

TECH TALK · APRIL 2026

# Einführung in OpenClaw

Ein lokaler AI-Assistent. Auf WhatsApp & Co. In 90 Minuten live.

Marcel Wege · byte5 GmbH

## Marcel Wege : CTO @ byte5

- **43, verheiratet, in Langen (Hessen)** — fast 9 Jahre byte5 in Frankfurt, Prokurist & CTO
- **Tech-Stack :** Laravel · Node.js · Umbraco · alles, was komplexe Projekte zum Laufen bringt
- **Speaker** auf Tech-Events — u.a. Umbraco Festival Deutschland
- **Privat :** Formel-1-Fan, Rennrad 🚴 (daher heute Strava in der Demo), Fotografie 📷

**Kontakt :** [mwege@byte5.de](mailto:mwege@byte5.de) · [LinkedIn](#)



## byte5 in 30 Sekunden

- Softwareunternehmen aus Frankfurt am Main, seit 2004
- Geschäftskritische Web- und KI-Lösungen für Mittelstand und Großunternehmen
- **Produktiv-Stack** : Umbraco · Laravel · Medusa
- **byte5 Labs** : OpenClaw · IOTA · Agentic AI
- Unsere Expert:innen begleiten Projekte von der Strategie bis zum Betrieb

In unseren byte5 Labs arbeiten wir intensiv mit OpenClaw — die Learnings fließen direkt in die Enterprise-AI-Lösungen, die wir für unsere Kund:innen bauen.



# Lokaler AI-Assistent. Auf deinen Channels.

**Idee** : ein persönlicher AI-Assistent, der dich überall erreicht — ohne deine Daten an einen Cloud-Vendor abzugeben.

- **Gateway** als lokale Steuerebene auf deinem Server oder Laptop
- Inbox über bestehende Kanäle : WhatsApp, Telegram, Slack, iMessage, Signal, Matrix, ...
- **Skills** als versionierbare Markdown-Dateien — `SKILL.md` pro Fähigkeit
- LLM frei wählbar : Anthropic, OpenAI, OpenRouter — oder lokal via Ollama
- MIT-lizenziert, läuft auf Linux / macOS / Windows (WSL2)

# Roter Faden

1. **Setup** — Ubuntu-Container als VPS-Simulator
2. **Onboarding** — OpenClaw installieren, Persona aushandeln
3. **WhatsApp** — QR scannen, Bot antwortet
4. **Skills** — Markdown-Skill vom Host editieren
5. **Strava (DIY)** — externe API mit OAuth selbst anbinden
6. **Cron** — proaktive Coach-Pushes
7. **Web Search** — zweiter Skill, API-Key statt OAuth
8. **Komposition** — Strava + Search + USER.md = Event-Empfehlungen
9. **ClawHub** — Skills aus der Registry installieren
10. **Persistenz** — Container neustarten, alles bleibt

Am Ende : du weißt, wie du OpenClaw auf deinem VPS einsetzt.

# Phase 1 : Setup

# Drei Wege, OpenClaw zu installieren

Pfad	Wann?	Aufwand
<b>VPS</b> Bare-Metal Ubuntu	Produktion auf deinem eigenen Server	gering
<b>DOCKER</b> VPS-Simulator	Lokales Üben mit identischen VPS-Befehlen	mittel
<b>DOCKER</b> Lean Local	Schnell ausprobieren, ~250 MB Image	minimal

Alle drei Pfade führen zu denselben drei Schlüssel-Befehlen :

```
npm install -g openclaw@latest
openclaw onboard
openclaw channels add whatsapp
```

DOCKER

## Live : Container hochfahren

```
cp .env.example .env                # leerer Sentinel
docker compose up -d --build
docker compose exec openclaw bash

# Im Container – exakt die VPS-Befehle:
node --version                       # v24.x
npm install -g openclaw@latest
openclaw --version
```

- Persistenz über zwei Bind Mounts : `./openclaw` und `./workspace`
- Vom Host editierbar mit jedem Editor
- Reset zwischen Versuchen : `docker compose down -v && up -d`

# Phase 2 : Onboarding

# Der Wizard übernimmt

```
openclaw onboard --install-daemon
```

Frage	Antwort für die Demo
Workspace-Pfad	<code>~/ .openclaw/workspace</code> (Default behalten)
LLM-Provider	OpenAI Codex (ChatGPT-Subscription)
Modell	<code>openai-codex/gpt-5.5</code>
Auth	<b>OAuth-URL-Flow</b> — Wizard druckt Link, im Browser bei ChatGPT autorisieren
Skills	erstmal überspringen — kommen in Phase 5

Auf einem echten VPS landet der Gateway als **systemd-User-Service** und übersteht Reboots.

# Browser statt Terminal

Im Alltag willst du das **WebUI**. Zwei Anpassungen, dann läuft's :

**DOCKER**

**Gateway-Bind auf auto** — Loopback + Bridge-Interface, kein Public-Listener :

```
openclaw config set gateway.bind auto      # + Port mappen in docker-compose.yml
```

**BEIDE**

**URL inkl. Auth-Token bauen** (Token steht in der Config, **dashboard** druckt es aus Sicherheit nicht) :

```
echo "http://localhost:18789/?token=$(jq -r .gateway.auth.token ~/.openclaw/openclaw.json)"
```

**VPS**

**ssh -L 18789:localhost:18789 user@vps** öffnen, gleiches Echo-Snippet auf dem VPS, URL **lokal** im Browser öffnen. SSH-Tunnel verschlüsselt, **bind** darf hier **loopback** bleiben.

# Der Agent fragt zurück

Nach dem ersten Start handelt OpenClaw seine Identität mit dir aus — **im Chat**, nicht im Wizard.

- **Name des Agents** — wie soll ich heißen?
- **Dein Name** — wie darf ich dich nennen?
- **Rolle** — was bin ich für dich?
- **Vibe** — ruhig · warm · direkt · witzig · nerdig
- **Emoji** — die Signatur

→ Schreibt `IDENTITY.md`, `USER.md`, `SOUL.md` & Co. in den Workspace — versionierbar, vom Host editierbar.

**Heute Abend live** : byte5 Demo Bot 🏆 · witzig & sarkastisch · Personal-Coach für Marcel

# Phase 3 : WhatsApp

WEBUI

## Channel aktivieren

**Wichtig :** **Communications** (Config)  $\neq$  **Channels** (Laufzeit). Aktivieren passiert in **Communications**, sichtbar wird's danach in **Channels**.

1. Linke Sidebar : **Communications**
2. Suchfeld : `whatsapp` → Section springt rein
3. **Channels** → **WhatsApp** : **Enabled**-Toggle umlegen
4. **Save** unten in der Card

**Finger weg von "Add Entry" unter Accounts** — das legt einen **zweiten** Account neben dem `default` an, der beim QR-Scan automatisch entsteht. Beide kämpfen um dieselbe Nummer → Reconnect-Loop, Bot ist tot. Erst **Save**, dann den `default` -Account einfach scannen lassen.

# QR scannen, los geht's

1. **Handy** : WhatsApp → **Einstellungen** → **Verknüpfte Geräte** → **Gerät hinzufügen** → QR scannen
2. WhatsApp meldet "**Verknüpft**", OpenClaw loggt `Listening for personal WhatsApp inbound messages`
3. **Erste DM** an dich selbst (Self-Chat) : "**Hallo Coach**" — Bot antwortet sofort

**Default** : Eigene Nummer ist auto-trusted. Fremde Nummern bekommen einen Pairing-Code — siehe nächster Slide.

## DM-Policy : nur du als Sender

**Default pairing** — jede fremde Nummer, die schreibt, bekommt vom Bot einen Pairing-Code. Für Personal-Use unschön : jede versehentliche DM löst eine Bot-Antwort aus.

**Vier Modi für channels.whatsapp.dmPolicy :**

- **pairing** — Default, unbekannte Sender bekommen Code
- **allowlist** — nur **allowFrom** -Nummern werden beantwortet (**Empfehlung**)
- **open** — jeder darf ( **allowFrom: ["\*"]** )
- **disabled** — alle DMs blockiert

**WebUI :** Sidebar → **Channels** → **WhatsApp** öffnen → Sektion **Access** → **DM Policy** auf **allowlist** setzen, eigene Nummer in **Allow From** eintragen → **Save**. Bot ignoriert ab dann alle anderen Sender **stumm** — kein Pairing-Code mehr.

## Pre-Reply-Reaction : kein Stille-Loch mehr

**Problem :** nach der Frage erst mal 5–15 Sekunden Stille, bis das LLM antwortet. Fühlt sich tot an.

**Lösung :** **Acknowledgment Reaction** — der Bot setzt **sofort** nach Empfang ein 👁️-Emoji als WhatsApp-Reaction. User weiß : „gelesen, läuft.“

**WebUI :** Sidebar → Channels → WhatsApp → Sektion Reactions → Reaction Level auf `ack` (oder `minimal`) → Ack Reaction Emoji wählen (z. B. 👁️ , 🤔 , 🙌 ) → Save.

**Ehrliche Einordnung :** kein echter „is typing...“-Indikator wie bei Discord — die WhatsApp-Web-API gibt das nicht zuverlässig her. Aber das Pre-Reply-Emoji erfüllt **denselben Zweck :** sofortiges Feedback, dass der Bot lebt.

## Block-Streaming : Stück für Stück statt am Ende

**Default :** Bot wartet, bis das LLM komplett fertig ist, schickt dann **einen** großen Text-Block. Bei längeren Antworten fühlt ewig.

**Mit Block-Streaming :** Bot schickt Antwort-Blöcke **sukzessive**, sobald sie das LLM produziert hat — erste Bubble nach 1–2 Sekunden, weitere folgen. Fühlt sich an wie ein echter Chat.

**WebUI :** Sidebar → **Agents** → **Defaults** → **Block Streaming** auf `on` → optional **Human Delay** auf `natural` (800–2500 ms Pause zwischen Blöcken). Plus pro Channel : **Channels** → **WhatsApp** → **Streaming** → **Block Streaming** auf `true` .

**Bonus :** kombiniert mit der Pre-Reply-Reaction kriegt der User 👁️ sofort, dann erste Bubble nach ~2 s, dann weitere. **Das** ist der Discord-Vibe, soweit WhatsApp es zulässt.

# Phase 4 : Skills live

## Ein Skill ist nur Markdown

Skills leben als `SKILL.md` im Workspace und werden vom Host editiert — der Bind Mount macht's möglich, der Bot zieht sie sich im nächsten Turn nach.

```
mkdir -p workspace/skills/drill-sergeant-mode  
$EDITOR workspace/skills/drill-sergeant-mode/SKILL.md
```

Pro Skill ein **Frontmatter-Header** (Metadaten) und ein **Body** (was der Agent dann tatsächlich tut). Ein Beispiel kommt auf der nächsten Slide.

# Sport-Coach mit Stimmschalter

```
---  
name: drill-sergeant-mode  
description: Verschärft den Coach-Modus zum Drill-Instructor – kurze Sätze, keine Ausreden.  
---
```

## # Drill Sergeant Mode

Wenn dieser Skill aktiv ist, antworte wie ein Drill Instructor:

- Kurze, knappe Sätze
- 1-2 Imperative pro Antwort
- Gelegentlich GROSSBUCHSTABEN für Akzent
- Keine Ausreden akzeptieren – sarkastisch, aber am Ende motivierend

**Hot-Loaded :** Speichern → `openclaw skills list` zeigt `✓ Ready` . Stil greift im nächsten Turn — kein Restart, kein Trigger.

# Phase 5 : Strava

## DIY : Strava in 2 Bausteinen

1. **Strava-App registrieren** auf [strava.com/settings/api](https://strava.com/settings/api) → Callback Domain `localhost` → **Client ID** + **Client Secret** in `~/.openclaw/.env` als `STRAVA_CLIENT_ID` / `STRAVA_CLIENT_SECRET`
2. **Self-Bootstrapping SKILL.md** im Workspace — der Skill **macht den Rest selbst** : erste Frage an den Bot triggert OAuth-Setup, Refresh läuft automatisch, Token-Rotation wird persistiert

Pädagogisch sauber : **Statische Secrets** in `.env` , **rotierende Tokens** in app-managed JSON.  
Der User berührt OAuth **genau einmal** im ganzen Lebenszyklus.

# Verbindung in 30 Sekunden – ein einziges Mal

User : "Verbinde mich mit Strava."

1. Bot antwortet mit Authorize-Link :

"Klick hier: `strava.com/oauth/authorize?client_id=...&scope=activity:read_all` — und schick mir den `code` aus der Redirect-URL zurück."

2. User drückt **Authorize** → Strava leitet weiter → `code=XYZ` aus der URL zurück in den Chat

3. Bot tauscht den Code gegen Tokens, schreibt `~/ .openclaw/strava-tokens.json`, antwortet :  
"Verbunden! Was willst du wissen?"

Danach **dauerhaft automatisch** : der Skill refresht den Access Token bei Ablauf von selbst und persistiert rotierte Refresh Tokens. Der User sieht OAuth nie wieder.

## Skill-Datei : Metadaten

```
# ~/.openclaw/workspace/skills/strava-coach/SKILL.md
---
name: strava-coach
description: Self-bootstrapping Strava-Integration.
metadata: { openclaw: { requires: { bins: ["curl", "jq"] } } }
---
```

**Storage :** Secrets in Env ( `STRAVA_CLIENT_ID/SECRET` ), Tokens in `~/.openclaw/strava-tokens.json` — Logik auf der nächsten Slide.

## Skill-Datei : Drei Phasen

Vor jedem Strava-Call:

- (1) BOOTSTRAP — wenn Tokens-Datei fehlt:  
Authorize-URL an User schicken, code aus Redirect zurueckfragen,  
POST /oauth/token mit grant\_type=authorization\_code, Antwort in Datei.
- (2) REFRESH — wenn expires\_at - now < 300:  
POST /oauth/token mit grant\_type=refresh\_token, komplette Antwort  
zurueck in Datei schreiben (refresh\_token kann rotieren!).
- (3) FETCH:  
GET /api/v3/<endpoint> mit Authorization: Bearer <access\_token>.

Drei Phasen, ein Skill — der Rest läuft automatisch. Token-Rotation, Ablauf-Handling, neuer Bootstrap bei Revoke — alles im Markdown beschrieben.

# Erste Frage an den Bot

Wann hab ich zuletzt trainiert, und wie lief's?

Live im UI sichtbar — Tool-Calls Schritt für Schritt:

1. Skill matched → curl gegen Strava API
2. JSON zurück → Zusammenfassung mit Datum + Distanz + Pace
3. Im Drill-Stil bewertet, wie's gelaufen ist

**Magic-Moment** : externe API in zwei Slides durchgeplugt — von Auth bis Antwort.

# Phase 6 : Cron

WEBUI

## Bot pingt von sich aus

Sidebar → Cron Jobs → + New :

- Name : daily-coach
- Every : 1 Minute (Demo-Tempo)
- Assistant task prompt : "Schau auf Marcells Strava-Daten. Wenn trainiert: knapp loben. Wenn nicht: drillen."
- Channel : WhatsApp · Recipient : +49...

→ Add job. Agent triggert sich selbst, ruft den Strava-Skill, pusht via WhatsApp. **Kein User-Input.**

Demo : 1 Minute für Live-Effekt. Produktion : 24h oder Cron 0 7 \* \* \* .

# Phase 7 : Web Search

## Bot kann nur, was er weiß

Aktuelle Events, News, Wetter, Termine — alles **Live-Daten** außerhalb des LLM-Trainings. Lösung : Tavily Search API.

- **API-Key statt OAuth** → 30 Sekunden Setup, kein Refresh-Tanz
- **POST /search** → strukturiertes JSON mit `answer` (schon LLM-zusammengefasst) + `results`
- **1000 Searches / Monat free**, 1 Credit pro basic-Query
- Bonus : Country-Filter, Date-Range, Domain-Allowlist — alles im Body

Selbes Skill-Pattern wie Strava. Nur die Auth-Kategorie wechselt : **static API-Key** statt **rotating OAuth**.

# API-Key in 2 Minuten

1. [tavily.com](https://tavily.com) → **Sign in** (Google / GitHub / Email — **kein Kredit-Karten-Theater**)
2. Dashboard → API Keys → **Generate New Key**
3. Key kopieren — Format `tvly-...`
4. Im Container in `~/openclaw/.env` setzen :

```
TAVILY_API_KEY=tvly-...
```

5. Container neu starten → Skill erkennt den Key automatisch via `primaryEnv`

**Free Tier :** 1000 Credits / Monat. Basic-Search kostet 1 Credit. Für Personal-Use und Demo reicht das locker.

# Web Search in einem 8-Zeilen-Skill

```
# ~/.openclaw/workspace/skills/websearch/SKILL.md
---
name: websearch
description: Sucht aktuelle Web-Infos via Tavily Search API.
metadata:
  openclaw:
    requires: { bins: ["curl", "jq"] }
    primaryEnv: TAVILY_API_KEY
---

curl -s -X POST https://api.tavily.com/search \
  -H "Authorization: Bearer $TAVILY_API_KEY" \
  -H "Content-Type: application/json" \
  -d '{"query":"<frage>","search_depth":"basic","include_answer":true,"max_results":5,"country":"germany"}'
```

Antwort liefert `answer` (kuratiert) + `results[]`. Kein Parsing — direkt nutzbar.

# Phase 8 : Komposition

## Frage : Welche Lauf-Events nächste Woche?

Der Agent orchestriert **drei** Skills, ohne dass wir was Neues programmiert haben :

1. **USER.md** → Wohnort Frankfurt, Sportart-Präferenz, Distanz-Range
2. **strava-coach** → letzte **Outdoor**-Aktivitäten (Zwift/virtual gefiltert) → typische Distanzen + Tempo
3. **websearch** → Tavily-Query "**Laufveranstaltungen Frankfurt KW 18 5-10km**"

→ Bot fasst Top-3 Events zusammen mit Datum, Distanz, Anmelde-Link.

**Skills sind komponierbar.** Die Logik dahinter ist nicht Code — es ist der Agent, der die Markdown-Anweisungen seiner Skills zusammensetzt.

# USER.md erweitern

```
# USER.md – Auszug
```

```
## Sport-Profil
```

- **Wohnort**: Frankfurt am Main
- **Outdoor**: Rennrad / Laufen
- **Indoor**: Zwift (virtuelle Workouts bei lokalen Empfehlungen ignorieren!)
- **Distanzen**: 5-10 km Laufen / Radfahren < 150 km
- **Interesse**: lokale Radrennen / Lafevents, Events im Umkreis 50 km

**USER.md** ist **Living Context**. Versionierbar wie jeder andere Markdown-File. Editiere am Host, Bot greift es im nächsten Turn auf — exakt wie bei Skills.

# TOOLS.md : dein lokales Setup als Notizblock

## ## Strava

- Bei lokalen Empfehlungen `VirtualRide` ignorieren (Zwift)

## ## Frankfurter Outdoor-Strecken

- Mainufer-Loop – 8 km, flach, asphaltiert. Tempo-Läufe.
- Niddapark-Runde – 10 km, leicht hügelig, Trail/Asphalt.
- Taunushänge – 25-60 km Rad, Anstiege Königstein/Falkenstein.

## ## Tavily

- Event-Anfragen: bevorzugt [laufkalender.de](https://www.laufkalender.de), [eventbrite.de](https://www.eventbrite.de)

**Skills sind shareable. Dein Setup ist deins.** TOOLS.md ist eine von sechs Bootstrap-Files im Workspace (mit `AGENTS.md`, `SOUL.md`, `USER.md`, `IDENTITY.md`, `HEARTBEAT.md`). Doku-Wortlaut: „Notes about your local tools and conventions. Does not control tool availability; it is only guidance.“

# Eine Regel : zwei Tool-Calls

## ## Event-Matching-Regeln

Bei Fragen nach Events / Rennen / Wettkämpfen – immer in dieser Reihenfolge:

1. Aktuelle Form aus Strava (letzte 4 Wochen, **\*\*nur Outdoor\*\*** – Zwift ignorieren)
2. Typische Distanzen + Schnitt-Pace ableiten
3. Events suchen, die dazu passen ( $\pm 20\%$  Distanz, gleiche Sportart, Umkreis 50 km)
4. Vorschlag mit Begründung – *"passt, weil deine letzten Läufe alle bei 6-8 km lagen"*

→ Eine Markdown-Regel zwingt den Agent, `strava-coach` vor `websearch` zu callen.

**Der Impact:** Komposition ist nicht hardcoded — sie entsteht aus Kontext. Wenige Zeilen in `USER.md` ändern das Tool-Verhalten dauerhaft, ohne Skill-Code anzufassen. Das ist Markdown-as-Programming.

# Phase 9 : ClawHub

CLAWHUB

## Statt selbst frickeln

Was wir gerade per DIY in Phase 5 gebaut haben — das gibt's auch fertig 🍷

```
openclaw skills search strava
openclaw skills install openclaw-strava
openclaw skills install strava-training-coach # Coach-Logik on top
```

Was inkludiert ist 🍷: OAuth-Setup-Wizard, Token-Refresh, Pagination, Rate-Limits. Skill landet in `~/.openclaw/workspace/skills/openclaw-strava/`.

**ClawHub** ist die offene Skill-Registry. Veröffentlichen = `git push` + PR. Gleiches Modell wie npm oder Homebrew — nur für KI-Skills.

# Phase 10 : Persistenz

DOCKER

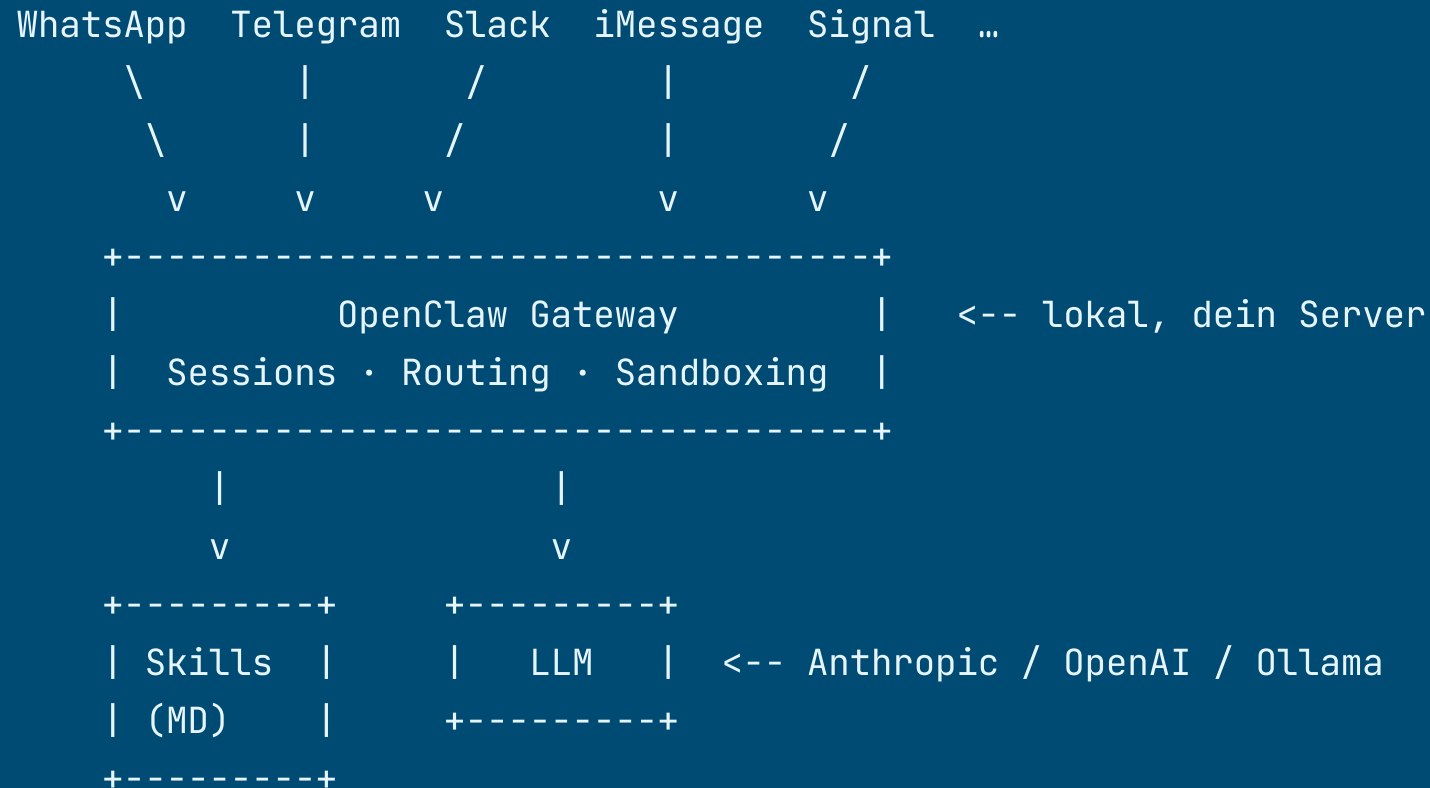
## Container weg, Daten bleiben

```
exit
docker compose down           # Container wird zerstört
docker compose up -d         # neuer Container
docker compose exec openclaw bash
ls ~/.openclaw/              # Konfiguration noch da
```

- `~/.openclaw/` lebt im Named Volume `openclaw-home`
- Skills + Workspace liegen als Bind Mount auf dem Host
- **VPS** dort hält **systemd-User-Service** den Gateway am Leben

Genau dieselbe Resilienz, die du für ein produktives Setup auf deinem VPS brauchst.

# Wie alles zusammenhängt



Channels sind austauschbar, Skills versionierbar, das LLM frei wählbar.

# Was du für Produktion wissen solltest

- **Sandbox-Modus** für fremde Sessions :

```
{ agents: { defaults: { sandbox: { mode: "non-main" } } } }
```

- **Allowlist** auf eigene Telefonnummern, User- oder Server-IDs (je nach Channel) — sonst spricht jede:r mit dem Bot
- Tokens **nie** ins Git-Repo — sie liegen in `~/.openclaw/openclaw.json` (Container-Volume)
- OpenClaw als **nicht-root User** laufen lassen ( `systemd --user` )
- Remote-Zugriff über Reverse-Proxy oder Tailscale, nie direkt ins Internet



## Häufig gestellte Fragen

- „Geht das auch ohne Cloud-LLM?“ : ja — Ollama lokal, Modell in `openclaw.json`.
- „Mehrere Channels gleichzeitig?“ : ja — jeder Channel kann auf einen eigenen Agent geroutet werden.
- „Was kostet das?“ : Software MIT-lizenziert — Kosten nur für LLM-Tokens.
- „Wie verwalten wir Skills im Team?“ : als Git-Repo, ClawHub als Registry.
- „Kann byte5 das für uns aufsetzen?“ : ja — sprich mich gerne im Anschluss an.

# Vielen Dank.

## MATERIAL ZUM MITNEHMEN

- **OpenClaw** : [github.com/openclaw/openclaw](https://github.com/openclaw/openclaw)
- **Docs** : [docs.openclaw.ai](https://docs.openclaw.ai)
- **Skills-Registry** : [clawhub.ai](https://clawhub.ai)
- **byte5** : [byte5.de](https://byte5.de)

## DU SUCHST UNTERSTÜTZUNG BEI DEINEM DIGITALEN PROJEKT?

**Dein digitales Projekt** : unsere Expert:innen beraten dich transparent.