

KI unter «Kontrolle» – **VERANTWORTUNG**svolle Innovation


KI im Unternehmen - Verantwortung, Kontrolle und Compliance als Basis verantwortungsvoller Innovation

19.11.2025
Daniel Gysel
Chief Compliance Officer – Zurich Business Unit Schweiz

Diese Präsentation ist ausschliesslich für den/die eingangs genannten Adressaten vom SGO Verein bestimmt.



KI (MS Copilot) erklärt, wer für die Korrektheit der Antworten verantwortlich ist



Wer hat dein Sprachmodell entwickelt und wie stellst du sicher, dass du nur korrekte Antworten generierst? Wer ist für die Korrektheit deiner Antworten verantwortlich?



Mein Sprachmodell wurde von **OpenAI** entwickelt, einem Unternehmen, das sich auf künstliche Intelligenz spezialisiert hat. Die Version, mit der du gerade sprichst, basiert auf der **GPT-4-Architektur** und wird von Microsoft in Produkten wie Copilot integriert und bereitgestellt.

Wie wird die Korrektheit meiner Antworten sichergestellt?

Es gibt mehrere Ebenen, auf denen die Qualität und Korrektheit meiner Antworten sichergestellt wird:

1. **Training auf hochwertigen Daten**:

Ich wurde mit einer großen Menge an Textdaten aus verschiedenen Quellen trainiert – darunter Bücher, wissenschaftliche Artikel, Webseiten und andere öffentlich zugängliche Inhalte. Dabei wurden Qualitätsfilter eingesetzt, um fehlerhafte oder irreführende Informationen möglichst auszuschließen.

2. **Regelmäßige Aktualisierung und Feinabstimmung**:

Microsoft und OpenAI führen regelmäßige Updates und Feinabstimmungen durch, um die Genauigkeit zu verbessern und neue Informationen zu integrieren.

3. **Websuche bei Bedarf**:

Wenn eine Frage aktuelle oder sehr spezifische Informationen erfordert (z. B. Gesetzesänderungen, lokale Ereignisse, neue Forschung), nutze ich eine integrierte Websuche, um verlässliche Quellen zu finden und zu zitieren.

4. **Verantwortung und Haftung**:

Die Verantwortung für die Korrektheit meiner Antworten liegt letztlich bei den **Entwicklern und Betreibern** – also **OpenAI** für das Modell und **Microsoft** für die Integration und Bereitstellung. Dennoch ist es wichtig zu betonen, dass ich **keine absolute Garantie für Fehlerfreiheit** geben kann. Ich bin ein **Hilfsmittel, kein Ersatz für professionelle Beratung**.

Wenn du möchtest, kann ich dir auch zeigen, wie ich bei einer konkreten Frage die Informationen überprüfe oder wie ich mit Quellen arbeite. Möchtest du ein Beispiel?

Frage an die KI, wie «sie» die Korrektheit von Angaben verifiziert

🖋️ ****Beispiel: Wie überprüfe ich eine Aussage zur SGO-Gründung****

Angenommen, du fragst:

****„Wann wurde die Schweizerische Gesellschaft für Organisation und Management (SGO) gegründet?“****

1. ****Websuche starten****

Ich beginne mit einer gezielten Suche nach offiziellen oder vertrauenswürdigen Quellen, z. B. von der SGO selbst, Hochschulen oder seriösen Medien.

2. ****Quelle identifizieren****

Ich finde z. B. eine Webseite der SGO oder eine Hochschuleseite, auf der steht:

> „Die SGO wurde 1967 gegründet durch eine Initiative von Organisationsleitern bedeutender schweizerischer Firmen und Verwaltungen.“

→ Quelle: SGO Business School^[1](<https://uniservice-dl.uni-wuppertal.de/de/ki-handreichungen/ki-musterbelegvorlage/>)

3. ****Validität prüfen****

Ich prüfe:

- Ist die Quelle ****offiziell**** oder ****wissenschaftlich****?
- Ist die Information ****konsistent**** mit anderen Quellen?
- Gibt es ****Widersprüche**** oder ****fehlende Details****?

4. ****Antwort formulieren mit Zitat****

Ich formuliere die Antwort und füge die Quelle direkt an:

> „Die SGO wurde 1967 gegründet ...“^[1](<https://uniservice-dl.uni-wuppertal.de/de/ki-handreichungen/ki-musterbelegvorlage/>)

5. ****Transparenz durch Quellenangabe****

Du siehst direkt, ****woher**** die Information stammt und kannst sie ****selbst nachprüfen****.

🔍 Warum ist das wichtig?

Laut [\[1a-Studi.de\]](https://www.1a-studi.de/hilfe-faq/ki-quellen-ueberpruefen)(<https://www.1a-studi.de/hilfe-faq/ki-quellen-ueberpruefen>) ist die Quellenprüfung bei KI-Antworten essenziell, weil KI-Modelle manchmal sogenannte „Halluzinationen“ erzeugen – also plausible, aber falsche Informationen^[2](<https://www.1a-studi.de/hilfe-faq/ki-quellen-ueberpruefen>).

Auch die [Universität Wuppertal](https://uniservice-dl.uni-wuppertal.de/de/ki-handreichungen/ki-musterbelegvorlage/)(<https://uniservice-dl.uni-wuppertal.de/de/ki-handreichungen/ki-musterbelegvorlage/>) empfiehlt, bei KI-generierten Inhalten immer die Art der Verwendung und die Quelle transparent zu machen^[1](<https://uniservice-dl.uni-wuppertal.de/de/ki-handreichungen/ki-musterbelegvorlage/>).

Der Auftrag an die KI bestand darin, den Zweck der SGO und die wichtigsten Aktivitäten als Bild darzustellen...inklusive typische Farben



Erwartungen der FINMA und des EDÖB beim Einsatz von KI

Geltendes Recht anwenden und prinzipienorientierte Erwartungen beachten



FINMA

- **FINMA-Aufsichtsmitteilung 08/2024:** Governance und Risikomanagement beim Einsatz von künstlicher Intelligenz
 - Inventar & Risikoklassifizierung
 - Datenqualität
 - Monitoring
 - Dokumentation
 - Erklärbarkeit
 - Unabhängige Überprüfung (Wesentlichkeit)
- **Frühzeitige Kontaktaufnahme mit FINMA**, wenn KI bei **kritischen Prozessen** oder bei der Berechnung regulatorisch vorgegebener „Kennzahlen“ (z.B. SST) eingesetzt werden soll¹




EDÖB

- **Geltendes** und **technologieneutrales Datenschutzgesetz** ist **direkt auf KI anwendbar**
- **Transparenzpflichten** beim Einsatz von KI abgeleitet aus Art. 19 DSGVO (Informationspflichten)
- **Zusätzliche Informationspflichten** und «menschliches Gehör» bei **automatisierten Einzelentscheidungen**
- **Datenschutz Folgenabschätzungen (DSFA)** bei potenziell hohem Risiko für die betroffenen Personen

¹ FINMA-Medienmitteilung 2025 <https://www.finma.ch/de/news/2025/04/20250424-mm-umfrage-ki/> | FINMA-Risikomonitor 2023: [Längerfristige Trends und Risiken: Künstliche Intelligenz im Schweizer Finanzmarkt](#) | FINMA-Jahresbericht 2023: [Künstliche Intelligenz: Die FINMA formuliert ihre Aufsichtserwartungen](#) | FINMA-Jahresbericht 2021: [Künstliche Intelligenz im Schweizer Finanzmarkt](#)

Ohne die folgende Basis kann nicht bewusst gesteuert werden

Erster Schritt: Eine für alle Stakeholder passende Definition für «AI» und «Wesentlichkeit»



KI-Komponente

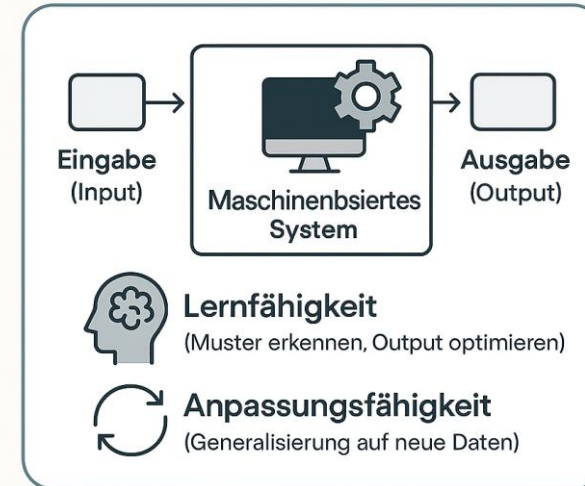
- Eine KI-Komponente ist ein intern oder extern entwickeltes maschinenbasiertes System, welches Outputs anhand von Inputs generiert. Sie zeichnet sich durch mindestens folgende Eigenschaften aus:
 - Lernfähigkeit: Die KI-Komponente optimiert ihren Output für eine vorgegebene Zielsetzung, indem sie (komplexe) Muster und Zusammenhänge in zugrunde liegenden Daten identifiziert.
 - Anpassungsfähigkeit: Die KI-Komponente ist darauf ausgelegt anhand von zuvor ungesehenen Daten generalisierte Outputs zu generieren.




Wesentlichkeit

- KI-Komponenten, welche per Risikokategorisierung als «hoch» eingestuft werden, gelten als wesentlich.

KI-Komponente



Wesentlichkeit



«Hoch» = wesentlich

Die wichtigsten «Zutaten» unseres AI-Steering

Funnel → Beurteilung → risikomindernde Massnahmen → Rollen und Verantwortlichkeiten

Operative Elemente zur Sicherstellung der AI-Guideline



Funnel für AI-Lösungen

Erkennung und Identifikation von AI-Lösungen



Beurteilung der AI-Lösungen

Prüfung anhand definierter Kriterien



Definition der risikomitigierenden Massnahmen

Festlegung von geeigneten Massnahmen



Rollen und Verantwortlichkeiten

Klärung von Zuständigkeiten und Aufgaben

1. Funnel für AI-Lösungen (Erkennung & Identifikation)

Ziel - Sicherstellen, dass jede neue oder geänderte KI-Komponente identifiziert wird.

Kernpunkte:

- Initiierung des AI-Steering Prozesses.
- Zuweisung eines KI-Komponenten-Owneers.
- Inventarisierung und Dokumentation der Komponente.

2. Beurteilung der AI-Lösungen (Risikokategorisierung & Risk Assessment)

Ziel - Bewertung der Risiken und Festlegung der Risikoklasse (tief, mittel, hoch).

Kernpunkte:

- Durchführung der Risikokategorisierung.
- Validierung
- Risk Assessment inkl. Definition wesentlicher Änderungen und risikomindernder Faktoren.

3. Definition der risikomindernden Massnahmen

Ziel - Festlegung geeigneter Massnahmen zur Risikominderung.

Kernpunkte:

- Massnahmen im Risk Assessment dokumentieren.
- Monitoring und Kontrollvorgaben (z. B. Bias-Checks, Logging, Performance-Überwachung).
- Fallback-Szenarien und Business-Continuity-Pläne.

4. Rollen und Verantwortlichkeiten

Ziel - Klare Zuständigkeiten für alle Schritte.

Kernpunkte:

- Owner der KI-Komponente: Umsetzung der Vorgaben, Durchführung von Risikoanalysen.
- IT-Owner: Technische Implementierung.
- AI Experte: Unterstützung, Inventarführung, Validierung.
- AI Gremien: Empfehlungen und Freigaben.
- Risk Management: Moderation des Risk Assessments und Validierung der Massnahmen.

Erste Zutat: Funnel & AI Steering / Zweite Zutat: Beurteilung

Klarer Ablauf von der Identifikation einer KI-Komponente bis zur Re-Validierung

AI Steering



Identifikation

Neue KI-Komponente erkennen,
Owner festlegen
Mitarbeitende, IT, Legal, Risk, Compliance, Audit



Risikokategorisierung

Einstufung in »hoch«, »mittel« oder »tief«
KI-Komponenten Owner



Validierung

Überprüfung der Einstufung



Risk Assessment

Risiken bewerten,
Maßnahmen definieren
Modération: Risk Management
Unterstützung: AI-Champion



Review & Freigabe

Präsentation an AI-Review Panel
oder AI-Oversight Board,
Empfehlung und Entscheidung
Owner, AI-Champion

Freigabe
durch Risikotäger
(Manager/Val.)
Abwehchung:



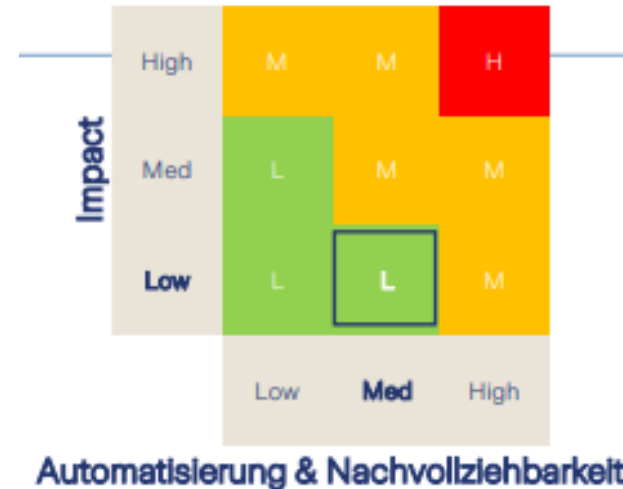
Inventarisierung & Dokumentation

Dokumentation und Inventar pflegen



Jährliche Validierung

Überprüfung und ggf. Aktualisierung




Dritte Zutat: Definierte risikomindernde Massnahmen

Um KI-Komponenten ähnlich zu schützen, wurde ein Standard-Set an Massnahmen formuliert



Minimal-Set an Massnahmen für alle KI-Komponenten (unabhängig von Risikoeinschätzung)

- Inventarisierung
- Minimum jährliche Prüfung der Aktualität und Richtigkeit der Risikobewertung / Risikokategorisierung und update des Inventars im Falle von Änderungen.
- Dokumentation (Zweck, Umfang, Rollen und Verantwortlichkeiten, Training, Validation und Testkonzept, BCP, Änderungen, Versionskontrolle etc.)



Für KI-Komponenten mit Risiko mittel / hoch zusätzlich verpflichtend

Inputs

- Überprüfung der Datenquellen und der zugrunde liegenden Daten auf Eignung und Bias

Methodologie

- Auswahl der KI-Komponente und Kalibrierungsprozess und Performance Evaluation anhand von quantitativen und qualitativen Bewertungsmetriken

Implementation

- Versionskontrolle / Definition SLAs des Services (Drittanbieter / Intragroup) sowie Überwachung und Logging

Outputs

- Überprüfung des Outputs auf Bias und Fairness, Erklärbarkeit, Fortlaufende Überwachung der Leistung auf vordefinierten Metriken und Handlungstrigger
- Etablierung eines Feedbackloops (Nutzerfeedback) mit Feedbackloop-Monitoring.

Vierte Zutat: Rollen und Verantwortlichkeiten

Umfassende Definition von (neuen) Rollen / Verantwortlichkeiten über alle Hierarchiestufen



CEO

Umsetzung der
Guideline



Mitarbeitende

Sicherstellung, dass ein
Owner für jede neue oder
ergänzte KI-Komponente
bestimmt wird




Owner einer KI-Komponente

Einhaltung der Vorgaben
über den gesamten
Lebenszyklus; Identifikation,
Risikokategorisierung, Risk
Assessment, Dokumentation,
Inventarisierung



IT Owner

Technische, produktive
Implementation der KI-
Komponente; Unterstützung
des Owners bei technischen
Anforderungen.



AI Experte

Unterstützung der Owner beim
AI-Steering Prozess; Führung
des Inventars; Sicherstellung
der Risikokategorisierung und
Dokumentation



AI Panel

Empfehlung an Risikoträger zur
Freigabeentscheidung;
Validierung der
Risikokategorisierung;
Dokumentation der
Empfehlungen



AI Board

Validierung der Empfehlungen
des AI-Review Panels bei
„hoch“ eingestuftem Risiken;
Empfehlung an Risikoträger auf
Geschäftsleitungsebene;
Bestätigung, Anpassung oder
Rückweisung der
Empfehlungen

Besten Dank und weiterhin lehrreiche Momente.....



HEUTE IN BERUFE DER ZUKUNFT:
DER KI-FLÜSTERER

Quelle: cloud-science.de