


DIE KUNST DER DATEN

Wie man dem Problem
fehlender Daten
entgegenwirken kann,
wenn man spezialisierte
Modelle trainieren will



Krista Frick & Susanne Waldthaler, Co-Founders wedomagic GmbH



René Larch

Co-Founder & CTO

AI Development

.NET/C#

UNSER SÜDTIROLER TEAM



Susanne Waldthaler

Co-Founder & CEO

Machine Learning

Python



Krista Frick

Co-Founder & COO


AI implementation

Javascript

DAS RECHTSPROBLEM

- in Italien sind die gesetzlichen Bestimmungen >10x umfangreicher als Deutschland, Frankreich und UK gemeinsam
- dynamische Gesetzgebung und **vielfältige juristische Interpretationen**

Durchsuchen von Millionen Gesetzen & Urteilen



UNSERE LÖSUNG

*Mehr Effizienz und Qualität durch eine auf
das italienische Recht spezialisierte KI*

- ✓ Prüft entsprechende Gesetze und Urteile
- ✓ Gibt eine Antwort auf eine juristische Fragestellung im Handumdrehen
- ✓ Referenziert strikt verifizierte Quellen (Gesetze & Urteile) und vermeidet “Hallucination”



in Zusammenarbeit
mit Anwaltskanzleien
entwickelt

WARUM EIN EIGENES MODELL TRAINIEREN?



- spezialisierte Bereiche brauchen spezialisierte KI-Modelle
- Datenschutz & Privacy
- Zugriff auf Millionen Dokumente (Gesetze, Normen, Rechtssprechung...)

Nach verschiedenen Experimenten und Entwicklungen:
eigenes Frage-Antwort Modell trainieren


DIE HERAUSFORDERUNG: TRAININGSDATEN



- Mangel an Daten erschwert das Training von spezialisierten KI-Modellen
- **Rechtliche Beschränkungen** und Datenschutzbestimmungen mit einigen realen Daten
- Hohe Kosten und Aufwand für echte Datengenerierung

WAS SIND SYNTHETISCHE DATEN?

- Definition: Künstlich generierte Daten, die **echten Daten ähneln/nachahmen**
- Arten von synthetischen Daten:
 - Text (unser Beispiel)
 - Bilder
 - Numerische Daten



VORTEILE VON SYNTHETISCHEN DATEN


- Überwindung von Datenknappheit
- Vermeidung von Datenschutzproblemen
- Anpassbar und skalierbar
- Kosteneffizient




PRAKTISCHES BEISPIEL: Chatbot für juristische Fragen



Endresultat
definieren &
Datenverständnis



Modellauswahl je
nach Stärke



Datengenerierung




Validierung

MIXTURE-OF-AGENTS-METHODE



- KI-Agents = KI-Mitarbeiter
- haben unterschiedliche Funktionen und Stärken
- führen zu bestimmten Zeitpunkt - je nach Prozessdefinition - ihre (einzige) Aufgabe aus

Source: *Mixture-of-Agents Enhances Large Language Model Capabilities*, Wang et al., Jun 2024, [arXiv:2406.04692](https://arxiv.org/abs/2406.04692)



CAVEATS UND LEARNINGS

- Sind synthetische Daten nicht anfällig für Bias (Verzerrungen)?

✓ *Ja! Qualitätskontrolle und Bias-Mitigation-Strategien einsetzen (KI-Agents)! Wo möglich kombinieren mit echten Daten!*

- Wie kontrolliere ich die Richtigkeit der erstellten Daten?

✓ *Menschliche Validierung wo möglich (Stichprobenartige Validierung mit Anwälten) + KI-Agents (=KI-Mitarbeiter)*

- Welche Methodik passt zu meiner Aufgabe und meinem Unternehmen?

✓ *Guten Plan erstellen und dann...
PROBIEREN GEHT ÜBER STUDIERN!*





TAKE HOME MESSAGES

1



GENÜGEND HOCHQUALITATIVE DATEN SIND ESSENZIELL FÜR EFFEKTIVES TRAINING

2



SYNTHETISCHE DATEN KÖNNEN DORT HELFEN WO ECHTE DATEN FEHLEN ODER ZU KOSTSPIELIG SIND

3



ZUSAMMENARBEIT MEHRERER MODELLE IST EIN EFFEKTIVER WEG UM DATEN ZU ERSTELLEN UND **QUALITÄT ZU SICHERN** - MENSCHLICHE VALIDIERUNG!