

AI Ethical Risk Karten

Christof Wolf-Brenner
cbrenner@know-center.at

Controller Institut



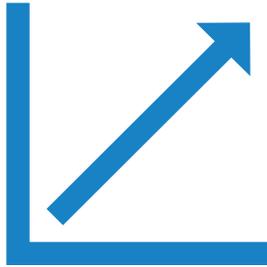


Dipl.-Ing. Christof Wolf-Brenner, MA



**Wie, wann, wo, von wem, warum...
werden ethische Risiken von
KI-Systemen heute identifiziert?**

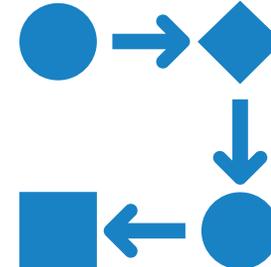
Warum?



**Rasanter Anstieg
von KI-Nutzung**



**Einseitiger Fokus
auf bekannte Risiken**



**Fehlende systematische
Betrachtung**

Ziel des Kartensets

- **Vielfalt ethischer Risiken sichtbar machen**, auch jenseits bekannter Themen (Transparenz, Bias, Datenschutz).
- **Interaktive Nutzung fördern**, um Teams zu einer strukturierten, tiefgehenden Reflexion und Diskussion ethischer Fragen anzuregen.
- **Vermittlung von Wissen über potenzielle ethische Risiken:** Kartensets dieser Art ermöglichen es spielerisch Informationen zu vermitteln.
- **Setzung von Impulsen und Strukturierung:** Mittels Kartensets können in Workshopszenarien Impulse für Überlegungen gegeben und das Vorgehen strukturiert werden.
- **Anschlussfähigkeit** an Risk Management Standards



Theoretische Grundlagen des Kartensets



- [AI, algorithmic and automation incidents and issues repository \(AIAAIC\)](#)
- [MIT AI Risk Repository](#)
- [Leitfaden zur Gestaltung vertrauenswürdiger Künstlicher Intelligenz – KI Prüfkatalog \(Fraunhofer\)](#)

Anmerkung: Es gibt unzählige Frameworks, Kataloge, Methoden, Datenbanken etc. zu diesem Thema. Diese drei wurden von mir im Rahmen des Projektes nach eingehender Recherche aufgrund der folgenden Kriterien ausgewählt.

- **Praxisnähe und Anwendungsorientierung**
- **Vielfalt und Abdeckung unterschiedlicher Perspektiven**
- **Glaubwürdigkeit und Akzeptanz**

Struktur des Kartensets

URSACHEN *(Auslöser)*

- Verzerrungen in Daten
- Intransparente Modelle
- Fehlende Tests
- Rechtliche Grauzonen
- uVm.

WIRKUNGEN *(Schaden)*

- Psychische Verletzung
- Finanzieller Schaden
- Manipulation
- Einschränkung der Handlungsfreiheit
- uVm

Struktur des Kartensets

URSACHEN UND WIRKUNGEN (SCHADEN)

1. Fördert systematisches Denken
2. Erleichtert präventives Handeln
3. Vermeidet verkürzte Perspektiven
4. Fördert interdisziplinäre Diskussionen
5. Unterstützt strukturiertes Mapping

UNSICHERHEIT

Ein Modell produziert Ergebnisse ohne ausreichende Sicherheit, was zu falschen, riskanten oder schwer nachvollziehbaren Entscheidungen führen kann.

Ein Modell zur medizinischen Diagnose gibt eine Diagnose für eine seltene Erkrankung aus, obwohl es kaum passende Daten zur Erkennung dieser hat.

25



KÖRPER & MATERIE

Physische Verletzung einer Person oder Gruppe oder Schäden an materiellen Gütern.

2



Struktur des Kartensets

Schadenskarten (Wirkung)

9 Karten – zeigen mögliche Folgen auf, die durch den Einsatz von KI-Systemen entstehen können.
Diese Karten beschreiben grundlegende Schadensarten, die Individuen, Organisationen, Gesellschaft oder Umwelt betreffen können – unabhängig davon, wodurch sie verursacht wurden.


Datenbezogene Ursachen

10 Karten – *thematisieren Probleme in Bezug auf Datenerhebung, -qualität oder -struktur.*
Diese Karten zeigen, wie **Fehler, Verzerrungen oder Lücken in Datensätzen** entstehen und sich negativ auf die Leistung und Fairness von KI-Systemen auswirken können.

Struktur des Kartensets

Modellbezogene Ursachen	<p><i>10 Karten – beschreiben Risiken, die durch die Struktur, das Verhalten oder die Entwicklung von KI-Modellen entstehen.</i></p> <p>Hier geht es um Grenzen in der Modellarchitektur, fehlerhaftes Lernen oder unzureichende Kontrolle.</p>
Systembezogene Ursachen	<p><i>10 Karten – beziehen sich auf Probleme im Gesamt-KI-System, in dem Modelle eingebettet sind.</i></p> <p>Diese Karten adressieren Schwächen in Benutzerschnittstellen, Prozessen, Rollenverteilung oder Integration.</p>
Organisatorische Ursachen	<p><i>10 Karten – beleuchten strukturelle, kulturelle oder strategische Defizite innerhalb von Organisationen.</i></p> <p>Sie zeigen, wie interne Anreize, fehlende Verantwortung, mangelnde Business-Ethik oder einseitige Perspektiven zu systematischen Fehlentwicklungen in KI-Anwendungen führen können.</p>

Beispiel Kartenaufbau (Schadenskarten)

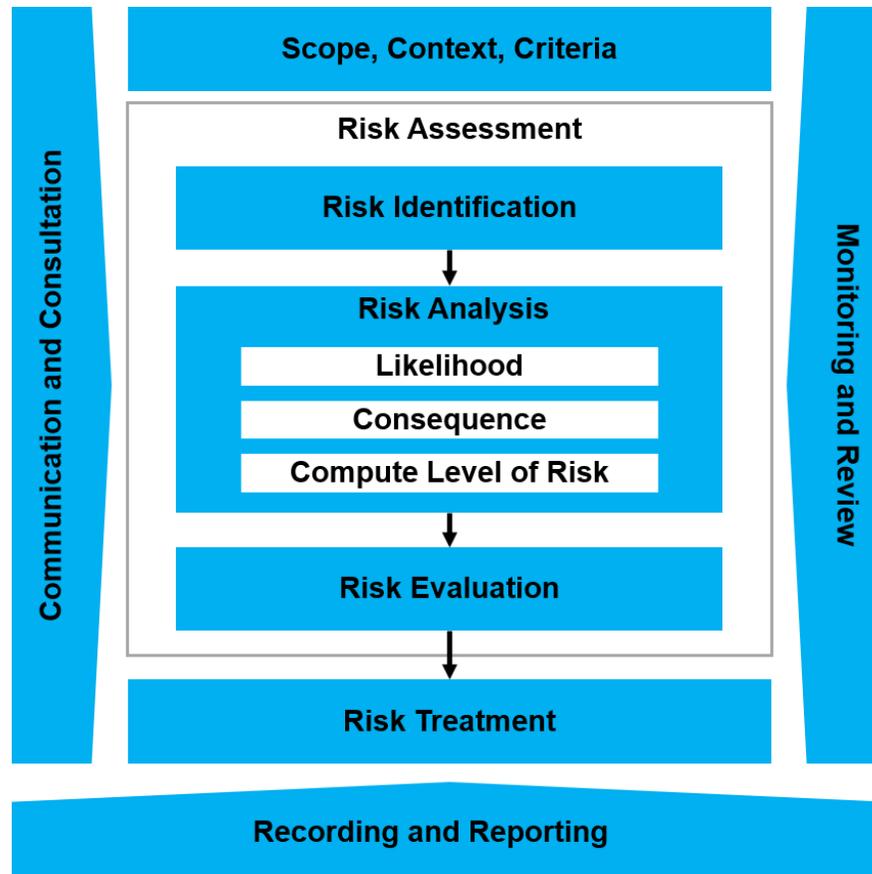


Beispiel Kartenaufbau (Schadenskarten)



Vorgehensweise im Risikomanagement

ISO 31000 Risk management process



RISIKOIDENTIFIKATION

Die Karten bieten strukturelle Inspiration.

- Ursachenkarten: decken typische Schwachstellen in Daten, Modellen, Systemen und Organisationen ab.
- Schadenskarten: machen die potenziellen Wirkungen greifbar.

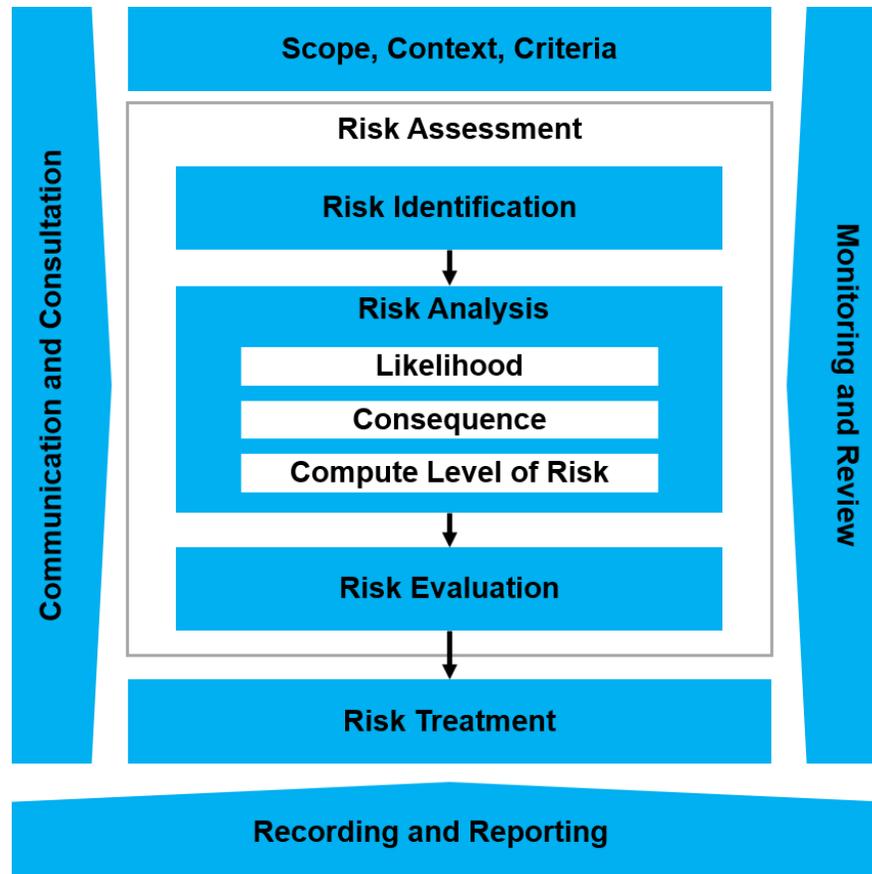
RISK ANALYSIS

Die Karten erleichtern eine gezielte Bewertung.

- Was ist wahrscheinlich? Fokus auf häufige oder wahrscheinliche Ursachen.
- Was ist kritisch? Fokus auf besonders schwere Auswirkungen.

Vorgehensweise im Risikomanagement

ISO 31000 Risk management process



RISK EVALUATION

Die Kartenpaare helfen bei der Priorisierung.

- Kombinationen aus häufiger Ursache & schwerwiegender Wirkung markieren **superkritische Risiken**.

RISK ANALYSIS

Die Karten liefern konkrete Behandlungsansätze.

- Ursachenkarten zeigen: **Was muss ich beheben, reduzieren oder kontrollieren?**

→ MIRO



Feedback und Evaluierung

20250328 - Methodenevaluierung AI Ethics Risk Cards



<https://forms.office.com/e/12c4Hw51mM>