



# Roadmap zur Implementierung einer KI-Plattform mit voller Compliance durch deutsches Hosting

PERSÖNLICH.  
STARK.  
SICHER.  
KLUG.  
**RICHTIG GUT.**

# Phasenplan

Die folgende Roadmap beschreibt einen 6-12-Monats-Plan für den Aufbau einer produktiven, sicheren KI-Plattform auf deutschem Hosting. Der Plan ist bewusst phasenbasiert, um Risiken zu minimieren, schnell Lernergebnisse zu erzeugen und ein Produktions-Deployment mit belastbaren Compliance-Artefakten zu erreichen.

## Phase 1: Use-Case-Selektion und Vorbereitung (Monat 1)

Ziel: Strategische Grundlage und Entscheidungsreife für das Hosting-Modell herstellen.

- > Erarbeitung eines Use-Case-Portfolios (3-5 KI-Kandidaten) mit vorläufiger Risikoeinstufung (Hochrisiko AI Act Annex III ja/nein, DSFA-Indikation nach Art. 35 DSGVO).
- > Rollenmapping nach DSGVO (Verantwortlicher/Auftragsverarbeiter) und AI Act (Provider/Deployer) für jeden Use Case.
- > Dateninventur: Dokumentation, welche Datenquellen in Prompts, RAG-Systeme oder Training einfließen sollen. Klassifizierung nach Sensitivität und regulatorischer Kategorie.
- > Provider-Shortlist (2-3 DE-Anbieter) und Erarbeitung eines standardisierten Due-Diligence-Fragenkatalogs (Rechenzentrumsstandorte, Subunternehmerliste, Zertifizierungen, Schlüsselmanagement, Remote-Zugriff-Politik).
- > Rollen und Verantwortlichkeiten: RACI-Matrix für Projekt und späteren Betrieb.

## Phase 2: Architektur- und Sicherheitsdesign (Monate 2-3)

Ziel: Technische Zielarchitektur und Compliance-Rahmen spezifizieren.

- > Zielarchitektur-Dokument: Kubernetes-Cluster-Topologie, GPU-Pool-Design (MIG-Konfiguration), S3-Objektspeicher-Anbindung, Serving-Stack (KServe/Triton oder vLLM), Monitoring-Architektur.
- > Security Baseline: IAM-Design, Netzwerksegmentierung, KMS/HSM-Anbindung, Logging-Konzept (was wird protokolliert, mit welcher Retention, unter welchem Zugriffsschutz).
- > Vertrags- und Nachweispaket: AVV-Entwurf, TOM-Anlage, Subunternehmerliste, Auditrechte-Klausel, Incident-Response-Pflichten.
- > SLO-Definition: Konkrete messbare Service Level Objectives für Latenz, Throughput, Verfügbarkeit und Wiederherstellung.
- > Datenschutz-Folgenabschätzung (DSFA) für Hochrisiko-Anwendungsfälle durchführen oder vorbereiten.

### Phase 3: Proof of Concept und Technischer Pilot (Monate 3-5)

Ziel: Technische Machbarkeit und Security-Posture validieren, erste Leistungsmessungen durchführen.


- > Minimal-Cluster aufbauen (2-4 GPUs) mit vollständigem Security-Rahmen: RBAC, NetworkPolicies, KMS-Anbindung, Audit-Logging aktiv.
- > Model-Serving-Stack integrieren (KServe/Triton), End-to-End-Test vom API-Call bis zur Model-Antwort.
- > S3-Kompatibilitätstest:  
Alle benötigten API-Operationen gegen den DE-Hosting-Objektspeicher testen und dokumentieren.
- > RAG-Pipeline (wenn relevant):  
ETL-Prozess, Index-Build, Retrieval-Test mit Access-Control-Verifikation.
- > Security-Tests:  
Tenant-Isolationstest (simulierter Cross-Tenant-Zugriff), IAM-Fehlkonfigurationstest, Audit-Log-Verifikation, Secret-Scan.
- > Benchmark-Ausführung:  
Latenz, Throughput, GPU-Utilization unter realistischen Last-Profilen dokumentieren.

### Phase 4: MVP in Produktion (Monate 6-9)

Ziel: Ersten produktiven Use Case mit vollständigem Governance-Rahmen in Betrieb nehmen.

- > Ein prioritärer Use Case geht in Produktion (z.B. interner Assistenz-Chat mit RAG auf Wissensdatenbank).
- > Governance-Implementierung abgeschlossen:  
Logging-Retention, Privacy Controls, Rollback-Prozesse, Incident-Response-Runbook.

- > SLAs vertraglich vereinbart und monitoring-seitig messbar gemacht.
- > AI Literacy Schulungen für betroffene Nutzer und Betriebsteam (Pflicht unter EU AI Act ab 2025).
- > Abschluss-Dokumentation audit-ready:  
Datenflussdiagramm, DSFA, AVV, TOM-Nachweis, Benchmark-Report.





## Phase 5: Skalierung und Portfolio-Ausbau (Monate 9-12)

Ziel: Weitere Use Cases onboarden, Plattform für Multi-Tenant-Betrieb optimieren.

- > Kapazitätsplanung finalisieren:  
Reserved GPUs für kritische Zeitfenster, Multi-Tenant-Strategie mit MIG-Profilen oder dedizierten Node Pools.
- > MLOps-Reife steigern:  
Supply Chain Signierung für Container Images, Model Registry vollständig integriert, Quality Gates für Modell-Deployments.
- > FinOps einführen:  
Kosten-Tracking pro Request/Token, Chargeback/Showback für interne Teams, Anomalie-Erkennung bei Kostentreibern.
- > Security-Programm verstetigen:  
Regelmäßige Penetrationstests, SBOM-Update-Prozess, Vulnerability-Scan-Automatisierung.

| Aufgabenbereich                             | CIO/IT-Leiter  | CISO           | DPO/Datenschutz | GRC            | SRE/Plattform  | Data/AI-Team   |
|---------------------------------------------|----------------|----------------|-----------------|----------------|----------------|----------------|
| <b>Hosting-Entscheidung</b>                 | Verantwortlich | Konsultiert    | Konsultiert     | Konsultiert    | Informiert     | Informiert     |
| <b>Provider-Auswahl &amp; AVV</b>           | Verantwortlich | Konsultiert    | Verantwortlich  | Konsultiert    | Informiert     | Informiert     |
| <b>Security Baseline &amp; Threat Model</b> | Konsultiert    | Verantwortlich | Konsultiert     | Konsultiert    | Mitarbeit      | Informiert     |
| <b>DSFA-Ausführung</b>                      | Konsultiert    | Konsultiert    | Verantwortlich  | Konsultiert    | Informiert     | Informiert     |
| <b>Plattform-Betrieb &amp; SRE</b>          | Konsultiert    | Konsultiert    | Informiert      | Informiert     | Verantwortlich | Konsultiert    |
| <b>Modellwahl &amp; KI-Wahl</b>             | Informiert     | Konsultiert    | Konsultiert     | Informiert     | Konsultiert    | Verantwortlich |
| <b>Compliance-Monitoring</b>                | Informiert     | Konsultiert    | Verantwortlich  | Verantwortlich | Konsultiert    | Informiert     |