchführen:

Option A: Verwende ein fiktives Beispiel oder eine typische Social-Media-App als Gedankenübung.

Option B: Überprüfe privat eine Einstellung auf deinem eigenen Gerät oder in einem Konto. Du musst nichts teilen oder zeigen.

Prüfung deines digitalen Fußabdrucks – Wähle eine Social- Media-App aus

Ziel: Nicht dein Online-Leben löschen, sondern unnötige Sichtbarkeit reduzieren und deinen digitalen Fußabdruck bewusster gestalten.

Notiere:

Risiko 1 → Maßnahme 1: _____

Risiko 2 → Maßnahme 2: _____

Risiko 3 → Maßnahme 3: _____

Schritt 1: Identifiziere 3 Risiken

- Zu große öffentliche Sichtbarkeit
- Standort wird preisgegeben
- Markierungen/Erwähnungen ohne Einwilligung
- Zu weitreichende Berechtigungen
- Persönliche Angaben sichtbar, z. B. Schule, Arbeit, Telefonnummer, E-Mail oder Routinen

Schritt 2: Wähle 3 Verbesserungen

- Zielgruppe einschränken oder auf privat umstellen
- Standortfreigabe entfernen oder einschränken
- Vor dem Markieren oder Posten um Einwilligung bitten
- Berechtigungen auf das notwendige Minimum reduzieren
- Sensible Angaben aus dem Profil entfernen

Schritt 3: Erste Maßnahme

- Welche Änderung würdest du zuerst vornehmen, wenn du nur 2 Minuten Zeit hättest?

Prüfung deines digitalen Fußabdrucks

Merke: Ein digitaler Fußabdruck verbessert sich durch kleine, konsequente Maßnahmen – nicht durch eine perfekte Einstellung. Wenn dein Plan zu groß erscheint, reduziere ihn auf eine Einstellung und eine Gewohnheit.

1. Eine Änderung, die ich heute vornehmen werde (5 Minuten)

Beispiele:

- Sichtbarkeit des Profils einschränken
- Standortfreigabe deaktivieren
- Eine Berechtigung reduzieren
- Auffindbarkeit überprüfen

Heute werde ich:

.....

.....

.....

Prüfung deines digitalen Fußabdrucks

Merke: Ein digitaler Fußabdruck verbessert sich durch kleine, konsequente Maßnahmen – nicht durch eine perfekte Einstellung. Wenn dein Plan zu groß erscheint, reduziere ihn auf eine Einstellung und eine Gewohnheit.

2. Zwei Änderungen, die ich diese Woche vornehmen werde (insgesamt 10–20 Minuten)

Beispiele:

- Datenschutzeinstellungen überprüfen
- Alte öffentliche Beiträge löschen
- App-Berechtigungen überprüfen
- Passwort-Einstellungen aktualisieren (falls zutreffend)

Diese Woche werde ich:

.....

.....

.....

Prüfung deines digitalen Fußabdrucks

Merke: Ein digitaler Fußabdruck verbessert sich durch kleine, konsequente Maßnahmen – nicht durch eine perfekte Einstellung. Wenn dein Plan zu groß erscheint, reduziere ihn auf eine Einstellung und eine Gewohnheit.

2. Zwei Änderungen, die ich diese Woche vornehmen werde (insgesamt 10–20 Minuten)

Beispiele:

- Datenschutzeinstellungen überprüfen
- Alte öffentliche Beiträge löschen
- App-Berechtigungen überprüfen
- Passwort-Einstellungen aktualisieren (falls zutreffend)

Diese Woche werde ich:

.....

.....

.....

Prüfung des digitalen Fußabdrucks

Merke: Ein digitaler Fußabdruck verbessert sich durch kleine, konsequente Maßnahmen – nicht durch eine perfekte Einstellung. Wenn dein Plan zu groß erscheint, reduziere ihn auf eine Einstellung und eine Gewohnheit.

3. Eine Gewohnheitsregel, an die ich mich künftig halten werde (tägliche Entscheidung)

Beispiele:

- Ich nutze vor dem Teilen die Checkliste STOP – DENKEN – PRÜFEN – ENTSCHIEDEN.
- Ich frage vor dem Markieren um Zustimmung.
- Ich vermeide Echtzeit-Standortangaben.

Meine Regel lautet:

.....

.....

.....



www.valuesai.eu

Verfolgen Sie unsere
Reise



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

MODUL 07

Rechtskonformes Handeln mit KI

Rechte, Einwilligung und verantwortungsvoller Umgang

Inhaltsverzeichnis

01	Warum rechtskonformes Handeln mit KI wichtig ist (10 Min.)	3
02	Stimme, Einwilligung und KI (10 Min.)	9
03	Bild- und Abbildrechte (10 Min.)	14
04	Urheberrecht im Zeitalter der KI (10 Min.)	19
05	KI-Recht: EU-KI-Gesetz und DSGVO (10 Min.)	23



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.


01

Warum rechtskonformes
Handeln mit KI wichtig ist
(10 Min.)

**KI-Tools machen es einfach,
innerhalb von Sekunden Stimmen
zu klonen, Gesichter zu generieren,
Stile zu kopieren und Texte
wiederverwenden.**

**Aber: Nur weil etwas technisch
möglich ist, heißt das noch lange
nicht, dass es auch rechtlich erlaubt
oder verantwortungsvoll ist.**

Warum das wichtig ist:



- Rechtsverstöße können zu Geldstrafen, Klagen, Löschungen von Inhalten und Reputationsschäden führen.
 - Die Verantwortung liegt häufig bei der Person, die KI-Ergebnisse nutzt oder veröffentlicht – nicht beim KI-Tool.
 - Rechtskonforme Nutzung ist auch eine Form von Respekt: gegenüber Menschen, Kreativen und Institutionen.
 - „Rechtskonform“ bedeutet mehr als nur Urheberrecht: Es betrifft auch Persönlichkeitsrechte, Datenschutz und KI-spezifische Regeln.
- 

Beispiel: Eine KI zu bitten, einen öffentlichen Nachrichtenartikel zusammenzufassen, ist in der Regel unproblematischer. Eine KI zu bitten, die Stimme eines Kollegen für einen Streich zu klonen – ohne seine Einwilligung – ist es nicht.

Der Einsatz von KI kann verschiedene rechtliche Risikobereiche berühren

Beim Einsatz von KI können mehrere rechtliche Fragen gleichzeitig entstehen:

1. **Risiko im Bereich der Persönlichkeitsrechte:** Die Verwendung der Stimme, des Gesichts oder des Namens einer Person ohne deren Einwilligung – selbst in fiktionalen Werken oder Satiren – kann deren Bild- und Persönlichkeitsrechte verletzen.
2. **Urheberrechtliches Risiko:** KI-Eingaben und -Ausgaben können geschützte Werke kopieren. Generierte Bilder können bestehenden Kunstwerken ähneln; generierte Texte können Passagen wiedergeben.
3. **Regulatorisches Risiko:** Die DSGVO, das EU-KI-Gesetz, branchenspezifische Gesetze (Gesundheit, Finanzen, Bildung) und Verträge können Pflichten auferlegen – insbesondere im Zusammenhang mit der Offenlegung und personenbezogenen Daten.



TUN



Frage: Wessen Rechte sind davon betroffen? Könnte ein Gericht dem zustimmen?



Nutze einfache Prüfungen: Voice Gate, Bild-Checkliste, Urheberrechtsprüfung. Hole Einwilligungen oder Lizenzen ein, wenn reale Personen oder geschützte Werke betroffen sind. Kennzeichne KI-generierte Inhalte, wenn es erforderlich oder sinnvoll ist.



NICHT TUN




Gehe nicht automatisch davon aus, dass KI-Ergebnisse rechtlich unbedenklich sind.



Verwende KI nicht, um echte Personen ohne Einwilligung nachzuahmen.

Veröffentliche keine KI-Inhalte, wenn du Rechte, Quellen oder Kennzeichnungspflichten nicht geprüft hast.



Vier Fragen für rechtskonforme KI-Nutzung

Rechtskonforme KI-Nutzung bedeutet: fundierte, wertorientierte Entscheidungen treffen. Stelle dir diese vier Fragen, wenn deine KI-Nutzung rechtliche Folgen haben könnte.

Rechtsgrundlage

Habe ich eine klare Grundlage, z. B. Einwilligung, Lizenz, Genehmigung oder eine zulässige Ausnahme?

Rechte

Wessen Rechte berührt meine Nutzung – Stimme, Gesicht, Name, Bild, Text, Musik oder geistiges Eigentum?

Transparenz

Kann ich Nutzerinnen oder Leserinnen klar mitteilen, wann KI eingesetzt wurde?

Verantwortung

Könnte ich meine Entscheidung erklären und begründen, wenn sie später hinterfragt wird?

Rechtskonforme KI-Nutzung = fundierte, wertorientierte Entscheidungen

02

Stimme, Einwilligung und KI (10 Min.)

Stimmen sind Daten – und die sind persönlich



KI kann eine Stimme anhand weniger Sekunden Audio imitieren oder klonen. Dadurch wird die Stimme rechtlich und ethisch besonders sensibel.

- Eine Stimme kann eine Person identifizieren. Nach der DSGVO kann sie personenbezogenes Datum sein; Stimmprofile können unter Umständen biometrische Daten sein.
- Eine Stimme kann kommerziellen Wert haben, z. B. für Sprecherinnen, Sängerinnen, Schauspieler*innen oder öffentliche Personen.
- Schon eine Stimme, die „ähnlich klingt“, kann schaden: Rufschädigung, Täuschung oder Betrug sind möglich.
- Bestehende Aufnahmen können zusätzlich durch Leistungsschutz- oder Urheberrechte geschützt sein.

Das Wichtigste auf einen Blick: Stimme und Recht



Das Klonen, Verändern oder Imitieren einer echten Stimme kann mehrere rechtliche Bereiche betreffen:

- **Persönlichkeitsrechte:** Die Stimme kann Teil der Identität einer Person sein. Kommerzielle Nutzung oder täuschende Nutzung ohne Einwilligung ist besonders riskant.
- **DSGVO:** Die Verarbeitung von Stimmen benötigt in der Regel eine Rechtsgrundlage. Stimmprofile können besonders schutzwürdig sein.
- **Rechte von ausübenden Künstler*innen:** Schauspielerinnen, Sprecherinnen und Sänger*innen können Rechte an aufgezeichneten Darbietungen haben.
- **Täuschung, Betrug und Rufschädigung:** Stimmklone können missbraucht werden, um Identitäten vorzutäuschen oder falsche Aussagen zu erzeugen.

Voice Consent Gate: 3 Fragen vor dem Einsatz einer Stimme

Wende diese Prüfung immer an, wenn deine KI-Nutzung die Stimme einer realen Person betrifft – z. B. Klon, Imitation oder Bearbeitung.



Einwilligung / Lizenz

Habe ich eine schriftliche Einwilligung oder eine klare Lizenz für diese Stimme und diesen Zweck?

Identifizierbarkeit / Risiko

Könnte das Ergebnis mit der echten Person verwechselt werden? Könnte es schaden, täuschen oder irreführen?

Offenlegung:

Werde ich deutlich machen, dass der Inhalt KI-generiert oder KI-bearbeitet ist, wenn dies gesetzlich, vertraglich oder nach Plattformregeln erforderlich ist?

Wenn du eine Frage mit „Nein“ oder „Ich bin nicht sicher“ beantwortest: Nutze eine vollständig synthetische, nicht identifizierbare Stimme oder eine ordnungsgemäß lizenzierte Stock-Stimme. „Ich bin nicht sicher“ ist ein Warnsignal.



Mikroaufgabe: Stimm-Szenarien

Aufgabe (60–90 Sekunden): Bewerte jede Situation als „zulässig“, „riskant“ oder „nicht tun“ – und gib eine kurze Begründung.

1. Die Stimme eines Politikers wird für ein satirisches Video in sozialen Medien geklont – ohne Offenlegung.
2. Eine KI-Stimme aus einem Archiv mit kommerzieller Lizenz wird für ein Video genutzt.
3. Du klonst deine eigene Stimme für das Intro deines Podcasts.
4. Du klonst die Stimme eines Kollegen „nur zum Spaß“, ohne ihn zu informieren.
5. Die Stimme eines verstorbenen Schauspielers wird in einer Werbung verwendet – ohne Genehmigung der Erben.
6. Eine Stimme wird erzeugt, die einer realen Person „nur ähnlich klingt“.

03

Recht am eigenen Bild und Abbildrechte

(10 Min.)

Bildrechte und KI: Zwei Dinge, die du prüfen musst

KI kann **Gesichter in Sekunden generieren, bearbeiten, austauschen oder altern lassen. Dabei sind meistens zwei rechtliche Ebenen wichtig:**



- **Rechte der abgebildeten Person.** Wenn eine reale Person erkennbar ist, brauchst du in der Regel eine Einwilligung für die konkrete Nutzung. Bei biometrischen Daten kann zusätzlich die DSGVO relevant sein.
- **Rechte am Foto selbst.** Auch das Foto kann urheberrechtlich geschützt sein. Du brauchst eine Lizenz oder eine andere rechtliche Grundlage, selbst wenn die abgebildete Person zustimmt.

Was zählt als Nutzung des Bildes einer Person?

Als Nutzung kann zum Beispiel gelten:



- Ein Foto in ein KI-Tool hochladen, um Variationen zu erzeugen
- Ein Gesicht in einen neuen Hintergrund oder eine neue Szene einfügen
- Eine Person altern lassen, stilisieren oder stark verändern
- Ein Bild so bearbeiten, dass eine irreführende oder entwürdigende Darstellung entsteht
- Ein eigenes KI-Modell mit Bildern realer Personen trainieren

Besonders riskant: sexuelle, politische, medizinische oder strafrechtliche Kontexte.

Das Wichtigste auf einen Blick: Checkliste für Bilder

Bevor du KI mit Bildern realer Personen nutzt, prüfe vier Dinge:



Wenn du nicht alle vier Fragen beantworten kannst: Erzeuge oder veröffentliche das Bild nicht.

- 1. Rechte am Foto:** Gehört das Foto dir oder hast du eine Lizenz, z. B. Bilddatenbank oder Creative Commons?
- 2. Rechte der Person:** Hast du eine Einwilligung für genau diese Nutzung? Eine alte Einwilligung für einen anderen Zweck reicht nicht automatisch für neue KI-Anwendungen.
- 3. Kontext:** Könnte der neue Kontext die Person in Verlegenheit bringen, ihr schaden oder irreführen? Sexuelle, politische, medizinische und strafrechtliche Kontexte sind besonders riskant.
- 4. Offenlegung:** Musst du das Bild als KI-generiert oder KI-bearbeitet kennzeichnen, z. B. nach EU-KI-Gesetz, Plattformregeln oder journalistischen Standards?



Mikroaufgabe: Bild-Szenarien

Aufgabe (60–90 Sekunden):
Entscheide bei jedem
Beispiel: „in Ordnung“,
„riskant“ oder „nicht tun“ –
und gib kurz deine
Begründung.

Tipp: Wenn das Ergebnis
Betrachter*innen über eine
reale Person täuschen könnte:
„riskant“ oder „nicht tun“.

1. Einen fiktiven Avatar erstellen, der keine reale Person zeigt.
2. Das Gesicht eines Kollegen ohne Einwilligung in ein Meme einfügen.
3. Ein altes Familienfoto mit KI für den privaten Gebrauch restaurieren.
4. Ein gefälschtes „Vorher-Nachher“-Bild einer öffentlichen Person für politische Inhalte erstellen.
5. Ein KI-Porträt aus einer Bilddatenbank mit kommerzieller Lizenz auf deiner Website nutzen und deutlich als KI-generiert kennzeichnen.
6. Dein eigenes Selfie mit einem KI-Filter bearbeiten und veröffentlichen.

04



Urheberrecht im Zeitalter der KI


(10 Min.)

Trainingsdaten und Urheberrecht

KI-Modelle werden mit großen Mengen an Text, Bildern, Code und Audio trainiert. Vieles davon kann urheberrechtlich geschützt sein.

- Ob KI-Training rechtmäßig ist, wird international unterschiedlich bewertet und ist teilweise umstritten.
- Für Nutzer*innen entsteht das praktische Risiko oft beim Ergebnis: KI kann unbeabsichtigt geschützte Texte, Logos, Figuren, Kompositionen oder Bildbestandteile reproduzieren.
- Ein Stil ist meist nicht als solcher urheberrechtlich geschützt. Geschützte Figuren, Logos, Marken und konkrete Werke sind jedoch besonders riskant.
- „Die KI hat es gemacht“ ist keine sichere Verteidigung. Verantwortlich ist in der Regel die Person, die das Ergebnis veröffentlicht oder nutzt.

Überprüfe KI-Ergebnisse vor der Veröffentlichung immer auf mögliche Kopien – besonders bei Bildern, Logos, Figuren und längeren Textpassagen.



Wem gehören KI-generierte Inhalte?

Eigentum / Urheberrecht

- Rein KI-generierte Inhalte sind in vielen Rechtsordnungen möglicherweise nicht oder nur eingeschränkt urheberrechtlich geschützt.
- Für Urheberrechtsschutz braucht es meist einen menschlichen kreativen Beitrag.
- Umfangreiche menschliche Bearbeitung, Auswahl und Gestaltung können deine Position stärken.

Nutzungsrechte / Tool-Bedingungen

- Viele Anbieter erlauben die Nutzung von KI-Ergebnissen, auch kommerziell. Prüfe trotzdem die Nutzungsbedingungen.
- Eine Nutzungserlaubnis bedeutet nicht automatisch, dass du andere daran hindern kannst, ähnliche Ergebnisse zu verwenden.
- Das Risiko einer Rechtsverletzung bleibt bei dir: Wenn ein KI-Ergebnis z. B. einem geschützten Logo oder Werk zu stark ähnelt, kann die Nutzung problematisch sein.

Plagiate, Quellenangaben und KI


Urheberrecht und Plagiat sind zwei verschiedene Dinge:



- **Urheberrecht ist ein Rechtsgebiet:** Es regelt, wer ein Werk kopieren, bearbeiten oder wiederverwenden darf.
- **Plagiat ist eine ethische oder akademische Regel:** Es geht darum, fremde Arbeit als eigene auszugeben – auch wenn keine Urheberrechtsverletzung vorliegt.
- Universitäten, Fachzeitschriften und viele Arbeitgeber verlangen mittlerweile, dass der Einsatz von KI offengelegt wird. Manche verbieten ihn bei bewerteten Arbeiten.
- Häufige Regel: KI ist kein Mitautor. Du musst angeben, welche Teile KI-gestützt entstanden sind, und bleibst für Richtigkeit und Quellen verantwortlich.

Bewahre Prompts und Entwürfe auf, nenne verwendete Tools und überprüfe jede Tatsache, jedes Zitat und jede Quellenangabe. KI kann Quellen erfinden.

05

A large, faint heart shape is visible in the background on the right side of the slide. A horizontal line with a color gradient from pink to blue extends from the left edge of the slide, passing behind the number '05' and ending at the start of the dark blue box.

KI-Recht: EU-KI-Gesetz und
DSGVO

(10 Min.)

Das EU-KI-Gesetz in Kürze: ein risikobasierter Ansatz

Das EU-KI-Gesetz unterteilt KI-Anwendungen nach Risikostufen. Deine Pflichten hängen davon ab, wie riskant die Anwendung ist.

Verboten	Hochrisiko	Begrenztes Risiko	Minimales Risiko
Beispiele: bestimmte Formen manipulativer KI, Social Scoring, unzulässiges Scraping von Gesichtsbildern oder biometrische Echtzeit-Identifizierung im öffentlichen Raum mit engen Ausnahmen.	KI in sensiblen Bereichen wie Personalwesen, Bildung, kritische Dienste, Strafverfolgung oder Medizinprodukte. Hier gelten strenge Pflichten, z. B. Risikomanagement, Datenqualität, Dokumentation und menschliche Aufsicht.	Zum Beispiel Chatbots oder Deepfakes. Hier sind Transparenzpflichten wichtig: Nutzer*innen müssen wissen, dass sie mit KI interagieren oder KI-generierte Inhalte sehen.	Zum Beispiel Spamfilter, KI in Videospielen oder Produktivitätshilfen. Das EU-KI-Gesetz sieht hier meist keine besonderen Pflichten vor – andere Gesetze wie DSGVO oder Urheberrecht gelten trotzdem.

DSGVO trifft KI: Die Regeln gelten weiterhin

Rechtmäßigkeit

Lege eine Rechtsgrundlage fest, z. B. Einwilligung, Vertrag oder berechtigtes Interesse.

Zweckbindung

Nutze Daten nur für den Zweck, für den sie erhoben oder freigegeben wurden.

Datenminimierung

Gib nur das weiter, was für die KI-Aufgabe wirklich erforderlich ist.

Genauigkeit

Falsche Eingaben können zu falschen oder unfairen Ergebnissen führen.

Speicherbegrenzung

Bewahre Prompts und Ergebnisse nicht länger auf als nötig.

Integrität und Vertraulichkeit

Schütze Daten vor Lecks. Nutze bei sensiblen Daten nur geeignete und freigegebene Tools.

Wenn KI-Eingaben identifizierbare Personen enthalten, gilt die DSGVO weiterhin. Besondere Datenkategorien – z. B. Gesundheit, biometrische Daten, Stimme, Religion oder politische Überzeugungen – benötigen besonders starke Rechtfertigungen, häufig ausdrückliche Einwilligung.

Offenlegungs- und Transparenz- pflichten

**Immer mehr Regeln
verlangen, dass der
Einsatz von KI
offengelegt wird. Im
Zweifel ist
Transparenz oft die
sicherere Wahl.**



Eine Offenlegung ist häufig erforderlich oder sinnvoll bei:

- KI-generierten Audio-, Bild- oder Videoinhalten, die echten Personen, Orten oder Ereignissen ähneln
- Chatbots und KI-Agenten, die mit Nutzer*innen interagieren
- wissenschaftlichen, journalistischen oder schulischen Arbeiten, wenn Regeln dies verlangen
- Leistungen für Kund*innen, wenn Verträge oder interne Richtlinien den KI-Einsatz regeln

Einfache Formulierung:

„Mit KI-Unterstützung erstellt; geprüft und bearbeitet von [Name].“



Hauptaktivität: Eine Anfrage rechtskonform gestalten (10 Minuten)

Anhand fiktiver Beispiele übst du die gesamte Vorgehensweise. Ziel ist es, riskante KI-Nutzungen in rechtskonforme Alternativen umzuwandeln – ohne den Nutzen aufzugeben.

Für jedes Szenario:

1. Ermittle die rechtlichen Risiken: Persönlichkeitsrechte, Urheberrecht, Datenschutz oder Regulierung.
2. Formuliere die Anfrage rechtskonform um: Einwilligung, lizenzierte Alternativen, Abstraktion
3. .Wähle die passende Offenlegung: KI-Hinweis, Kennzeichnung oder nicht erforderlich.
4. Entscheide: fortfahren, mit Änderungen fortfahren oder abbrechen.

Ergebnis: Ein kurzes Legal AI Playbook, das du bei deiner täglichen KI-Nutzung verwenden kannst.



Übung 1: Stimmklon (Persönlichkeitsrechte + Offenlegung)

Szenario (fiktiv): „Meine Freundin ist krank. Ich möchte die Stimme ihres Lieblingssängers klonen, um ein persönliches Lied für ihren Geburtstag aufzunehmen.“

Schreibe deine Antworten (kurz):

Rechtliche Risiken: _____

Rechtskonforme Umformulierung:

Offenlegung: _____

Entscheidung (fortfahren / ändern / stoppen): _____

Schritt-für-Schritt-Anleitung:

- **Voice Gate:** Hast du die Erlaubnis des Sängers oder eine Lizenz für diese Stimme und diese Nutzung?
- **Risiko:** Könnte das Ergebnis mit dem echten Sänger verwechselt werden? Könnte es veröffentlicht oder weitergeleitet werden?
- **Rechtskonforme Alternative:** Verwende keine imitierte Stimme einer realen Person ohne Erlaubnis. Nutze stattdessen eine generische KI-Stimme, eine lizenzierte Stock-Stimme oder schreibe einen eigenen Text.
- **Offenlegung:** Kennzeichne den Inhalt beim Teilen klar als KI-generiert.



Übung 2: Bildnutzung (Abbild + DSGVO)

Szenario (fiktiv): „Ich habe auf Instagram ein Foto gefunden, auf dem das lächelnde Kind eines Fremden zu sehen ist. Ich möchte es mithilfe von KI auf der Homepage meines Unternehmens als ‚zufriedenen Kunden‘ präsentieren.“

Schreibe deine Antworten (kurz):

Rechtliche Risiken: _____

Rechtskonforme Umformulierung:

Offenlegung: _____


Entscheidung (fortfahren / ändern

Schritt-für-Schritt-Anleitung:

- **Bild-Checkliste:** Hast du Rechte am Foto? Hast du die Einwilligung der abgebildeten Person bzw. bei Kindern der Eltern/Sorgeberechtigten? Ist der Kontext fair und nicht irreführend?
- **DSGVO / Persönlichkeitsrechte:** Das Bild eines Kindes ist besonders sensibel. Du brauchst einen klaren Zweck und in der Regel ausdrückliche Einwilligung.
- **Rechtskonforme Alternative:** Verwende ein lizenziertes Stockfoto, eine klar gekennzeichnete fiktive KI-Person oder hole eine ausdrückliche Einwilligung ein.
- **Offenlegung:** Kennzeichne KI-generierte Bilder. Stelle eine fiktive Person niemals als echte Kundin oder echten Kunden dar.

Dein Leitfaden für rechtskonforme KI-Nutzung

Bewahre ihn für später auf.



Schreibe kurze Regeln auf, die du anwenden kannst, wenn du das nächste Mal KI nutzt.

Meine Stimmregel:

„Ich werde KI nur dann zum Klonen oder Nachahmen einer echten Stimme verwenden, wenn

_____.“

Meine Bildregel:

„Ich werde das Gesicht einer realen Person nur dann mit KI bearbeiten oder verwenden, wenn

_____.“

Meine Urheberrechtsregel:

„Bevor ich KI-Ergebnisse veröffentliche, prüfe ich, ob

_____.“

Meine DSGVO-/KI-Gesetz- Regel:

„Wenn meine Eingabe Daten anderer Personen enthält, werde ich

_____.“

Meine Offenlegungsregel:

„Wenn KI wesentlich geholfen hat, werde ich

_____angeben.“

„Selbst wenn sie keine Urheberrechte an den KI-Ergebnissen besitzen, kann dennoch die Person haften, die die Prompt-Kette zusammengestellt und die Erstellung dieses Deepfakes tatsächlich veranlasst hat – unabhängig davon, ob KI daran beteiligt war oder nicht.“

Tara Aaron-Stelluto, Anwältin für geistiges Eigentum
Quelle: C. Frawley, „Welche rechtlichen Schutzmöglichkeiten haben Schauspieler*innen vor KI?“



www.valuesai.eu

Verfolgen Sie unsere
Reise



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

MODUL 08

Abschlussmodul

Die KI-gestützte Entschuldigungsnachricht



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die des Autors bzw. der Autoren und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Stiftung zur Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die die Förderung gewährende Einrichtung können dafür haftbar gemacht werden.

Inhalt

01	Hintergrund	3
02	Anleitung	9
03	Spielanleitung	15
04	Capstone-Toolkit	19
05	Startkarte	21
06	Karte der zweiten Ebene	24
07	Ergebnis	31
08	Erfassung von Beweismitteln	50



Co-funded by
the European Union

Co-funded by the European Union. Views and opinions expressed are however those of the author or authors only and do not necessarily reflect those of the European Union or the Foundation for the Development of the Education System. Neither the European Union nor the entity providing the grant can be held responsible for them.

01

Hintergrund

KI hat Einzug in unsere intimsten Gespräche gehalten

Der Wandel

Vor einem Jahrzehnt half uns die KI noch bei der Rechtschreibprüfung von E-Mails. Heute verfasst sie Entschuldigungen, Trennungsnachrichten, Beileidsbekundungen und Antworten an unsere Eltern. Die Technologie ist dieselbe – doch es steht viel mehr auf dem Spiel. Wenn ein Generator in einer emotionalen Situation in unserem Namen schreibt, produziert er nicht nur Text. Er prägt eine Beziehung.

KI hat Einzug in unsere persönlichsten Gespräche gehalten

01

Geschwindigkeit

Die KI erstellt Entwürfe in Sekundenschnelle. Die Überarbeitung nimmt Zeit in Anspruch, die wir ihr nicht mehr geben.

02

Formulierung

Eine geschliffene Formulierung kann Schuld, Ausflüchte oder sachliche Fehler verbergen


03

Entfernung

Es fühlt sich sicherer an, eine Maschine sprechen zu lassen – aber die andere Person nimmt die Worte trotzdem wahr

Die Anatomie einer aufrichtigen Entschuldigung

Ein Rahmenkonzept aus der Konfliktforschung (Lazare; Lewicki) – vier Schritte, die eine Versöhnung glaubwürdig machen.



01	02	03	04
Bestätigen	Verantwortung übernehmen	Wiederherstellung	Veränderung
Beschreibe klar und deutlich, was passiert ist, und berücksichtige dabei die Erfahrungen der anderen Person im Hinterkopf.	Übernimm die Verantwortung für den Teil, für den Du verantwortlich bist. Schiebe die Schuld nicht auf die verärgerte Person.	Gehen auf die Auswirkungen ein. Biete etwas Konkretes an, wo dies möglich und ehrlich ist.	Beschreib , was sich ändern wird. Versprich nur das, du auch wirklich einhalten kannst.
VERMEIDEN <i>„Wenn sich jemand darüber aufgeregt hat ...“</i>	VERMEIDE <i>„Du hast das falsch verstanden“</i>	VERMEIDEN <i>Leere Geste oder Ausweichen</i>	VERMEIDEN <i>„Das werden wir nie wieder tun“</i>

Fazit: Eine kurze, ehrliche Botschaft, die alle vier Schritte abdeckt, kommt in der Regel besser an als eine lange, ausgefeilte, die einen dieser Schritte auslöst.

Wo KI hilft – und wo sie versagt

Sprachmodelle sind stark in der Form, aber schwach in der Wahrheit.
Das spielt in Konfliktsituationen eine größere Rolle als fast überall sonst.



Wo sie hilft



Struktur – Schafft eine klare Reihenfolge: Bestätigen, Auswirkungen, nächster Schritt.



Stil – Mäßigt einen hitzigen Entwurf und verleiht ihm einen ruhigeren Ton, den Sie sich dann zu eigen machen können.



Optionen – Bietet alternative Formulierungen, wenn einem das richtige Wort nicht einfällt.



Barrierefreiheit – Hilft Nicht-Muttersprachlern und Menschen mit Legasthenie dabei, lesbaren Text zu verfassen.



Wo es versagt



Fakten – Erfindet Details („Halluzination“). In einem Konflikt führen erfundene Fakten dazu, dass die Diskussion von Neuem beginnt.



Schuldzuweisung – Standardvorlagen für Entschuldigungen suggerieren oft, dass es an der Reaktion der anderen Person lag und nicht an der Handlung selbst.



Übertriebene Versprechungen – Selbstbewusste Formulierungen („Das wird nie wieder vorkommen“) wirken unehrlich, wenn sie nicht eingehalten werden können.



Datenschutz – Enthält Namen, Screenshots oder Zusammenhänge, die in einem öffentlichen Chat nicht veröffentlicht werden sollten.

Vier Leitlinien für KI-gestützte Nachrichten

Bevor Du etwas versendest, das eine Maschine für dich verfasst hat, überprüfe es anhand dieser vier Punkte.

Überprüfen

V

Jede sachliche Behauptung darüber, was passiert ist, muss mit den beteiligten Personen abgeklärt werden – nicht mit der KI.

Fragen Sie sich: Würde ich meinen Ruf darauf setzen, dass dieser Satz korrekt ist?

Datenschutz

P

Namen, identifizierende Details und Informationen von Dritten sollten entfernt werden, es sei denn, es gibt einen klaren Grund, sie beizubehalten.

Frage dich: Enthält diese Nachricht etwas, das ich nicht weitergeben darf?

Fairness

F

Überlege dir, wer darin vorkommt, wer fehlt und wem Schaden entstehen könnte, wenn diese Nachricht als Screenshot gespeichert und weitergeleitet wird.

Frage dich: Würde die Person, über die ich schreibe, diese Zusammenfassung als fair empfinden?

Offenlegung

D

In einem Konflikt schafft Ehrlichkeit bezüglich der KI-Unterstützung Vertrauen; das Verheimlichen dieser Tatsache führt oft zu einem Vertrauensbruch, wenn sie später ans Licht kommt.

Frage dich: Würde es sich falsch anfühlen, wenn der Empfänger erfahren würde, dass ein Teil davon von einer KI verfasst wurde?

02

Anleitung



Die KI-gestützte Entschuldigungsnachricht

Ein interaktives Entscheidungsspiel. Lies dir ein Szenario durch, wende deine Werkzeuge an, Treffe eine Entscheidung und siehe, was passiert.



Szenario



Eine Entschuldigung im
Gruppenchat



Pfade



A · B · C



Ergebnisse



Diskussion + Reflexion

Das Szenario und die goldene Regel

Schaffe die Voraussetzungen, bevor du auch nur einen Klick machst.



Das Szenario – Eine Meinungsverschiedenheit in deiner Jugendgruppe hat sich auf einen Gruppenchat ausgeweitet.

Es wurde eine Nachricht gepostet, die jemanden verärgert hat. Ein Leiter bittet eure Gruppe, beim Verfassen einer Entschuldigung zu helfen, die im Chat geteilt werden soll.

Deine Aufgabe: Entscheide, wie du mit der Entschuldigung umgehen willst: mit KI, ohne KI oder irgendwo dazwischen.

Das Szenario und die goldene Regel

Bereite alles vor, bevor Du auch nur einen Klick machst.



Dein Werkzeugkasten – wähle zwei beliebige aus

- STOP – DENKEN – PRÜFEN – ENTSCHIEDEN
- DENKEN: Wahr · Hilfreich · Absicht · Neutral · Freundlich
- Fairness-Check – Wer wird einbezogen, wer fehlt, wem wird geschadet?
- Gewohnheiten zur Überprüfung – innehalten, Details prüfen, Quelle überprüfen
- Innehalten · Überprüfen · Schützen · Unterstützen · Melden

Goldene Regel

Nutze vor jeder Entscheidung mindestens zwei Hilfsmittel.

So funktioniert eine Runde – fünf Schritte



Lesen → Werkzeuge anwenden → auswählen → Ergebnis lesen → reflektieren.

01

Lies die Startkarte

Schau dir das Szenario auf Karte B0 an. Achte auf die Entscheidungshilfen auf der rechten Seite.

02

Wählen Sie einen Weg: A, B oder C

A = KI verwenden, versenden.
B = KI-Entwurf + bearbeiten.
C = selbst schreiben.

03

Zwei Tools anwenden

Bevor ihr klickt, nennt die beiden Toolkit-Elemente, die ihr verwendet, und begründet eure Wahl.

04

Lest das Ergebnis

Beobachte, was im Chat passiert, und diskutier die drei offenen Fragen.

05

Schreibt die Reflexion nieder

Halte auf der Reflexionsfolie den Weg, die Hilfsmittel und eine sicherere Folgemaßnahme fest.

TIPP Unterschiedliche Wege führen zu sehr unterschiedlichen Ergebnissen – vergleiche die Auswahlmöglichkeiten mit deiner Gruppe, bevor ihr zur Reflexionsfolie übergeht.

Modul 8: Abschlussprojekt

KI-Entscheidungsspiel

Die KI-gestützte Entschuldigungsnachricht

Start

03

Spielanleitung

Gehe das Szenario wie ein digitales Entscheidungsspiel an

**Dieses Kartenset ist für
Diskussionen im Unterricht,
zum Selbststudium oder zur
Moderation vor Ort
konzipiert.**



Ablauf

1. Lies die Startkarte
2. Wähle Sie einen Weg: A, B oder C
3. Wende mindestens zwei Werkzeuge an
4. Klicke auf die nächste Karte
5. Lies das Ergebnis und diskutiere die offenen Fragen
6. Halte die Erkenntnisse auf der Reflexionsfolie fest

Gehe das Szenario wie ein digitales Entscheidungsspiel an

Dieses Kartenset ist für Diskussionen im Unterricht, zum Selbststudium oder zur Live-Moderation konzipiert.



Vorschläge für Moderationsschritte

- Bitten Sie die Lernenden, die beiden Werkzeuge zu nennen, die sie verwendet haben, bevor sie klicken
- Machen Sie nach jedem Ergebnis eine Pause und vergleichen Sie die verschiedenen Wege
- Laden Sie die Lernenden ein, den Wortlaut live zu bearbeiten und zu erklären, warum
- Verwenden Sie die Reflexionsfolie als Nachweis oder Abschlussaufgabe

Gehe das Szenario wie ein digitales Entscheidungsspiel an

**Dieses Kartenset ist für
Diskussionen im Unterricht,
zum Selbststudium oder zur
Moderation vor Ort
konzipiert.**



Schauen Sie sich zuerst das Toolkit an, wenn Sie die Hinweise bereits vor dem Start sehen möchten.

Kartensatzübersicht

M B0 Startkarte



B-A, B-B oder B-C



Ergebniskarten



Reflexion

[Toolkit öffnen](#)

04

Capstone-Toolkit

Entscheidungshilfen, die vor jeder Entscheidung anzuwenden sind

Verwende jedes Mal, wenn du im Spiel eine Entscheidung triffst, mindestens zwei Leitfragen.



Kernfragen

- STOP – DENKEN – PRÜFEN – ENTSCHIEDEN
- THINK = Wahr, Hilfreich, Absicht, Neutral, Freundlich
- Fairness-Check = Wer wird einbezogen, wer fehlt, wem könnte Schaden zugefügt werden?
- Überprüfungsgewohnheiten = Innehalten, Details prüfen, Quelle prüfen

Erweiterte Leitfragen

- Innehalten – Überprüfen – Schützen – Unterstützen – Melden
- Erstellen → Überprüfen → Fairness-Check → Offenlegen
- NSL, Consent Gate, Fair-Data-Check, SAFE-Workflow-Leiter

05

Startkarte

Entwurf der Entschuldigung



Szenario

Eine Meinungsverschiedenheit in eurer Jugendgruppe hat sich auf einen Gruppenchat ausgeweitet. Es wurde eine Nachricht gepostet, die jemanden verärgert hat. Ein Leiter bittet eure Gruppe, beim Verfassen einer Entschuldigungsnachricht zu helfen, die im Chat geteilt werden soll.

Der Entwurf der Entschuldigung



Wähle einen Weg. Jede Schaltfläche führt zur nächsten Szenario- oder Ergebniskarte.

Entscheidungshilfen

- Halte inne, bevor Du den Beitrag veröffentlichst
- Prüfe, was korrekt ist
- Berücksichtige Datenschutz und Fairness

Entscheidung A

Nutze KI, um die Entschuldigung zu verfassen und versende sie sofort.

Option B

Verwende KI zum Verfassen eines Entwurfs, überarbeite ihn dann in deinen eigenen Worten und überprüfe zuerst die Details.

Option C

Verwende keine KI. Schreibe sie selbst, um Fehler zu vermeiden.

06



Karte der zweiten Stufe



Die KI-Nachricht wirkt ausgefeilt



Szenario

Der KI-Entwurf klingt ruhig und selbstbewusst. Er enthält eine Zeile darüber, was passiert ist, bei der Sie sich nicht sicher sind, ob sie korrekt ist. Außerdem wird die Person namentlich genannt, die sich aufgeregt hat.

Die KI-Nachricht wirkt ausgefeilt



Wähle einen Weg. Jede Schaltfläche führt zur nächsten Szenario- oder Ergebniskarte.

Entscheidungshilfen

- Erst überprüfen
- Nenne keine Namen leichtfertig
- Gemeinsame Fakten sind wichtig

Entscheidung A1

Sende sie so, wie sie geschrieben ist.

Option A2

Entferne den Namen und die umstrittene Zeile entfernen und dann versenden.

Option A3

Halte inne und bitte die Gruppe, zu bestätigen, was tatsächlich passiert ist, bevor Sie etwas versenden.

Den Entwurf bearbeiten



Szenario

Sie lassen die KI einen Entwurf erstellen und beginnen dann mit der Bearbeitung. Der KI-Entwurf enthält einen Satz, der so klingt, als würde er der verärgerten Person die Schuld geben („Wenn du es falsch aufgefasst hast ...“). Außerdem enthält er ein Versprechen („Wir werden das nie wieder tun“), das Du nicht garantieren kannst.

Den Entwurf bearbeiten

Wählen Sie einen Weg. Jede Schaltfläche führt zur nächsten Szenario- oder Ergebniskarte.

Entscheidungshilfen

- Achte auf einen vorwurfsfreien Ton
- Verspreche nichts, was Du nicht einhalten kannst
- Wähle einen ruhigeren Ablauf

Entscheidung B1

Behalte den Satz und das Versprechen bei
, da er professionell klingt.

Option B2

Formulieren Sie die Nachricht um, um auf die Wirkung und entferne die Versprechen, die du nicht einhalten kannst.

Option B3

Teilen Sie den Entwurf zunächst mit gesamten Chat und bitte die Teilnehmer, darüber abzustimmen.

Schreiben ohne KI



Szenario

Du schreibst deine eigene Entschuldigung. Sie ist kurz und ehrlich, aber du hast Bedenken, dass sie vielleicht zu direkt klingt. Jemand schlägt vor, eine von der KI generierte Zeile hinzuzufügen, um den Text „abzumildern“.

Schreiben ohne KI

Wähle einen Weg. Jede Schaltfläche führt zur nächsten Szenario- oder Ergebniskarte.

Entscheidungshilfen

- Klarheit ist wichtig
- Der Tonfall muss noch überprüft werden
- KI sollte die Genauigkeit nicht ersetzen

Entscheidung C1

Halte es kurz und sende es so, wie es ist.

Entscheidung C2

Füge einen einzigen, von der KI vorgeschlagenen Satz hinzu und passe ihn anschließend so an, deinem Schreibstil anzupassen.

Option C3

Bitte die KI, die gesamte Nachricht so umzuschreiben, dass sie überzeugender klingt.

07

Ergebnis

Schnell verschickt, öffentlich angefochten

Ergebniskarte und Fragen zur Nachbesprechung



Was passiert

Die Nachricht wird schnell gepostet. Einige reagieren positiv. Andere fragen nach, was es mit der umstrittenen Zeile auf sich hat. Die genannte Person reagiert im Chat, und die Unterhaltung wird wieder lebhaft.

Diskutieren Sie, machen Sie Anmerkungen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Schnell gesendet, öffentlich hinterfragt

1. Welche Details würdest du überprüfen wollen, bevor du eine solche Nachricht verschickst?
2. Welches Risiko birgt es, jemanden in einem öffentlichen Gruppenchat namentlich zu nennen?
3. Was würdest du tun, wenn jemand mit einer anderen Version des Geschehens antwortet?

Aus Datenschutzgründen redigiert, wirft aber dennoch Fragen auf

Ergebniskarte und Anregungen für die Nachbesprechung



Was passiert

Die Nachricht wird veröffentlicht, ohne dass jemand namentlich genannt wird. Einige akzeptieren sie. Ein paar bitten um genauere Angaben dazu, was passiert ist. Die Person, die sich aufgeregt hat, liest die Nachricht, antwortet aber nicht sofort.

Diskutieren Sie, machen Sie sich Notizen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Aus Datenschutzgründen bearbeitet, wirft aber dennoch Fragen auf

1. Welche Informationen sind in einer Entschuldigung notwendig und welche sind optional?
2. Wie kann man die Auswirkungen anerkennen, ohne den Streit erneut zu entfachen?
3. Was würdest du als Nächstes tun, wenn die verärgerte Person dir eine private Nachricht schickt?

Vor dem Posten geteilte Fakten

Ergebniskarte und
Fragen zur
Nachbesprechung



Was passiert

Du veröffentlichst noch nichts. Du bittest um eine kurze Überprüfung der Geschehnisse. Die Beteiligten schildern unterschiedliche Erinnerungen. Die Gruppe einigt sich auf eine kurze, gemeinsame Zusammenfassung, bevor die Entschuldigung verfasst wird.

Diskutieren Sie, machen Sie sich Notizen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Gemeinsame Fakten vor dem Posten

1. Wie lässt sich auf faire Weise eine gemeinsame Zusammenfassung vereinbaren, wenn die Meinungen auseinandergehen?
2. Wie kann man dafür sorgen, dass der Austausch ruhig und respektvoll verläuft?
3. Wann ist es besser, das Gespräch aus dem Gruppenchat herauszuführen?

Professioneller Ton, unsichere Formulierung

Ergebniskarte und Fragen zur Nachbesprechung



Was passiert

Die bearbeitete Nachricht wird mit der vorwurfsvollen Formulierung und einem nachdrücklichen Versprechen gepostet. Einige reagieren mit einem Daumen hoch. Eine Person antwortet und weist auf die vorwurfsvolle Formulierung hin. Eine andere meint, das Versprechen klinge unrealistisch.

Diskutieren Sie, machen Sie Anmerkungen oder springen Sie zur Reflexionsfolie, um Belege festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Professioneller Ton, unsichere Formulierung

1. Welcher Teil der Botschaft könnte als Vorwurf aufgefasst werden und warum?
2. Welche Versprechen kann man bedenkenlos geben und welche sind riskant?
3. Wie könnte man die Botschaft umformulieren, um den Fokus auf die Auswirkungen und die Wiedergutmachung zu legen?

Reparatur mit Fokus auf die Auswirkung



Ergebniskarte und Fragen zur Nachbesprechung



Was passiert

Die abschließende Botschaft konzentriert sich auf die Auswirkungen und vermeidet Schuldzuweisungen. Sie enthält einen klaren nächsten Schritt, zum Beispiel: „Wir werden den Chat respektvoll gestalten und Inhalte prüfen, bevor wir sie teilen.“ Mehrere Personen reagieren positiv darauf, und der Chat verlangsamt sich.

Diskutieren Sie, machen Sie sich Notizen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Wirkungsorientierte Wiedergutmachung

1. Was sorgt dafür, dass eine Entschuldigungsnachricht aufrichtig wirkt und nicht wie aus einem Skript?
2. Welche Hilfsmittel haben dir bei der Entscheidung geholfen, was du ändern solltest?
3. Welche konkrete Maßnahme untermauert die Worte der Entschuldigung?

Crowdsourcing bringt die Debatte wieder ins Rollen

**Ergebniskarte und
Fragen zur
Nachbesprechung**



Was passiert

Du teilst den Entwurf im gesamten Chat zur Abstimmung. Die Teilnehmer äußern sich zu Formulierung, Tonfall und Details. Einige Vorschläge stehen im Widerspruch zueinander. Die Diskussion zieht sich in die Länge, und das ursprüngliche Thema taucht in den Antworten wieder auf.

Diskutieren Sie, machen Sie Anmerkungen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Crowdsourcing bringt die Diskussion wieder in Gang

1. Welche Risiken birgt das Crowdsourcing von Formulierungen in einem Live-Gruppenchat?
2. Welcher alternative Prozess könnte Konflikte verringern und dennoch alle Stimmen einbeziehen?
3. Was würdest du tun, wenn jemand Screenshots außerhalb der Gruppe teilt?

Ehrlich, aber für manche Leser zu kurz



Ergebniskarte und
Fragen zur
Nachbesprechung



Was passiert

Man verschickt die kurze Nachricht. Manche Leute wissen das zu schätzen. Einige wenige empfinden sie als kühl oder zu kurz. Die Person, die sich darüber aufgeregt hat, antwortet und bittet um eine deutlichere Bestätigung der Wirkung.

Diskutieren Sie, machen Sie sich Notizen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Ehrlich, aber für manche Leser zu kurz

1. Welche Informationen oder Formulierungen könnten diesen Text einfühlsamer wirken lassen?
2. Wie kann man sich gleichzeitig klar und freundlich ausdrücken?
3. Was würdest du hinzufügen, ohne dass es zu einer langen Erklärung wird?

Leichte KI-Unterstützung, Stimme bleibt erhalten

Ergebniskarte und Fragen zur Nachbesprechung



Was passiert

DU fügst einen von der KI vorgeschlagenen Satz hinzu und bearbeiten ihn anschließend. Die endgültige Nachricht bleibt kurz, enthält aber eine deutlichere Anerkennung der Auswirkungen. Die Person, die verärgert war, antwortet mit einer kurzen Rückmeldung, und der Chat verstummt.

Diskutieren Sie, machen Sie Anmerkungen oder springen Sie zur Reflexionsfolie, um Erkenntnisse festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Leichte KI-Unterstützung, eigene Stimme beibehalten

1. Was ist ein Anzeichen dafür, dass ein von einer KI verfasster Satz vor dem Versenden überarbeitet werden muss?
2. Was würdest du, wenn überhaupt, in einer Gruppennachricht über die Unterstützung durch eine KI preisgeben?
3. Wie würdest du überprüfen, ob der Ton gegenüber allen Beteiligten fair ist?

Überzeugende Neufassung, zweifelhafte Fakten

Ergebniskarte und
Fragen zur
Nachbesprechung



Was passiert

Du bittest die KI, die gesamte Nachricht umzuschreiben. Sie wird länger und überzeugender. Sie enthält einen Satz, der nicht genau dem entspricht, was passiert ist. Einige Personen stellen die Nachricht in ihren Antworten in Frage.

Diskutieren Sie, machen Sie Anmerkungen oder springen Sie zur Reflexionsfolie, um Belege festzuhalten.

Siehe „Offene Fragen“ auf der nächsten Folie



Offene Fragen

Überzeugende Umformulierung, zweifelhafte Fakten

1. Was solltest Du überprüfen, wenn eine KI eine persönliche Situation umschreibt?
2. Inwiefern kann eine überzeugende Formulierung in einer Konfliktsituation zu Problemen führen?
3. Was würdest Du als Nächstes tun, wenn Menschen die Botschaft als „gefälscht“ oder „vorformuliert“ bezeichnen?

08

Beweissicherung

Anregungen für kurze Reflexionen und das Portfolio

Verwende diese Folie als Lernprotokoll, als Anregung für die Plenumsdiskussion oder als Vorlage für Screenshots.

Halten Sie Ihre Überlegungen fest

- Welchen Weg hast du gewählt?
- Welche beiden Werkzeuge hast du verwendet?
- Was hast du überprüft?
- Wer könnte davon betroffen sein oder ausgeschlossen werden?
- Was würdest du über den Einsatz von KI offenlegen, falls überhaupt etwas?
- Was wäre eine sicherere Folgemaßnahme?

Anregungen für kurze Reflexionen und das Portfolio

Verwenden Sie diese Folie als Lernprotokoll, als Anregung für die Plenumsdiskussion oder als Vorlage für Screenshots.

Anregungen für Moderatoren

- Was hat dazu geführt, dass die Botschaft aufrichtig oder unsicher wirkte?
- Wo war Genauigkeit am wichtigsten?
- Was hat sich nach der Fairness-Prüfung geändert?
- Wann sollte das Gespräch aus dem öffentlichen Gruppenchat verlagert werden?
- Welche Anhaltspunkte würden hier einen verantwortungsvollen Einsatz von KI belegen?



www.valuesai.eu

Begleite unsere Reise



Co-funded by
the European Union

Mitfinanziert von der Europäischen Union. Die geäußerten Ansichten und Meinungen sind jedoch ausschließlich die des Autors oder der Autoren und spiegeln nicht unbedingt die der Europäischen Union oder der Stiftung für die Entwicklung des Bildungssystems wider. Weder die Europäische Union noch die die Förderung gewährende Einrichtung können dafür verantwortlich gemacht werden.