

# AI Use Case - Canvas <sup>3.1</sup>

## INPUT

### Daten

KI-Projekte "leben" von Daten und ihrer Qualität. Was haben wir zur Verfügung?  
Wie viel davon? Was könnte beschafft oder erzeugt werden?

### Rauschen

Was verzerrt und stört Daten? Was macht Daten schwer zu verstehen?

### Ressourcen

Was brauchen neben Daten noch? Zugänge, Freigaben, Analysen, Server und Tools?

### Kosten

Was sind Kosten und Kostentreiber? Gibt es fixe und variable Kosten? Wovon hängen sie ab? In welchen Größenordnungen bewegen wir uns?  
Gibt es Synergien mit anderen Produkten, Dinge die wir wiederverwenden könnten?

### Idee und Wertversprechen

Welches Problem wird gelöst? Warum brauchen wir das?

### Zielgrößen

Woran erkennen wir die Qualität der Lösung? Was wird "optimiert?" Gern mindestens eine Kennzahl, die schnell und nach jedem Entwicklungsschritt errechenbar ist.

### Risiken

Was kann schon schiefgehen? Was gefährdet den Projekterfolg? Welche unerwünschten Konsequenzen könnte der Projekterfolg haben? Worauf möchten wir vorbereitet sein?

Angelehnt an den bewährte Business-Modell-Canvas von Osterwalder (2008) bietet der AI Use Case-Canvas eine Unterstützung bei der Strukturierung von Anwendungsfällen im Bereich KI / Generative KI.  
Eine Idee, die zu komplex ist, um sie auf einer Seite zu erklären ist zu komplex und möchte aufgeteilt werden.

## OUTPUT

### Stakeholder

Wer muss abgeholt werden, damit die Idee Nutzen stiften kann?

### Test Slices

Welche Gruppen von Fällen / Menschen / Datensätzen brauchen Aufmerksamkeit?

### Nutzen

Was versprechen wir uns davon? Was können wir erreichen? Langfristig, gern qualitative und quantitative Aspekte aufzeigen.

## Was ist KI und was nicht?

"The question of whether machines can think is about as relevant as the question of whether submarines can swim."

— Edsger Dijkstra

Intelligenz ist ein schillernder und beweglicher Begriff. Der EU-Ai-Act definiert ihn nicht, sondern richtet sich auf KI-Systeme, die konzipiert sind, Anpassungsfähigkeit zu zeigen, um Ziele zu verfolgen oder sogenannte Foundation Models, die in ähnlicher Weise vortrainiert sind, wie zum Beispiel Large Language Models (LLM).

Relevante Begriffe im Zusammenhang:

**KI** - Der Oberbegriff für die gesamte Forschungsdisziplin und Methodengruppe. Ein breites Feld, in dem zunächst regelbasierte Experten-Systeme und Beweis-Automaten Erfolge hatten. Die sind zwar sehr flexibel anzupassen, haben aber keine Anpassungsfähigkeit im Sinne des EU-Ai-Acts. Hier gibt es auch weiterhin spannende, neue Methoden abseits des maschinellen Lernens wie bspw. die Kausal-Inferenz.

**Machine Learning** - Hier werden algorithmisch Zusammenhänge aus Daten generalisiert, Prognosen und Klassifikationen gemacht.

**Deep Learning** - Der Bereich des Machine-Learning, der mit tiefen neuronalen Netzen arbeitet und sich damit unstrukturierte Daten wie Texte oder Bilder erschließt.

**Generative KI** - Der Bereich des Deep Learning, der per Definition verwendet wird, um neue Inhalte zu erzeugen. Die gleichen Technologien können aber auch genutzt werden, um geschlossene Fragen zu Texten und Bildern zu beantworten ("Welche Produkte stehen auf dieser Quittung?") oder um etwas zu übersetzen ("Fach-Chinesisch <-> Deutsch").

Während es einzelne Machine Learning-Verfahren gibt, denen man "beim Lernen zusehen" kann und bei denen das enthaltene Wissen prüfbar ist, wie bspw. bei einem Entscheidungsbaum, ist das bei Deep Learning Verfahren nicht ohne Weiteres möglich - das Wissen ist in unbeschrifteten Gewichten implizit enthalten.

Moderne Verfahren der **erklärbaren KI** (XAI) können dennoch experimentell Licht darauf werfen, bspw. um die Wichtigkeit einzelner Einflussfaktoren im Durchschnitt oder für einzelne Fälle zu quantifizieren: Man kann KI-Verfahren nutzen, um selbst Etwas zu lernen.

**Datengruppe 1:** Hier steckt das Wissen. Es gibt mehrere Quellen zur Auswahl. Gut so.

**Datengruppe 2:** Meta-Daten sind auch wichtig, um zu Filtern, zu priorisieren oder einen Gold-Standard zu definieren: Was ist beliebt und was ist relevant, was richtig oder falsch?

**Datengruppe 3:** Gibt es Daten, an denen wir den Erfolg einer Lösung sehen könnten?

Für KI-Lösungen reichen einzelne Testfälle nicht aus, denn sie sind zu kleine Stichproben, um zu sehen, ob ein System etwas besser oder schlechter wird.

Außerdem besteht die Gefahr Gruppen durch KI-Systeme schlechter zu stellen. Für welche Gruppen von Fällen wollen wir das ausschließen?

## Wie kommt man auf gute Anwendungsfälle? Vielleicht mit diesen Impulsen...

• **Pain Point** - finden wir einen Weg, sie mit KI-Mitteln zu beheben oder ihre Auswirkungen zu verringern?

• **Dekomposition** - Aus welchen Schritten besteht mein Prozess - welche davon eigenen sich für eine Automatisierung oder Unterstützung durch KI?

• **Zeit ist Geld** - Wo investieren wir unsere Zeit? Mit welchen Dokumenten-Typen verbringen wir vielleicht zu viel Zeit? Hier lohnt sich die Suche nach LLM-Potenzialen besonders.

• **Gelegenheit macht KI** - System wird umgebaut? Investitionsentscheidung steht an? Wichtige Verhandlung? Einzelne Gelegenheiten können vom KI-Einsatz in Planung und Vorbereitung profitieren.

• **Parameter-Tuning** - Gibt es Parameter im Prozess, die man "intelligent" variieren kann?

• **Hochfrequenz** - Welche Entscheidungen treffen wir am häufigsten? Könnten wir diese Entscheidungen verbessern oder teilautomatisieren?

• **QS** - Können wir einen Text- oder Bild-Output qualitätssichern / verbessern?

• **Orientierung** - Wo ist es unübersichtlich? Können wir KI einsetzen, um einen Überblick zu bekommen und ist der uns etwas wert? Clustering / Zusammenfassung?

• **Variation** - Gibt es Aufgaben, die sich durch Variation und Vielfalt bis jetzt nicht durch IT unterstützen ließen?

• **Dezentralisierung** - Vielleicht hat unsere Zielgruppe schon Ideen für Use Cases. Wie erfahren wir davon? Wie können wir das fördern?

• **Datenschätze** - Können wir aus einer spannende Sammlung von Daten oder kostbarem Expertenwissen durch KI-Einsatz mehr Nutzen stiften und es zugänglicher machen?

• **Datenschmutz** - Freitextfelder mit unklarem Inhalt, Tippfehler, Anomalien, Inkonsistenzen und Duplikate lassen sich mit KI-Verfahren finden. Können wir unstrukturierte Daten in strukturierte verwandeln oder sie in Bezug setzen?


• **Werkzeug-Evolution** - Gibt es Entscheidungstabellen oder DMN-Regeln, die "intelligenter" werden könnten?

• **Transfermarkt** - Was macht der Wettbewerb und lassen sich Ideen aus anderen Branchen übertragen?

• **Synthese** - Uns fehlen Daten - können wir welche generieren?

• **Verfügbarkeit** - GPUs haben nachts Zeit? Lohnt es sich durch KI vielleicht Dinge detaillierter zu planen / prüfen / erproben, die sich manuell nicht gelohnt hätten?

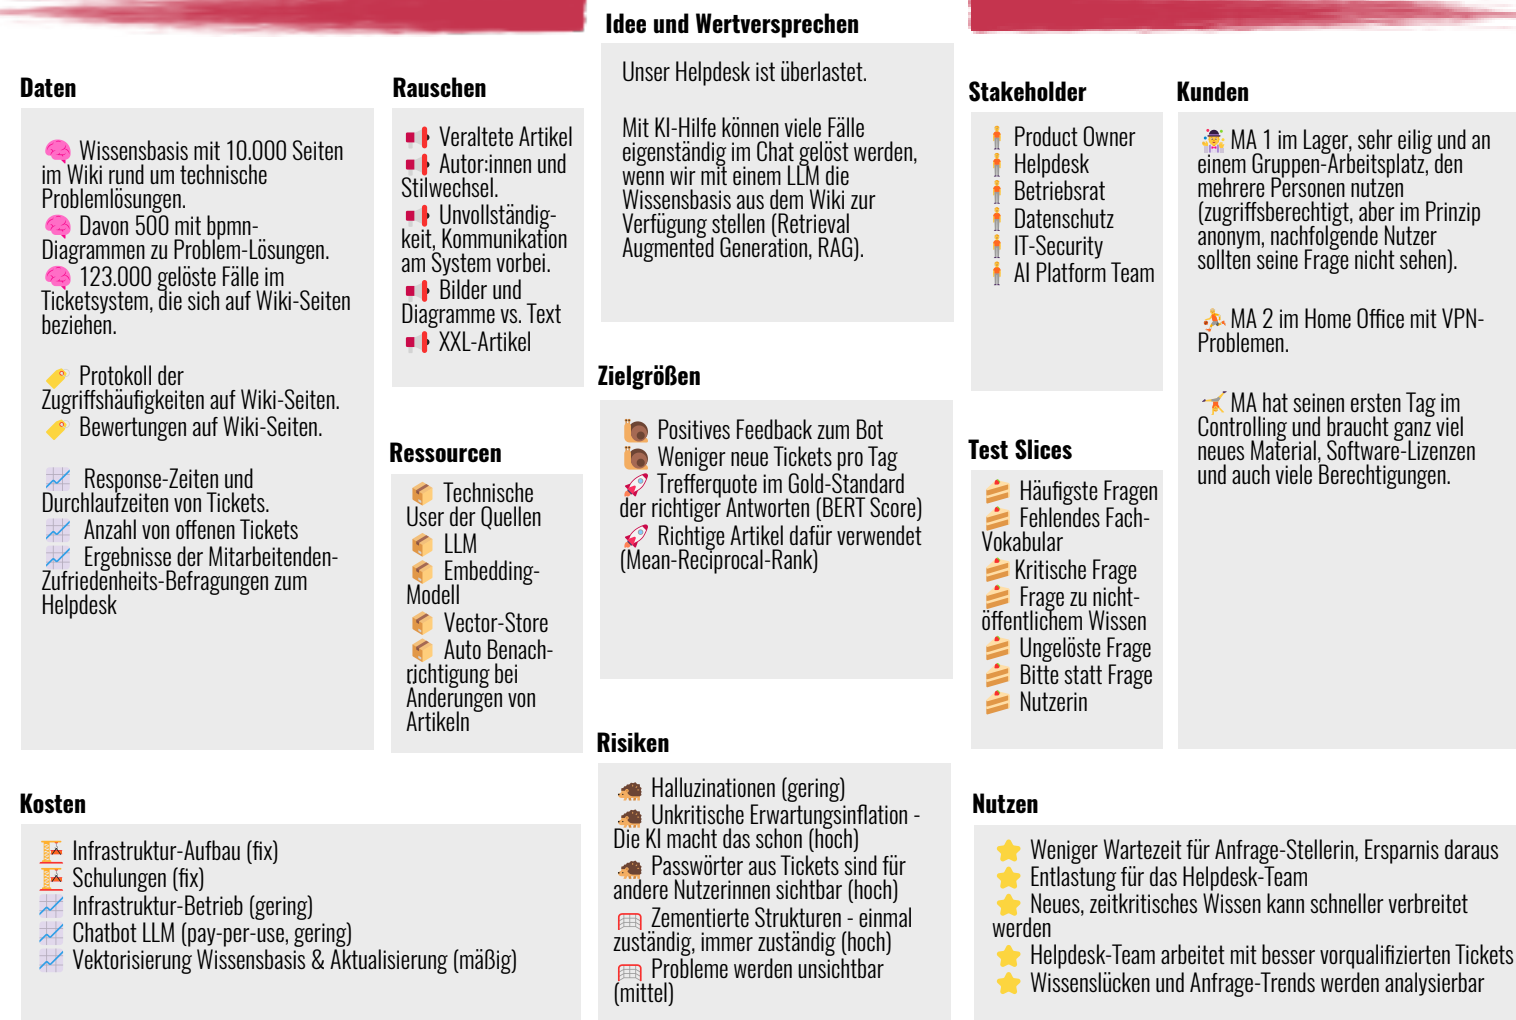
• **Erwartung** - Wo erwartet die Kundin eine KI und erwartet sie das vielleicht zurecht?



Der Canvas hilft in den frühen Phasen eines KI & Data-Science-Projektes, um den Anwendungsfall auszurichten und um aufzuzeigen, mit welchen Fragen man die Data Understanding-Phase gehen sollte.

Er hilft aber auch in späteren Iteration die Erkenntnisse und Feedbacks einzuordnen und den Anwendungsfall dann datengestützt neu auszurichten und die neue Ausrichtung zu kommunizieren.

## AI Use Case - Fiktives Beispiel "KI-Chat mit dem Helpdesk-Wiki" im Canvas



## Wo fange ich an im Canvas?

"When you do things you are bound to make mistakes. The only way to avoid them is not to do anything, which is the biggest mistake."

— Eliyahu Goldratt

Der typische Startpunkt wäre die Idee, also das zu lösende Problem oder das Wertversprechen, dass wir machen möchten. Oft lohnt es sich dieses sehr gut zu verstehen, den "Problem Space" zu durchleuchten und dann ein passendes Teilproblem auszuwählen.

Das ist schwer, aber auch eine der besonderen Eigenschaften von KI / Data-Science-Projekten. Oft entstehen aus der Datenanalyse oder der Betrachtung von Risiken, Rausch-Faktoren, Biases oder den verfügbaren Ressourcen neue Erkenntnisse, die den Zuschnitt des Problems in Frage stellen oder schlicht neue Möglichkeiten aufzeigen.

Hier ist es wichtig die richtige Balance zu finden: Es gilt die Ziele im Auge zu behalten, aber sie nicht stoisch zu verfolgen, um die teils überraschenden Erkenntnisse unterwegs aufgreifen zu können und auch Ziele zu hinterfragen oder mehrere gleichzeitig zu verfolgen. Anders als im klassischen Software-Engineering steuern oft die Daten selbst das Projekt mit.

Ein weiterer typischer Startpunkt sind die verfügbaren Daten. Sie sind Voraussetzung für ein "Lernen" aller Art und bringen uns auf Ideen, was möglich sein könnte. Oft ist es eine gute Idee in Workshops zu KI-Anwendungsfällen auch beispielhaft Datensätze anzuschauen.

Das Daten-Segment kann aber auch Ergebnis der Überlegungen sein: Welche Daten müssen wir sammeln, um erfolgversprechende KI-Projekt gezielt aufsetzen zu können?

Lernende Systeme brauchen Kennzahlen, an denen sie Erfolg messen können. Nur so ist ein "Machine Learning" möglich, bei dem viele Varianten (automatisch) mit diesen Kennzahlen bewertet werden müssen.

Gute Zielgrößen beziehen sich daher nur auf Dinge, die für ein Projekt-Team während der Erstellung des Systems schon greifbar sind: Daher gilt "Trefferquote auf bekannten Daten" statt "Kostenersparnis im ersten Jahr"

Eine Kostenersparnis wäre eher ein angestrebter Nutzen als eine Zielgröße. Die Wahl einer geeigneten Zielgröße ist oft der schwierigste Schritt bei der Planung eines KI-Projektes.

Einige Risiken sind ähnlich zu denen anderer Software-Projekte.

Anders als dort, haben KI-Projekte oft weitere Risiken, wie das Potenzial Gruppen ungleich oder ungleich gut zu behandeln. LLMs können außerdem Stereotypen reproduzieren (Bias) oder sporadisch Fehler machen.

Auch wichtig ist die Frage, welche Risiken ein sehr erfolgreiches KI-Projekt mit sich bringt - möglicherweise entstehen dadurch "Eigentore"

- Wenn ich den Stau richtig vorhersage, findet er dann noch statt?
- Wenn mein Wissensmanagement gut funktioniert, lernen meine Mitarbeitenden dann noch hinzu? Sehen sie Probleme noch?