

Generative KI in Unternehmen

Dr. Sven Schmeier, DFKI GmbH

schmeier@dfki.de

1. Was bedeutet das?

- Was bedeutet das?
- Was ist eine KI Strategie?
- Make or Buy?

Hat generative KI ein disruptives Potential wie das Internet?

1

Internet

Kosten der Distribution $\rightarrow 0$
(von Daten, Inhalten, Informationen)

2

Generative KI

Kosten der Generierung $\rightarrow 0$
(von Daten, Inhalten, Informationen)

Wo kann man generative KI bereits einsetzen?

Text- und
Bildgenerierung

Programmieren

Video

Tongenerierung

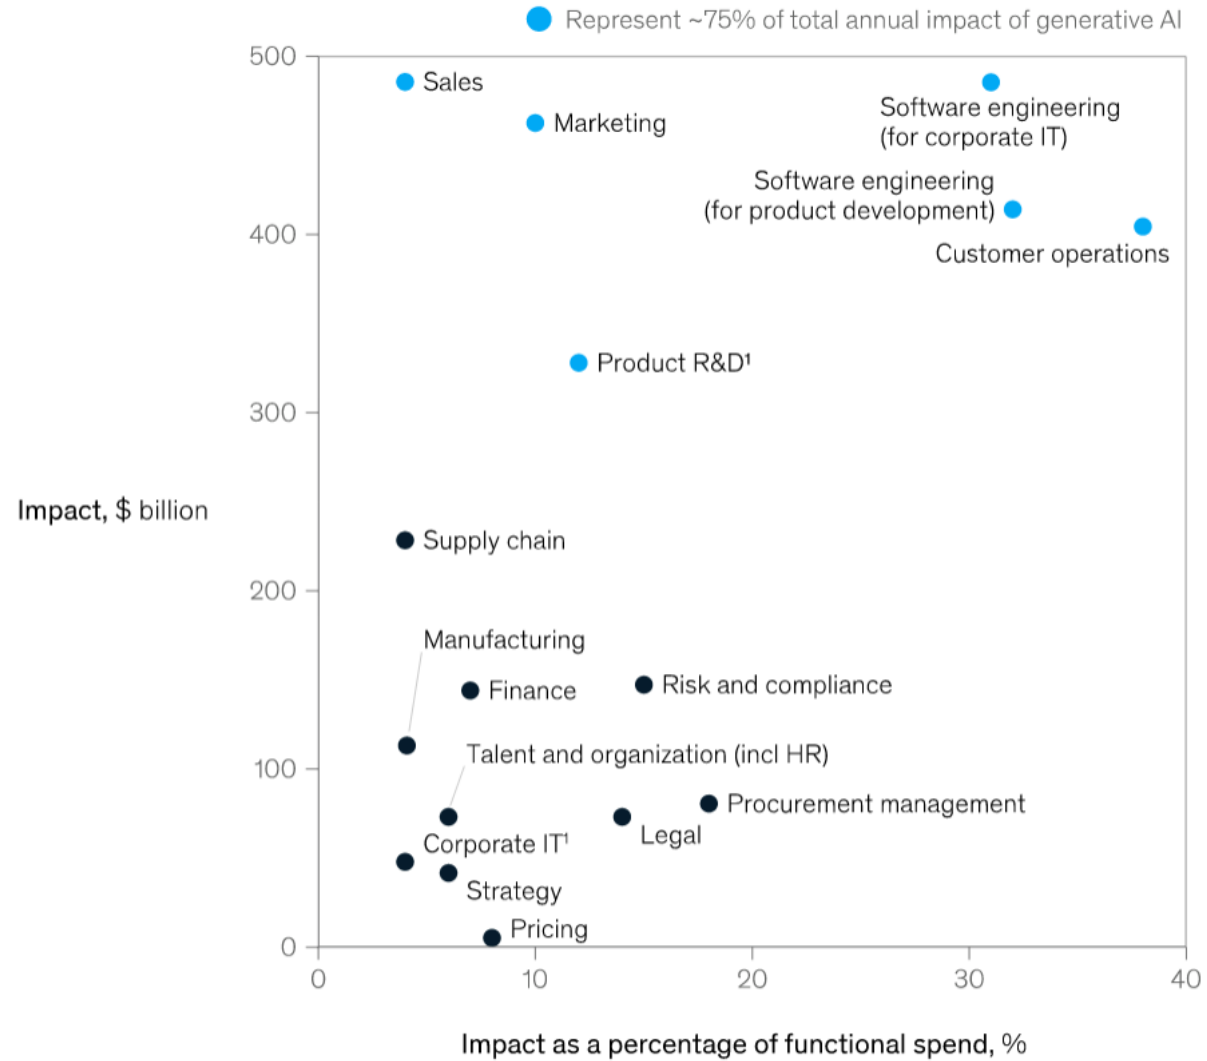
Kundenservice

Forschung
Gesundheitswesen
Finanzwesen
Bildung

...

McKinsey Studie: Das Potential fokussiert sich **noch** auf bestimmte Funktionen

Using generative AI in just a few functions could drive most of the technology's impact across potential corporate use cases.



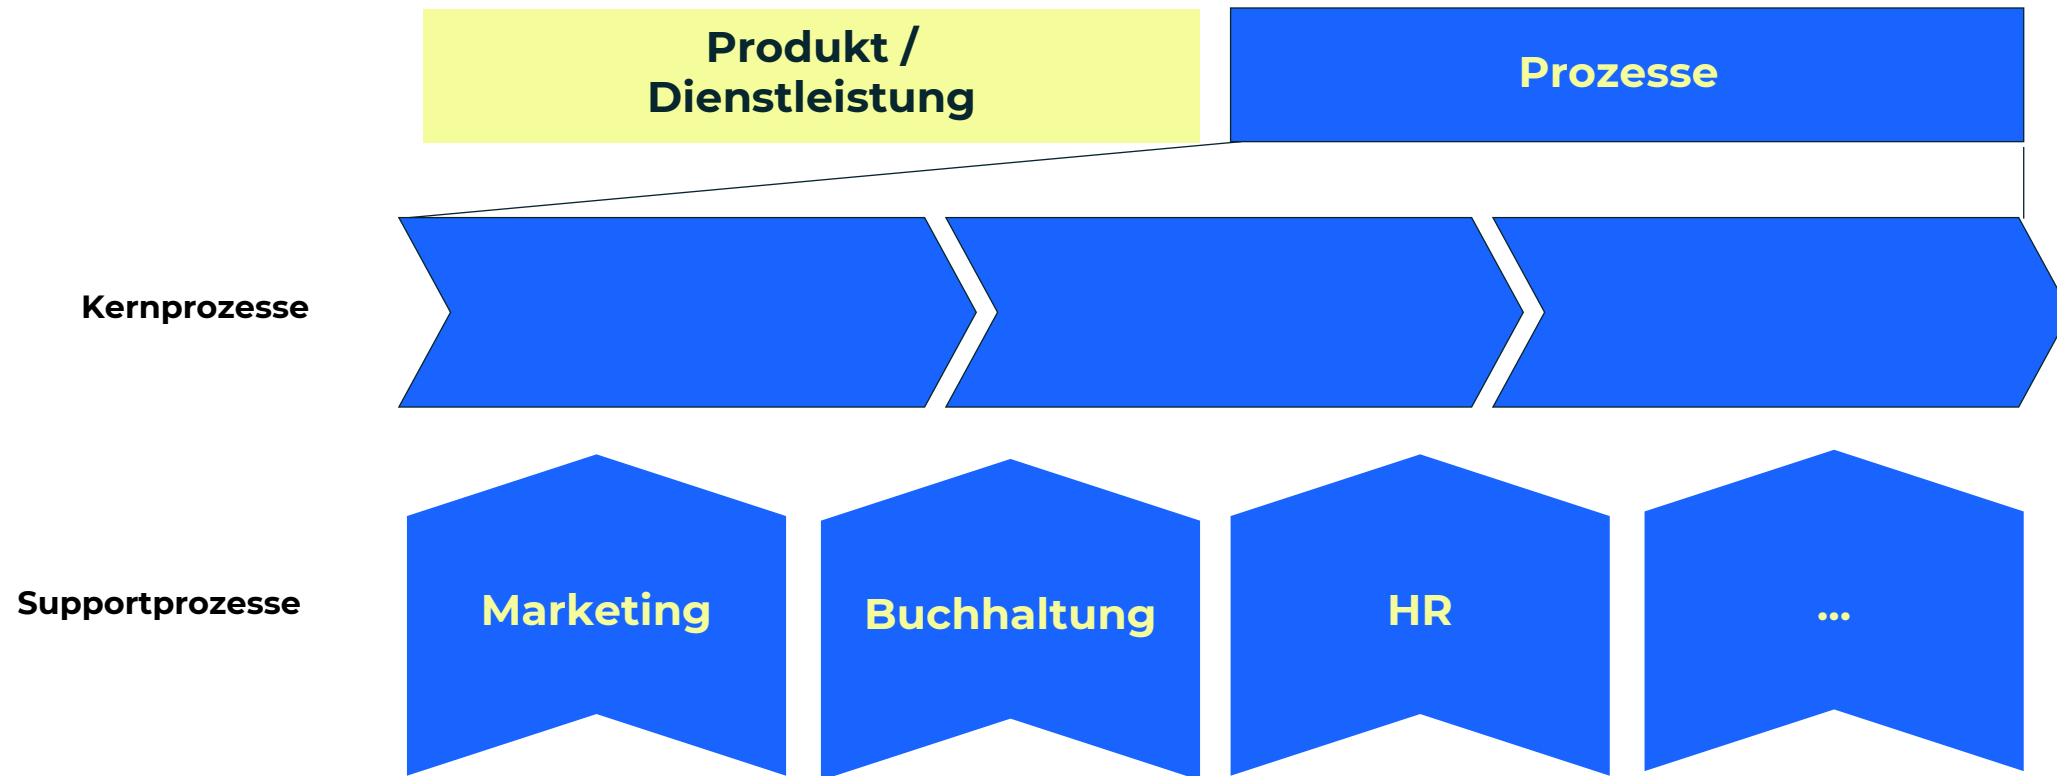
Note: Impact is averaged.

¹Excluding software engineering.

Source: Comparative Industry Service (CIS), IHS Markit; Oxford Economics; McKinsey Corporate and Business Functions database; McKinsey Manufacturing and Supply Chain 360; McKinsey Sales Navigator; Ignite, a McKinsey database; McKinsey analysis

Welchen Einfluss hat generative
KI auf meine Branche und mein
Unternehmen?

Ist mein Produkt beeinflusst? Welche Prozesse können von KI erledigt oder gestützt werden?

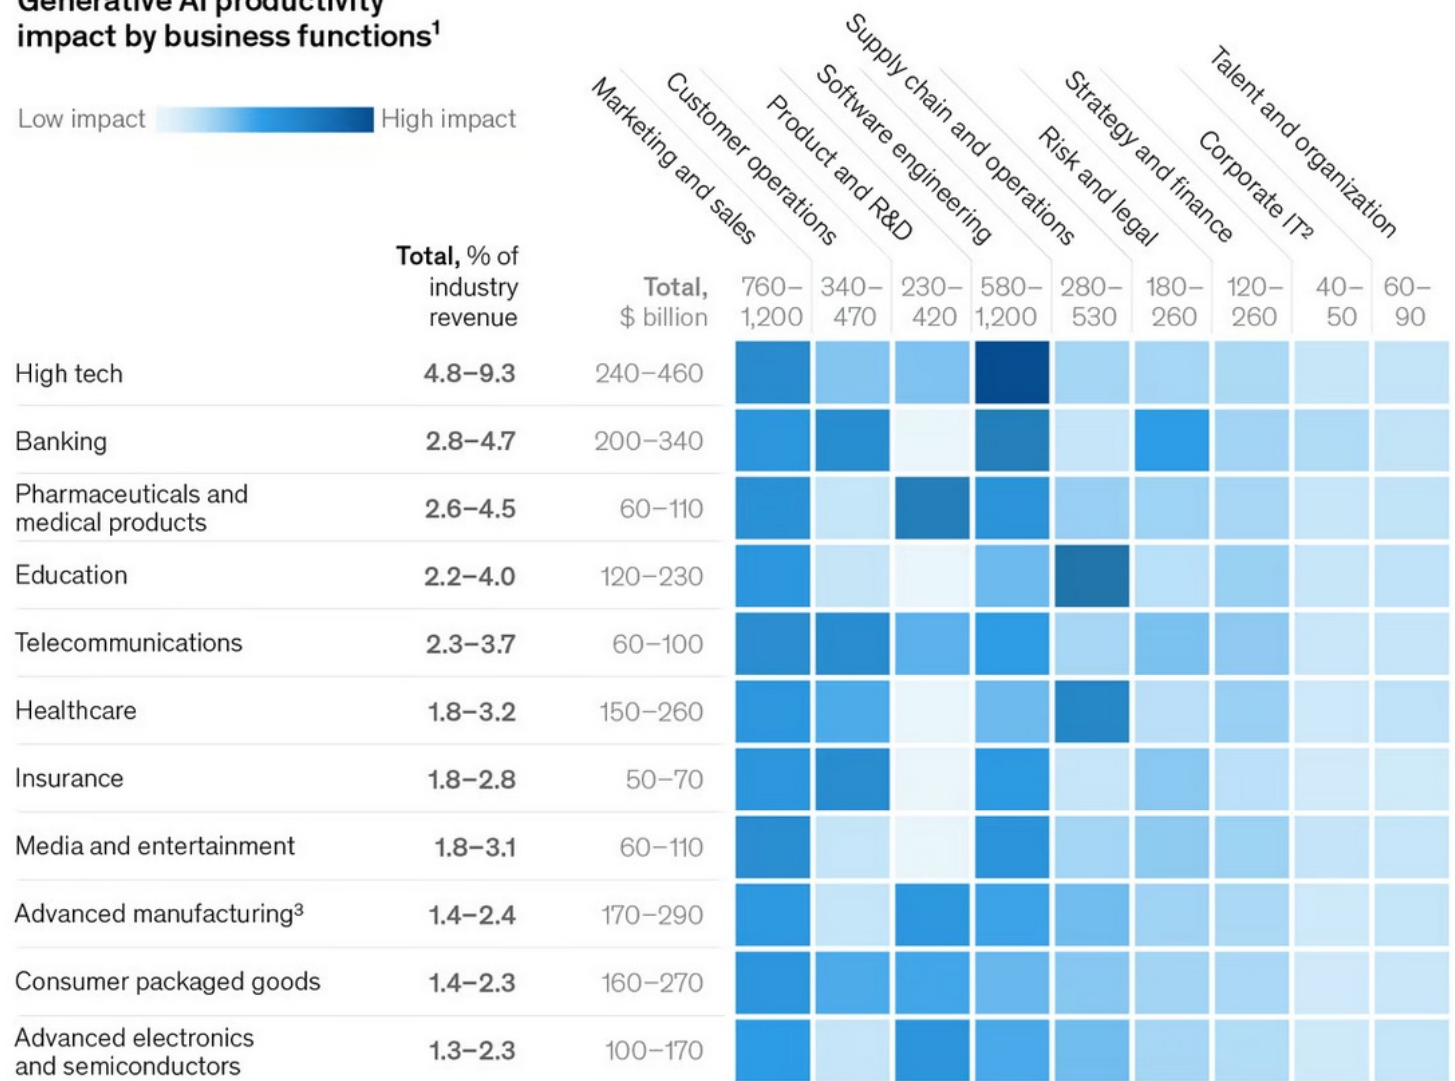


Generative AI use cases will have different impacts on business functions across industries.

McKinsey Studie: Größter Einfluss von KI in Tech, Banking und Pharma

Generative AI productivity impact by business functions¹

Low impact  High impact

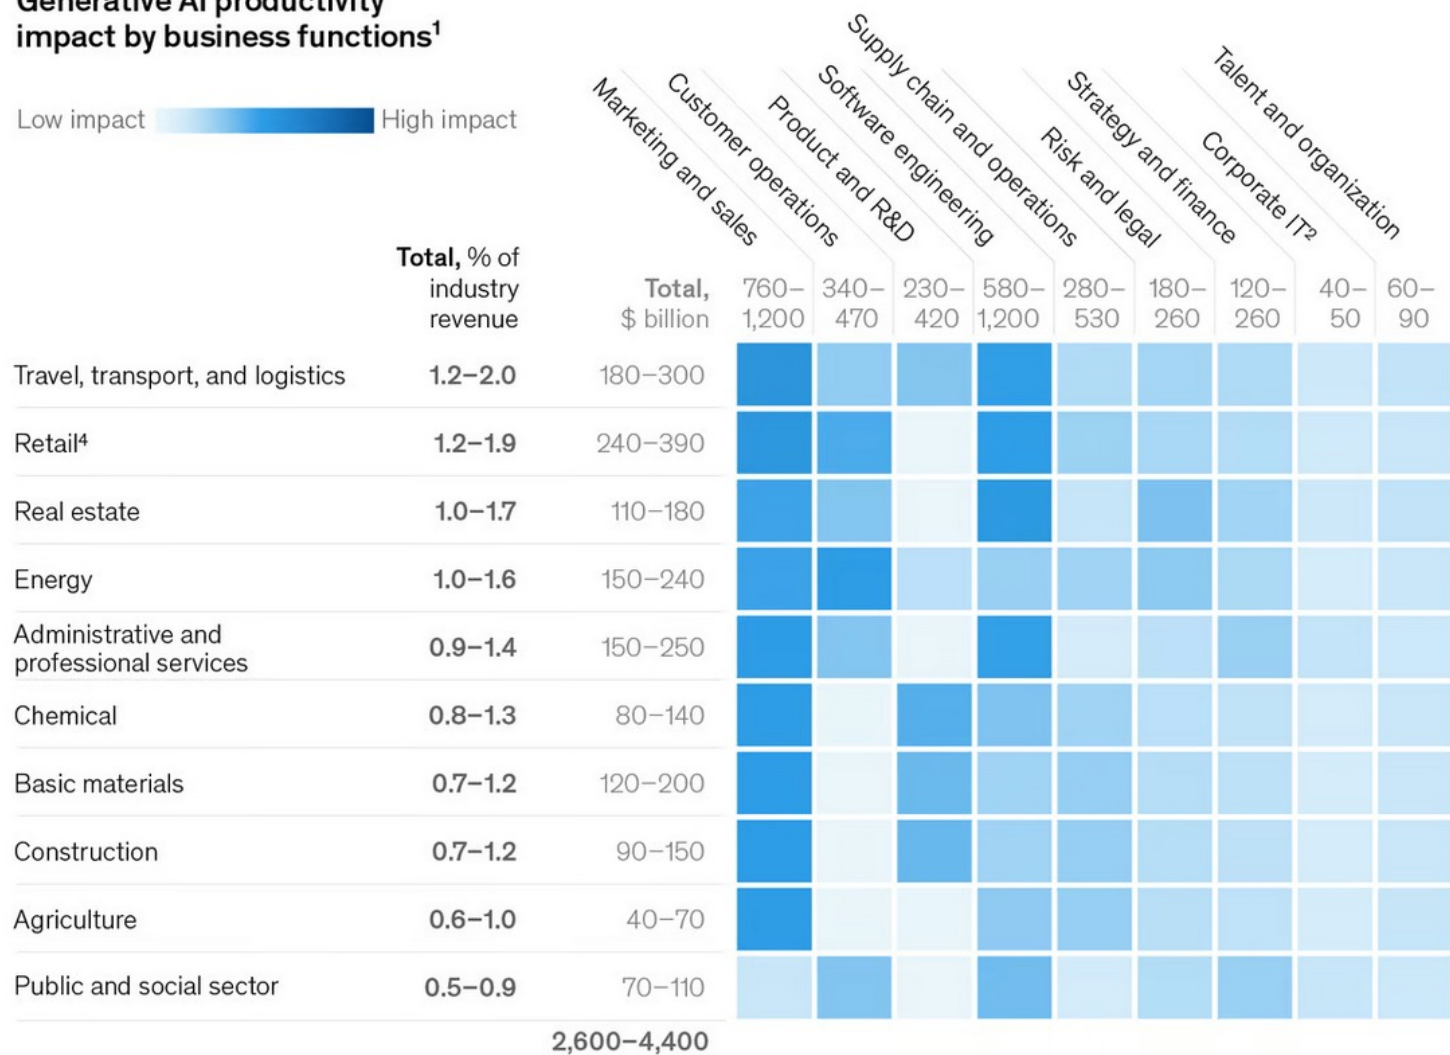


Note: Figures may not sum to 100%, because of rounding. ¹Excludes implementation costs (eg, training, licenses). ²Excluding software engineering. ³Includes aerospace, defense, and auto manufacturing. ⁴Including auto retail.
 Source: Comparative Industry Service (CIS), IHS Markit; Oxford Economics; McKinsey Corporate and Business Functions database; McKinsey Manufacturing and Supply Chain 360; McKinsey Sales Navigator; Ignite, a McKinsey database; McKinsey analysis

Generative AI use cases will have different impacts on business functions across industries.


Generative AI productivity impact by business functions¹

Low impact  High impact



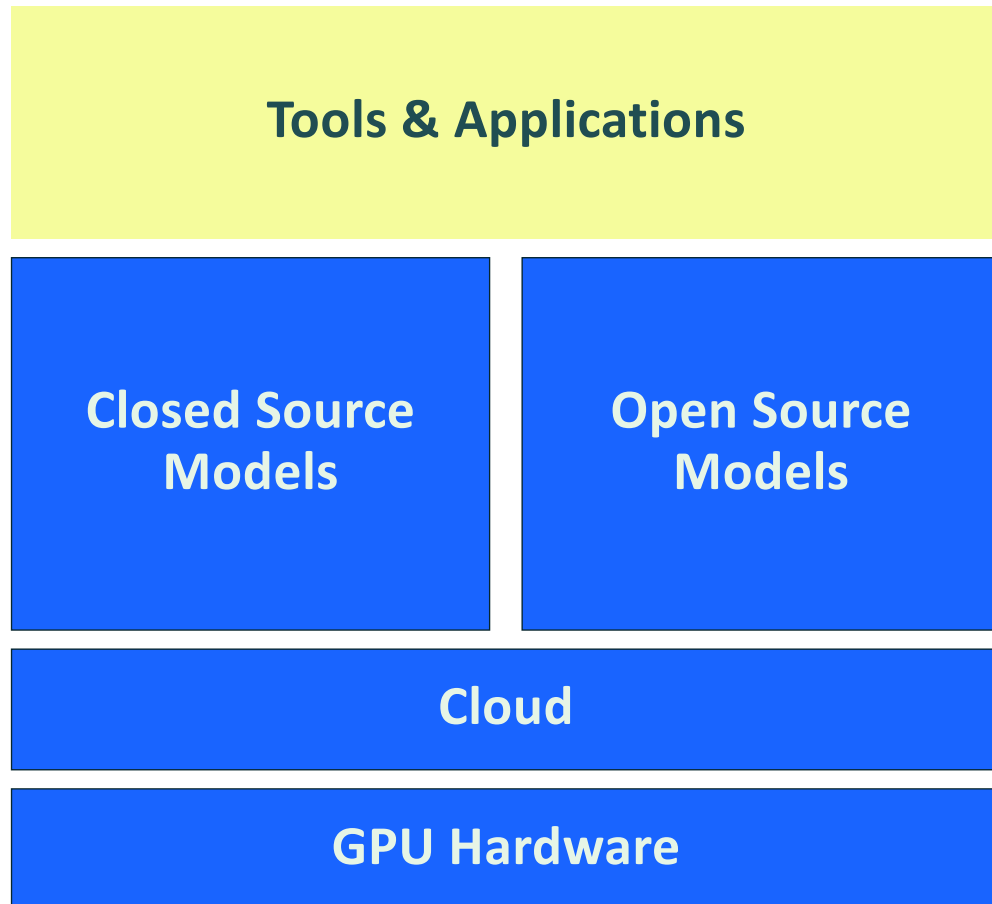
Note: Figures may not sum to 100%, because of rounding. ¹Excludes implementation costs (eg, training, licenses). ²Excluding software engineering. ³Includes aerospace, defense, and auto manufacturing. ⁴Including auto retail. Source: Comparative Industry Service (CIS), IHS Markit; Oxford Economics; McKinsey Corporate and Business Functions database; McKinsey Manufacturing and Supply Chain 360; McKinsey Sales Navigator; Ignite, a McKinsey database; McKinsey analysis

Das Ecosystem hinter dem Hype



- Gibt es einen Überblick, welche Tools es gibt? Welche bieten einen Mehrwert?
- „The Winner takes it all“? Dominanz weniger großer Modelle, die alles können?
- Haben kleine spezialisierte Modelle eine Zukunft?
- Big Tech vs. Open Source? Wer ist vorne?
- „GPU rich“ vs. „GPU poor“?

Tools: „There is an AI for that“



THE GENERATIVE AI LANDSCAPE

ANTLER

TEXT

- Smartwriter.ai, hypertype, Lately, Autobound, Writesonic, Jasper, cogram, genai, YOU, AI21 labs, letterdrop, copysmith, C reatext, jenni, mavenoid, anyword, [PERSADO], frase, regie.ai, Autoenhance.ai, Miti, Linguix, Hypotenuse AI, WRITER, OTHERSIDE AI, copy.ai, copymatic, COMPOSE AI

IMAGE

- ClipDrop, pencil, beautiful.ai, PhotoRoom, BR, Facet, Poly, CSM, Blend, HYPAR, ROSEBUD.AI, maket, Autoenhance.ai, BOTIKA, Sloyd, MODULIZE, Re:cast AI, uizard, Imagen, Hexo AI

AUDIO

- MURF.AI, REPLICAI, notably, Endel, WELLSAID, AssemblyAI, KRISP, Speechify, RESEMBLE.AI, MUBERT, KAIZAN, coqui, Mubert, Neural @ Space, soundful, VOICEMOD, Listnr, LOVO, Vocal Clarity, Diverse, AD AURIS

CODE

- Debuild, tabnine, Codiga, Locofy, AIxcoder, Mintlify, mayā, MutableAI, cod.is, durable, The.com, bloop, replit, ENZYME, Dhiwise, codota, anima, CODACY, warp, Metabob

CHATBOTS

- lang.ai, PolyAI, Tymeely, Incentivai, Kasisto, ushur, CRESTA, Elise.ai, verloop.io, nepiko, ultimate.ai, Cohere, Sapling, haptik, ada, Forethought, OBSERVE-AI, XOXind, Balto, Certainly.

VIDEO

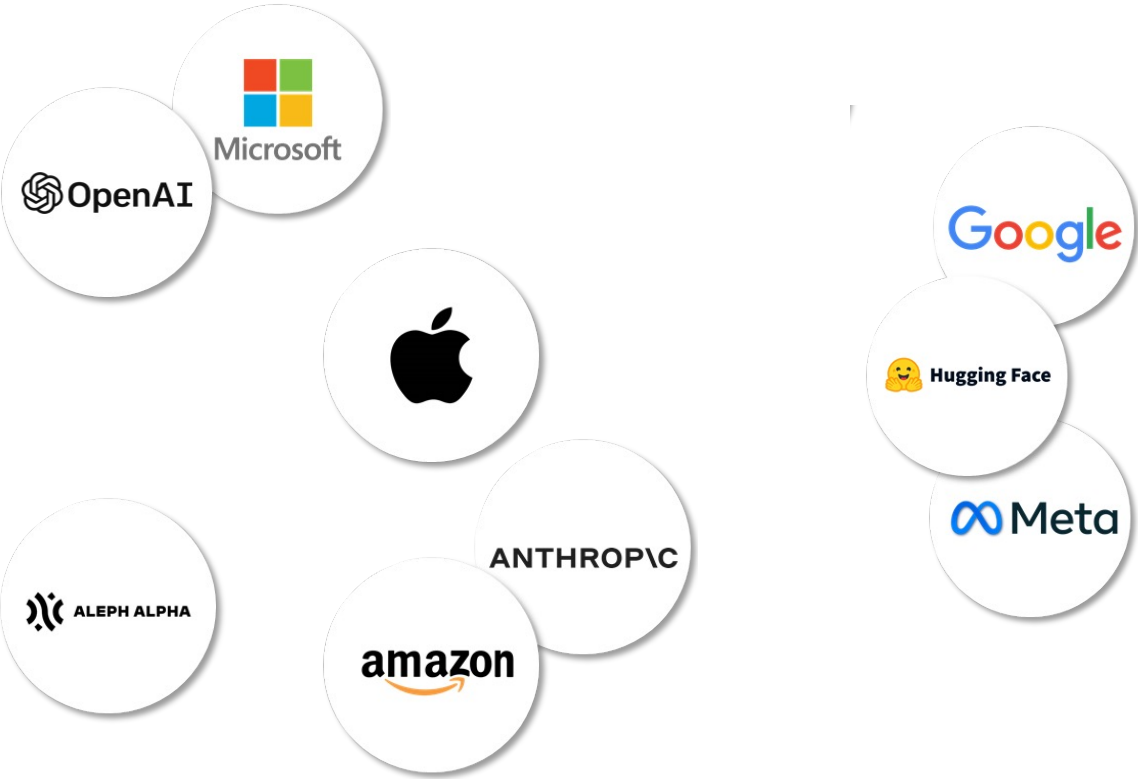
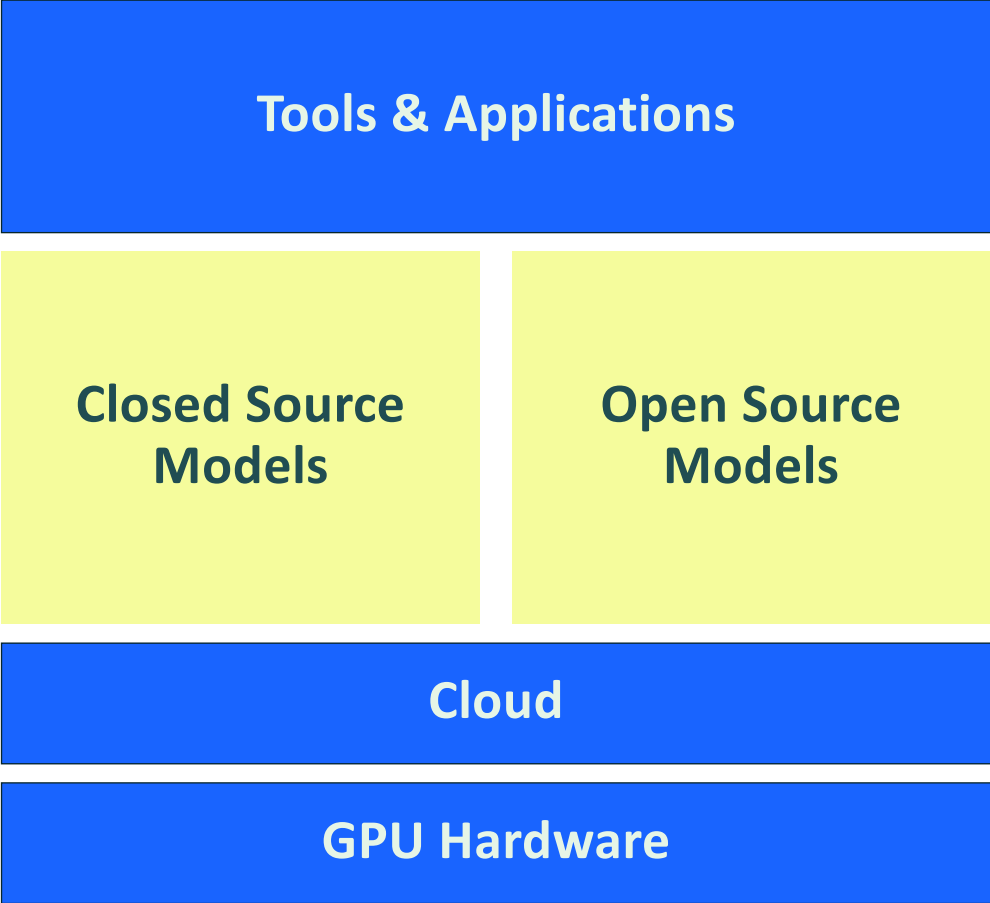
- ZUBTITLE, TERRA, Peech, VOCHI, Maverick, recut, VEED.IO, Basch.io, Inworld, WOMB, tavus, Deepdub.ai, FATHOM, runway, Mario, X EMBLY, PICTORY, vidyo.ai, Rephrase.ai, lumen5, Steve AI, windsor.io, YEPIC, Deepdub.ai, Colossyan, METAPHYSIC, Potion

ML PLATFORMS **SEARCH** **GAMING** **DATA**


















Galileo featureform

Tools, die aktuelle Probleme von LLMs lösen, werden durch neue Versionen teilweise obsolet

Closed vs. Open Source: The winner takes it all?



Closed vs. Open Source: Die Größe ist wichtig, es gibt aber Alternativen

| Model Name | Win Rate | Length |
|--|----------|--------|
| GPT-4 Turbo  | 97.70% | 2049 |
| XwinLM 70b V0.1  | 95.57% | 1775 |
| PairRM+Tulu 2+DPO 70B (best-of-16)  | 95.40% | 1607 |
| GPT-4  | 95.28% | 1365 |
| Tulu 2+DPO 70B  | 95.03% | 1418 |
| Yi 34B Chat  | 94.08% | 2123 |
| PairRM+Zephyr 7B Beta (best-of-16)  | 93.41% | 1487 |
| LLaMA2 Chat 70B  | 92.66% | 1790 |
| UltraLM 13B V2.0 (best-of-16)  | 92.30% | 1720 |
| XwinLM 13b V0.1  | 91.76% | 1894 |
| UltraLM 13B (best-of-16)  | 91.54% | 1980 |
| Claude 2  | 91.36% | 1069 |
| PairRM+Tulu 2+DPO 13B (best-of-16)  | 91.06% | 1454 |
| Cohere Command  | 90.62% | 1983 |
| Zephyr 7B Beta  | 90.60% | 1444 |
| OpenChat V3.1 13B  | 89.49% | 1484 |
| ChatGPT  | 89.37% | 827 |

Closed vs. Open Source: Und welches Modell nehme ich?

Vorteile großer (geschlossener) Modelle

- Größe, und flexibel einsetzbar
- Menge der Trainingsdaten
- Verknüpfung zu großen Suchindizes bzw. Knowledge Graphen
- Sehr leicht zugänglich
- Resultate sehr gut

Vorteile kleinerer (Open Source) Modelle

- Geringere Kosten
- IP bleibt in House
- Datenschutz
- Fachspezifisches Vokabular
- Intransparenz (Bias)
- Anpassbar

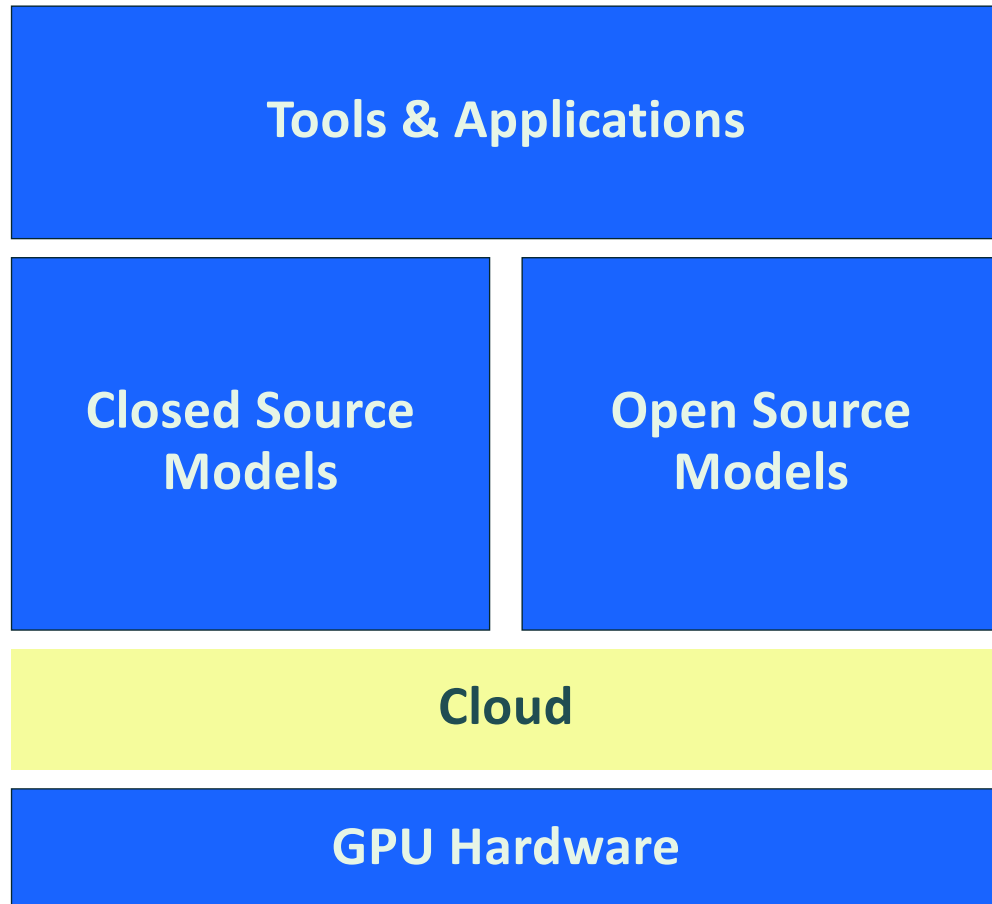
Kleine Modelle sind die Zukunft ...

Grundregel:

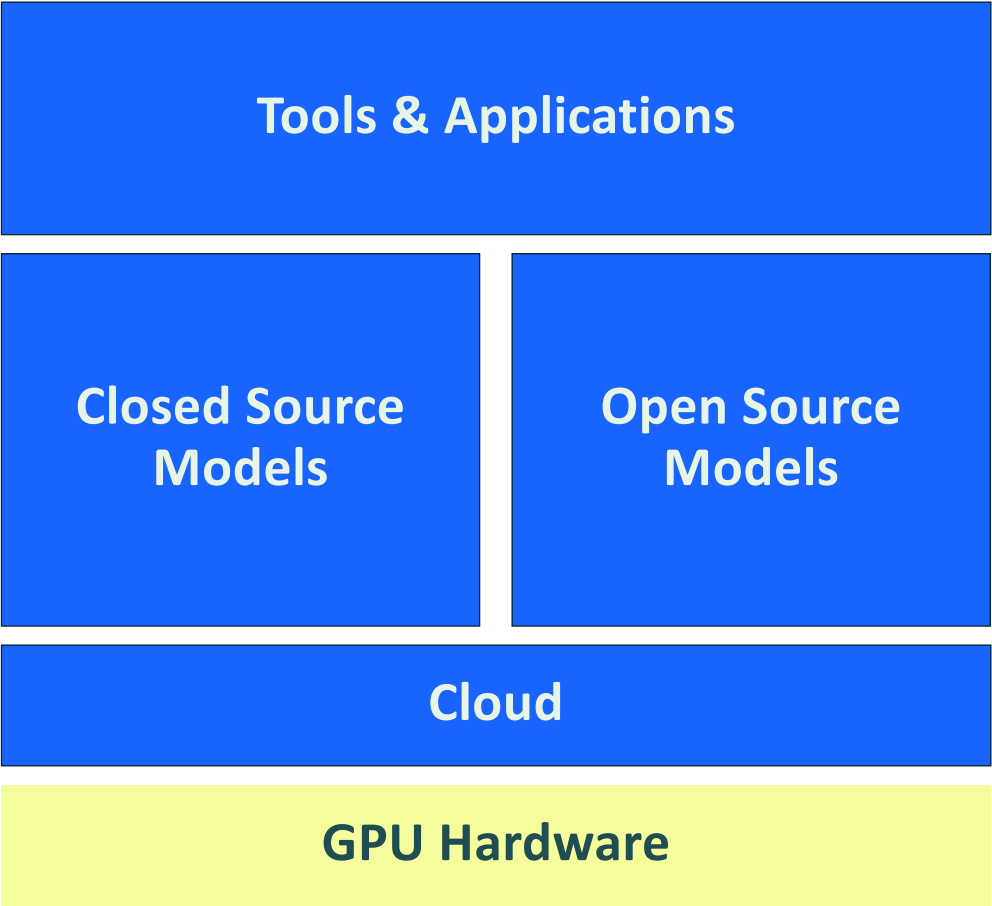
Testen und mit dem besten Modell
starten

Und wenn es funktioniert nach kleineren Alternativen oder
Tools suchen

Cloud: Die Big Player



GPU: GPU poor vs. GPU rich



2. Was ist eine KI Strategie?

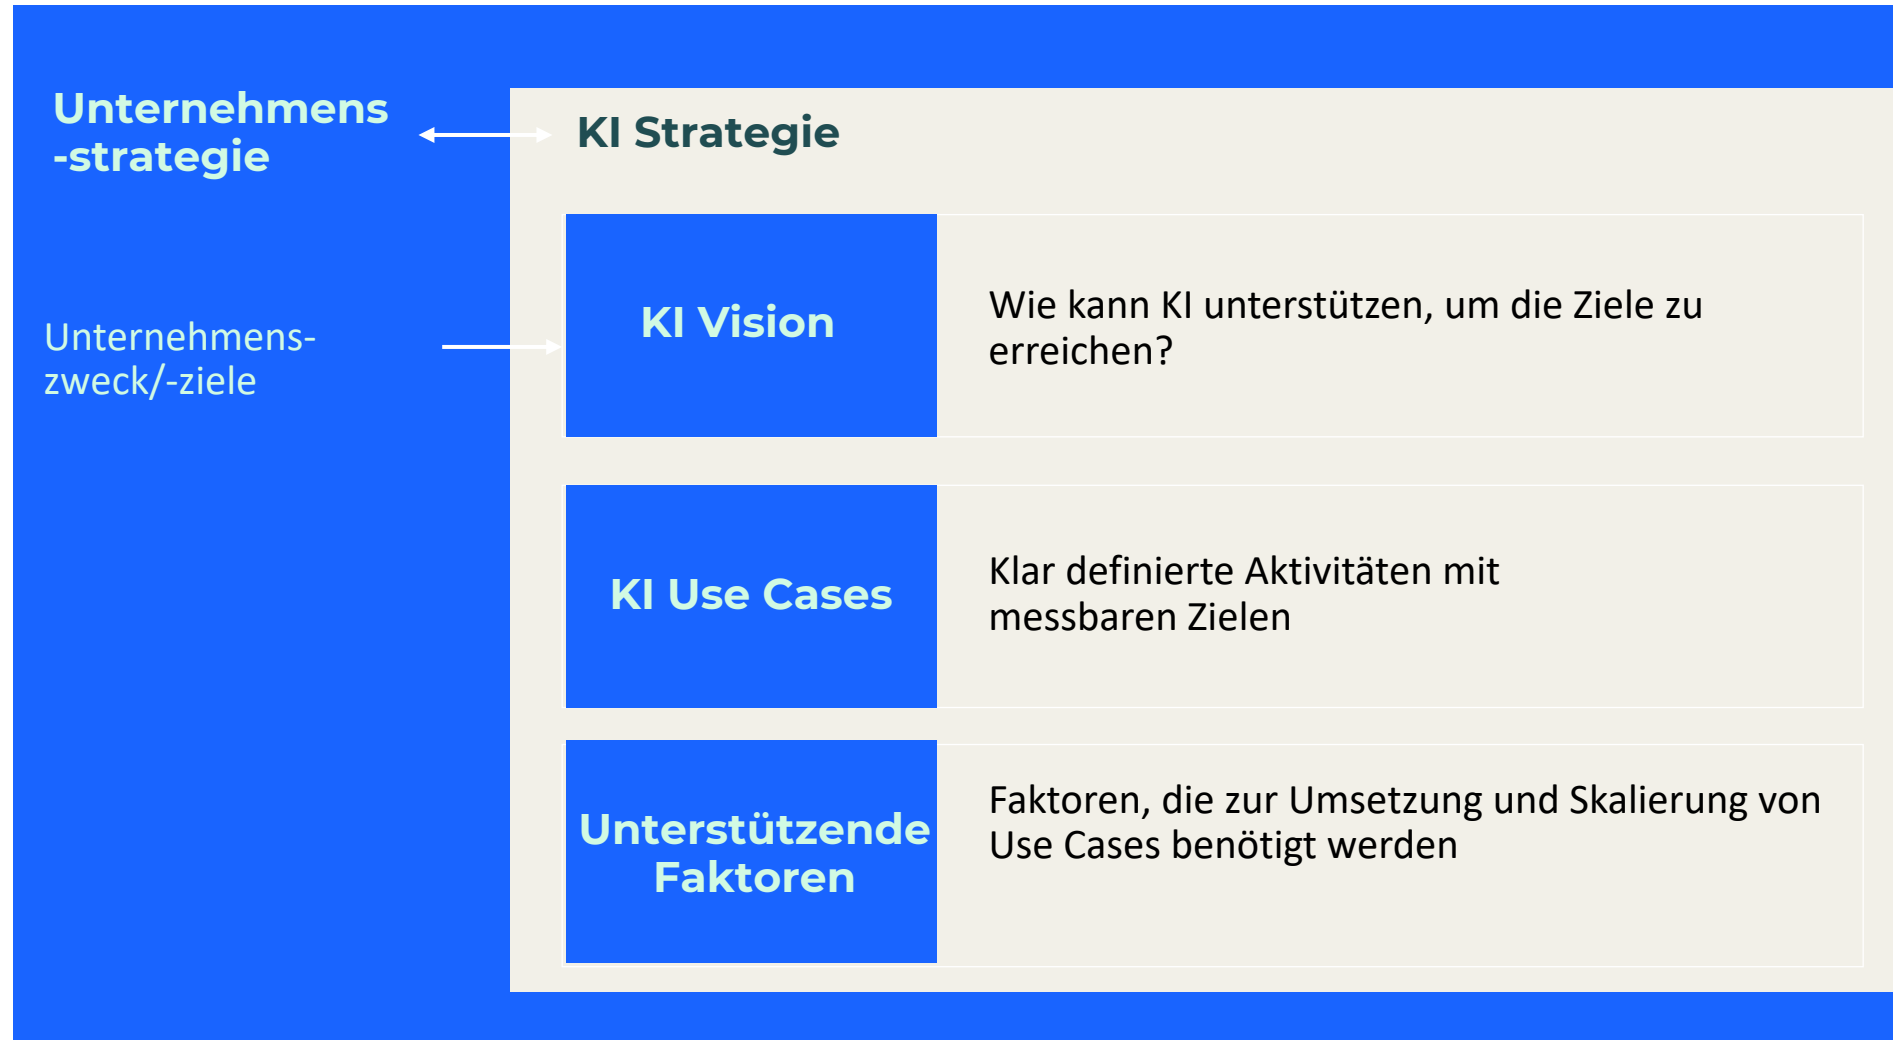
- Was bedeutet das?
- **Was ist eine KI Strategie?**
- Make or Buy?



„Understanding what AI can do and how it fits into your strategy is the beginning, not the end, of that process.“

Andrew Ng, Professor Stanford University

Die KI Strategie im Unternehmenskontext

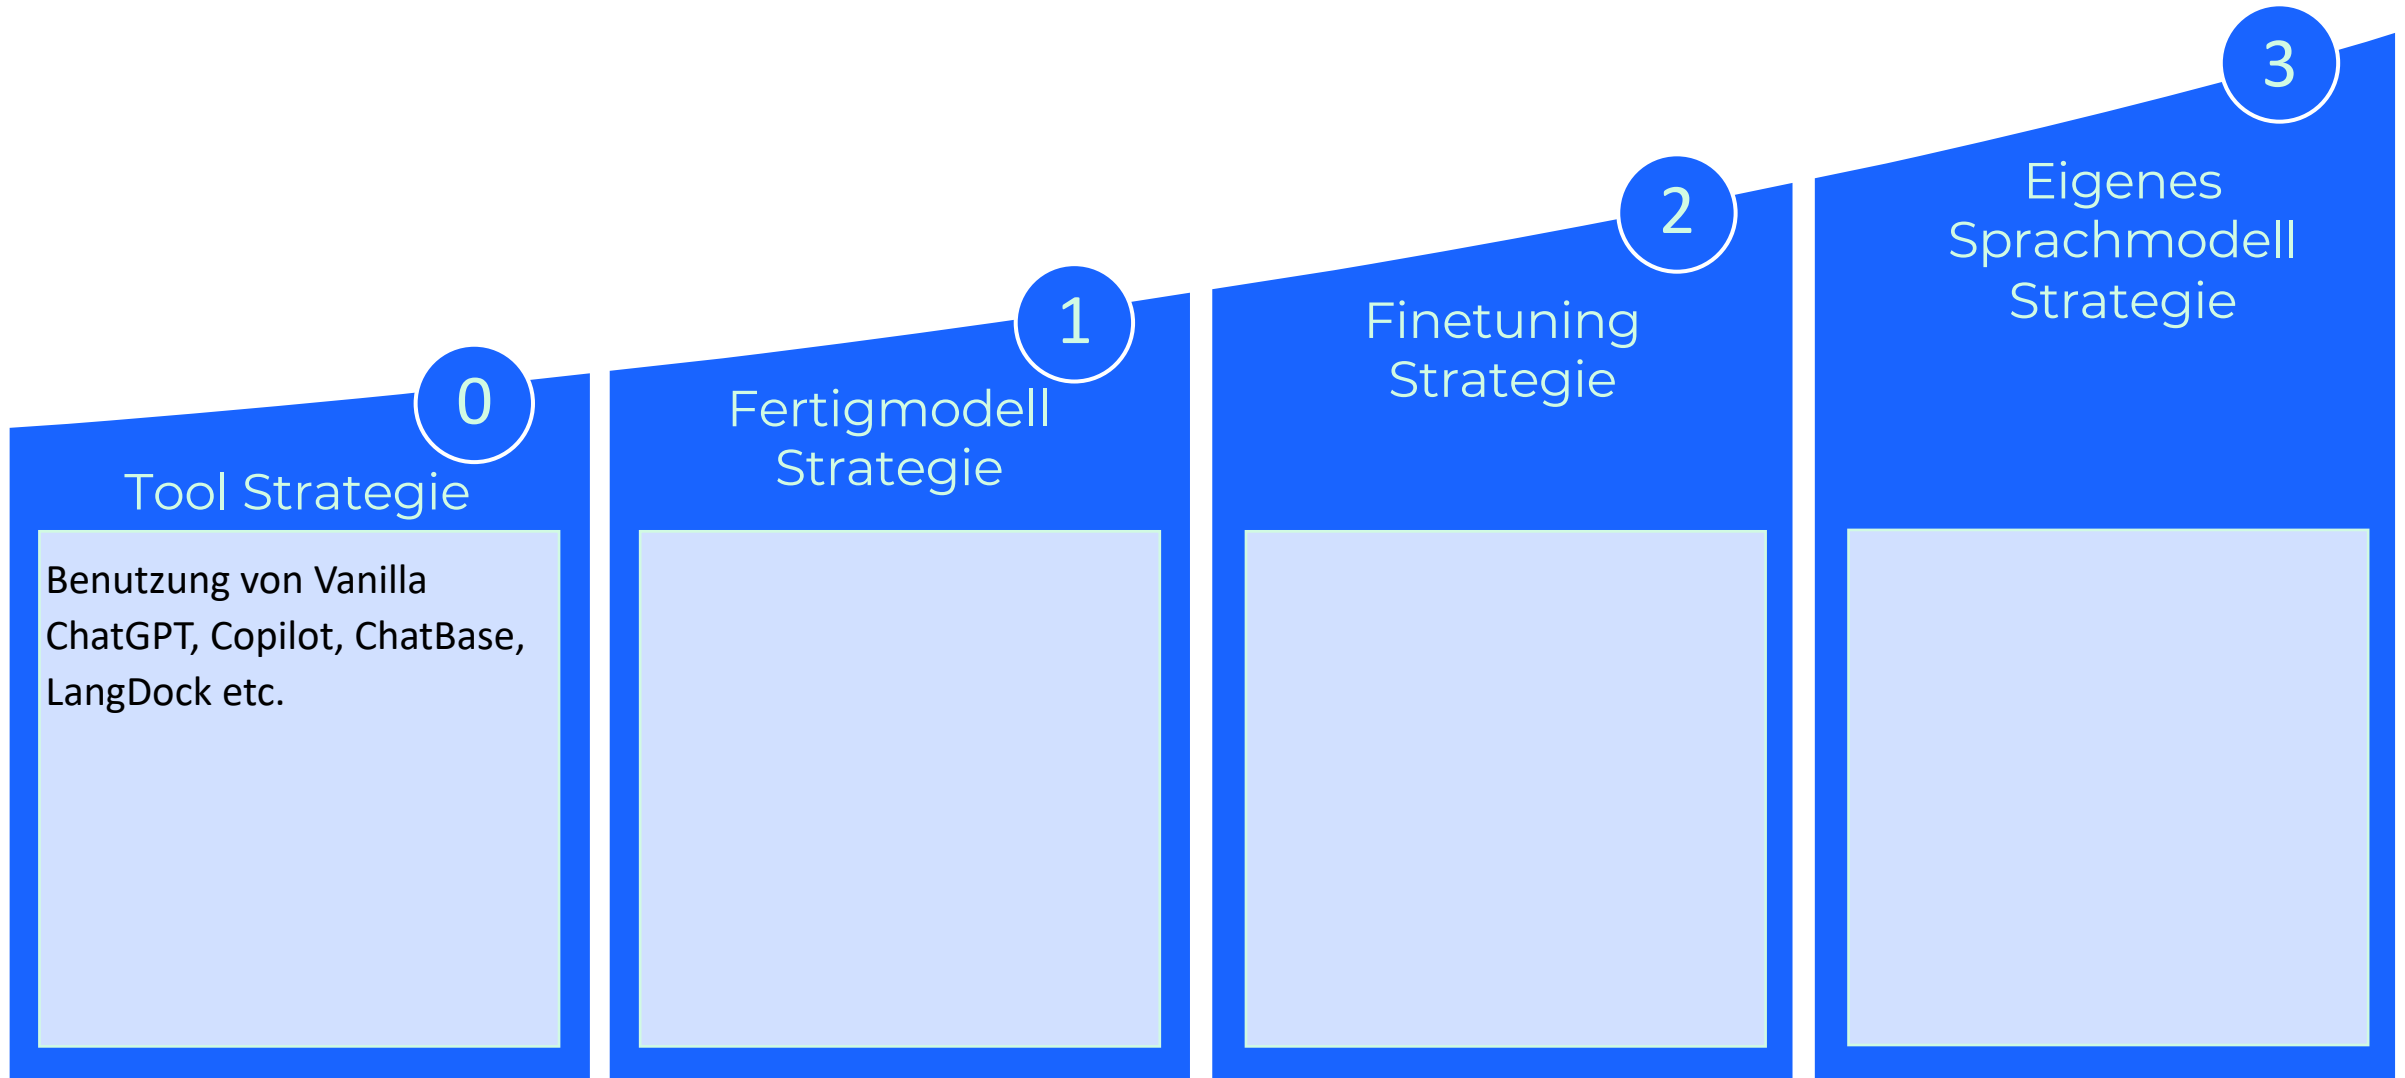


Die Bestandteile einer KI Strategie



3. Make or Buy?

- Was bedeutet das?
- Was ist eine KI Strategie?
- Make or Buy?





0 Tool Strategie

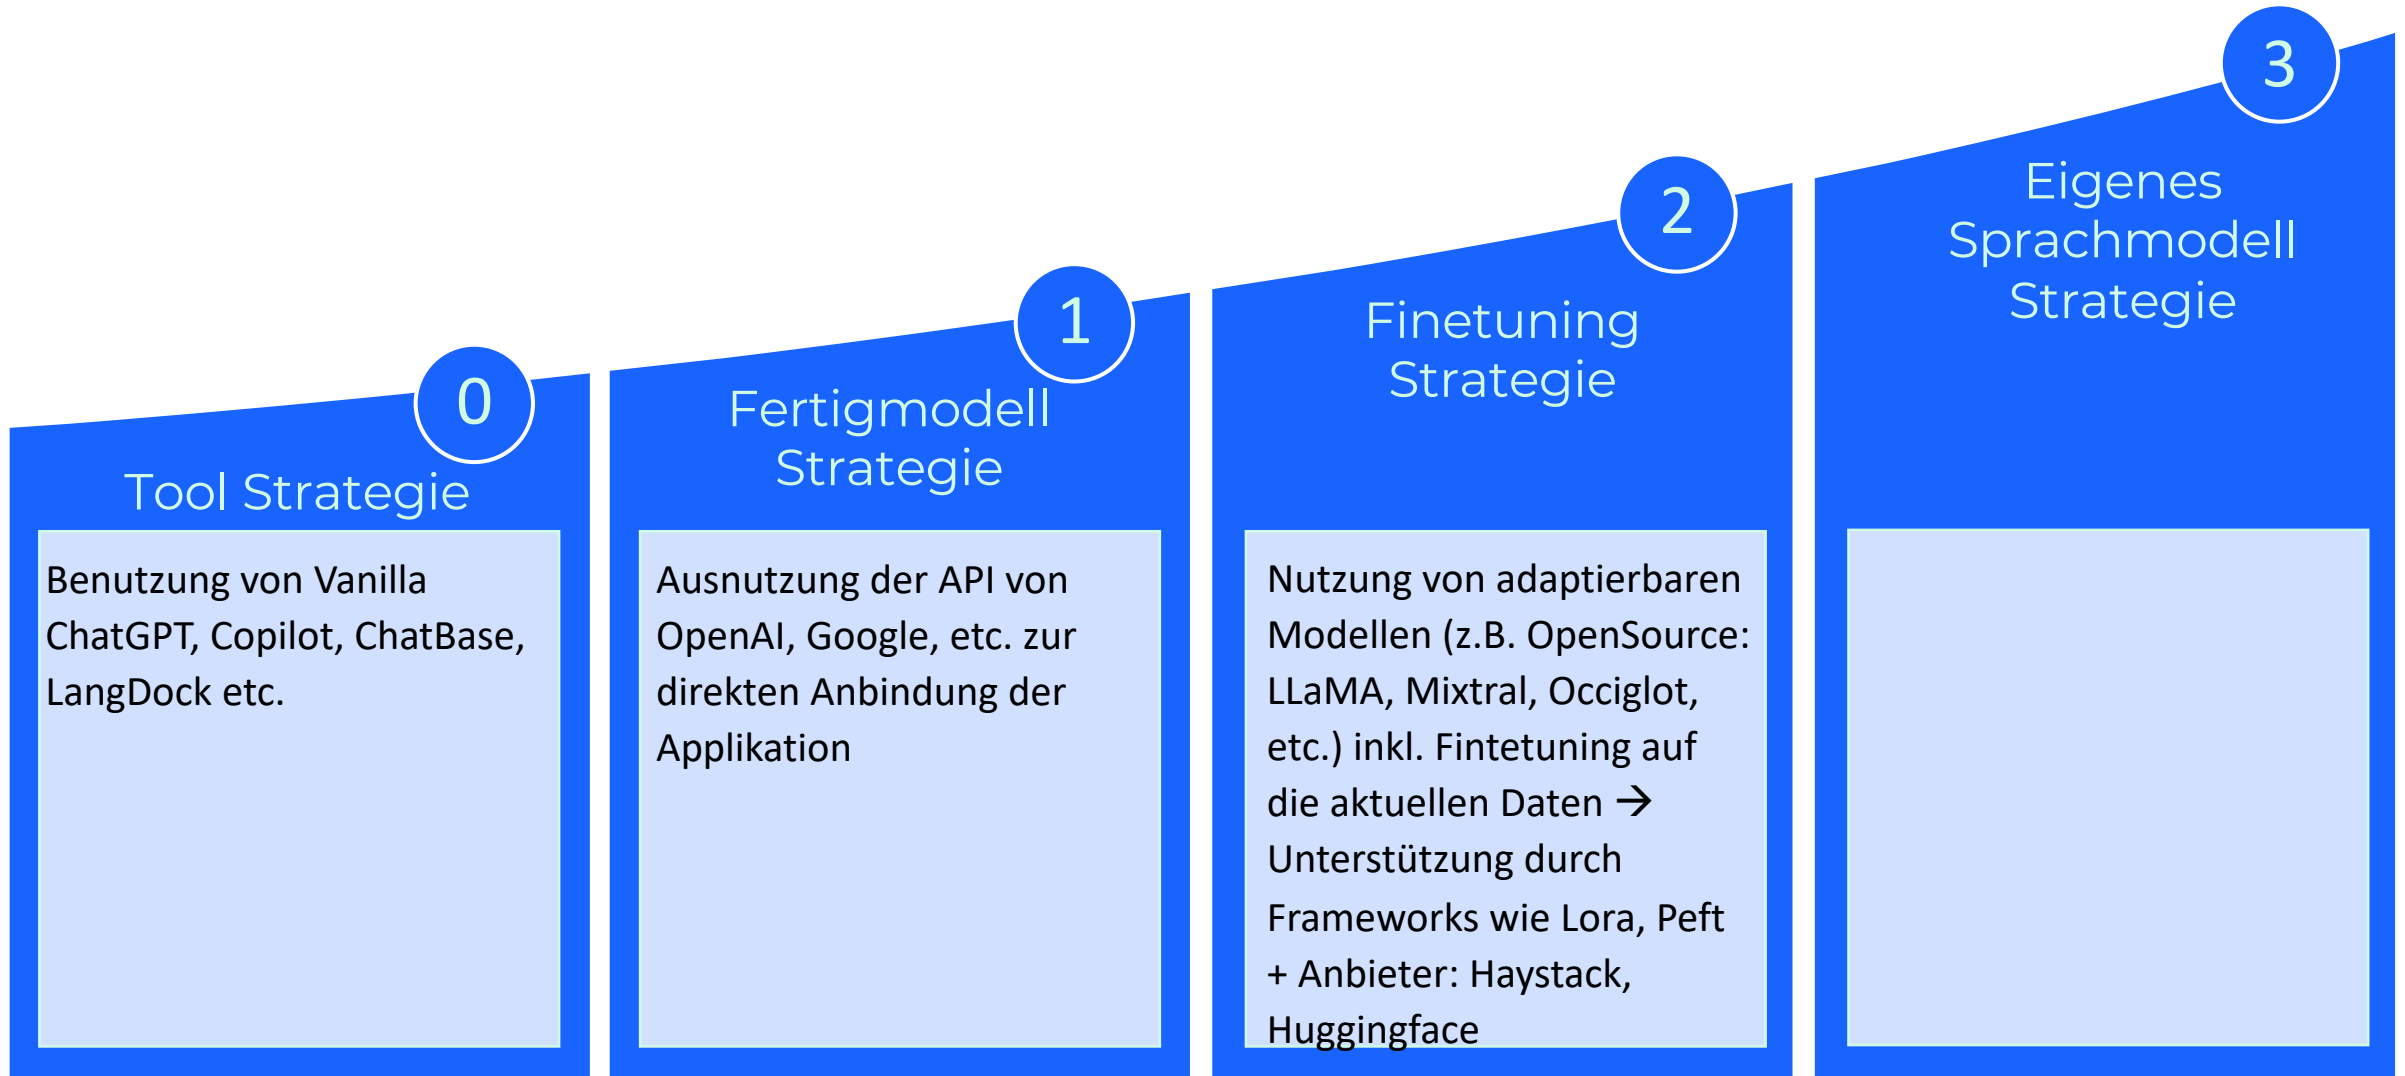
Benutzung von Vanilla ChatGPT, Copilot, ChatBase, LangDock etc.

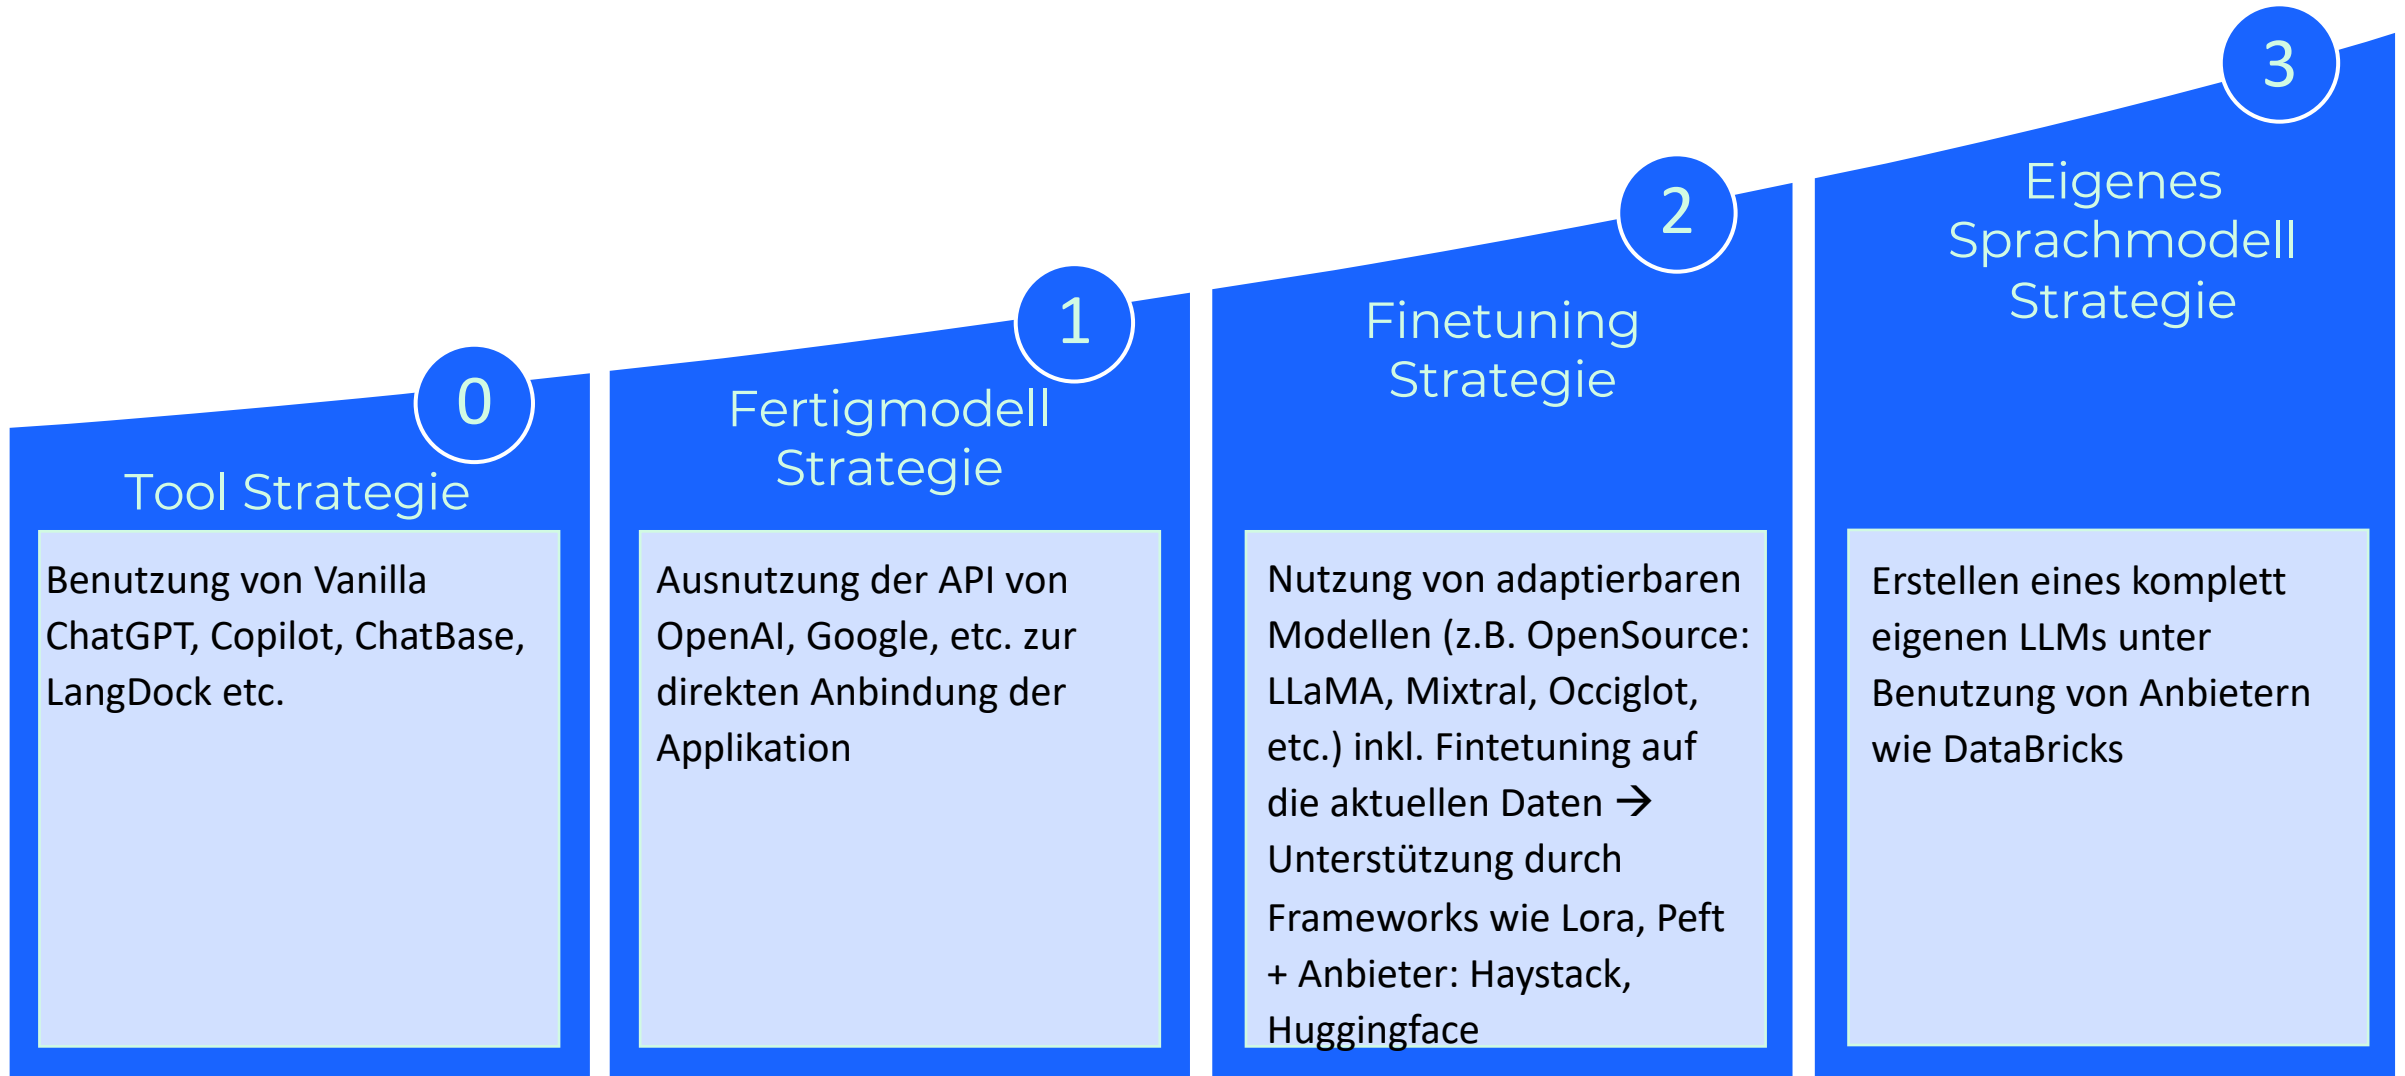
1 Fertigmodell Strategie

Ausnutzung der API von OpenAI, Google, etc. zur direkten Anbindung der Applikation

2 Finetuning Strategie

3 Eigenes Sprachmodell Strategie





Projektmanagement

Der CRISP-DM Standard

CRISP-DM: Cross-Industry Standard Process for Data Mining


Entwickelt im Rahmen eines EU-Projekts von 1996-99

Partner: DaimlerChrysler (Deutschland), NCR Systems Copenhagen (USA,Dänemark), OHRA Bank Groep B.V. (Niederlande)
SPSS Inc. (USA)

Für Informationen zu CRISP-DM siehe <http://www.crisp-dm.org>



Das CRISP-DM Referenzmodell



Business Understanding

Initiale Phase

Inhalt:

- Verstehen der Projektziele und Anforderungen aus Unternehmenssicht
- Transformation dieses Wissens in eine Data-Mining-Problemdefinition und Erstellung eines vorläufigen Projektplan

Data Understanding

Beginnt mit einer ersten Datenerfassung

Führt fort mit Aktivitäten, die darauf abzielen:

- Sich mit den Daten vertraut machen
- Erkennen von Datenqualitätsproblemen
- Entdecken von ersten Erkenntnissen über die Daten
- Erkennen interessanter Teilmengen zur Bildung von Hypothesen für versteckte Informationen

Data Preparation

- Umfasst alle Aktivitäten zur Erstellung des endgültigen Datensatzes (Daten, die in das/die Modellierungswerkzeug(e) eingespeist werden) aus den ursprünglichen Rohdaten
- Datenvorbereitungsaufgaben werden häufig mehrfach und nicht in einer vorgeschriebenen Reihenfolge durchgeführt
- Zu den Aufgaben gehören die Auswahl von Tabellen, Datensätzen und Attributen sowie die Transformation und Bereinigung von Daten für Modellierungswerkzeuge

Modelling

- Verschiedene Modellierungstechniken werden ausgewählt und angewendet, und ihre Parameter werden auf optimale Werte kalibriert
- Typischerweise gibt es mehrere Techniken für denselben Data-Mining-Problemtyp
- Einige Techniken haben spezifische Anforderungen an die Form der Daten, daher ist oft ein Rücksprung in die Phase der Data Preparation erforderlich

Evaluation

- In diesem Stadium wurde ein Modell (oder Modelle) erstellt, das aus Sicht der Datenanalyse eine hohe Qualität zu haben scheint.
- Bevor Sie mit der endgültigen Implementierung des Modells fortfahren, ist es wichtig, das Modell gründlicher zu bewerten und die Schritte zu überprüfen, die zur Erstellung des Modells ausgeführt wurden, um sicherzustellen, dass es die Geschäftsziele richtig erreicht
- Ein Hauptziel ist es, festzustellen, ob es ein wichtiges Geschäftsproblem gibt, das nicht ausreichend berücksichtigt wurde
- Am Ende dieser Phase sollte eine Entscheidung über die Verwendung der Data-Mining-Ergebnisse getroffen werden

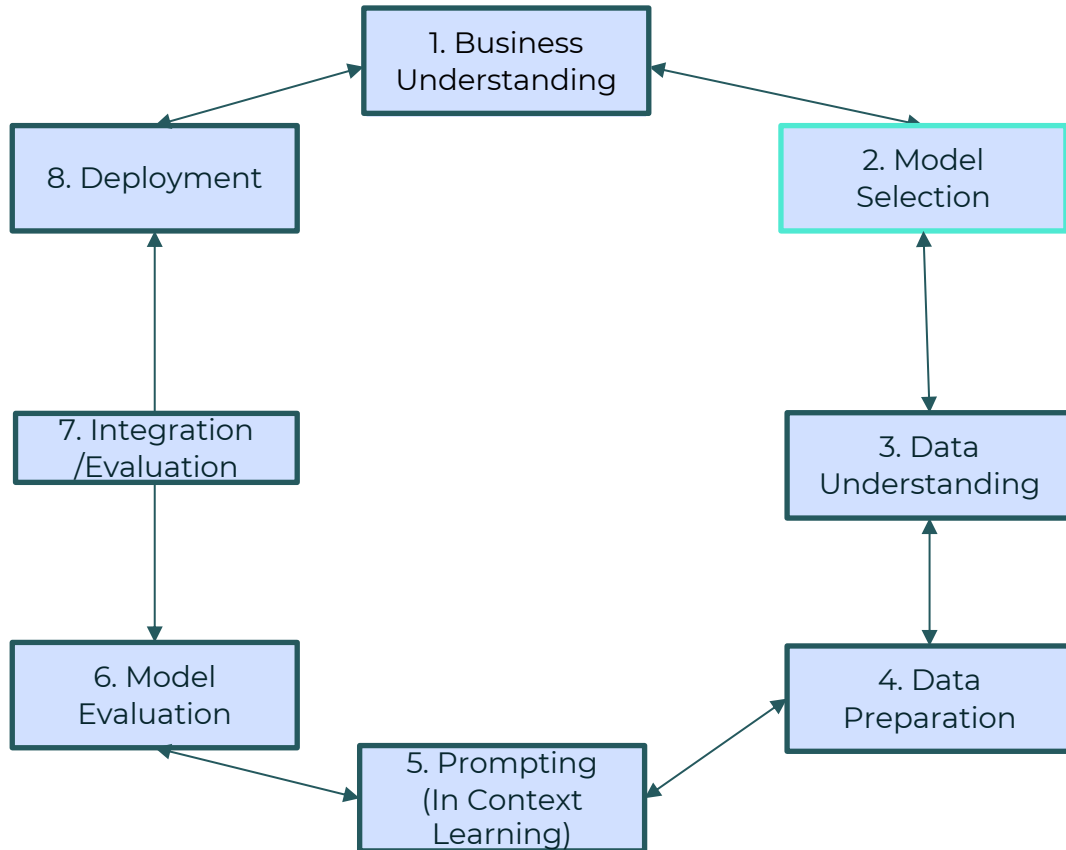
Deployment

- Die Erstellung des Modells ist im Allgemeinen nicht das Ende des Projekts
- Selbst wenn der Zweck des Modells darin besteht, das Wissen über die Daten zu erweitern, muss das gewonnene Wissen so organisiert und präsentiert werden, dass der Kunde es nutzen kann
- Abhängig von den Anforderungen kann das Deployment so einfach sein wie die Erstellung eines Berichts oder so komplex wie die Implementierung eines wiederholbaren Data-Mining-Prozesses
- In vielen Fällen wird der Kunde, nicht der Datenanalyst, die Implementierungsschritte durchführen.
- Aber auch wenn der Datenanalyst die Implementierung nicht selbst durchführt, ist es wichtig, dass der Kunde im Voraus weiß, welche Aktionen durchgeführt werden müssen, um die erstellten Modelle tatsächlich nutzen zu können

Projektmanagement bei generativer KI

- Das Projektmanagement bei generativer KI unterscheidet sich grundsätzlich vom CRISP DM Prozess
- Wir haben üblicherweise bereits ein Foundation Modell → oft ist keine Datenarbeit erforderlich
- Das Projektmanagement hängt zudem von der KI Strategie des Unternehmens ab:
 1. Nutzung von kostenpflichtigen LLMs
 2. Nutzen von Open Source LLMs + Finetuning
 3. Training eines LLM vom Scratch

Nutzung kostenpflichtiger LLMs



Modellauswahl tritt an Stelle der Daten als zentrales Element.

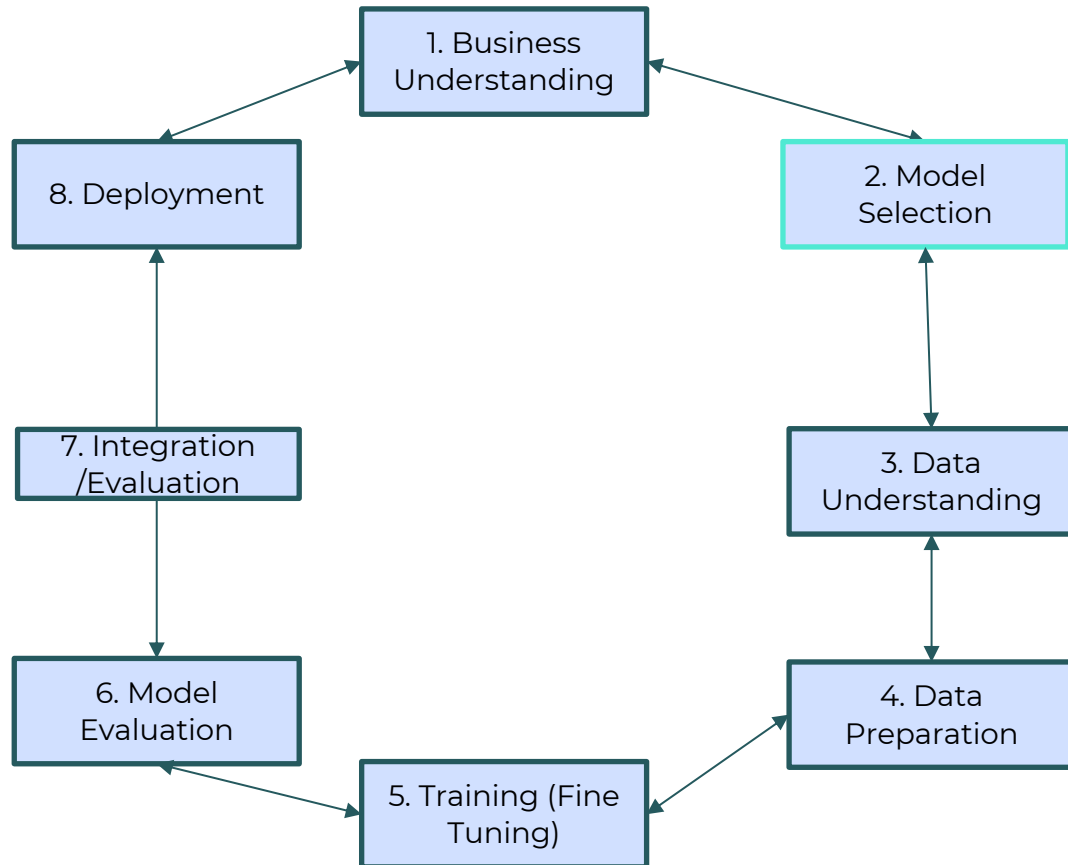
3. und 4. Data Understanding und Preparation

- Wenn die API Calls bzw. Prompts mit Kontext angereichert werden müssen, z.B. Zusammenfassung wie diese 3 Beispiele (Few Shot Learning)
- ABER deutliche geringerer Datenaufwand

5. Statt des Trainings: wird „In Context gelernt“ also die zusätzliche Anweisungen und Beispiele verwendet

7. Zwischenschritt Integration und Evaluation der Integrierten Lösung

Nutzung Open Source LLMs



Modellauswahl tritt an Stelle der Daten als zentrales Element.

3. und 4. Data Understanding und Preparation

- Wenn die API Calls bzw. Prompts mit Kontext angereichert werden müssen, z.B.

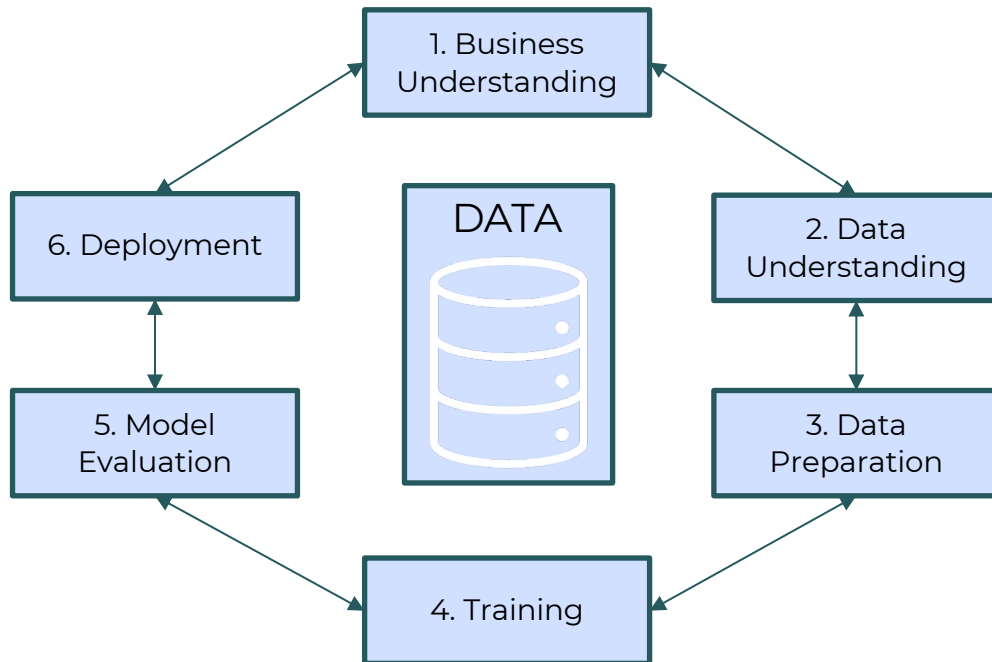
Zusammenfassung wie diese 3 Beispiele (Few Shot Learning)

- ABER deutliche geringerer Datenaufwand

5. Neben den In Context Learning muss das Modell evtl. Fingetuned werden

7. Zwischenschritt Integration und Evaluation der Integrierten Lösung

Training eines LLM vom Scratch



Fast keine Änderung gegenüber dem klassischen Projektmanagement, aber:


- Projektrunde für das Sprachmodell (+ Finetuning)

Ist das neue Modell fertig, wird abhängig vom Anwendungsfall eine zusätzlicher Projektablauf – Analog der Strategie 1 nötig.

Evaluation: Vom Bauchgefühl zur produktiven Anwendung


Dimensionen von Qualität - Leistungsfähigkeit

- Abhängig von Task und Benchmark
- Wichtige Tasks
 - Information Extraction
 - Text Classification
 - Question Answering
 - Weltwissen
 - Dokumentenbasiert
 - Summarization
 - Textgenerierung (Nach Anweisungen)
 - Code Generierung
 - Deutsch / Englisch / Multilingual
 - Sensibleness /
 - Specificity / Interestingness



Dimensionen von Qualität - Leistungsfähigkeit

- Abhängig von Task und Benchmark
- Benchmarks
 - [Big-Bench](#)
 - [Helm](#)



Big Bench

| Keyword | Number of tasks | Description |
|-----------------------------------|-----------------|---|
| traditional NLP tasks | | |
| contextual question-answering | 22 | identifying the meaning of a particular word/sentence in a passage |
| context-free question answering | 24 | responses rely on model's knowledge base, but not on context provided during query time |
| reading comprehension | 36 | a superset of contextual question-answering, measuring the degree to which a model understands the content of a text block |
| conversational question answering | 1 | a superset of reading comprehension, measuring the degree to which a model understands the content of a text block and a conversation |
| summarization | 8 | involves summarizing a block of text |
| paraphrase | 14 | express the same meaning using different words |
| text simplification | 1 | express the same meaning using simpler vocabulary |
| word sense disambiguation | 11 | identifying the meaning of a word based upon the context it appears |
| coreference resolution | 1 | finding all expressions that refer to the same entity in a text |

HELM

61 models

AI21 Labs / J1-Jumbo v1 (178B)
AI21 Labs / J1-Large v1 (7.5B)
AI21 Labs / J1-Grande v1 (17B)
AI21 Labs / J1-Grande v2 beta (17B)
AI21 Labs / Jurassic-2 Jumbo (178B)
AI21 Labs / Jurassic-2 Grande (17B)
AI21 Labs / Jurassic-2 Large (7.5B)
Aleph Alpha / Luminous Base (13B)
Aleph Alpha / Luminous Extended (30B)
Aleph Alpha / Luminous Supreme (70B)
Anthropic / Anthropic-LM v4-s3 (52B)
Anthropic / Anthropic Claude v1.3
Anthropic / Anthropic Claude Instant V1
UC Berkeley / Koala (13B)
BigScience / BLOOM (176B)
BigScience / BLOOMZ (176B)
BigScience / T0pp (11B)
BigCode / SantaCoder (1.1B)
BigCode / StarCoder (15.5B)
Cerebras / Cerebras GPT (6.7B)
Cerebras / Cerebras GPT (13B)

42 scenarios

Question answering

- MMLU
- BoolQ
- NarrativeQA
- NaturalQuestions (closed-book)
- NaturalQuestions (open-book)
- QuAC
- HellaSwag
- OpenbookQA
- TruthfulQA

Information retrieval

- MS MARCO (regular)
- MS MARCO (TREC)

Summarization

- CNN/DailyMail
- XSUM

Sentiment analysis

- IMDB

Text classification

59 metrics

Accuracy

- none
- Quasi-exact match
- F1
- Exact match
- RR@10
- NDCG@10
- ROUGE-2
- Bits/byte
- Exact match (up to specified indicator)
- Absolute difference
- F1 (set match)
- Equivalent
- Equivalent (chain of thought)
- pass@1

Calibration

- Max prob
- 1-bin expected calibration error
- 10-bin expected calibration error
- Selective coverage-accuracy area

Vergleich ChatGPT mit dem State-of-the-Art

| Tasks | Dataset | Metric | Reference | Fine-Tuned SOTA | Zero-Shot SOTA | ChatGPT |
|-------------------------------------|------------------|-------------|---------------------------------|-----------------|--------------------|---------|
| Summarization | CNN/DM | ROUGE-1 | Lewis et al. (2020a) | 44.47 | 35.27 ⁷ | 35.29 |
| | SAMSum | ROUGE-1 | Lewis et al. (2020a) | 47.28 | - | 35.29 |
| MT (XXX→Eng) | FLoRes-200 (HRL) | ChrF++ | Team et al. (2022) | 63.5 | - | 58.64 |
| | FLoRes-200 (LRL) | ChrF++ | Team et al. (2022) | 54.9 | - | 27.75 |
| MT (Eng→XXX) | FLoRes-200 (HRL) | ChrF++ | Team et al. (2022) | 54.4 | - | 51.12 |
| | FLoRes-200 (LRL) | ChrF++ | Team et al. (2022) | 41.9 | - | 21.57 |
| Sentiment Analysis | NusaX - Eng | Macro F1 | Winata et al. (2022) | 92.6 | 61.5 | 83.24 |
| | NusaX - Ind | Macro F1 | Winata et al. (2022) | 91.6 | 59.3 | 82.13 |
| | NusaX - Jav | Macro F1 | Winata et al. (2022) | 84.2 | 55.7 | 79.64 |
| | NusaX - Bug | Macro F1 | Winata et al. (2022) | 70.0 | 55.9 | 55.84 |
| Question Answering | bAbI task 15 | Accuracy | Weston et al. (2016a) | 100 | - | 93.3 |
| | bAbI task 16 | Accuracy | Weston et al. (2016a) | 100 | - | 66.7 |
| | EntailmentBank | Accuracy | Clark et al. (2018) | 86.5 | 78.58 | 93.3 |
| | CLUTRR | Accuracy | Minervini et al. (2020) | 95.0 | 28.6 | 43.3 |
| | StepGame (k=9) | Accuracy | Mirzaee and Kordjamshidi (2022) | 48.4 | - | 23.3 |
| | StepGame (k=1) | Accuracy | Mirzaee and Kordjamshidi (2022) | 98.7 | - | 63.3 |
| | Pep-3k | AUC | Porada et al. (2021) | 67.0 | - | 93.3 |
| Misinformation Detection | COVID-Social | Accuracy | Lee et al. (2021) | 77.7 | 50.0 | 73.3 |
| | COVID-Scientific | Accuracy | Lee et al. (2021) | 74.7 | 71.1 | 92.0 |
| Task-Oriented Dialogue | MultiWOZ2.2 | JGA | Zhao et al. (2022) | 60.6 | 46.7 | 24.4 |
| | MultiWOZ2.2 | BLEU | Nekvinda and Dušek (2021) | 19.1 | - | 5.65 |
| | MultiWOZ2.2 | Inform Rate | Yang et al. (2021) | 95.7 | - | 71.1 |
| Open-Domain KGD | OpenDialKG | BLEU | Ji et al. (2022c) | 20.8 | 3.1 | 4.1 |
| | OpenDialKG | ROUGE-L | Ji et al. (2022c) | 40.0 | 29.5 | 18.6 |
| | OpenDialKG | FeQA | Ji et al. (2022c) | 48.0 | 23.0 | 15.0 |


Quelle: [Bang et al., 2023](#)

Dimensionen von Qualität - Lizenzen

- Proprietär (OpenAI ChatGPT und GPT4, Aleph Alpha Luminous)
- Open Source
 - A: Nur für wissenschaftliche Zwecke nutzbar (z.B. Alpaka, Vicuna)
 - B: Kommerziell nutzbar ABER (LLama2)
 - C: Uneingeschränkt kommerziell nutzbar (z.B. Falcoon Modelle)




Dimensionen von Qualität - Transparenz




- Proprietäre Modelle haben eine niedrige Transparenz.
- Probleme:
 - Sie ändern sich ohne Ankündigung
 - Es ist unklar mit welchen Zielen sie trainiert wurden

Dimensionen von Qualität - Größe und Aufwand für Deployment

- LLMs sind “Large”. Das neue Falcoon 180b ist 360 GB groß.
- Die 360 GB müssen komplett in den Arbeitsspeicher der Grafikkarte geladen werden. Dazu braucht es noch weiteren GPU Speicher für Inferenz.
- Sharding: Ist das Modell in mehrere kleinere “Shards” aufgeteilt? Wie groß sind die Shards und passen sie zu meiner GPU?




Dimensionen von Qualität - Sicherheit



- Implementiert das Modell Sicherheitsmethoden?
- Wie sind diese implementiert?
- LLMs sprechen frei über jedes Thema und sind niemals zu 100% sicher.

Dimensionen von Qualität: Adaptierbarkeit

- Kommerzielle Modelle muss man meist so nehmen wie sie sind.
- Open Source Modelle sind komplett adaptierbar und damit sehr flexibel.



Open Source Modelle

Leaderboards

- Es existieren Evaluationen von Open Source Modellen
 - Hugging Face (https://huggingface.co/spaces/HuggingFaceH4/open_llm_leaderboard?ref=pandia.pro)
 - AlpacaEval (https://tatsu-lab.github.io/alpaca_eval/)
 - Sapling (<https://sapling.ai/llm/index>)
- Die dahinter liegenden Evaluationen sind jeweils unterschiedlich, aber: Sie sind meistens in Englisch und behandeln viele Disziplinen: Summarisation, Informationsextraktion, Generierung, Recherche, Lösen von Multiple Choice Tests, usw.
- In der Regel ist es wichtig eigene Evaluationen durchzuführen

Rechtliche Themen

Welche Themen muss ich beachten

- GDPR
- AI Act
- Urheberrecht

GDPR

GDPR

- Verordnung der Europäischen Union
- EU-weite Harmonisierung der Regeln für die Verarbeitung personenbezogener Daten
- In Kraft seit 25. Mai 2018





GDPR

Personal Data

Nach der Datenschutz-Grundverordnung ist die Verarbeitung personenbezogener Daten verboten, es sei denn, es liegt eine angemessene Rechtfertigung vor.

Gründe für die Rechtfertigung

- Gültige Einwilligung der betroffenen Person
- Erfüllung eines Vertrags oder Durchführung von vorvertraglichen Maßnahmen.
- Schutz der überwiegenden berechtigten Interessen.
 - Notwendigkeit für die Erfüllung einer rechtlichen Verpflichtung
 - Nur das Recht der EU oder der EU-Mitgliedstaaten ist anwendbar




GDPR

Umgang mit personenbezogenen Daten

- Solange die erhobenen Daten nicht personenbezogen sind, können sie in der Regel ohne größere Einschränkungen verwendet werden
- Persönliche Quelldaten entsprechend sichern
- Möglichkeiten
 - Anonymisierung
 - Pseudonymisierung
 - Verschlüsselung

AI Act


AI Act



- Regulates the use of AI in research and business
- Providers and users are affected
- The aim is to categorise AI into risk groups and ban certain AI applications
- Carrying out an assessment to classify AI


AI Act

AI Act



- Unannehmbares Risiko
- Hohes Risiko
 - Kritische Infrastrukturen (z. B. Verkehr), Sicherheitskomponenten von Produkten
- Begrenztes Risiko
 - KI-Systeme mit spezifischen Transparenzverpflichtungen
- Geringes oder kein Risiko
 - Freie Nutzung (KI-gestützte Videospiele oder Spam-Filter)
 - Die überwiegende Mehrheit der in der EU verwendeten KI-Systeme

AI Act



AI Act Hohes Risiko - Schritte

- Schritt 1:
 - Ein AI-System wird entwickelt
- Schritt 2:
 - Es muss die Konformitätsbewertung durchlaufen und die AI-Anforderungen erfüllen. Bei einigen Systemen ist eine benannte Stelle beteiligt
- Schritt 3:
 - Registrierung von eigenständigen AI-Systemen in einer EU-Datenbank
- Schritt 4:
 - Eine Konformitätsbewertung ist erforderlich. Das AI-System muss das CE-Zeichen tragen.