

OST
Ostschweizer
Fachhochschule

AnkiGenerator

Challenge Task FS2026

Diego Salazar

18.05.2026

Department Informatik


Architektur & Design

Teil 1 von 3

WO WISSEN WIRKT.

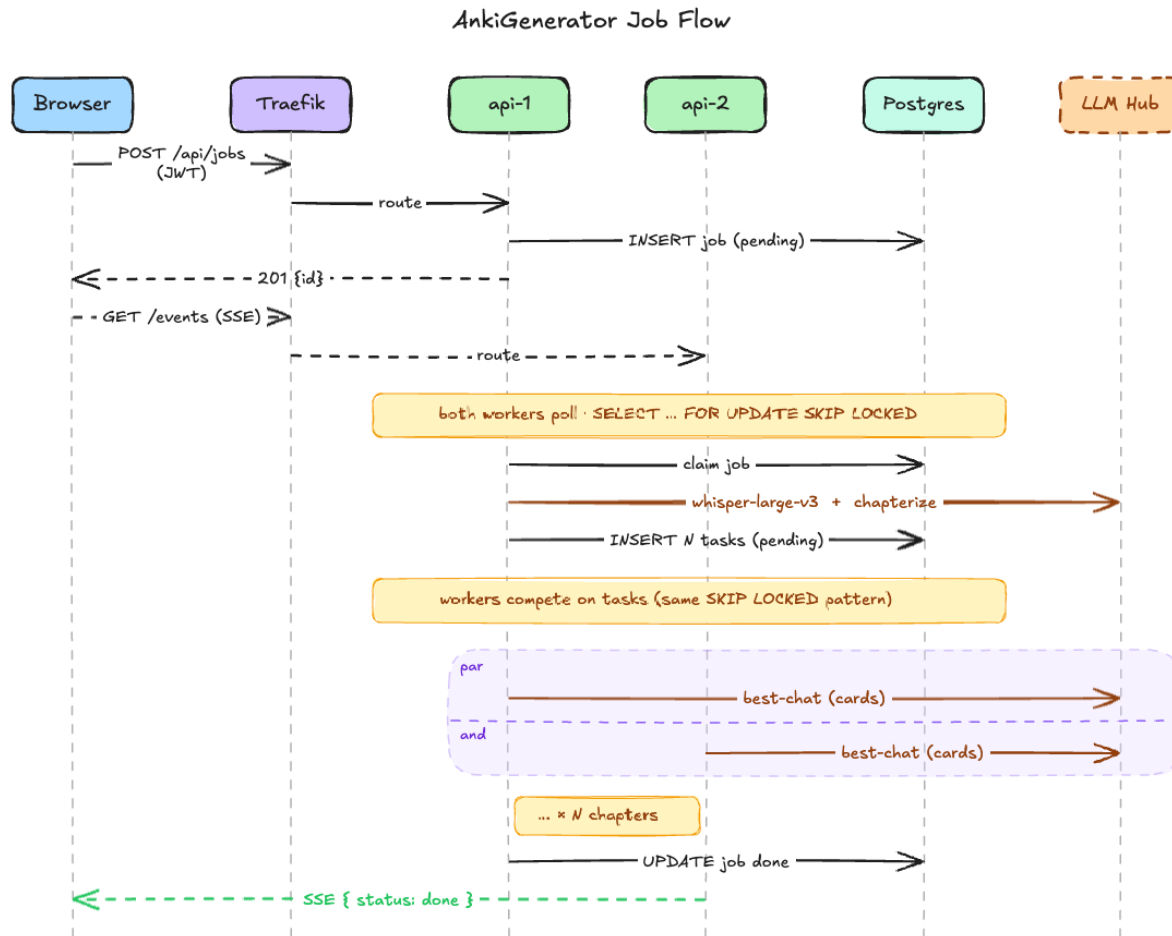
1 Überblick

- **5 Container**
 - Start mit docker compose up
- **Traefik**
 - Round Robin für API calls
 - Health checks (/api/health) im 5 Sekunden Takt
 - Failover
- **2x FastAPI + Worker**
 - Identisches Image & .env
 - Stateless
- **PostgreSQL**
 - Application Data & Job Queue
- **Frontend**
- **LLM Hub (Dependency)**



Architektur & Design

2 Flow



- Browser
 - Job mit Videofile wird gestartet (JWT im Header)
 - Öffnet SSE-Verbindung für Progress
- Traefik
 - Verteil via RR
- HTTP Request Handler
 - Validiert JWT
 - Insert Job Row (status='pending')
 - Antwortet sofort mit 201 {id}
- Worker (beide Instanzen pollen parallel)
 - Job Level
 - Claimed Job (via SELECT ... FOR UPDATE SKIP LOCKED)
 - Konvertiert mp4 → mp3 (ffmpeg), splittet falls > 25 MB
 - Whisper-Aufruf → Audio-Transkript
 - LLM-Aufruf → Chapterization (JSON)
 - Ein Task pro Kapitel in DB einfügen
 - Task Level
 - Claimed Task via SELECT ... FOR UPDATE SKIP LOCKED
 - LLM-Aufruf für Flashcard Generierung
 - Flashcards in «flashcards» table einfügen
 - Letzter Task im Job → job.status = 'done' → SSE { status: done }

3 Authentication

- **JWT-Mechanismus**

- HS256
- Access-Token 15min
- Refresh-Token 7d

- **Auth-Endpoints**

- Register, Login, Refresh
- Passwort reset & Email verify
- Bcrypt mit auto-salt für Passwörter

- **OWASP**

- Type-Claim-Enforcement zentral → verhindert Token-Confusion
- User-Enumeration-Prevention auf /forgot-password → immer 204, kein Email-Probing
- Minimale Payload (user_id, type, exp) → kein Leak von Email / Rolle bei Token-Abgriff

- **DS-Payoff**

- Token ist self-contained → kein Session-State auf den Instanzen
- API-Tier stateless → Round-Robin ohne Sticky Sessions
- Horizontale Skalierung ohne Auth-Änderungen

- **Tradeoffs**

- Tokens im localStorage (XSS-exposed)
- httpOnly-Cookie-Migration dokumentiert, nicht implementiert

4 Design Choices

- **Postgres-as-Queue (statt Redis / RabbitMQ)**
 - Workers claimen via `SELECT ... FOR UPDATE SKIP LOCKED`
 - Eine Komponente weniger zu deployen / monitoren
 - Row-Lock löst sich beim Disconnect → Crash-Recovery gratis
- **Worker-Thread im API-Container (statt Celery)**
 - Ein Image, ein docker compose up
 - Blocking LLM-Calls laufen in dediziertem Thread → Request-Latenz bleibt flach
 - Bricht: wenn Worker und API unabhängig skalieren müssten
- **Zwei-Level-Decomposition: jobs → tasks**
 - Ein Upload → N Task-Rows nach Chapterization
 - Beide Worker konkurrieren auf tasks → echter Fan-Out über Instanzen
 - Mehr Instanzen = mehr parallele Chapter
- **SSE statt WebSocket**
 - One-way reicht (Server → Client)
 - Funktioniert durch Traefik mit disabled Buffering
 - `@microsoft/fetch-event-source` erlaubt JWT im Header (statt native EventSource da Token im local storage)

5 Bottlenecks & Load Tests

- **Bottleneck-Hierarchie**
 - **LLM Hub:** >5 min Wall-Time pro 1-Std-Lecture · hub-bound · extern, nicht kontrollierbar
 - **DB Connection Pool:** ThreadedConnectionPool(2, 10) pro Instanz · 20 Connections total
 - **Whisper 25 MB Limit:** Workaround via 10-min mp3-Chunking
- **Was skaliert, was nicht**
 - Throughput (Jobs/h) ← skaliert *linear* mit Instanz-Anzahl
 - Per-Job-Latenz (>5 min) ← (llm-)hub-bound · unabhängig von Instanz-Anzahl
- **Load Test mit hey** (Endpoint: GET /api/jobs · JWT-protected · DB-Query)
 - 2 Instanzen, c=10: **1109 req/s · 100 % Success · P99 = 24.5 ms**
 - c=50+: Pool-Exhaustion sichtbar · ~1000 req/s Steady State unter Overload
 - /api/health ohne DB: **5291 req/s** → bestätigt: Pool ist der Bottleneck, nicht das Framework
- **Demo zeigt**
 - Live Load Test gegen Bottleneck #2 (DB-Pool)
 - Failover: docker compose stop api-2 → Traefik dropped Instanz nach Health-Check-Fail (~5 s)
 - Bottleneck #1 (LLM Hub) nicht in 5 min reproduzierbar, daher nur für demo: OpenAI API

Demo

Teil 2 von 3

WO WISSEN WIRKT.

Q&A

Teil 3 von 3

WO WISSEN WIRKT.