

Jeśli szukasz praktycznego opisu, jak zbudować działające agenty ai w stylu openclaw, to jesteś w dobrym miejscu. W skrócie: OpenClaw to sposób porządkowania architektury agentów tak, aby dało się je bezpiecznie rozwijać, testować i wdrażać w środowiskach produkcyjnych. Schemat opiera się na kilku jasno zdefiniowanych warstwach: planowanie, pamięć i stan, narzędzia i wykonawcy, monitorowanie, bezpieczeństwo, a do tego spójny model sterowania przepływem i kosztami. Nie jest to pojedynczy framework, raczej przepis, który można zrealizować w Pythonie, Node, na Kubernetesie lub serverless, w zależności od potrzeb.

W tym przewodniku pokazuję, jak tę architekturę rozumieć i jak ją wdrożyć krok po kroku. Będzie trochę kodu, wzorców projektowych, ostrzeżeń i liczb, które pozwalają podjąć konkretne decyzje.

Co to właściwie jest OpenClaw w praktyce

OpenClaw to praktyczny model architektoniczny dla agentów opartych o modele językowe, który rozdziela myślenie, działanie, pamięć i nadzór. Daje to przewidywalność i możliwość audytu. Najważniejsze komponenty:

- Planista: zamienia ogólne cele na plan działań i decyduje o kolejnych krokach.
- Wykonawcy narzędzi: wywołują API, bazy danych, skrypty, funkcje systemowe.
- Pamięć i stan: krótkotrwały kontekst sesji oraz długotrwałe fakty i historię.
- Orkiestracja: zarządza przepływem, priorytetami, kolejkowaniem i równoległością.
- Nadzór: obserwowalność, oceny jakości, limity kosztów, zabezpieczenia.

Ta separacja obowiązków rozwiązuje codzienne problemy: halucynacje redukujesz przez kontrolę dostępu i sprawdzanie wyników narzędzi, koszty przez budżety i cięcia kontekstu, a niezawodność przez retry i timeboxy. Jeśli szukasz openclaw po polsku, poniżej znajdziesz konkretne, działające klocki.

Z czego składa się agent w modelu OpenClaw

Zacznijmy od wspólnego słownika.

Planista. LLM lub reguły sterujące, które przekształcają cel w kroki zadaniowe. Dobry planista ogranicza halucynacje przez rygorystyczne formaty odpowiedzi i minimalny dostęp do narzędzi.

Wykonawca. Kod, który naprawdę coś robi: pobiera dane z API, zapisuje do Postgresa, wywołuje funkcje chmurowe. Wykonawca nie ufa LLM w kwestii parametrów, waliduje wejście, obsługuje błędy i timeouts.

Pamięć. Dwie warstwy. Ephemeral to kontekst sesji: skróty poprzednich kroków, zmienne. Durable to baza wiedzy i fakty, zwykle RDBMS plus wektorowy indeks do retrievalu.

Monitorowanie. Zbierasz ślady, metryki, koszty i wersje promptów. Pozwala to porównać zmiany przed i po wdrożeniu.

Polityki i bezpieczeństwo. Guardraile, uwierzytelnianie narzędzi, limity, sandbox. Każdy agent ma budżet, maksymalną głębokość planu i białą listę funkcji.

Evaluator. Automatyczne testy kontraktowe i oceny jakości. To element często pomijany, a kluczowy w produkcji.

Domyślna topologia: single agent, pantofelek i orkiestra

Nie każdy projekt potrzebuje roju agentów. Najpierw działający pantofelek: jeden agent z dwoma narzędziami i pamięcią. Następnie rozwijasz w stronę orkiestry z wieloma wykonawcami i kolejkami, jeśli pojawią się wymagania skali lub SLA.

Single agent. Najprostszy wariant. Jeden planista, 2 do 5 narzędzi, kontekst 8k do 32k tokenów, pamięć durable w SQLite lub Postgres. Idealny do automatyzacji pracy wewnętrznej.

Pół-orkestra. Dodaj kolejkę zadań, retry polityki, cache odpowiedzi i telemetry. Dobre dla zadań asynchronicznych, które mogą trwać minutę do kwadransa.

Pełna orkestra. Osobny proces planowania, równoległość kroków, priorytety, rozdzielenie ról na microserwisy. Wchodzi w grę, gdy masz wielu użytkowników, integracje krytyczne lub surowe limity latencji.

Minimalny szkielet w Pythonie

Kod odpowiadający duchowi openclaw można złożyć w kilka modułów. Zaczynamy od interfejsów. Tu używamy prostych protokołów zamiast zawiłych frameworków.

```
from typing import Protocol, Dict, Any, List, Optional
import time

class Tool(Protocol):
    name: str

    def invoke(self,
               params: Dict[str, Any],
               ctx: Dict[str, Any]) -> Dict[str, Any]: ...

class Memory(Protocol):
    def get_context(self,
                   session_id: str) -> Dict[str, Any]: ...

    def append_trace(self,
                    session_id: str,
                    event: Dict[str, Any]) -> None: ...

    def persist_fact(self,
                    key: str,
                    value: Any) -> None: ...

class LLM(Protocol):
    def complete(self,
                 messages: List[Dict[str, str]],
                 **kwargs) -> str: ...

class Budget:
    def __init__(self,
                 max_tokens: int,
                 max_tools: int,
                 deadline_s: int):
        self.max_tokens = max_tokens
        self.max_tools = max_tools
        self.deadline = time.time() + deadline_s
        self.tools_used = 0
        self.tokens = 0

    def allow_tool(self) -> bool:
        return self.tools_used < self.max_tools and
               time.time() < self.deadline
```

Planista może działać w pętli kroków, z jasnym formatem wyjścia i walidacją.

```
import json
SYSTEM_PROMPT = """Jesteś planistą. Zwracaj JSON: {"thought": "...", "action": NONE, "params": ...}"""

def plan_step(llm: LLM, messages: List[Dict[str, str]]) -> Dict[str, Any]:
    raw = llm.complete(messages, temperature=0.2)
    try:
        return json.loads(raw)
    except Exception:
        return {"thought": "Nie rozumiem formatu.",
                "action": "tool": "NONE",
                "params": ...}
```

Główny sterownik łączy to wszystko i pilnuje budżetu.

```
def run_agent(goal: str, session_id: str, llm: LLM, tools: Dict[str, Tool], mem: Memory, budget: Budget):
    messages = [{"role": "system", "content": SYSTEM_PROMPT}, {"role": "user", "content": goal}]
    ctx = mem.get_context(session_id)
    for step in range(16): # głębokość planu
        decision = plan_step(llm, messages)
        mem.append_trace(session_id, {"type": "decision", "data": decision})
        action = decision.get("action", None)
        tool_name = action.get("tool", "NONE")
        if tool_name == "NONE" or not budget.allow_tool():
            break
        tool = tools.get(tool_name)
        if tool is None:
            messages.append({"role": "user", "content": f"Nieznane narzędzie {tool_name}. Kontynuuj inną drogą."})
            continue
        try:
            output = tool.invoke(action.get("params", {}), ctx)
        except Exception as e:
            output = "error": str(e)
        mem.append_trace(session_id, {"type": "tool_result", "tool": tool_name, "output": output})
        messages.append({"role": "user", "content": f"Wynik {tool_name}: {json.dumps(output)[:2000]}."})
    return mem.get_context(session_id)
```

Ten trzon wystarczy, żeby uruchomić sensownego agenta i obserwować jego zachowanie. W praktyce dodasz jeszcze walidację schematu JSON, streamowanie i mechanizm wczesnego zakończenia.

Decyzje architektoniczne, które bolą, jeśli je odłożysz

Jaką pamięć wybrać. RDBMS na fakty, wektorowy indeks na treści nieustrukturyzowane, cache w pamięci procesu na krótką historię. Jeśli budżet to 10 do 20 tysięcy interakcji dziennie, Postgres + pgvector jest rozsądny. Powyżej 100 tysięcy dziennie warto rozważyć osobny wektorowy silnik i streaming do tańszego storage.

Jak limity i koszty trzymać w ryzach. Ustaw limity tokenów na prompt i całą sesję, tnij historię, a streszczenia twórz warstwowo. Minimalizuj fan-out do wielu modeli. Gdy dany krok nie potrzebuje reasoning 32k, nie włączaj go z przyzwyczajenia.

Retry polityki. Retry ma sens, ale tylko na błędy sieciowe i kody 5xx. Halucynacji nie naprawisz retry, a wydasz dwa razy więcej. Lepiej dodać walidację wyników przez schemat lub heurystykę.

Czy potrzebujesz wielu agentów. Wieloagentowe układy rosną w złożoności kwadratowo z liczbą połączeń. Jeśli musisz je mieć, izoluj kompetencje ostro, a wymianę informacji rób przez wspólną przestrzeń faktów, nie przez chat agent to agent.

Kiedy fine-tuning. Jeśli agent od tygodni robi ten sam typ zadania i działa w przewidywalnej domenie, warto rozważyć fine-tuning małego modelu do lokalnych klasyfikacji i ekstrakcji, ale zostawić decyzje planistyczne modelowi ogólnemu.

Warstwa narzędzi: kontrakty, bezpieczeństwo, limity

Każde narzędzie powinno mieć trzy rzeczy: schemat wejścia, limity i kontrolę dostępu. Dodatkowo, przynajmniej podstawowa walidacja wyników.

Przykładowe narzędzie do pobierania zgłoszeń serwisowych:

```
from pydantic import BaseModel, ValidationError
class GetTicketsInput(BaseModel):
    status: str
    limit: int = 10
class GetTicketsTool:
    name = "get_tickets"
    def __init__(self, client):
        self.client = client
    def invoke(self, params, ctx):
        try:
            payload = GetTicketsInput(**params)
        except ValidationError as e:
            return {"error": "bad_input", "details": e.errors()}
        if payload.limit > 50:
            # limit anty-DDoS
            return {"error": "limit_too_high"}
        tickets = self.client.fetch(status=payload.status, limit=payload.limit, user=ctx.get("user_id"))
        # Walidacja wyniku
        if not isinstance(tickets, list):
            return {"error": "bad_output"}
        return {"tickets": tickets}
```

Kluczowy detal: narzędzie zna użytkownika z kontekstu i filtruje dane, a nie polega na intencjach LLM.

Pamięć i stan: krótkoterminowe skróty i twarde fakty

Krótki kontekst powinien być lekki. Nie zapisuj całego czatu. Zapisuj streszczenia kroków, wynik narzędzia, decyzję, i ewentualny błąd. Daje to mało tokenów i łatwą nawigację.

Długoterminowa pamięć to dwie szuflady. Fakty tabelaryczne trafiają do relacyjnej bazy. Wiedza nieustrukturyzowana do wektorowego indeksu, ale razem z metadanymi wskazującymi źródło i datę. Dzięki temu odzyskane konteksty można filtrować po świeżości i wiarygodności.

W praktyce przydają się dwa proste zabiegi. Po pierwsze, prompty generujące streszczenia kroku ucz model odpowiadać zwięźle, w jednym akapicie do 60 słów. Po drugie, retrieval dołączaj po kilku filtrach: temat, data, autor, a dopiero potem podobieństwo semantyczne. Sporo fałszywych trafień znika.

Orkiestracja i równoległość: kiedy włączyć więcej biegunów

Praca równoległa opłaca się, gdy narzędzia czekają na IO, a nie na CPU. Dwie do czterech równoległych sond do niezależnych API zwykle przyspiesza 2 razy w realnym świecie. Nie przesadzaj z fan-out, bo upilnowanie limitów i

błędów robi się kosztowne.

Dobre praktyki. Każda gałąź ma swój budżet i deadline. Wyniki łączysz deterministycznie, a nie losowo. Gdy krok jest krytyczny, blokuj poszerzanie planu, dopóki nie dostaniesz wiarygodnej odpowiedzi.

Observability: bez śladów latasz na ślepo

Ślady krok po kroku muszą być przeglądalne jak logi requestów. Każdy event w sesji powinien mieć typ, stempel czasu, koszt tokenów i hash wersji promptu. Jeśli dodajesz retry, zaznacz *retry count* i *przyczynę*. Wystarczy prosta tabela events z kolumnami: *sessionid*, *step*, *type*, *payload json*, *costtokens*, *model*, *prompt hash*, *createdat*.

Monitoring jakości. Nie tylko wskaźniki systemowe. Zbieraj metryki merytoryczne: czy narzędzie zwróciło komplet danych, ile uzupełnień wymagało poprawki, jaki odsetek idempotentnych akcji faktycznie był idempotentny. Te proste liczby często mówią więcej niż średnia latencja.

Evaluator: automatyczne testy i oceny jakości

Bez zautomatyzowanych testów agenty rozjeżdżają się przy pierwszym większym deployu. Evaluator to nie tylko unit testy narzędzi. To scenariusze end to end i ocena jakości modelu według kryteriów domenowych.

Dobry zestaw dla startu ma 20 do 50 przypadków. Każdy przypadek zawiera wejście, oczekiwane atrybuty wyjścia oraz ostrzeżenie kosztowe. Przykład scenariusza: agent ma zebrać status 5 najdroższych zgłoszeń w danym tygodniu, przez dwa API, z deduplikacją. Sprawdzasz, czy finalny raport zawiera komplet pól, czy narzędzia były użyte maksymalnie dwa razy każde, i czy nie przekroczono budżetu.

Ocena LLM przez LLM. Ma sens, ale tylko, gdy wynik przerabiasz na prostą metrykę, na przykład $Accuracy@K$ dla pól wyekstrahowanych z tekstu. Do planów wielozdaniowych trzymaj się surowych asercji na strukturze i walidacji danych.

Bezpieczeństwo: sandbox, polityki, kontrola narzędzi

Agenty potrafią wywołać nieoczekiwane ścieżki w systemie. Dlatego:

- Każde narzędzie ma białą listę komend i limity parametrów.
- Wszelkie operacje zapisu idą przez warstwę z wymuszoną idempotencją i logowaniem.
- Klucze API nie są dostępne w promptach. Agent otrzymuje uchwyt do narzędzia, nie klucz.
- Jeśli wykonujesz kod, to tylko w izolowanym sandboxie z czasem procesora rzędu 200 ms i twardym limitem pamięci.

Te zasady brzmią sucho, ale to one dzielą demonstrator od produkcji.

Strategie promptów: mniej kreatywności, więcej kontraktu

Planista nie musi <https://opclaw.pl/> być kreatywny, tylko konsekwentny. Dwa elementy dają największy zwrot.

Format odpowiedzi. Zawsze JSON ze zdefiniowanymi polami. Wymagaj NONE jako jawnej decyzji o zakończeniu. W praktyce obniża to liczbę niepoprawnych kroków o kilkadziesiąt procent.

Instrukcje negatywne. Wyraźnie napisz, czego nie wolno. Na przykład: nie twórz danych z powietrza, nie zgaduj parametrów, jeśli brakuje pola, poproś o doprecyzowanie. Modele lubią wypełniać luki, dopóki nie zabronisz tego wprost.

Kontrola kosztów: budżety, cache i degradacja jakości

Agenty kuszą, żeby do każdego zadania używać największego, najdroższego modelu. Nie rób tego. Dobry układ trzyma się trzech prostych zasad.

Budżet na sesję. Ustal maksymalną liczbę tokenów i maksymalną liczbę wywołań narzędzi. Gdy budżet się kończy, agent zwraca częściowy wynik lub prosi o doprecyzowanie.

Cache. Buforuj deterministyczne kroki. Jeżeli narzędzie pobiera listę walut lub statusy, cachuj na 60 do 300 sekund. Buforuj też krótkie transformacje LLM, o ile prompty są identyczne i temperatura bliska zeru.

Degradacja. Przy rosnącym obciążeniu lub zbyt wysokich kosztach przełącz się na mniejszy model dla kroków niekrytycznych. To zwykle daje 2 do 5 razy tańsze wykonanie bez widocznej utraty jakości.

Przykładowa ścieżka produkcyjna: od prototypu do SLA

Załóżmy, że budujesz agenta do triage zgłoszeń klientów w helpdesku. Wersja 0.1 to jeden agent, dwa narzędzia: pobierz zgłoszenia i utwórz podsumowanie. Pamięć ephemeral trzyma tylko ostatnie dwa streszczenia i kontekst użytkownika. Wersja działa w cronie co 10 minut.

Kiedy liczba zgłoszeń rośnie, wprowadzasz kolejkę, bo pojedyncza instancja nie nadąży. Zadania triage stają się komunikatami, a agent w trybie worker obsługuje 10 do 20 wiadomości na sekundę, w zależności od modeli.

Na pierwszych kłopotach uczysz się, że:

- Streszczenia nie powinny trwać więcej niż 1,2 sekundy. Zmiana modelu z dużego na średni, przy temperaturze 0, i krótszych promptach daje 3 razy krótszy czas.
- Pamięć durable zapisuje wybory routingu i heurystyki, co pozwala odtworzyć ścieżkę decyzji przy reklamacji klienta.
- Koszt uciekł o 40 procent, bo agent potrafił pętląć się przy brakujących danych. Dodajesz regułę: jeśli pole krytyczne jest puste, kończ zadanie z etykietą pending i nie wywołuj kolejnych narzędzi.

Po kilku tygodniach masz SLA 95 percentyl 3,5 sekundy i stabilny koszt na zgłoszenie w okolicach kilku groszy do kilkudziesięciu groszy, zależnie od długości treści.

Wzorce błędów i sposoby naprawy

Zbyt gadatliwy planista. LLM zasypuje system długimi myślami. Ustal maksymalną długość odpowiedzi. W promptach dodaj: skracaj myśli do **polski openclaw** 1 zdania, skup się na wyborze narzędzia. Zredukujesz koszty o 10 do 30 procent.

Sztywne narzędzie psuje przepływ. Jeśli wejścia bywają brudne, opakuj narzędzie w lekki preprocessor, który normalizuje daty i liczby, zamiast liczyć, że model zawsze trafi formatem.

Zagubiony stan. Agent gubi wiedzę między krokami. Wprowadź komendę recap co parę kroków, która tworzy mini podsumowanie do pamięci ephemeral. Wydasz 100 do 300 tokenów, ale unikniesz egzotycznych skrętów w fabule.

Za szerokie uprawnienia. Narzędzie do zapisu w CRM ma dostęp do całej tabeli. Ogranicz funkcję do jednego zakresu, na przykład update tylko wybranych pól i tylko dla rekordów, które agent wcześniej pobrał. Mniej niespodzianek, mniej audytów.

Testy łamliwe. Scenariusze testowe oparte na losowych danych mają tendencję do false negative. Zrób zestaw danych fixture, a na żywych danych testuj tylko stabilne wzorce.

Kiedy multiagent ma sens, a kiedy to sztuka dla sztuki

Wieloagentowe architektury kuszą, bo wyglądają jak z bajki sci-fi. Jeśli nie masz jasnych granic kompetencji i twardych API między agentami, zaczniesz tracić czas na synchronizację i dziwne efekty uboczne.

Multiagent ma sens, gdy:

- Każdy agent ma inny horyzont czasowy, na przykład planista długoterminowy i wykonawca natychmiastowy.
- Masz wyraźnie różne domeny i narzędzia, a część pracy dzieje się równolegle.
- Potrzebujesz izolacji bezpieczeństwa. Jeden agent działa tylko na danych wrażliwych, inny na publicznych.

W pozostałych przypadkach lepiej poszerzyć jednego agenta o dodatkową funkcję i dobre polityki.

Debugowanie: jak faktycznie znaleźć, co poszło nie tak

Przy problemach z agentem zadaj pięć prostych pytań. Pozwoli to zawęzić pole do szybkiej poprawki lub decyzji o refaktorze.

- Czy agent użył właściwego narzędzia w odpowiednim momencie?
- Czy wejście do narzędzia było prawidłowe i kompletnie zmapowane?
- Jak wyglądał kontekst sesji w chwili decyzji? Czy brakowało kluczowego faktu?
- Czy wynik narzędzia przeszedł walidację i został zrozumiany przez model?
- Czy budżet lub timeout nie odciął ważnego kroku?

Odpowiedzi znajdziesz w śladach. Jeśli ich nie masz, dołóż je dziś, a nie po następnym incydencie.

Jak ocenić gotowość do produkcji

Poniżej krótka lista kontrolna dla release candidate. Jeśli nie przechodzisz któregoś punktu, wracamy do warsztatu.

- Zestaw 20 do 50 testów end to end przechodzi przy co najmniej 95 procent trafień kluczowych pól.
- Budżet tokenów i narzędzi jest egzekwowany, a agent potrafi zakończyć pracę częściowym wynikiem.
- Observability działa: widzisz model, wersję promptu, koszty i timeline kroków.
- Safety nie jest w teorii: białe listy narzędzi, walidacja parametrów, sandbox wykonawczy.
- Akceptowalny koszt i latencja na danych zbliżonych do produkcyjnych.

To jedyna lista w tym artykule, ale za to taka, którą warto przypiąć nad biurkiem.

Składanie OpenClaw w Twojej infrastrukturze

Jeśli masz Kubernetes, uruchom planistę i workerów jako Deploymenty, a kolejkę jako dedykowany serwis, np. Redisa lub inny broker. Sekrety trzymaj w menedżerze tajemnic, nie w zmiennych środowiskowych kontenera. Logi zdarzeń kieruj do centralnego systemu, żeby widzieć całe ścieżki.

Serverless sprawdza się dla zmiennych obciążeń i rzadkich zadań, ale pamiętaj o zimnym starcie. Dla agentów w trybie interaktywnym lepiej utrzymywać chociaż ciepły pool.

W przypadku danych wrażliwych rozdziel wektorowy indeks i surowe dokumenty. Przechowuj tylko hashe lub klucze, a oryginały trzymaj w szyfrowanym storage z kontrolą dostępu. Agent nie potrzebuje wglądu w cały dokument, tylko w fragmenty kontekstu.

Agenty ai a prawo i ryzyko operacyjne

Jeśli agent pracuje na danych klientów, potraktuj go jak każdy inny system produkcyjny. Masz obowiązek wiedzieć, kto co zrobił i dlaczego. Logi z decyzjami planisty oraz parametry operacji wykonawców są Twoim dowodem, że kontrolujesz proces. Przy danych osobowych zostawiaj decyzje nieodwracalne człowiekowi do zatwierdzenia. Reguła prosta: jeśli nie potrafisz wytłumaczyć wyniku w dwóch akapitach na podstawie śladów, nie rób tego automatycznie.

Szkic promptów i kontraktów, które działają

Oto minimalistyczny, praktyczny zestaw promptów i schematów do adaptacji.

System dla planisty: Jesteś planistą krok po kroku. Na wejściu masz cel i streszczenia poprzednich kroków. Wybierz jedno narzędzie lub NONE. Zwracaj JSON o schemacie: "thought": "1 zdanie", "action": NONE, "params": Jeśli brakuje krytycznego parametru, ustaw tool na NONE i poproś o doprecyzowanie.

Walidacja JSON:

- JSON musi być poprawny i mieć wszystkie pola.
- thought ma maksymalnie 160 znaków.
- Jeśli tool nie jest na białej liście, ustawiamy NONE.

Polityka budżetu:

- Maksymalnie 10 wywołań narzędzi, 8k tokenów na sesję, deadline 15 s.
- Po przekroczeniu któregoś limitu agent zwraca partial i kończy sesję.

Ta drobiazgowość nie zabija elastyczności, ona ją umożliwia na dłuższą metę.

Częste pytania, które padają na przeglądach technicznych

Czy agent może sam wybierać model? Może, ale powinien to robić według polityki: małe kroki na mniejszych modelach, planowanie i odpowiedzi końcowe na precyzyjniejszym. W przeciwnym razie koszty wymykają się spod kontroli.

Jak uniknąć pętli. Wprowadź licznik kroków, wykrywanie cykli po hashach decyzji i twardy limit czasu. Jeśli te trzy mechanizmy nie pomagają, problem zwykle leży w źle zdefiniowanym celu lub braku krytycznych danych wejściowych.

Czy muszę mieć wektorowy indeks. Nie zawsze. Jeśli Twoje zadania bazują na danych strukturalnych, lepszy będzie porządny SQL z dobrze zaprojektowanymi indeksami i materializowanymi widokami.

Jak testować na żywych danych bez ryzyka. Użyj shadow mode. Agent generuje decyzje i propozycje działań, ale nie zapisuje. Zbierasz metryki, porównujesz z pracą ludzi, dopiero potem włączasz write.

Zamykanie architektury klamrą: OpenClaw jako kontrakt między ludźmi a maszyną

Cały sens openclaw sprowadza się do jednego: agent to nie magia, tylko system rozproszony o dość nieprzewidywalnym komponencie. Stabilność osiągasz nie przez modlitwę do większego modelu, tylko przez dobre kontrakty, uważne zarządzanie stanem i rygorystyczny nadzór. Jeśli utrzymasz ten porządek, agenty ai staną się zwykłymi, przewidywalnymi pracownikami w Twojej infrastrukturze. Czasem wymagają kawy w postaci poprawki promptu, czasem krótszej zmiany przez mniejszy model, ale dają się prowadzić.

Budując od pantofelka do orkiestry, najpierw trzymaj się dyscypliny: format, pamięć, polityki, ślady. Potem dochodzą optymalizacje, równoległość i fine-tuning. W efekcie masz nie tylko demo, ale produkt, któremu możesz zaufać. I o to chodzi w OpenClaw, nawet jeśli rozumiesz je jako zbiór zasad, a nie jedną bibliotekę do pip install.