

# Entwicklung & Optimierung von LLM-Anwendungen (Python).

**Von Architekturprinzipien bis Agenten: Sie entwickeln LLM-Systeme und setzen DSGVO-konforme KI produktiv um.**

---

|                             |                         |                           |
|-----------------------------|-------------------------|---------------------------|
| Seminar                     | 3 Termine verfügbar     | Teilnahmebescheinigung    |
| Präsenz / Virtual Classroom | 24 Unterrichtseinheiten | Garantietermine vorhanden |

---

Seminarnummer: 31381

Stand: 30.07.2026. Alle aktuellen Informationen finden Sie unter <https://akademie.tuv.com/s/31381>

Dieses Training vermittelt AI Engineers, Data Scientists und Softwareentwicklern die Grundlagen und Best Practices für die Entwicklung leistungsstarker LLM-Anwendungen in Python. Es vermittelt praxisnah moderne Architekturprinzipien und -muster, darunter RAG-Architekturen, Agentensysteme und fortgeschrittenes Prompt-Engineering bis hin zu Deployment und LLMOps. Dabei werden ebenso wichtige Themen wie DSGVO-Konformität, Monitoring und Responsible AI behandelt.

Die Teilnehmer lernen, wie sie moderne KI-Systeme effizient aufbauen, konfigurieren und skalieren können – von der Auswahl passender Modelle und Quantisierungstechniken bis zur Integration von Vektordatenbanken und der Orchestrierung von Multi-Agenten-Systemen. Praktische Übungen runden das Training ab, sodass ein direkter Transfer in reale Anwendungsfälle erleichtert wird.

Dieses Training bietet eine kompakte Wissensbasis, um KI-Projekte sicher und performant zu realisieren, von der Architektur über die Umsetzung bis zum Betrieb und der Governance.

## Nutzen

- Sie erlernen Architekturen und Best Practices für skalierbare LLM-Anwendungen.
- Sie entwickeln RAG-Systeme mit Vektordatenbanken eigenständig.
- Sie planen und setzen sichere, DSGVO-konforme KI-Integrationen um.
- Sie erhalten eine Einführung in LLMOps für Monitoring, Fine-Tuning und CI/CD.
- Sie sammeln Erfahrung mit Multi-Agent-Systemen und praxisnahen Projekten.

## Zielgruppe

AI Engineers, Data Scientists & Softwareentwickler mit Python-Erfahrung, die LLM-Anwendungen entwickeln und produktiv einsetzen wollen, wie

- Software Engineers (Python)
- Machine Learning Engineers
- Data Scientists
- Architekten für KI-Systeme.

## Voraussetzungen

Gute Python-Kenntnisse (Fortgeschrittenen-Niveau)

## Abschluss

### Teilnahmebescheinigung

Teilnahmebescheinigung der TÜV Rheinland Akademie

## Inhalte des Seminars

### Tag 1:

#### Grundlagen, Architektur & Prompting

- Architektur moderner LLM-Anwendungen
- Überblick: RAG, Agenten-Architekturen, Orchestrierungsmuster
- Best Practices & Design Patterns für skalierbare KI-Systeme
- Trade-offs: Latenz, Kosten, Qualität

#### Prompt Engineering intensiv

- Grundlagen: Few-Shot, Zero-Shot, Chain-of-Thought
- Erweiterte Techniken: ReAct, Self-Ask, Structured Outputs, Guardrails
- Hinweis auf weiterführende Techniken (Tree-of-Thought, Graph-of-Thought)
- Hands-on: Erste Prototypen mit OpenRouter, OpenWebUI & Python

#### Modelle, Quantisierung & Konfiguration

- Überblick Modellfamilien (LLaMA, Mistral, Phi, Falcon, Mixtral, etc.)
- Parametergrößen (7B, 13B, 70B ...) und ihr Einfluss auf Qualität & Hardwarebedarf
- Quantisierung (Q4, Q8 ...) für Performance & Speicheroptimierung

- Model Configuration: Temperatur, Top-K/P, Prompt-Templates, System-Prompts

## Tag 2:

### RAG & Deployment

- Retrieval-Augmented Generation (RAG)
- Embeddings & Chunking-Strategien
- Vektordatenbanken: FAISS, Weaviate, Pinecone, Milvus
- Advanced RAG: Ranking, Hybrid Retrieval, Query Expansion
- Optimierung: Latency-Reduktion, Kontextfenster-Strategien, Guardrails
- Hands-on: Aufbau & Optimierung eines RAG-Systems mit LangChain

### Deployment & Infrastruktur

- Lokale & Cloud-Bereitstellung: Vor- & Nachteile
- 
- Deployment-Server: openLLM, vLLM, llama.cpp im Vergleich
- Containerisierung & Skalierung mit Docker/Kubernetes
- Monitoring & Observability: GPU-Auslastung, Kosten, Antwortqualität

## Tag 3:

### LLMOps, Agenten & Praxisprojekt

- LLMOps & Governance
- Monitoring & Evaluation: automatisierte Benchmarks, Halluzinationserkennung
- Fine-Tuning & Parameter-Efficient Tuning (LoRA/QLoRA)
- CI/CD & Testing von LLM-Anwendungen
- DSGVO-Compliance, Responsible AI & Audit-Fähigkeit

### Multi-Agent-Systeme & MCP

- Monitoring & Evaluation: automatisierte Benchmarks, Halluzinationserkennung
- Fine-Tuning & Parameter-Efficient Tuning (LoRA/QLoRA)
- CI/CD & Testing von LLM-Anwendungen
- DSGVO-Compliance, Responsible AI & Audit-Fähigkeit

## Wichtige Hinweise

## Terminübersicht und Buchung

Buchen Sie Ihren Wunschtermin jetzt direkt online unter <https://akademie.tuv.com/s/31381> und profitieren Sie von diesen Vorteilen:

- Schneller Buchungsvorgang
- Persönliches Kundenkonto
- Gleichzeitige Buchung für mehrere Teilnehmer:innen

Alternativ können Sie das Bestellformular verwenden, um via Fax oder E-Mail zu bestellen.