



tim@sentinel:~/backend \$

Sentinel

Интеллектуальный тайм-менеджер

Серверная часть

Максимов Тимофей Степанович

БПИ-236

Руководитель: Гурин С. Б.

\$ # 02 — Предметная область



III — AI-ассистент

- > умное планирование · диалог · ребалансировка
- > Motion, Reclaim.ai — платно · закрыто · нет русского

II — Мотивация и вовлечение

- > геймификация · система достижений · выработка привычек
- > Habitica, Streaks — изолированно, вне планировщика

I — Базовый календарь

- > хранение событий · напоминания · синхронизация
- > Google Calendar · Apple Calendar · Яндекс

Sentinel = I + II + III

\$ # 03 — Глоссарий

Tool-use / Function calling

Механизм OpenAI API: LLM вызывает функции бэкенда вместо генерации свободного текста

Propose-Before-Apply

Наш паттерн: LLM не мутирует данные напрямую, а создаёт предложения со статусом `proposed`, применяемые только после явного подтверждения пользователем

Rebalance

Алгоритм перераспределения событий по временным слотам через LLM с учётом нагрузки по дням

Event / Reminder

Два типа записей в расписании: событие имеет начало и конец; напоминание — только начало

Chat

Сессия диалога пользователя с AI-ассистентом; хранит историю сообщений и предложенные действия

System prompt

Инструкция, которая передаётся модели с каждым запросом: описывает роль ассистента, текущее время и часовой пояс пользователя

\$ # 04 — Цели и задачи

Цель

Разработать серверную часть мобильного приложения Sentinel — масштабируемый асинхронный **REST API** с интеграцией **LLM**

Задачи

- [1]** Анализ аналогов и формирование требований
- [2]** Выбор стека технологий и архитектурных решений
- [3]** Проектирование схемы базы данных
- [4]** Разработка REST API (аутентификация, события, синхронизация)
- [5]** Интеграция LLM с паттерном **Propose-Before-Apply**
- [6]** Алгоритмы: ребалансировка расписания и система достижений
- [7]** Обеспечение надёжности: тестирование, rate limiting, CI/CD

\$ # 05

— Анализ аналогов

Критерий	Todoist	Google Cal	Motion	Reclaim.ai	Sunsama	Things 3	Notion Cal	Sentinel
Отображение событий	+	+	+	+	+	+	+	+
Генерация через ИИ	-	-	-	+	-	-	-	+
Нативная интеграция с Apple Calendar	-	+	-	-	-	+	-	+
Ребалансировка расписания	-	-	+	+	-	-	-	+
Модель энергии дня	-	-	-	-	-	-	-	+
Геймификация	-	-	-	-	+	-	-	+
Кроссплатформенность	+	+	+	+	+	-	+	-
Уведомления	+	+	+	+	+	+	+	+



\$ # 06 — Стек технологий

Python 3.11 + FastAPI

async-first веб-фреймворк, OpenAPI 3.x из коробки

SQLAlchemy 2.0 async + asyncpg

нативная асинхронность драйвера и ORM

Alembic

версионизируемые миграции схемы БД

PostgreSQL 15

реляционная модель с FK-каскадами и JSONB

OpenAI SDK

tool-use из коробки, structured outputs

Docker Compose

воспроизводимое окружение dev и prod

JWT (HS256)

stateless-аутентификация, TTL 7 дней

pytest + httpx

unit и integration тестирование async-эндпоинтов

S3

хранилище изображений в чатах

Сервер: **async I/O** на всех уровнях — LLM-запрос занимает 2–5 с, без блокировки event-loop'a



\$ # 07 — Архитектура бэкенда

LAYER · 01

API Layer

принимает HTTP-запросы · валидирует через Pydantic · проверяет JWT · не содержит бизнес-логики

auth.py

events.py

chats.py

achievements.py

rebalance.py

↓ DEPENDS ON

LAYER · 02

Business Layer

сложная логика · оркестрация LLM · ребалансировка · достижения · email · не знает про HTTP

LLMService

RebalanceService

AchievementService

EmailService

StorageService

↓ DEPENDS ON

LAYER · 03

Infrastructure Layer

SQL-запросы к PostgreSQL · вызовы OpenAI API · операции с S3 · не знает про бизнес-логику

UserRepository

EventRepository

ChatRepository

AchievementRepository

CounterRepository

OpenAIClient

S3Client

Async-first

весь I/O неблокирующий

Repository pattern

инфраструктура за интерфейсами

Dependency Injection

через FastAPI

Depends

\$ # 08 — Схема базы данных

9 таблиц

users	events
chats	chat_messages
achievements	user_achievements
user_counters	idempotency_keys
auth_tokens	

Архитектурные решения

TIMESTAMPTZ + IANA timezone UTC в БД, IANA-timezone у пользователя — конвертация на клиенте
JSONB для content_structured EventAction-предложения AI хранятся без изменения схемы БД
is_fixed флаг у события — не трогать при ребалансировке
user_counters достижения — данные в БД, не захардкоженная логика

\$ # 09 — REST API

Auth	9	Events	6	Chats	7	Rebalance	2	Achievements	1	System	1
------	---	--------	---	-------	---	-----------	---	--------------	---	--------	---

X-Idempotency-Key

iOS повторяет запрос при обрыве сети — сервер находит ключ в БД (TTL 24ч) и возвращает ранее созданный объект вместо дубликата

POST /events/sync

Батч до 500 upsert + 500 delete в одной транзакции — для офлайн-режима iOS

Cursor pagination

`?before=<uuid>&limit=50` — при новых сообщениях страницы не смещаются в отличие от offset-based

\$ #10 — LLM · Propose-Before-Apply

Проблема: LLM не должен изменять расписание пользователя без его ведома

1

Сообщение

Клиент отправляет текст в чат;
FastAPI принимает запрос
системный промпт: роль ассистента ·
время · ai_instructions



2

Tool-calls

LLM вызывает `search_events`,
`create_event`, `update_event`,
`delete_event`



3

Proposed

Создаются `EventAction` со `status`
= `proposed` — БД не меняется



4

Confirm

Клиент отображает предложения;
пользователь выбирает
подмножество



5

Apply

`POST /apply` → одна транзакция,
атомарное применение в БД



✓ **Гарантия:** LLM никогда не мутирует данные напрямую — только через подтверждённый apply

\$ #11 — Алгоритмы

Rebalance

массовый перенос событий через propose-before-apply

1 Сбор контекста

события за период · границы `is_fixed` · пожелания пользователя

2 LLM перестраивает расписание

получает JSON событий + workload summary · возвращает новые слоты

3 Валидация + retry

fixed не сдвинуты · нет перекрытий · retry при ошибке (до 2 попыток)

4 Подтверждение клиентом

пользователь выбирает подмножество переносов

5 Применение одной транзакцией

атомарно, без частично применённых изменений

Тот же паттерн, что в чате — пользователь видит и выбирает

Achievements

data-driven выдача через счётчики активности

1 Создание события

триггер — каждое новое событие от пользователя

2 Инкремент затронутых счётчиков

`total_events` · `ai_events` если source=ai · `total_reminders` если reminder

3 Проверка порогов

только по изменившимся счётчикам · `target ≤ current`

4 Выдача атомарно

`INSERT user_achievements` · достижения не отзываются при удалении

5 Без изменения кода

новое достижение — одна строка в таблице

Логика в данных, не в коде — миграция не нужна

\$ #12 — Надёжность и тестирование



JWT + аутентификация

Подпись **HS256** · **TTL 7 дней** для мобильного · проверка без обращения к БД · одноразовые токены для email и сброса пароля



CI/CD

push → тесты (unit + integration) → деплой на VPS только если тесты прошли



Docker Compose

3 сервиса: **PostgreSQL** · **S3** · **FastAPI app**



Rate limiting

Защита дорогих эндпоинтов: LLM 10 req/min, upload 30 req/min (**slowapi**)

80%+

Кодовая база покрыта unit и integration тестами

31 тестовый файл · pytest + httpx · async-фикстуры



\$ #13 — Демонстрация



[здесь будет видео]

регистрация → создание события → чат с AI → предложение → подтверждение → ребалансировка



\$ #14 — Результаты и выводы

- [1]

✓

Анализ аналогов и формирование требований
8 конкурентов · выявлены ключевые отличия Sentinel
- [2]

✓

Выбор стека технологий и архитектурных решений
FastAPI · SQLAlchemy 2.0 async · PostgreSQL 15 · слоистая архитектура
- [3]

✓

Проектирование схемы базы данных
9 таблиц · JSONB · TIMESTAMPTZ · idempotency_keys
- [4]

✓

Разработка REST API
25 эндпоинтов · аутентификация · офлайн-sync · cursor pagination
- [5]

✓

Интеграция LLM с паттерном Propose-Before-Apply
4 tool-функции · системный промпт · ai_instructions · атомарное apply
- [6]

✓

Алгоритмы: ребалансировка расписания и система достижений
JSON + workload summary → LLM · data-driven счётчики без изменения кода
- [7]

✓

Надёжность: тестирование, rate limiting, CI/CD
80%+ покрытие · Docker Compose · GitHub Actions · sentinel-ai.tech

\$ #15 — Направления развития

- > Prometheus + Grafana мониторинг
- > Распознавание голоса через AI для голосового управления
- > Монетизация: реклама в AI-чатах и premium-подписка
- > Redis для distributed rate limiting
- > WebSocket для real-time push-уведомлений

Список использованных источников:

1. FastAPI Documentation — fastapi.tiangolo.com
2. SQLAlchemy 2.0 Documentation — docs.sqlalchemy.org
3. OpenAI API Reference — platform.openai.com/docs
4. PostgreSQL 15 Documentation — postgresql.org/docs/15
5. Docker Documentation — docs.docker.com
6. pytest Documentation — docs.pytest.org



GitHub репозиторий



tim@sentinel:~/backend \$

Спасибо за внимание

Готов ответить на вопросы