

Prof. Dr.-Ing. Jan Conrad

**FAIRD: Faire
und
transparente KI
für Forschung
und Lehre**



KI-Nutzung von Studierenden 2025?

Studie der Hochschule Darmstadt - Prof. Jörg von Garrel

4.910 Studierende aus 395 Hochschulen

Dramatischer Anstieg der KI-Nutzung

- 2023: **63%** der Studierenden nutzen KI-Tools
- 2025: **92%** - Steigerung um 29 Prozentpunkte

→ KI-Tools sind zum Standardwerkzeug geworden

→ *"KI-basierte Tools sind inzwischen ein fester Bestandteil des Hochschulalltags"* - Prof. von Garrel

Die beliebtesten KI-Tool

- **ChatGPT** (kostenlose Version)
 - 82% der Studierenden
- **DeepL**
 - 45% der Studierenden

→ LLMs, basierend auf der Transformer-Architektur

Large Language Models (LLMs)

- LLMs sind KI-Modelle, die in der Lage sind, natürliche Sprache zu verstehen und zu generieren.
- Sie basieren auf tiefen neuronalen Netzen und großen Textdatensätzen.
- Hauptziele:
 - **Encoding**: Interpretation und Analyse von Texten
 - **Decoding**: Erzeugung kohärenter und kontextgerechter Texte

Large Language Models (LLMs)

- LLMs bestehen **aus Milliarden von Parametern**, die komplexe Muster und Zusammenhänge in Sprachdaten erfassen.
- Sie werden mit **gigantischen Mengen an Texten** aus dem Internet, Büchern, wissenschaftlichen Artikeln und mehr trainiert.

„Attention is all you need“

- Transformer:
 - **Skalierbarkeit:** Effiziente Handhabung großer Datenmengen
 - **Flexibilität:** Anpassbar an verschiedene *sprachliche* Aufgaben
- Der Algorithmus basiert auf Statistik.

Attention Is All You Need

Ashish Vaswani*
Google Brain
avaswani@google.com

Noam Shazeer*
Google Brain
noam@google.com

Niki Parmar*
Google Research
nikip@google.com

Jakob Uszkoreit*
Google Research
usz@google.com

Llion Jones*
Google Research
llion@google.com

Aidan N. Gomez*[†]
University of Toronto
aidan@cs.toronto.edu

Lukasz Kaiser*
Google Brain
lukaszkaizer@google.com

Illia Polosukhin*[‡]
illia.polosukhin@gmail.com

Abstract

The dominant sequence transduction models are based on complex recurrent or convolutional neural networks that include an encoder and a decoder. The best performing models also connect the encoder and decoder through an attention mechanism. We propose a new simple network architecture, the Transformer, based solely on attention mechanisms, dispensing with recurrence and convolutions entirely. Experiments on two machine translation tasks show these models to be superior in quality while being more parallelizable and requiring significantly less time to train. Our model achieves 28.4 BLEU on the WMT 2014 English-to-German translation task, improving over the existing best results, including ensembles, by over 2 BLEU. On the WMT 2014 English-to-French translation task, our model establishes a new single-model state-of-the-art BLEU score of 41.0 after training for 3.5 days on eight GPUs, a small fraction of the training costs of the best models from the literature.

1 Introduction

Recurrent neural networks, long short-term memory [12] and gated recurrent [7] neural networks in particular, have been firmly established as state of the art approaches in sequence modeling and transduction problems such as language modeling and machine translation [29, 2, 5]. Numerous efforts have since continued to push the boundaries of recurrent language models and encoder-decoder architectures [31, 21, 13].

*Equal contribution. Listing order is random. Jakob proposed replacing RNNs with self-attention and started the effort to evaluate this idea. Ashish, with Illia, designed and implemented the first Transformer models and has been crucially involved in every aspect of this work. Noam proposed scaled dot-product attention, multi-head attention and the parameter-free position representation and became the other person involved in nearly every detail. Niki designed, implemented, tuned and evaluated countless model variants in our original codebase and tensor2tensor. Llion also experimented with novel model variants, was responsible for our initial codebase, and efficient inference and visualizations. Lukasz and Aidan spent countless long days designing various parts of and implementing tensor2tensor, replacing our earlier codebase, greatly improving results and massively accelerating our research.

[†]Work performed while at Google Brain.

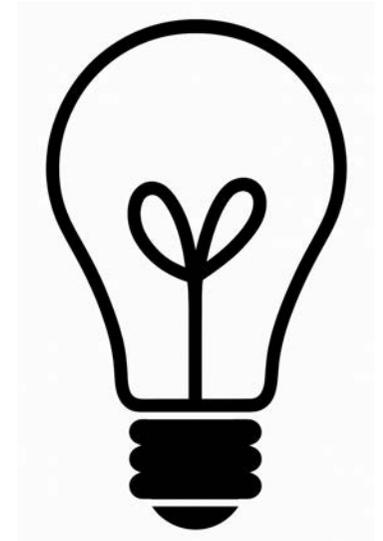
[‡]Work performed while at Google Research.

Wissenstand ist von den Trainingsdaten abhängig

- **Datenvielfalt:** Sprachliche, kulturelle und thematische Breite, kein Expertenwissen in bestimmten Domänen
- **Datenmenge:** Einfluss auf Modellgenauigkeit und -leistung
- **Datenqualität:** Relevanz, Fehlerfreiheit, Aktualität
- Datenquellen: Wikipedia, Bücher, Websites

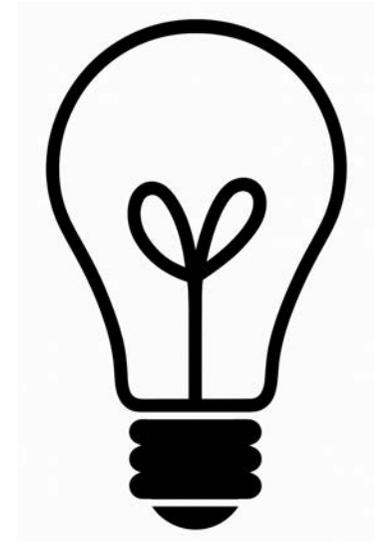
Lösungsansätze

- Pre-Training (selbst trainieren)
- On-premises (selbst hosten)
- Fine-Tuning (Grundmodel anpassen)
- Retrieval Augmented Generation (RAG)



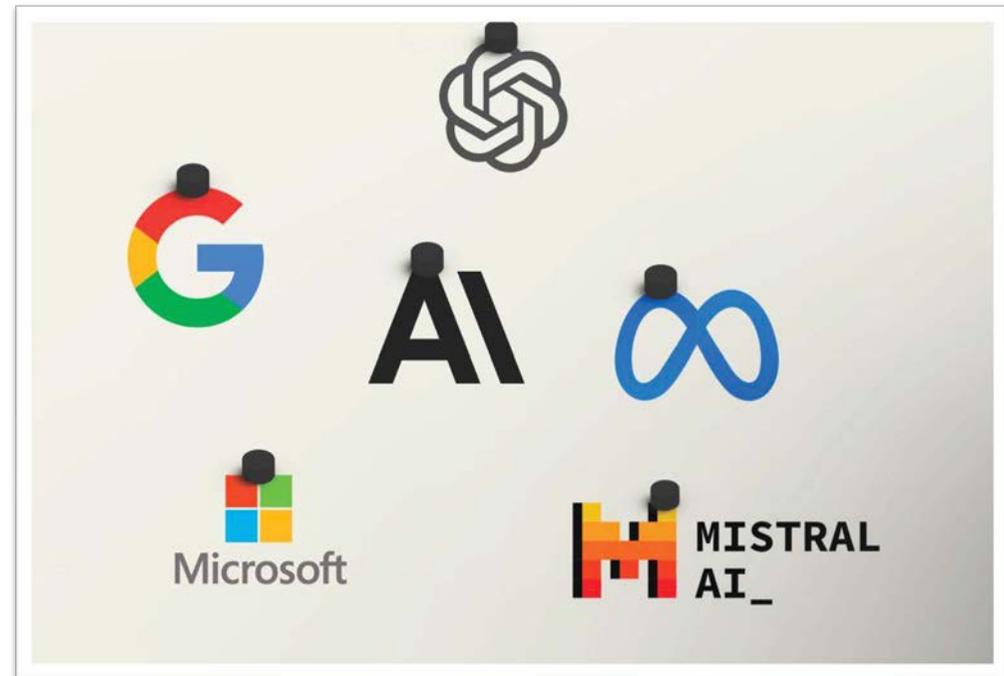
Lösungsansätze

- Pre-Training (selbst trainieren)
- On-premises (selbst hosten)
- Fine-Tuning (Grundmodel anpassen)
- Retrieval Augmented Generation (RAG)



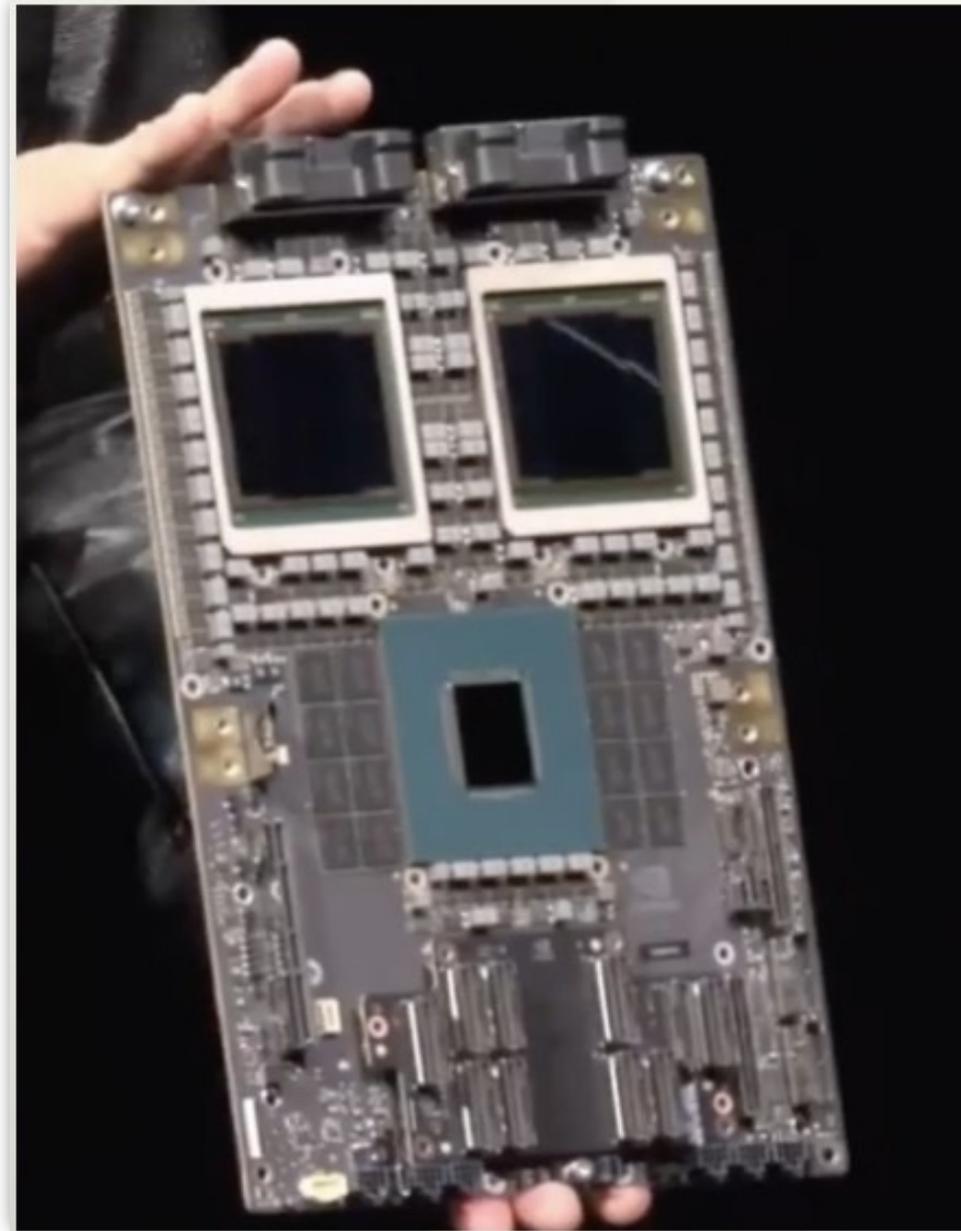
Verfügbare LLMs

- Proprietäre Systeme:
 - ChatGPT-4o
 - Gemini 2.5
 - Claude 4



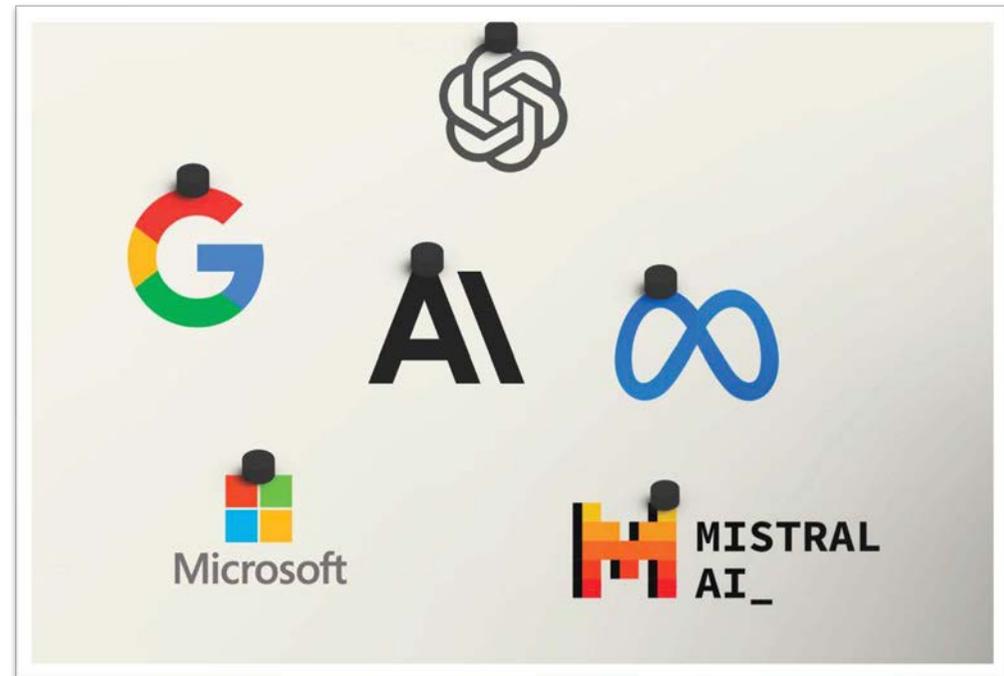
Was ist Pre-Training

- Man trainiert ein LLM mit eigenen Daten aber...
 - Es entstehen extrem hohe Kosten, Meta's Cluster kostet \$480 Millionen
 - Man braucht Infrastruktur
 - Man braucht Experten
 - Man braucht Unmengen an hochwertigen Daten



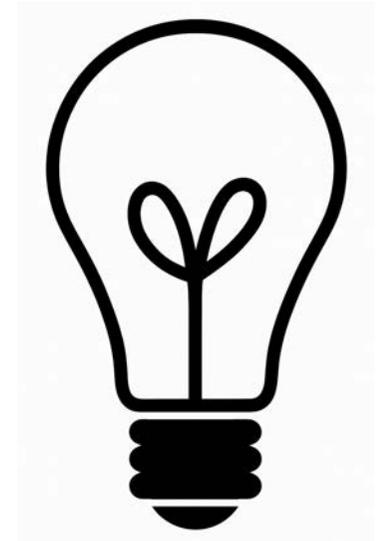
Verfügbare LLMs

- Proprietäre Systeme:
 - ChatGPT-4o
 - Gemini 2.5
 - Claude 4
- Open Weights:
 - Gemma 3
 - Llama
 - Mixtral
 - DeepSeek



Lösungsansätze

- Pre-Training (selbst trainieren)
- On-premises (selbst hosten)
- Fine-Tuning (Grundmodel anpassen)
- Retrieval Augmented Generation (RAG)



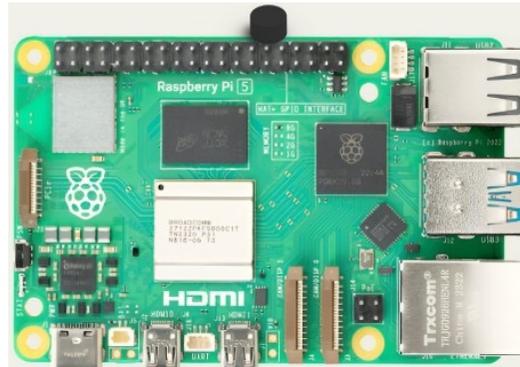
On-Premises



Machine Learning Server



Leistungstarker PC



Einplatinencomputer

Live Demo

On-Premises Open Source LLMs:

Sichere lokale AI-Applikationen



Live Demo

Die Demo zeigt das Potential von Open-Source Large Language Models (LLMs) und deren Implementierung auf einer Vielzahl von Hardware-Plattformen. Im Gegensatz zu proprietären Modellen, die von Großanbietern kommerziell bereitgestellt werden, ermöglichen Open-Source-Alternativen eine On-Premises Umsetzung, also einen lokalen Betrieb. Dies bietet den wesentlichen Vorteil einer Offline-Nutzung, was sowohl die Zuverlässigkeit als auch den Datenschutz signifikant erhöht. Die Bandbreite der möglichen Host-Systeme erstreckt sich dabei von leistungsfähigen High-End-Servern bis hin zu kosteneffizienten Desktop-PCs und Einplatinencomputern.

FAIRD: AI Retrieval Augmented Generation

Chatte mit deinen Dokumenten

FAIRD ermöglicht es, Dokumente (z.B. PDFs) hochzuladen und mit Hilfe von künstlicher Intelligenz (KI) mit den Inhalten zu chatten. Unser System verwendet einen Vector-Store, um relevante Informationen aus den Dokumenten zu extrahieren und der KI zur Verfügung zu stellen.

Vorteile:

- Hochladen von hunderten Dokumenten mit nur einem Klick
- Die KI kann Expertenwissen aus diesen Dokumenten erlangen, auch wenn sie nicht darauf trainiert wurde
- Eindeutige Quellenangaben durch die KI möglich
- Verringert die Wahrscheinlichkeit, dass die KI halluziniert



Datenschutz garantiert:

- Das System läuft komplett lokal und auf Open Source-Basis (Langchain, Ollama, verschiedene Open Source LLM Modelle)
- Zu keinem Zeitpunkt verlassen Daten ungewollt das eigene Netzwerk



Live Demo: Lokales Hosting von Open Source Large Language Modellen

<h5 style="color: #00728f;">Einplatinencomputer</h5> <p>Modell: Phi-3-mini 3.8b, Microsoft Leistung: Mehr als 4 Wörter pro Sekunde Kosten: ~120€ (Raspberry Pi 5 8GB) Textqualität: Gute Ausgaben Benutzeranzahl: Sollte nicht mehr als von einem oder zwei Benutzern bedient werden, ansonsten kann es zu langen Wartezeiten kommen.</p>	<h5 style="color: #00728f;">Leistungsstarker PC</h5> <p>Modell: Llama-3 8b, Meta Leistung: Generierung ist schneller als Lesegeschwindigkeit Kosten: ~1.500-3.000€ Textausgabe: Sehr gute Ausgaben Benutzeranzahl: Kann eine kleine Anzahl von Benutzern bedienen, es kann zu Wartezeiten kommen.</p>	<h5 style="color: #00728f;">KI Server</h5> <p>Modell: Llama-3 70b, Meta Leistung: Generierung ist schneller als Lesegeschwindigkeit Kosten: ab ~80.000€ Textausgaben: Auf annähernd ChatGPT-4 Level Benutzeranzahl: Kann gleichzeitig mehrere Benutzer bedienen ohne Wartezeiten.</p>
--	--	--





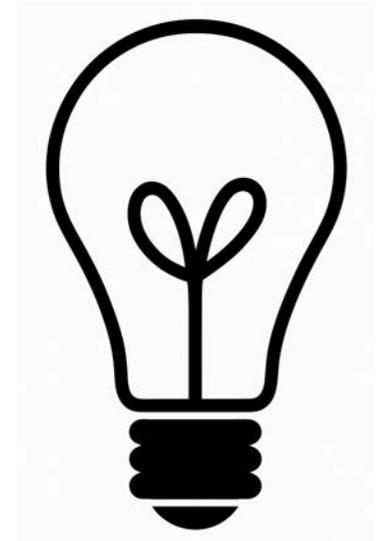


Zukunftssymposium KDE 2024



Lösungsansätze

- Pre-Training (selbst trainieren)
- On-premises (selbst hosten)
- Fine-Tuning (Grundmodel anpassen)
- Retrieval Augmented Generation (RAG)



Was ist Fine-Tuning

- Man nimmt ein vor trainiertes generelles Model und trainiert es mit einem eigenen kleinen Datensatz weiter
 - Anpassung der Parameter eines generellen Models
 - Geeigneter für kleinere Modelle
 - Fine Tune auf Medizinischen Daten oder Coding Daten

Vorteile Fine-Tuning

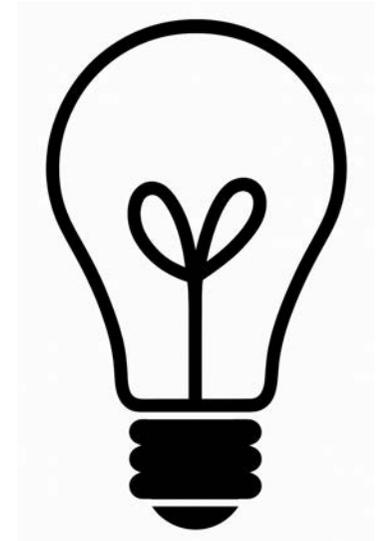
- Spezialisierung auf spezifische Aufgaben
- Effektive Nutzung kleinerer Modelle
- Reduzierte Abhängigkeit von externen Datenquellen
- Einfachere On-Device-Implementierung
- Stabilität und Konsistenz
- Bessere Handhabung von festgelegtem Wissen

Nachteile Fine-Tuning

- Datenanforderungen
- Keine aktuellen Daten
- Trainingsprozesse können kostenintensiv sein
- Risiko der Überanpassung
- Wenig Flexibilität

Lösungsansätze

- Pre-Training (selbst trainieren)
- On-premises (selbst hosten)
- Fine-Tuning (Grundmodel anpassen)
- Retrieval Augmented Generation (RAG)



Was ist Retrieval-Augmented Generation (RAG)?

Erweiterte LLM-Textgenerierung mit Informationsabruf

Extrahiert spezifische Daten aus verschiedenen Quellen (Datenbanken, Dateien, Live-Daten, Firmenwissen, Web Suche)

Ergänzt im Kontext die extrahierten Daten für genauere Antworten

Vorteile von RAG

Erweiterbarkeit mit
externem Wissen

Flexibilität und
Anpassungsfähigkeit

Geringere
Datenanforderungen

Kosteneffizienz

Erweiterte
Wissensabdeckung

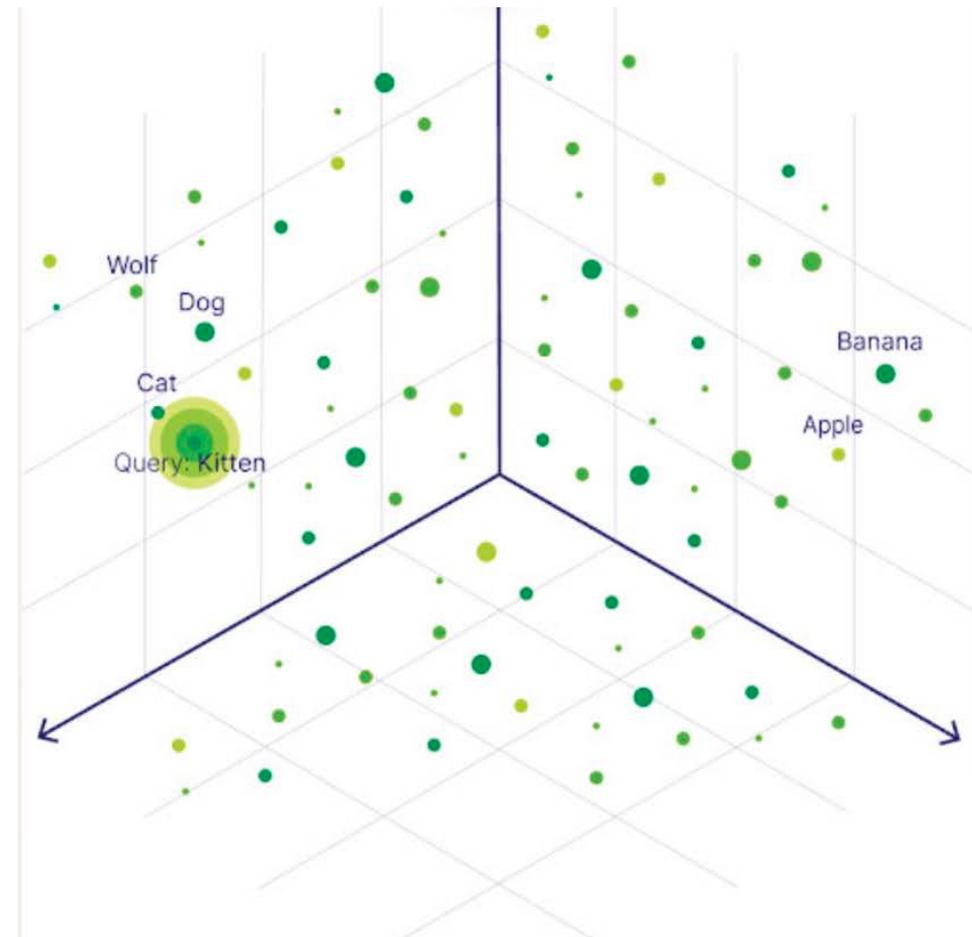
Verbesserte
Konsistenz und
Genauigkeit

Vielseitigkeit

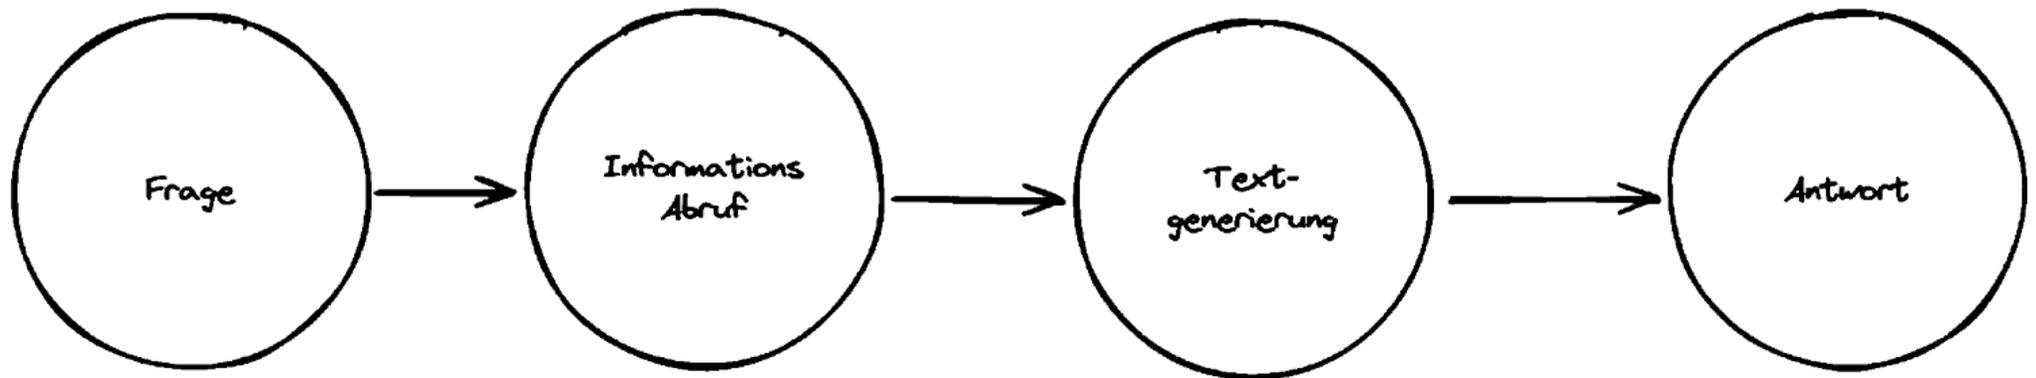
Quellenangaben

Vector Store Datenbanken

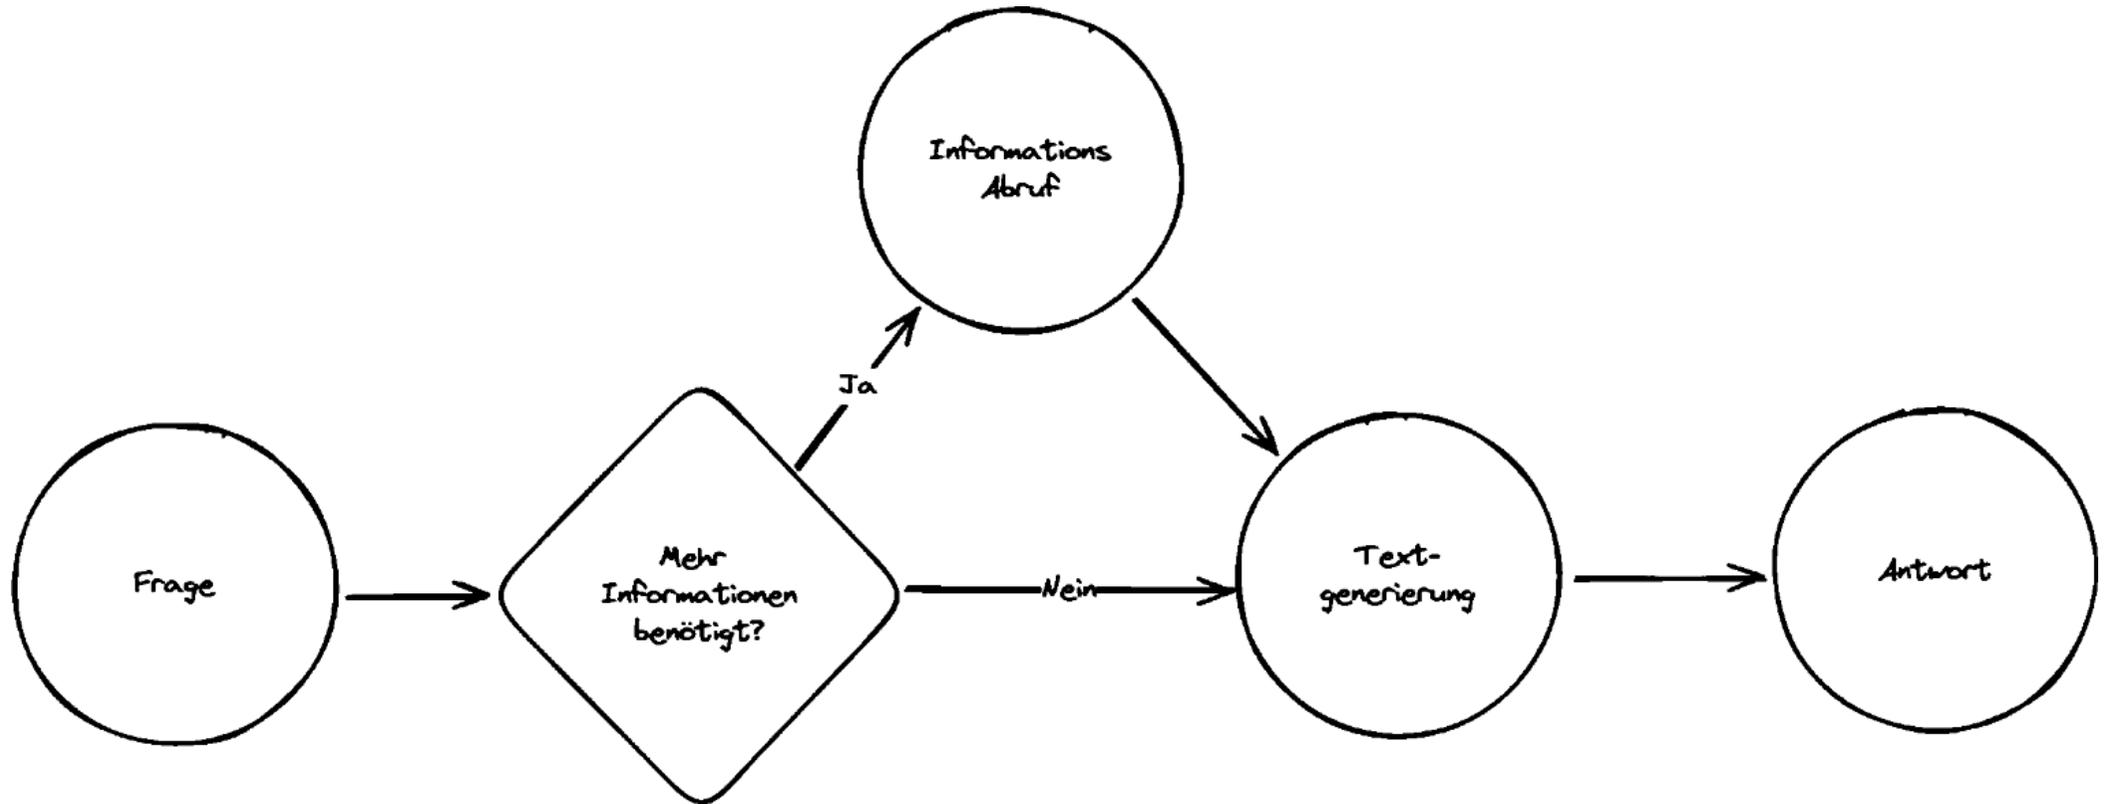
- Datenpunkte als Vektoren
- Semantische Klassifizierung
- Sehr schnelle Semantische Suche
- Skalierbar für große Datenmengen



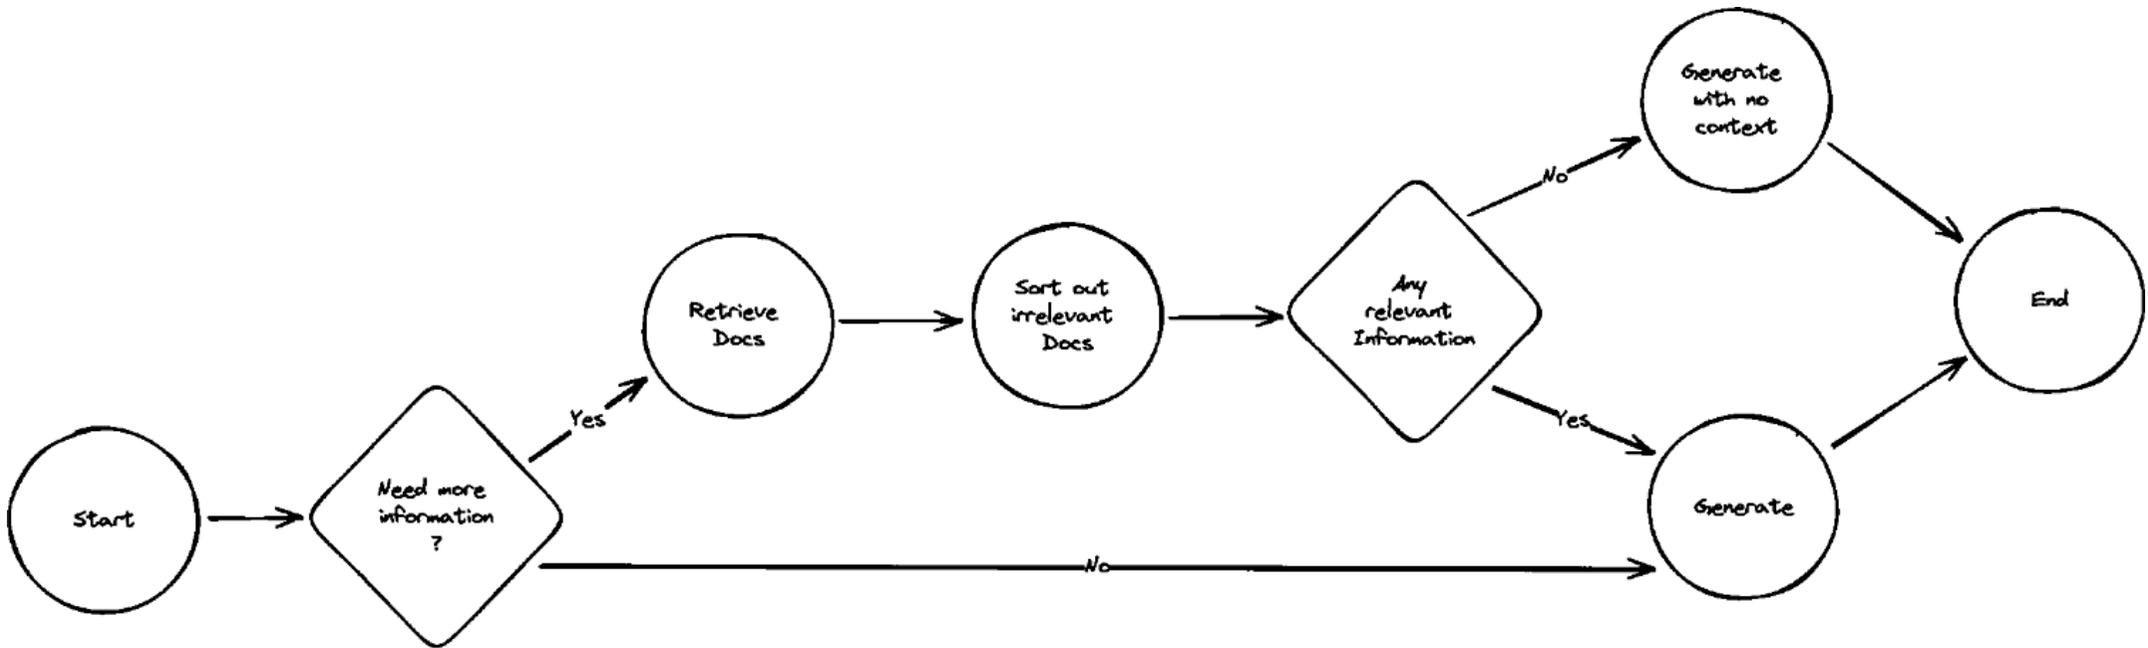
Einfaches RAG

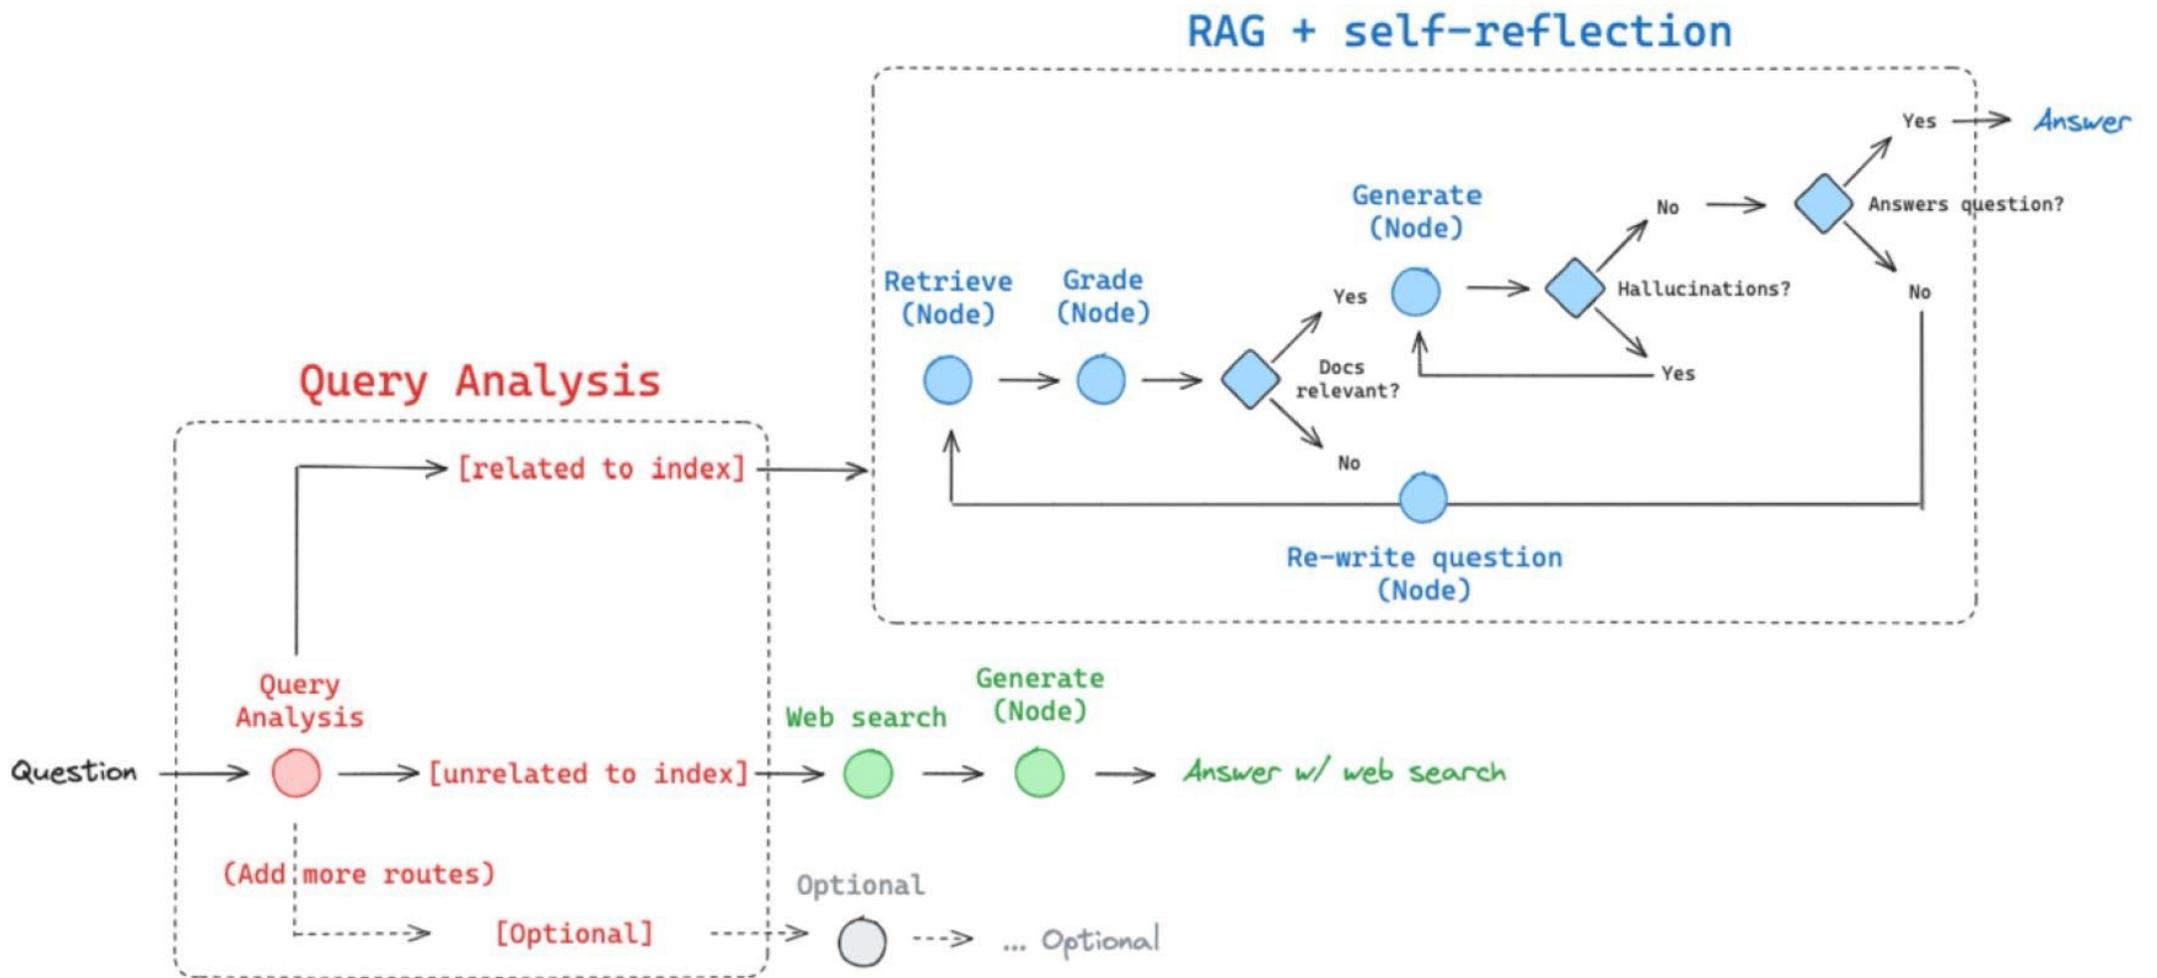


Self Reflective RAG



Self Reflective RAG mit Irrelevanz Check





FAIRD

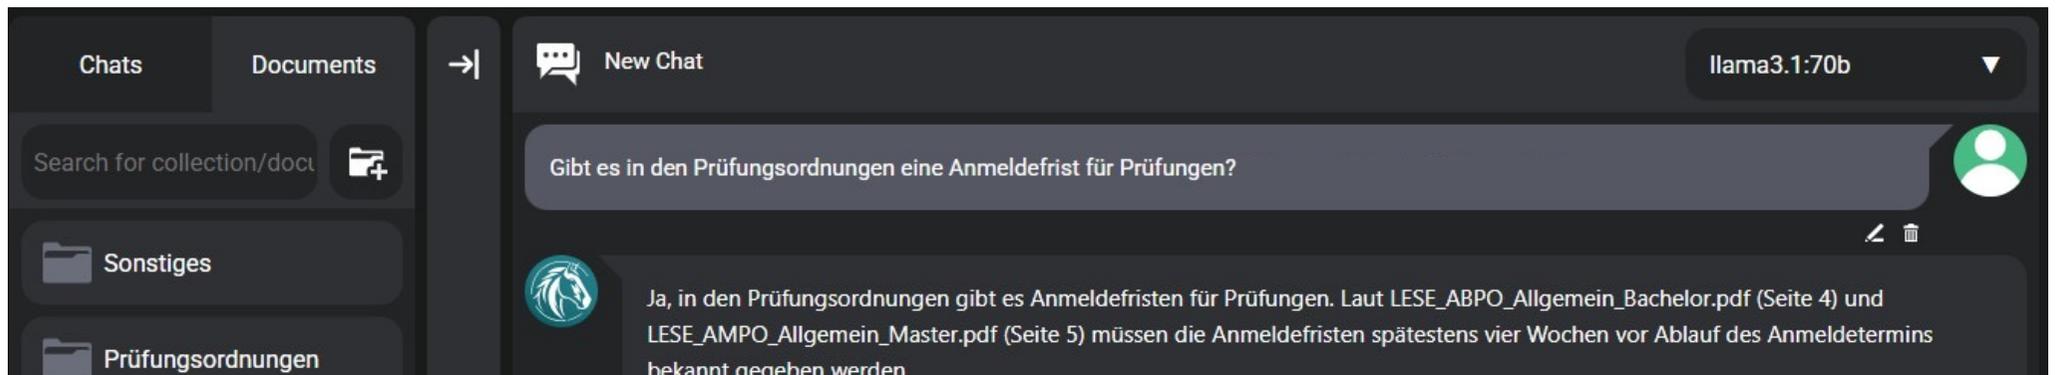
- Fair AI R&D
- On-Premises Open Weights LLM mit RAG
- Fachbereichsübergreifende Initiative:
 - Jan Conrad
 - Klaus Knopper
 - Eugen Staab
 - Dieter Wallach
 - ...
- Unterstützt durch den Senatsausschuss
Qualität und Lehre (SQL)



Hci^{2B}
GROUP

FAIRD-Features

- Modell-agnostisch
- Server selbst gehostet (ZW)
- Lokale Anwendung (Electron):
 - Lokaler Dokumentenspeicher
 - Lokale Chathistorie
 - Lokales RAG – Anfragen mit gefundenen Daten gehen an Server



Nutzungs- szenarien

- **Stand-Alone**
Einzelnutzung mit lokalen sensiblen Daten,
z. B. Abschlussarbeiten mit Sperrvermerk
- **Intranet**
Nutzung als Auskunftsbot im Intranet für
Studierende (Dokumente sind z. B.
Studiengangwebseiten,
Prüfungsordnungen) ohne Chathistorie
- **Internet**
Einbindung als Auskunftsbot in Hochschul-
Webseite — RAG mit öffentlichen Daten
- **Team-Fähigkeit**
Nutzung im Team mit einem Shared Space
(auf dem Server), Idee, dass Studierende
gemeinsam auf einem Dokumentenpool
arbeiten können



Suche nach Sammlungen/Dokumenten

Prüfungsordnung

IT-Sicherheit

KI-Themen

Studienarbeiten - Informatik

ALDS_Gamification_UI.pdf

Erkennungsmethoden zur Identifizierung KI-generierter Bild...

Schadprogramme_Gefahren_und_Schutzmaßnahmen_240...



I. EINLEITUNG

Durch die rasante Entwicklung von bildgenerierenden KI-Modellen, wie unter anderem Dall-E von OpenAI oder Images von Google, wird es zunehmend schwieriger, echte Bilder von KI-generierten Bildern zu unterscheiden. Was auf der einen Seite eine bahnbrechende technische Errungenschaft ist, birgt auf der anderen Seite Gefahren, die es in dieser Form zuvor noch nie gegeben hat. So können frei zugängliche Image-Generatoren als mächtige Tools für böswillige Akteure dienen, die diese Technologie unter anderem zur Verbreitung von Fehlinformationen, Betrug oder Identitätsdiebstahl nutzen können. Mit dem Vormarsch der KIs und deren ständiger Weiterentwicklung wird auch die Notwendigkeit von Tools und Methoden zur Erkennung generierter Inhalte immer wichtiger. Viele dieser Tools und Methoden nutzen selbst KIs, um diese Inhalte zu erkennen und zu klassifizieren, verfolgen dabei jedoch verschiedene Herangehensweisen und Ansätze.

II. CIFAKE

Jordan J. Bird und Ahmad Lotfi von der Nottingham Trent University veröffentlichten am 19. Januar 2024 einen wissenschaftlichen Artikel [1]. Dort beschreiben sie eine Studie, indem sie verschiedene tiefe neuronale Netzwerke mit Hilfe eines umfassenden eigens erstellten Datensatzes namens "CIFAKE" darauf trainieren, KI-generierte Bilder zu erkennen nach dem Prinzip "fighting fire with fire".

sich als ausschlaggebend herausstellt. Die genutzte KI zur Generierung der falschen Bilder namens CompVis SD scheint laut Aussage der Forscher sehr gut darin zu sein, diese Klassen zu generieren.

Nach Abschluss dieser Studie stellten Jordan J. Bird und Ahmad Lotfi das CIFAKE Dataset öffentlich, sodass weitere Studien und Forschungsarbeiten diese Bildersammlung zum Trainieren von KIs nutzen können.



2. Gradient Class Activation Maps verschiedener Klassen (J. J. Bird and A. Lotfi, "CIFAKE: Image Classification and Explainable Identification of AI-Generated Synthetic Images," in IEEE Access, vol. 12, pp. 15642-15650, 2024, doi:10.1109/ACCESS.2024.3356122)

III. CONVOLUTIONAL NEURAL NETWORKS UND VISION TRANSFORMER

Eine Methode, in der das CIFAKE Dataset zum Einsatz kommt, ist die Erkennungsmethode mit sogenannten Convolutional Neural Networks (CNNs) und Vision Transformers (ViT). Bei einem CNN handelt es sich um eine Form des Machine Learnings, die bei der Untersuchung und Identifikation visueller Daten Verwendung findet.

Strukturell setzen sich CNNs aus verschiedenen Schichten zusammen, darunter ein Input-Layer, ein Output-Layer und eine beliebige Anzahl an Filterschichten, sogenannten Convolutional Layers, mit denen bestimmte Merkmale eines Bildes identifiziert werden können. Der Filterprozess wird auch als Faltung bezeichnet. Alle relevanten Merkmale in einer zusätzlichen Schicht, dem Pooling-Layer, zusammengefasst.

Anders als CNNs untersuchen Vision Transformer geschieht bei einem Vision Transformer die Klassifizierung eines Bildes durch die Untersuchung einzelner Bildbestandteile und deren Beziehung zueinander. Dabei

- Horse - herd, in a field, in the forest, outdoors, running, wildlife photography
Ship - at sea, boat, cargo, cruise, on the water, river, sailboat, tug
Truck - 18-wheeler, car transport, fire, garbage, heavy goods, lorry, mining, tanker, tow

1. Prompts zur Generierung (J. J. Bird and A. Lotfi, "CIFAKE: Image Classification and Explainable Identification of AI-Generated Synthetic Images," in IEEE Access, vol. 12, pp. 15642-15650, 2024, doi:10.1109/ACCESS.2024.3356122)

Vor allem war es ihnen wichtig, dass es nachvollziehbar ist, warum und durch welche Bildstellen die KI entscheidet. Dazu nutzten sie Gradient Class Activation Mapping, kurz Grad CAM, um die Aktivität der KIs durch eine Heatmap darzustellen.

Die Forscher erreichten eine durchschnittliche Erkennungswahrscheinlichkeit von 91,79% und einen Bestwert von 93,55% bei einem Netzwerk bestehend aus 64 Neuronen.

Beim Auswerten der Heatmaps kamen sie zu einigen interessanten Schlüssen. Viele der durch KI-Generierung auftretenden Artefakte sind leicht zu erkennen, da Details fehlerhaft sind. So wurden unter anderem Flugzeuge ohne Cockpit oder anatomische Fehler bei den Tieren generiert. Bei LKWs liegt das Highlight der Heatmap auf den Kühlergrillen, da die KIs Schwierigkeiten haben, diese korrekt darzustellen.

Bei Flugzeugen, Pferden, Vögeln und Schiffen ist die Heatmap nahezu kalt. Es gibt kein bestimmtes Feature, das

Table with 4 columns: Model, Accuracy, Precision, Recall. Rows include CNN Setup-1, CNN Setup-2, CNN Setup-3, Bird & Lotfi [16], and ViT-S16.

3. Leistungsvergleich von verschiedenen Modellen (M. Z. Hossain, F. Uz Zaman and M. R. Islam, "Advancing AI-Generated Image Detection: Enhanced Accuracy through CNN and Vision Transformer Models with Explainable AI Insights", 2023 29th International Conference on Computer and Information Technology (ICCIIT), Cox's Bazar, Bangladesh, 2023, pp. 1-6, doi: 10.1109/ICCIIT60459.2023.10440990)

In einer Studie von 2023 untersuchten Md. Zahid Hossain und Md. Rakibul Islam von der Ahsanullah University of Science and Technology, sowie Farhad Uz Zaman von der Southeast University verschiedene Variationen von CNN-Modellen in Kombination mit dem CIFAKE Dataset [2] und verglichen die Leistung dieser Modelle mit denen eines Vision Transformer Modells.

Die CNN-Modelle wurden dabei mit echten und gefälschten Bildern, jeweils 40.000 Stück, trainiert und mit jeweils 10.000 Bildern von beiden Kategorien validiert und getestet. Bei dem verwendeten Vision Transformer Modell mit der Bezeichnung ViT-S16, handelt es sich um ein vortrainiertes Modell, welches mit dem ImageNet-21 und ImageNetI Datensätzen trainiert wurde.

Dabei zeigten sich CNNs in ihrer allgemeinen Performance als recht zuverlässig, wobei das CNN-Modell mit den meisten Convolutional-Layers eine höhere Genauigkeit aufweist, auch wenn der Unterschied zu den anderen verwendeten Modellen verhältnismäßig gering ausfällt. Der signifikante Unterschied fällt bei der Leistung des Vision Transformer Modells auf, welche deutlich hinter den Ergebnissen von allen drei CNN-Modellen liegt.

IV. DIRE-MODEL

Generative Adversarial Networks, kurz "GANs", dienen als Trainingsmethode von generativen KIs. GANs setzen sich hauptsächlich aus zwei verschiedenen neuronalen Netzwerken zusammen, dem Generator und dem Diskriminator. Der Generator hat die Aufgabe, Daten zu generieren, die dann vom Diskriminator ausgewertet werden. Dabei muss der Diskriminator die generierten Daten des



Was genau sind eigentlich CNNs?



CNN steht für Convolutional Neural Networks. Es handelt sich dabei um eine Form des Machine Learnings, die bei der Untersuchung und Identifikation visueller Daten Verwendung findet. Strukturell setzen sich CNNs aus verschiedenen Schichten zusammen, darunter Convolutional-Layer, Pooling-Layer und Fully-Connected-Layer. (Quelle: Erkennungsmethoden zur Identifizierung KI-generierter Bilder_VersionNr2.pdf, Seite 2)



Wie genau funktionieren diese unterschiedlichen Layer?

Die Convolutional-Layer dienen dazu, bestimmte Merkmale eines Bildes zu identifizieren. Dies geschieht durch eine Faltung, bei der ein Filter über das Bild wandert und bestimmte Muster erkennt. Die Ergebnisse werden dann in einer Feature-Map zusammengefasst.

Die Pooling-Layer dienen dazu, die räumliche Auflösung der Feature-Maps zu reduzieren und somit die Anzahl der Parameter im Netzwerk zu verringern. Dies wird erreicht, indem das Bild in kleinere Bestandteile aufgeteilt und dann die wichtigsten Informationen extrahiert werden.

Die Fully-Connected-Layer dienen dazu, die Merkmale, die durch die Convolutional-Layer und Pooling-Layer identifiziert wurden, zu klassifizieren. Hierbei werden die Merkmale miteinander verbunden, um eine Vorhersage treffen zu können. (Quelle: Erkennungsmethoden zur Identifizierung KI-generierter Bilder_VersionNr2.pdf, Seite 2)



KI-Themen

Dokumentensuche

Schreibe eine Nachricht...



+ Neuer Chat

Was ist Ransomware?

CNNs vs Vision Transformers

Funktionsweise des DIRE-Modells

Was sind CNNs?

Was genau ist eine Ransomware?



Eine Ransomware (eng. ransom, dt. Lösegeld) ist eine erpresserische Variante von Schadprogrammen. Diese Form von Schadsoftware zeichnet sich dadurch aus, dass sie dem Nutzer den Zugriff auf das Computersystem verweigert indem, in den häufigsten Fällen, Dateien auf dem Computer verschlüsselt werden oder der Zugang auf diese einfach gesperrt wird. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 10)



Wie verbreitet sich Ransomware?



Ransomware verbreitet sich auf ähnliche Weise wie Computerviren oder andere Schadprogramme. Methoden wie Social Engineering und Phishing sind sehr beliebt bei der Verbreitung von Ransomware, genauso wie die Nutzung von Exploits. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 10)



Ransomware bedeutet aber auch, dass ein Lösegeld gefordert wird, richtig?



Ja, das ist korrekt! Ransomware bedeutet nicht nur die Sperrung oder Verschlüsselung von Daten, sondern auch die Forderung eines Lösegelds, um den Zugriff auf diese Daten wiederherzustellen. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 10)



Wie sehen denn die Infizierungsmechanismen von Schadprogrammen aus?



Schadprogramme können sich auf verschiedene Weise verbreiten. Einige Arten von Schadprogrammen, wie z.B. Viren, verfügen über Mechanismen und Routinen, um sich selbst zu kopieren und sich über den Speicherplatz eines Systems zu verbreiten. Dazu müssen sie in der Lage sein, das System und dessen Speicher nach Dateien abzusuchen, die infiziert werden können. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 5)

Ein weiterer Mechanismus ist die Infektion durch Trojaner oder andere Arten von Schadsoftware, die sich auf dem System verbreiten und andere Schadprogramme installieren können. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 13)

Es ist auch möglich, dass Schadprogramme durch unsichere Internetseiten oder Sicherheitslücken auf den Computer gelangen. (Quelle: Schadprogramme_Gefahren_und_Schutzmaßnahmen_240307_145804.pdf, Seite 13)



IT-Sicherheit



Dokumentensuche

Schreibe eine Nachricht...



Suche nach Sammlungen/Dokumenten

Gamification

Prüfungsordnung

IT-Sicherheit

KI-Themen

Studienarbeiten - Informatik



<< 17 / 95 >> - 140 +

richtigen Elemente an der richtigen Stelle eingesetzt werden und so die Chancen für ein erfolgreiches Konzept erhöhen.

6

2.3 Methodik

UCD für Spiele in der Lehre

Das User-Centered-Design (kurz: UCD) ist ein Software-Entwicklungsmodell, das für das dynamische Entwickeln von Software benutzt wird und sich auf eine spezifische Nutzergruppe konzentriert. Dankov, Antonova und Bontchev [17] hat die Prinzipien des User-Centered-Designs so angepasst, dass sich damit Spiele für den Einsatz in der Lehre anhand von festgelegten Metriken der Nutzererfahrung (User Experience/UX) entwickelt und weiterentwickelt werden können. Die Erkenntnisse von Dankov, Antonova und Bontchev [17] stammen aus einer Literaturrecherche sowie von der Analyse der APOGEE-Plattform. Die APOGEE-Plattform soll Lehrkräften ermöglichen, 3D-Labyrinth-Spiele sowie kleineren Aufgaben für die Lehre zu erstellen [17]. Dankov, Antonova und Bontchev [17] unterteilt die Analyse der Nutzererfahrung für Lernspiele in die drei Hauptkategorien Playability, Learnability und Usability. Die folgenden Abschnitte erläutern die Hauptkategorien nach der Beschreibung von Dankov, Antonova und Bontchev [17].

Playability

Playability beschreibt die Qualität des Spiels für den Nutzer. Wichtige Faktoren sind dabei, die vermittelte Spielerfahrung, der individuelle Grad der Herausforderung (Challenge), Erleben von Immersion, der „Game flow“ (Erzeugt das Spiel einen konsistenten Fluss für den Spieler?), die Affektierung zum Spieler (positive Neigungen, Meinung, Sicherheitsgefühl) sowie die Motivation zum Spiel. Für ein Serious Game lassen sich noch die Fidelity (Sinnhaftigkeit und Qualität des Produkts) mithilfe des Grads des Realismus prüfen. Die Immersion, welche als das Eintauchen des Spielers in das Spielsystem beschrieben werden kann, soll durch überzeugende, an das Szenario angepasste Audio und Grafiken vermittelt werden.

Learnability

Learnability bezeichnet die Qualität des Lerneffekts des Spiels. Die Lernerfahrung wird oft durch die vermittelte Effektivität des Lernens, durch klare Ziele und Rückmeldung, wie passend die Aktionen des Lernenden sind, beschrieben. Diese Aspekte sollen das Lernen ermöglichen. Für eine effektive Einreihung eines Spiels in den Unterricht sind nach Dankov, Antonova und Bontchev [17] die Anpassung des Spiels an den Lehrplan sowie die Lernziele des Fachgebiets bedeutend. Der Aspekt der Integration und die passende Vermittlung des Inhalts wird mithilfe des Erfolgs der Spielaktivitäten gemessen. Diese Spielaktivitäten sollen das Reflektieren des Wissens und Könnens der Spieler verbessern und das Nutzen von individuellem Wissen sowie Erlernen neuen Wissens anregen. Die Wahl des Mediums für die Vermittlung des Lehrinhalts sollte zusätzlich überprüft werden. Medien wie Audio, Text, Bilder, Animationen können für manche Inhalte passend, für andere jedoch störend wirken.

7



Gamification in der Lehre

llama3.1:70b

Lehre beschäftigen. Ein Beispiel ist die Arbeit von Zainuddin et al., die den Einfluss von Gamification auf das Lernen und die Motivation von Studenten untersucht hat (Quelle: ALDS_Gamification_UI.pdf, Seite 90). Eine andere Studie von Tolks und Sailer beschäftigt sich mit der Anwendung von Gamification als didaktisches Mittel in der Hochschulbildung (Quelle: ALDS_Gamification_UI.pdf, Seite 90).

Es ist jedoch wichtig zu beachten, dass die Effektivität von Gamification in der Lehre von verschiedenen Faktoren abhängt, wie z.B. der Art und Weise, wie es eingesetzt wird, den Zielen und den Bedürfnissen der Nutzer (Quelle: ALDS_Gamification_UI.pdf, Seite 90).



Playability beschreibt die Qualität des Spiels für den Nutzer. Wichtige Faktoren sind dabei, die vermittelte Spielerfahrung, der individuelle Grad der Herausforderung (Challenge), Erleben von Immersion, der „Game flow“ (Erzeugt das Spiel einen konsistenten Fluss für den Spieler?), die Affektierung zum Spieler (positive Neigungen, Meinung, Sicherheitsgefühl) sowie die Motivation zum Spiel. Für ein Serious Game lassen sich noch die Fidelity (Sinnhaftigkeit und Qualität des Produkts) mithilfe des Grads des Realismus prüfen.

Quelle: ALDS_Gamification_UI.pdf

Kannst du diesen Absatz etwas genauer erklären?



Ja, natürlich! Der Absatz beschreibt die sogenannte "Playability" eines Spiels, also die Qualität des Spiels für den Nutzer. Es werden mehrere wichtige Faktoren aufgeführt, die dazu beitragen, dass ein Spiel eine positive Erfahrung für den Spieler bietet:

- Vermittelte Spielerfahrung:** Hier geht es darum, wie gut das Spiel in der Lage ist, dem Spieler eine bestimmte Erfahrung zu vermitteln. Zum Beispiel soll ein Spiel, das auf einem historischen Ereignis basiert, dem Spieler ein Gefühl dafür geben, wie es damals war.
- Individueller Grad der Herausforderung (Challenge):** Ein gutes Spiel sollte den Spieler herausfordern, aber nicht überfordern. Die Herausforderungen sollten also auf das individuelle Niveau des Spielers abgestimmt sein.
- Erleben von Immersion:** Immersion beschreibt das Gefühl, sich komplett in einem Spiel zu befinden und die Realität um sich herum zu vergessen. Ein gutes Spiel sollte den Spieler in diese Welt eintauchen lassen.
- "Game flow" (Konsistenter Fluss):** Der "Game flow" beschreibt, wie gut das Spiel den Spieler durch eine

* Playability beschreibt die Qualität des Spiels für den Nutzer. Wichtige Faktoren sind dabei, die vermittelte Spielerfahrung, der individuelle Grad der Herausforderung (Challenge), Erleben von Immersion, der „Game flow“ (Erzeugt das Spiel einen konsistenten Fluss für den Spieler?), die Affektierung zum Spieler (positive Neigungen,...

Quelle: ALDS_Gamification_UI.pdf

Gamification

Dokumentensuche

Schreibe eine Nachricht...



+ Neuer Chat

Umfang einer Masterprüfung

Gamification in der Lehre

Was ist Ransomware?

CNNs vs Vision Transformers

Funktionsweise des DIRE-Modells

Was sind CNNs?

der Prüfungskandidatinnen und -kandidaten, Beginn und Ende der Prüfung sowie eventuelle besondere Vorkommnisse aufzunehmen sind.

§ 8a Assignment

(1) Ein Assignment besteht aus mehreren lehrveranstaltungsbegleitenden, zeitlich nacheinander zu erbringenden schriftlichen Ausarbeitungen, insbesondere aus einzelnen Fragestellungen, Aufgaben oder Fallbearbeitungen im Umfang von in der Regel bis zu fünf Seiten. Insgesamt können nicht mehr als vier schriftliche Ausarbeitungen vorgesehen werden, sofern die Fachprüfungsordnung es nicht ausdrücklich abweichend regelt.

(2) Bearbeitungszeit und -umfang der einzelnen Ausarbeitungen müssen im Gesamtarbeitsaufwand des Moduls enthalten sein und den ausgewiesenen Leistungspunkten (ECTS) des Moduls entsprechen. Bearbeitungszeit und -umfang müssen hierbei in einem ausgewogenen Verhältnis zueinanderstehen. Die Bearbeitungszeiten und Abgabefristen werden von der Prüferin oder dem Prüfer festgelegt.

(3) Die schriftlichen Ausarbeitungen werden mit Punkten bewertet. Die Note des Assignments ergibt sich aus der Gesamtpunktzahl der schriftlichen Ausarbeitungen. Werden diese nicht fristgemäß erbracht, können für die jeweilige Ausarbeitung keine Punkte vergeben werden. Die maximal erreichbare Punktzahl für jede Ausarbeitung und das Assignment sowie die Bewertungskriterien werden den Studierenden zu Beginn der Lehrveranstaltung bekannt gegeben.

§ 8b Wissenschaftliches Poster

Das wissenschaftliche Poster wird in Form eines Plakates (DIN A0) erbracht. Es kombiniert textliche und visuelle Elemente miteinander, um eine fachliche Fragestellung, den wissenschaftlichen Lösungsweg und das Ergebnis anschaulich und selbstklärend darzustellen. Die Abgabe des Posters erfolgt in der Form und in der Bearbeitungszeit, die von der Prüferin oder dem Prüfer zu Veranstaltungsbeginn bekannt gegeben werden. Das wissenschaftliche Poster kann entsprechend § 8 Absatz 3 Satz 2 und 3 im Rahmen einer Gruppenarbeit erbracht werden.

§ 8c Take-Home-Exam

(1) Ein Take-Home-Exam besteht aus der schriftlichen Bearbeitung einer oder mehrerer vorgegebener Fragestellungen, die von den Studierenden örtlich unabhängig und unbeaufsichtigt unter Zuhilfenahme von Hilfsmitteln innerhalb einer kurzen Bearbeitungszeit erfolgt. Die Bearbeitungszeit kann einen Rahmen von bis zu 48 Stunden umfassen; sie wird durch die Bekanntgabe von Ausgabe- und Abgabezeitpunkt bestimmt.

(2) Eine Vorgabe für den Umfang der schriftlichen Ausarbeitung sowie das Erfordernis der Angabe von Quellen und Hilfsmitteln können ebenfalls festgelegt werden. Die Aufgaben für das Take-Home-Exam werden elektronisch oder in anderer geeigneter Weise ausgegeben und entsprechend in der von der prüfenden Person festgelegten Form abgegeben.

(3) Bei der Abgabe versichern die Studierenden, dass sie die Leistung selbständig ohne fremde Hilfe verfasst und, sofern eine Angabe festgelegt wurde, keine anderen als die angegebenen Quellen und Hilfsmittel verwendet haben. Es gilt § 13 Absatz 4 zur Plagiat-Prüfung.

§ 8d Lernportfolio

(1) Das Lernportfolio zählt zu den kompetenzorientierten Formen von Prüfungsleistungen laut § 6 Absatz 3 und dient der persönlichen Auseinandersetzung mit dem individuellen Lernprozess, indem angestrebte und erreichte Kompetenzzuwächse in Bezug auf die jeweiligen Modulziele dokumentiert und reflektiert werden.

(2) Mit einem Lernportfolio werden Dokumente oder Materialien zu einem lehrrelevanten Thema erstellt bzw. gesammelt, dokumentiert und selbst reflektiert, die den Lernfortschritt und Leistungsstand eines Studierenden nachweisen.

(3) Die Erstellung eines Lernportfolios findet unter einer kontinuierlichen Begleitung durch eine Lehrperson studien-/semesterbegleitend statt.

(4) Der Gestaltungs- sowie der inhaltliche Rahmen eines Lernportfolios wird von der Lehrperson vorgegeben.

1. Der Masterarbeit
2. Dem Kolloquium über die Masterarbeit
3. Den weiteren, in der Fachprüfungsordnung aufgeführten Modulprüfungen.

(Quelle: Master_PO.pdf, Seite 17)

Wann gilt eine Prüfung als nicht bestanden?

Eine Prüfung gilt als nicht bestanden, wenn:

- die Studierenden den Prüfungstermin ohne triftige Gründe versäumen oder nach Ablauf der Meldefrist um mindestens zwei Semester versäumt wird (Quelle: Master_PO.pdf, Seite 9)
- bei überwiegenden Bewertungen mit „nicht ausreichend“ (Quelle: Master_PO.pdf, Seite 14)
- die Wiederholungsmöglichkeiten einer Prüfung ausgeschöpft sind (Quelle: Master_PO.pdf, Seite 15)

Es gibt jedoch Ausnahmen und spezielle Regelungen, wie z.B. bei Teilzeitstudium oder wenn eine letztmalige Wiederholungsmöglichkeit nicht bestanden wurde oder als nicht bestanden gilt (Quelle: Master_PO.pdf, Seite 16).

Wie sind kombinierte Prüfungen strukturiert? Bitte als Tabelle ausgeben

Kombinierte Prüfungen sind wie folgt strukturiert:

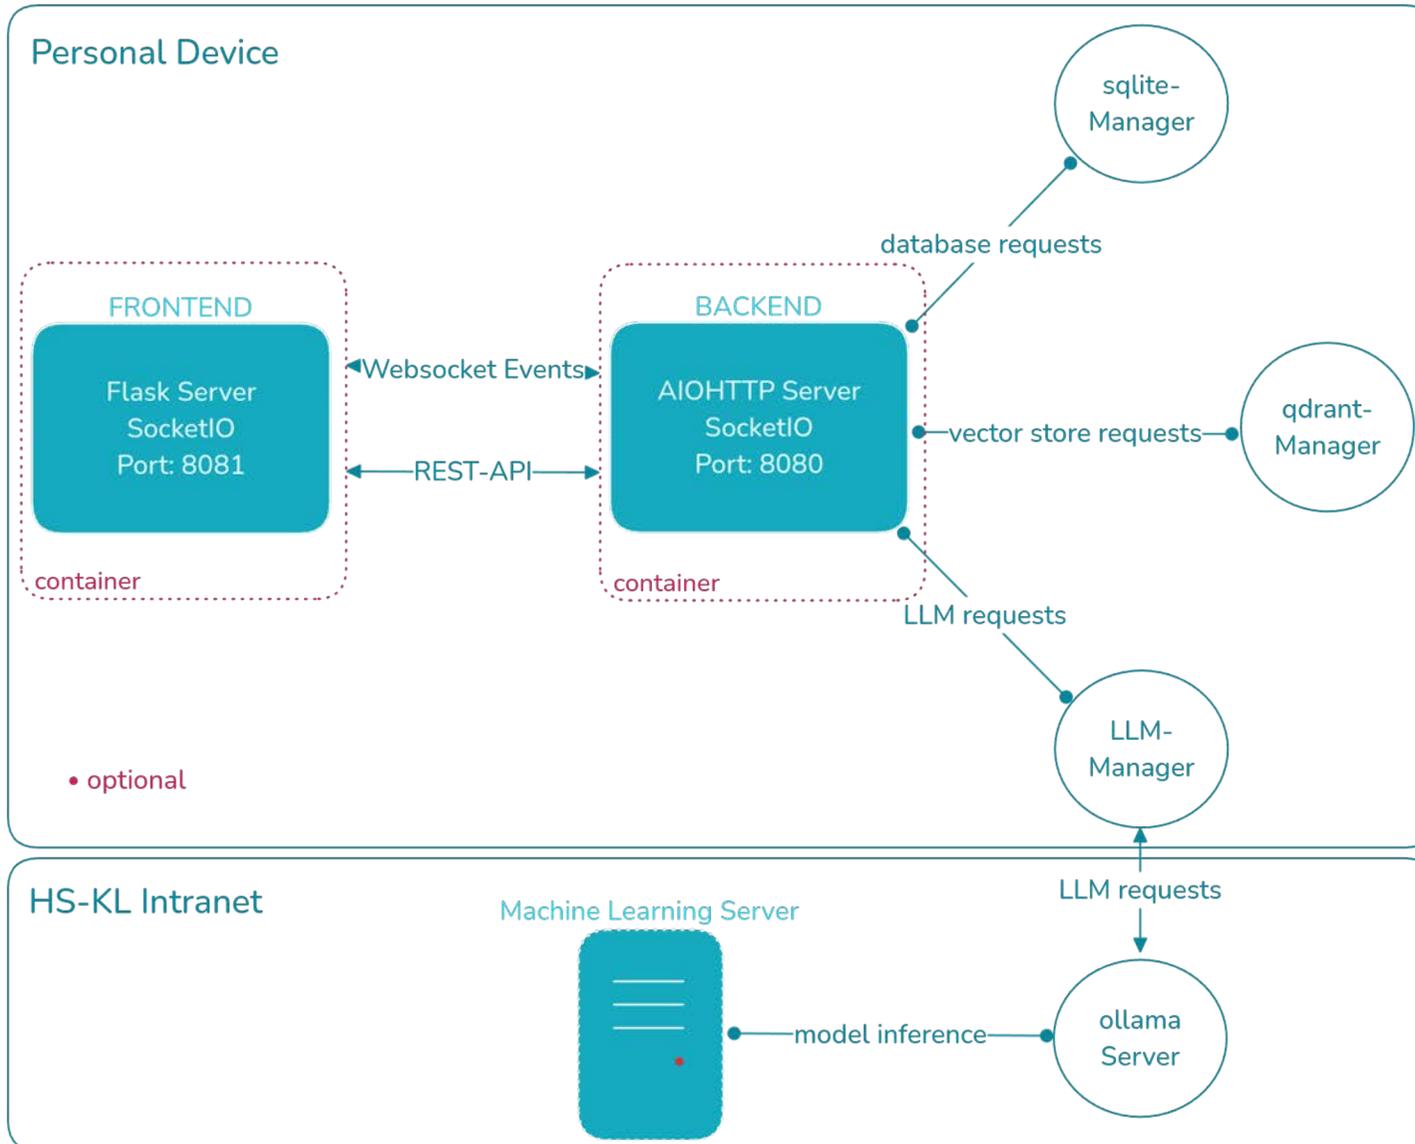
Kürzel	Praktischer Teil	Theoretischer Teil
KP	Studienleistungen, siehe Absatz 4 Satz 4	-
KP1	bestanden oder nicht bestanden (unbenotet)	benotet
KP2	benotet	bestanden oder nicht bestanden (unbenotet)
KP3	benotet	benotet

Beide Prüfungselemente sind unabhängig voneinander zu bestehen. Die Gewichtung der Teile ist 50/50.

(Quelle: Master_PO.pdf, Seite 12)

Prüfungsordnung Dokumentensuche

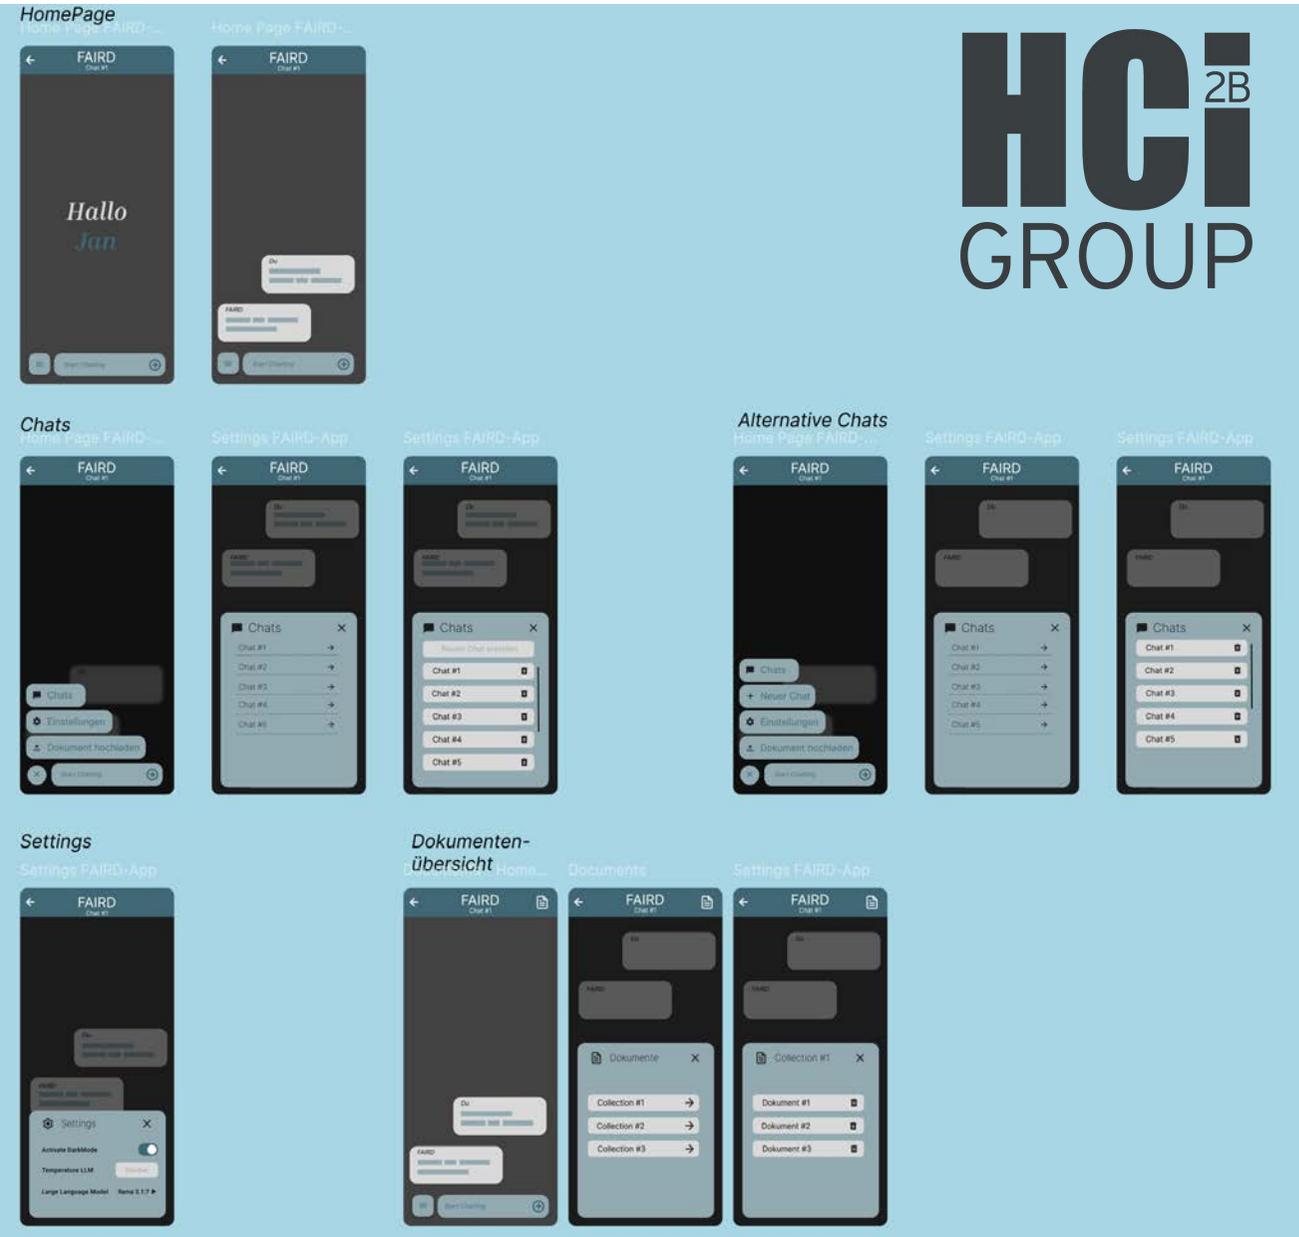
Schreibe eine Nachricht...



- **Frontend:** Flask & Socket.IO (Port 8081)
- **Backend:** AIOHTTP & Socket.IO (Port 8080)
- **Kommunikation** via REST-API und WebSockets
- **Datenbanken:** SQLite (relational), Qdrant (Vektor-DB)
- **LLM-Verarbeitung** über externen Ollama-Server (HS-KL Intranet)
- **Containerisierung** der Dienste (Frontend/Backend) optional

HCI^{2B} GROUP

Master-Projekt
Flutter-Anwendung für iOS
und Android
André Bieber
Noah Ehlert
Joshua Ginkel



Text to Speech (TTS) Speech to Text (STT)



Master Projekt
TTS STT „Joni“
Artur Gibert
Jens Müller
Florian Reichle

Microtec Academy
Jonas Wallach



Master-Projekt
Text to Speech
Steven Abich
Erik Hüther

§ 3 Regelstudienzeit, Studienaufbau und Umfang des Lehrangebots

- (1) Die Regelstudienzeit beträgt drei Semester.
- (2) Studierende wählen zum Zeitpunkt der Einschreibung einen der beiden Studienschwerpunkte „Software-Entwicklung“ und „Mensch-Technik-Interaktion“.
- (3) Das Studium ist modular aufgebaut. Das Studium enthält Pflichtmodule, Profil-Wahlpflichtmodule und profilübergreifende Wahlpflichtmodule. Pflichtmodule sind für alle Studierenden verbindlich. Profilwahlpflichtmodule und Wahlpflichtmodule sind Module, die Studierende aus einem jeweiligen Katalog von Vertiefungsfächern auswählen können. Der Katalog von Profilwahlpflicht- und Wahlpflichtmodulen kann durch Beschluss des Prüfungsausschusses in Abstimmung mit der Studiengangsleitung aktualisiert werden.
- (4) Aus den Katalogen der Profilwahlpflichtmodule sowie der profilübergreifenden Wahlpflichtmodule müssen 24 ECTS-Punkte erworben werden, davon mindestens 6 ECTS-Punkte aus dem Katalog der Profilwahlpflichtmodule.
- (5) 18 ECTS-Punkte der profilübergreifenden Wahlpflichtmodule können im Rahmen eines Mobilitätsmoduls nach § 7 absolviert werden. Alternativ können 12 ECTS-Punkte der profilübergreifenden Wahlpflichtmodule durch das Modul „Mentorbegleitende praktische Tätigkeit“ erworben werden.



HCI^{2B}
GROUP

Innovative
Hochschule



Bundesministerium
für Bildung
und Forschung



DFG
Deutsche Forschungsgemeinschaft

Kennst du schon die 6-3-5 Methode?

6 Teilnehmer



3 Ideen



5 Durchläufe



Jetzt testen!



offene
digitalisierungs
allianz
pfalz



Hochschule
Kaiserslautern
University of
Applied Sciences

HCI^{2B}
GROUP

Sophia Hertzler
Dieter Wallach

Ausblick

- Erstes Ziel: Minimum Viable Produkt
 - Finalisierung Update-Mechanismus,
 - CI-Pipeline,
 - aktuelle Modelle,
 - ...
- Testphase
- Entwicklung der Nutzungsszenarien Intranet und Internet
- Neue Features („Custom FAIRDs“, Multi-Modalität, etc.)
- Weitere Teamverstärkung
- Finale Namensgebung