




/// Kundentag 2024

# **WISSENS- MANAGEMENT MIT KI**

M. Höflinger mit F. Wallner | 24.10.2024 | 15:05 Uhr



# **Copyright**

---

Diese Unterlagen sind urheberrechtlich geschützt. Alle Rechte – auch die der Übersetzung, des Nachdruckes und der Vervielfältigung der Unterlagen oder Teilen daraus – vorbehalten. Kein Teil der Unterlagen darf ohne Genehmigung der Dr. Wallner Engineering GmbH in irgendeiner Form (Fotokopien, Mikrofilm oder ein anderes Verfahren) – auch nicht für Zwecke der Unterrichtsgestaltung – reproduziert oder unter Verwendung elektronischer Systeme verarbeitet oder vervielfältigt oder Dritten zugänglich gemacht werden.

## **Dr. Wallner Engineering GmbH**

Charles-Lindbergh-Str. 7  
71034 Böblingen


Tel      +49 7031 410309-0  
Fax     +49 7031 410309-11  
Mail    kontakt@drwe.de  
Web    www.drwe.de



/// Was ist zu erwarten?

# AGENDA


1. Warum Wissensmanagement mit KI?
2. Was ist ein LLM?
3. Warum lokal?
4. Was nutzen wir?
5. Wissen integrieren
6. Ausblick und weitere Ansätze



/// 1.

# **WARUM WISSENS- MANAGEMENT MIT KI?**

- Userfreundlich
- Zeitsparend
- Zentralisierte Anlaufstelle über verschiedene Ressourcen hinweg



/// 2.

# **WAS IST EIN LLM?**

**Eine KI welche:**

- Auf großen Mengen von Text trainiert wird
- Sprache verstehen und generieren kann
- Muster und Zusammenhänge einer Sprache versteht



/// 3.

## **WARUM LOKAL?**

- Kostenpunkt
- Privacy / Datenkontrolle



# Kosten

## Externe KI-Anbieter


- Chatgpt Premium → 23€ / User / Monat
- Gemini Premium (Google) → 22€ / User / Monat
- Microsoft Copilot → 22€ / User / Monat

## Lokale KI


Anschaffungskosten (variiieren) | Beispiel:

Server + RTX 3090 → 3000€

Unterhalt → ca. 500€ / Jahr, bei 8h  
maximal Auslastung / Tag




# Datenkontrolle




/// 4.

# **WAS NUTZEN WIR?**

- Open Web UI
- Ollama / Llama
- Docker



# Warum nutzen wir es?



/// 5.

## **WISSEN INTEGRIEREN**

- RAG
- Training / fine-tuning



# Training / fine-tuning

- Daten müssen aufbereitet werden (Textform)
- Tokenizer
- Fine-Tuning Frameworks
  - Huggingface
  - PyTorch
- Lernrate
- Batchgröße
- Epochen
- Dropout Rate
- Gewichtsinitialisierung

## Vorteile

- Abfragen sind schneller
- Verbesserte Datenqualität für übergreifende Abfragen
- Antworten werden aus Wissen generiert

## Nachteile

- Datenaufbereitung ist aufwendiger
- „Richtige“ Initialisierung des Trainings ist komplex
- Lange Trainingszyklen
- Wissen bleibt nach Veränderung bestehen

# **Retrieval-Augmented-Generation**

## **Vorteile**

- Kein „Training“ benötigt
- Wissen kann in verschiedenen Medien dokumentiert sein
- Bei Änderung einer Dokumentation ist diese „sofort“ verfügbar
- KI-Modell wird „nicht“ vergrößert

## **Nachteile**

- Datenabfrage dauert länger
- Datenabfrage kann verfälscht werden wenn mehrere Einträge ähnliche Informationen enthalten
- Antworten werden Großteils lediglich zitiert

/// 6.

# **AUSBLICK & WEITERE ANSÄTZE**

- GPU / CPU Vergleich
- Demonstration
- Pipelines



# Vergleich GPU / CPU

## GPU

- Verarbeitung: parallel
- Anzahl der Kerne: (RTX3090) 10'500
- Optimiert für Berechnungen und große Datenmengen




für **datenintensive** Aufgaben

## CPU

- Verarbeitung: seriell
- Anzahl der Kerne: 4 – 24
- Optimiert für Prozessverarbeitungen und Steuerungslogik



für **prozessintensive** Aufgaben



**VIELEN DANK!**





DR. WALLNER ENGINEERING

