MWS AI Agents Platform

Инструкция по установке экземпляра программного обеспечения

Содержание

О ПРОДУКТЕ

MWS AI Agents Platform – это платформа для создания AI решений, которые автоматизируют обслуживание клиентов через коммуникационные каналы и поддерживают омниканальное взаимодействие. Особенность MWS AI Agents Platform – набор готовых инструментов, не требующих от пользователей опыта в машинном обучении или навыков программирования. Благодаря этому клиенты платформы могут самостоятельно управлять жизненным циклом ботов и AI-агентов, создавать и обслуживать ML-модели и AI-сервисы. В зависимости от варианта поставки платформа MWS AI Agents Platform предоставляет следующие возможности:

- создание сценария бота или агента в удобном no-code-конструкторе;
- обработка логики бота на высокопроизводительном и отказоустойчивом движке;
- подключение ботов к каналам взаимодействия с поверхностями;
- подключение и использование LLM к ботам;
- создание и обучение ML-моделей типов Классификатор и NER;
- разметка данных для формирования и совершенствования обучающих датасетов;
- создание RAG-сервисов для быстрого поиска ответов на вопросы в регулярно обновляемой базе знаний.

Основные понятия

Агент
Автономная система, использующая LLM для сбора данных, анализа, принятия решений и выполнения задач различной сложности.

База знаний RAG
Набор документов, загруженных в систему, используемый RAG для выдачи релевантных ответов пользователю.

Бот
Программа для имитации общения с пользователями через голосовые или текстовые интерфейсы, предназначенная для предоставления информации или выполнения задач.

Веб-клиент MWS AI Agents Platform
Пользовательский веб-интерфейс для работы с платформой через браузер. Позволяет создавать и адаптировать ботов под конкретные требования.

Датасет
Набор данных для обучения, тестирования и оценки ML-моделей.

Движок (agent-engine)
Сервис для обработки запросов пользователей с помощью ботов, созданных в no-code-конструкторе.

Индекс RAG
Хранилище фактологической информации для использования в RAG, содержащее векторную часть (embedding) и текстовое представление, позволяющее проводить быстрый поиск релевантных записей.

Интент
Намерение пользователя, отражённое в поисковом запросе.

Краулинг (crawling)

Процесс автоматического сканирования, обхода и скачивания веб-страниц с помощью специальных сервисов – краулеров. Краулинг используется для сбора информации с веб-сайтов, анализа и индексации контента.

Классификатор (Classifier)
Модель машинного обучения, которая автоматически обучается и оптимизируется для решения задач классификации.

Модель машинного обучения (ML-модель)
Алгоритмическая конструкция для прогнозирования или классификации данных на основе обучения.

Паттерн
Формальное правило, описывающее ключевые слова и выражения для классификации запросов пользователя.

Проект

Совокупность сценариев разработанного бота или агента. Может содержать несколько версий.

Промпт
Подсказка для нейросети о том, что именно от неё требуется.

Сценарий
Логика работы навыка, направленная на достижение определённой цели в диалоге с клиентом. В no-code-конструкторе сценарий состоит из нод, связанных ребрами.

AI-сервис
Сервисы, использующие искусственный интеллект для обработки информации и решения задач в различных сферах.

AncSetFit (Anchored SetFit)

Расширение способа обучения ML-моделей SetFit, использующее «якорные» (anchor) примеры для каждого класса, что обеспечивает более стабильное обучение и лучшую генерализацию при экстремально малом количестве данных.

AutoML
Автоматизированный процесс создания и улучшения моделей машинного обучения.

Autoscaling (автомасштабирование)

Автоматическое изменение количества работающих экземпляров (инстансов) модели в зависимости от текущей нагрузки и потребления ресурсов.

Batching (батчинг)

Подход, при котором несколько отдельных запросов объединяются в одну группу (батч), чтобы выполнить их одновременно за одно обращение к модели.

Embedding (Эмбеддинг, вектор)
Векторное представление слова или фразы, полученное из моделей обработки естественного языка.

Fine-tuning

Дообучение предварительно обученной модели на новых данных путём обновления всех или части весов модели и/или добавления новых слоёв для адаптации к специфической задаче.

Large language model (LLM)
Языковая модель, обученная на больших объёмах текста для выполнения задач NLP.

Named Entity Recognition (NER)
Модель машинного обучения для выделения и классификации именованных сущностей в тексте.

Natural Language Processing (NLP)
Область искусственного интеллекта, занимающаяся обработкой и анализом естественного языка.

Retrieval Augmented Generation (RAG)
Технология ML, объединяющая поиск информации и генерацию текста для создания ответов на запросы.

SetFit

Метод эффективного обучения ML-моделей на малом количестве данных, использующий обучение через сравнение примеров из разных классов и последующее обучение классификатора на полученных векторных представлениях (эмбеддингах) без дообучения всей модели.

Slug (слаг)

Уникальный ключ, который представляет собой имя сценария строчными буквами. Вместо пробелов в качестве разделителей используются знаки нижнего подчеркивания.

РАЗВЕРТЫВАНИЕ

В разделе описываются требования к программному обеспечению и ресурсам, необходимым для развертывания платформы MWS AI Agents Platform. Приведены действия по подготовке к развертыванию, порядок установки и конфигурирования.

Требования к аппаратному и программному обеспечению

Требования к ПО

> Гарантируется работа платформы только на указанных версиях компонентов. Если версия не указана, используйте последнюю стабильную.

Компонент	Требование
Операционная система	Работа платформы гарантирована на следующих ОС: • Ubuntu 24.04 • Astra Linux Орел • РЕД ОС

Кластер Kubernetes	Не ниже версии 1.25.7 и не выше 1.31
	В k8s:
	• nginx ingress controller
	• cert-manager
	• GPU nodes на базе:
	  ○ Nvidia GPU operator;
	  ○ Драйвера 580 серии (LTSB ветка)
	> Убедитесь, что у ноды есть доступ к карте. Доступ можно организовать через виртуализацию или путем установки на физическом оборудовании
	Или
	CPU nodes на базе процессоров x86_64 (Intel/AMD) со стандартной средой выполнения контейнеров (containerd)
	> Этот вариант влечет снижение производительности.
	• Prometheus или VictoriaMetrics
	• OTEL Collector
	Также рекомендуется использовать Persistent Volumes (PV):

Компонент	Требование

	• для сбора метрик системой мониторинга Prometheus. При этом Prometheus может передавать метрики в другую систему для хранения и анализа данных, например VictoriaMetrics;
	• для модели Cotype. Она поставляется в двух вариантах:
	  ○ в виде большого образа;
	  ○ в виде образа, который при запуске загружает необходимые модели и требует большего объема временного хранилища на ноде или PV

Платформа потоковой передачи и обработки данных	Confluent Kafka 7.4.1-1 или Kafka версии 3.4.1
Хранение данных	PostrgeSQL 14.19-14.XX Redis 7.2.3 (авторизация поддерживается) Milvus 2.5.14 (Helm Chart версии 4.2.56) Хранилище S3 (минимум 2ГБ + 1 ГБ на каждую модель классификации). Работа платформы гарантируется на MinIO (minio.RELEASE.2023-12-20T01-00-02Z) и Yandex Object Storage ClickHouse 25.1.3.23
Мониторинг	Prometheus или VictoriaMetrics Grafana не ниже версии 11
Логирование	Для сбора логов вы можете использовать ПО, которое соответствует требованиям вашей компании
Трейсинг	Трейсы в приложениях экспортируются с помощью библиотек Opentelemetry. Для сбора трейсов используйте OTEL collector и далее перенаправляйте их в одну из выбранных систем – Jaeger, Grafana и т.д.

Минимальные требования к ресурсам

Состав компонентов отличается в зависимости от поставки. Ориентируйтесь на требования того блока, компоненты которого входят в вашу поставку.

Блок	Компонент	CPU, m	RAM, Mi	Disk, GB	GPU (A100 80GB), unit
Общие компоненты	web-backend	50	552		
	cms-frontend	50	96		
	KServe	50	512		
	ai-registry	50	288		
	automl-gateway	50	96		
	kafka (не входит в комплект поставки)	4000	8192	50	

Блок	Компонент	CPU, m	RAM, Mi	Disk, GB	GPU (A100 80GB), unit
	PostgreSQL (не входит в комплект поставки)	4000	16384	50	
	Redis (не входит в комплект поставки)	4000	8192		
No-code	agent-engine	50	1024		
	bot-registry	50	384		
	channel-registry	50	128		
	environment-registry	50	288		
	go-webim-adapter	50	128		
	http-adapter	50	192		
	telegram-adapter	50	216		
	mfaas	50	672		
Агенты	bot-registry	50	256		
AI-сервисы (AutoML)	automl-manager	50	432		
	automl-pipelines (образ поставляется в комплекте к automl-manager)	-	-		
	automl-serving (образ поставляется в комплекте к automl-manager)	-	-		
AI-сервисы (LLM / RAG)	shrag	50	3072		
	cotype	200	2048		1
	embedding	50	4096		1 Примечание. На данный момент Cotype можно запустить вместе с embedding. Также embedding может работать на CPU, но с существенной потерей производительности
	milvus (не входит в комплект поставки)	4000	16384	50	
Разметка	labelx-web	50	840		

Блок	Компонент	CPU, m	RAM, Mi	Disk, GB	GPU (A100 80GB), unit
Аналитика и BI	*clickhouse (не входит в комплект поставки)*	4000	16384	100	
	DataFacade	50	288		

Подготовка к установке

1. Перед установкой ознакомьтесь с требованиями к аппаратному и программному обеспечению.
2. Разверните кластер Kubernetes.

   Используется один кластер Kubernetes, так как видеокарты доступны только в нем. Разделение выполняется на уровне пространства имен.

3. В кластер Kubernetes с помощью менеджера пакетов Helm установите nginx ingress controller, cert-manager, Nvidia device plugin. Также установите GPU ноды и необходимые драйвера.
4. Разверните компоненты хранения данных:
   - Confluent Kafka или Kafka;
   - PostrgeSQL;
   - Redis;
   - Milvus;
   - S3;
   - ClickHouse.
5. Установите компоненты мониторинга:
   - Prometheus или VictoriaMetrics;
   - Grafana.
6. В Kubernetes создайте пространства имен (namespace):

   ```
   kubectl create ns dev
   kubectl create ns prod
   kubectl create ns kserve
   ```

   Kserve использует одно общее пространство имен (namespace) для dev и prod, так как оно инфраструктурное и его сложно разделять на dev и prod.

7. Сохраните на компьютере архивы с компонентами для установки.
8. Загрузите docker-образы в локальный реестр, который будет доступен из кластера Kubernetes.
9. Установите Cotype Pro 2.5 – большую языковую модель для генерации и редактирования текстов, суммирования и анализа информации. Инструкция по развертыванию входит в комплект поставки.

Настройка экспорта трейсов

В платформе есть возможность отследить последовательность выполнения запроса к боту или агенту, время выполнения каждого шага, а также места возникновения ошибок и другие детали. Для этого используется вкладка **Трейсинг** в режиме тестирования и отладки. Чтобы данные отображались, перед установкой сервисов платформы необходимо настроить экспорт трейсов в базу данных ClickHouse.

1. Создайте пустую базу данных в ClickHouse, например с именем «otel». Создайте пользователя с полными правами доступа к этой БД.
   Если у вас уже есть настроенный коллектор трейсов OpenTelemetry, то в его конфигурацию добавьте соответствующие секции.

   > При добавлении учитывайте существующие настройки.

   Пример конфигурации:
   - processors:batch/clickhouse:
   - processors:memory_limiter:
   - exporters:clickhouse:
   - service:pipelines:traces/clickhouse:
2. Создайте объект для хранения учетных данных доступа к ClickHouse. Его следует создать в том же пространстве имен, где развернут OpenTelemetry.
   Пример настройки:

```
apiVersion: v1
kind: Secret
metadata:
  name: otel-collector-clickhouse-secrets
type: Opaque
stringData:
  CLICKHOUSE_USERNAME: ""
  CLICKHOUSE_PASSWORD: ""
```

3. Обновите конфигурацию коллектора трейсов.
   Пример настройки:

```
apiVersion: opentelemetry.io/v1beta1
kind: OpenTelemetryCollector
metadata:
  name: otel
spec:
  mode: deployment
  envFrom:
    - secretRef:
        name: otel-collector-clickhouse-secrets
  autoscaler: {}
  podSecurityContext: {}
  priorityClassName: ""
  securityContext:
    allowPrivilegeEscalation: false
    readOnlyRootFilesystem: true
    capabilities:
      drop:
        - all
  tolerations: []
  resources: {}
  config:
    ### Receivers definition
    receivers:
      otlp:
        protocols:
```

```
        grpc:
          endpoint: 0.0.0.0:4317
        http:
          endpoint: 0.0.0.0:4318
    processors:
      batch/clickhouse:
        send_batch_size: 1000
        send_batch_max_size: 10000
        timeout: 1s
      memory_limiter:
        check_interval: 1s
        limit_percentage: 85
        spike_limit_percentage: 15
    ### Exporters definition
    exporters:
      # https://github.com/open-telemetry/opentelemetry-collector-
    contrib/blob/main/exporter/clickhouseexporter/README.md
      clickhouse:
        endpoint: <clickhouse_url> # For example,
    tcp://10.217.0.10:9000?dial_timeout=10s
        username: "${CLICKHOUSE_USERNAME}"
        password: "${CLICKHOUSE_PASSWORD}"
        database: otel
        async_insert: true
        ttl: 336h
        compress: lz4
        create_schema: true
        traces_table_name: otel_traces
        timeout: 10s
        retry_on_failure:
          enabled: true
          initial_interval: 5s
          max_interval: 30s
          max_elapsed_time: 300s
    ### Service definition
    service:
      # https://opentelemetry.io/docs/collector/internal-telemetry/#configure-
    internal-logs
      # Sets the minimum enabled logging level. Other possible values are DEBUG,
    WARN, and ERROR.
      telemetry:
        logs:
          level: INFO
        metrics:
          level: detailed
      pipelines:
        traces/clickhouse:
          receivers:
            - otlp
          processors:
            # https://github.com/open-telemetry/opentelemetry-
    collector/tree/main/processor/memorylimiterprocessor#best-practices
            - memory_limiter
            - batch/clickhouse
          exporters:
            - clickhouse
```

4. Настройте сервис data-facade. Для этого в переменной окружения **CLICKHOUSE_TRACES_DATABASE** укажите базу данных, в которую экспортируются трейсы, например «otel»:CLICKHOUSE_TRACES_DATABASE: "otel"

> У пользователя **CLICKHOUSE_USER** должны быть права на чтение базы данных, в которую экспортируются трейсы. Если вы используете pre-hook с именем clickhouse:dbCreation, то нужные права будут предоставлены автоматически перед запуском сервиса.

Установка платформы

1. По умолчанию для платформы уже заданы значения обязательных параметров для каждого компонента. При необходимости скорректируйте их. Для этого в файле values.yaml раскомментируйте строку с нужным параметром и укажите для него значение. При этом, если в параметре предполагается ссылка:
   - на базу данных PostgreSQL, то предварительно создайте ее;
   - на хранилище S3, то предварительно создайте соответствующий бакет.
2. Для сервисов embedding и automl-manager заранее разместите модели в хранилище S3.
3. Установите Kserve. Примеры команд:

```
kubectl apply -f ./kserve/ns-prepare.yaml
kubectl apply -n kserve -f ./kserve/kserve.yaml
kubectl apply -n kserve -f ./kserve/kserve-cluster-resources.yaml
kubectl apply -n kserve -f models-web-app.yaml
```

4. Установите каждый компонент с помощью Helm Chart. Вместо <SERVICE_NAME> укажите имя сервиса:

```
helm upgrade "<SERVICE_NAME>" \
    --install \
    --atomic \
    --namespace "dev" \
    --values "charts/<SERVICE_NAME>/values.yaml" \
    charts/<SERVICE_NAME>
```

Конфигурирование

По умолчанию настройки платформы уже заданы. При необходимости вы можете их изменить. Для этого в файле values.yaml раскомментируйте строку с нужным параметром и задайте для него значение. В таблицах приведены компоненты их параметры.

При необходимости включите пакетные запросы к модели и автомасштабирование, а также отключите системный датасет, если это влияет на качество обучения.

Общие компоненты

Компоненты	Параметры
web-backend	• **SERVICE_ENVIRONMENT** – параметры окружения; • Agent Engine configuration **AGENT_ENGINE_URL** – адрес сервиса agent-engine; • AI-Registry url: **AI_REGISTRY_URL** – URL до сервиса ai-registry; • Bot-Registry url: **BOT_REGISTRY_URL** – URL до сервиса bot-registry; • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии; • Rag Manager configuration: **RAG_MANAGER_URL** – URL до сервиса rag-manager;

Компоненты	Параметры
	• AutoML Manager configuration: **AUTOML_MANAGER_URL** – URL до сервиса automl-manager; • LabelX configuration: **DATA_FACADE_URL** – URL до сервиса data-facade; **LABELX_URL** – URL до сервиса разметки; **LABELX_JWT_SECRET** – секретный ключ для подписи и проверки JWT-токена; **LABELX_JWT_ALGORITHM** – алгоритм шифрования для подписи JWT-токена; **LABELX_ACCOUNT** – имя аккаунта. • crawler-gateway configuration: **CRAWLER_URL** – URL сервиса crawler-gateway; • **AUTOML_GATEWAY_URL –** URL сервиса automl-gateway Настройки генерации ответов с помощью AI-ассистента: • Подключение модели: **AI_ASSIST_LLM_URL** – URL модели. По умолчанию "http://cotype.dev-mars:8000/v1" **AI_ASSIST_LLM_MODEL_NAME** – имя модели. По умолчанию "cotype_pro_2_mars" • Системные промпты для генерации значений можно изменить в переменных: **AI_ASSIST_SYSTEM_PROMPT_PROMPT** – для полей, в которых задаются промпты. Например, в блоках **LLM** и **AI-agent**; **AI_ASSIST_SYSTEM_PROMPT_PYTHON_SCRIPT** – для полей, в которых задается код скрипта, например в блоке **Скрипт**; **AI_ASSIST_SYSTEM_PROMPT_PYTHON_EVAL** – для значений, которые указываются в виде скрипта, например поле **Код** в блоке **Переменная**; **AI_ASSIST_SYSTEM_PROMPT_PYTHON_TOOL** – для поля пользовательского инструмента **Custom tool** блока **AI-агент**; **AI_ASSIST_SYSTEM_PROMPT_CUSTOM_IF** – для поля **Выражение** в блоке **Условие перехода**; **AI_ASSIST_SYSTEM_PROMPT_REGEX** – для полей, которые заполняются регулярным выражением; **AI_ASSIST_SYSTEM_PROMPT_REGEX_MAP** – для полей, которые заполняются массивом регулярных выражений **Примечание**. По умолчанию промпты уже заданы. При необходимости вы можете их изменить в указанных переменных
cms-frontend	• **CONSTRUCTOR_AUTO_SAVE_ENABLED** – признак того, что включено автосохранение сценариев. По умолчанию **False**
KServe	kserve.yaml: • **data.credentials** – параметры подключения к S3 хранилищу models-web-app.yaml: • **spec.rules.host** – FQDN для KServe models web app inference-service-prepare.yaml – параметры подключения к S3 хранилищу
ai-registry	• **SERVICE_ENVIRONMENT** – переменные окружения;

Компоненты	Параметры
	• OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии; • PostgreSQL configuration: **POSTGRES_SERVERS** – список серверов PostgreSQL; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB_NAME** – название базы данных
environment-registry	• Service configuration: **SERVICE_ENVIRONMENT** – переменные окружения. По умолчанию: local; **IMAGE_TAG –** тег образа. По умолчанию: local_tag; **X_AI_WORKSPACE –** Workspace. По умолчанию: default • PostgreSQL configuration: **POSTGRES_SERVERS** – список серверов PostgreSQL. Обязательный параметр; **POSTGRES_USER** – имя пользователя. Обязательный параметр; **POSTGRES_PASSWORD** – пароль. Обязательный параметр; **POSTGRES_DB** – имя базы данных. По умолчанию: environment-registry; • Encryption configuration: **ENCRYPTION_KEY** – Ключ Fernet для шифрования токенов. Обязательный параметр
bot-registry	• Service configuration: **CHANNELS_SERVING_HOST** – адрес хоста обработки запросов; • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии; • PostgreSQL configuration: **POSTGRES_SERVERS** – список серверов PostgreSQL; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB_NAME** – имя базы данных • **AUTOML_GATEWAY_URL –** URL сервиса automl-gateway
mfaas	• Service configuration: **SERVICE_ENVIRONMENT** – переменные окружения • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии. Требуется, если включена телеметрия • PostgreSQL configuration: **POSTGRES_SERVERS** – список серверов PostgreSQL; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB_NAME** – имя базы данных

No-code-конструктор

Компоненты	Параметры
agent-engine	• Otel configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных

Компоненты	Параметры
	телеметрии; **OTEL_SERVICE_NAME** – имя сервиса, отправляющего данные трассировки; **OTEL_EXPORTER_OTLP_TRACES_INSECURE** – признак того, что следует экспортировать данные трассировки через небезопасное соединение без https. Возможные значения: **True**, **False**; **OTEL_EXPORTER_OTLP_TRACES_PROTOCOL** – протокол для передачи данных трассировки (grpc, http/protobuf); **OTEL_EXPORTER_OTLP_TRACES_COMPRESSION** – стратегия сжатия передаваемых данных трассировки (gzip или none); • PostgreSQL configuration: **POSTGRES_SERVERS** – список серверов БД; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB** – имя базы данных; • Kafka configuration: **KAFKA_BOOTSTRAP_SERVER** – адрес брокера Kafka; **DIALOG_HISTORY_KAFKA_TOPIC** – название топика; **DIALOG_HISTORY_SOURCE** – источник данных в Kafka; • Events API configuration: **EVENTS_API_ENABLED** – включить Events API. По умолчанию: true; **EVENTS_INPUT_KAFKA_TOPIC –** входной топик событий. По умолчанию: engine-request • Priority Activator: **PRIORITY_ACTIVATOR** – приоритет условия активации. Укажите условие активации, которое нужно проверить в первую очередь. Возможные значения: **intent** – первым выбирается активационный блок с интентом независимо от порядка сценариев. Значение по умолчанию; **match** – первым выбирается активационный блок с регулярным выражением независимо от порядка сценариев; **none** – активационные блоки проверяются в порядке их добавления • **EXTERNAL_PYTHON_EXECUTOR_URL** – адрес сервиса mfaas. Если обработка кода выполняется в стороннем сервисе, укажите в качестве значения null; • **ON_ERROR_STUB_ANSWER** – сообщение, которое отображается при возникновении технической ошибки. По умолчанию «Возникла техническая ошибка»; • Service configuration: **SSL_VERIFY** – Проверка SSL-сертификатов. По умолчанию:True **BOT_REGISTRY_URL** – URL bot-registry. По умолчанию:http://bot-registry:8080 **CHANNEL_REGISTRY_URL** – URL channel-registry. По умолчанию: http://channel-registry:8080 **AUTOML_GATEWAY_URL** – URL automl-gateway. По умолчанию: http://automl-gateway:8080 **RAG_SERVICE_URL** – URL RAG-сервиса. По умолчанию:http://shrag:8080 **ENVIRONMENT_REGISTRY_URL** – URL сервиса переменных окружений. По умолчанию: http://environment-registry:8080
channel-registry	• Common Kafka configuration **KAFKA_BROKER_ADDRESS** – адрес брокера Kafka;

Компоненты	Параметры
	• Channel-config-telegram producer configuration **CHANNEL_CONFIG_TELEGRAM_REDEFINED_TOPIC_NAME –** топик для Telegram. Требуется, если используется Telegram • Channel-config-webim producer configuration **CHANNEL_CONFIG_WEBIM_REDEFINED_TOPIC_NAME –** топик для Webim. Требуется, если используется Webim • Channel-config-http producer configuration **CHANNEL_CONFIG_HTTP_REDEFINED_TOPIC_NAME –** топик для HTTP. Требуется, если используется HTTP • Channel-config-langflow producer configuration **CHANNEL_CONFIG_LANGFLOW_REDEFINED_TOPIC_NAME** • Channel-config-max **CHANNEL_CONFIG_MAX_REDEFINED_TOPIC_NAME** – топик для мессенджера Max. Требуется, если мессенджер используется • Channels configuration Топики каналов: **CHANNEL_HTTP_REDEFINED_TOPIC_NAME** **CHANNEL_LANGFLOW_REDEFINED_TOPIC_NAME** **CHANNEL_TELEGRAM_REDEFINED_TOPIC_NAME** **CHANNEL_WEBIM_REDEFINED_TOPIC_NAME** **CHANNEL_MAX_REDEFINED_TOPIC_NAME** • OpenTelemetry configuration **OTEL_SERVICE_NAME** – имя сервиса, отправляющего данные трассировки; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки; **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии; • PostgreSQL configuration **POSTGRES_HOST** – имя хоста Postrgres; **POSTGRES_PORT** – порт; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB_NAME** – имя базы данных
go-webim-adapter	• Common Kafka configuration: **KAFKA_BROKER_ADDRESS** – адрес брокера Kafka; • Channel-config-webim consumer configuration: **CHANNEL_CONFIG_WEBIM_REDEFINED_TOPIC_NAME** • Channel-webim consumer configuration: **CHANNEL_WEBIM_REDEFINED_TOPIC_NAME** • Engine-request producer configuration: **ENGINE_REQUEST_REDEFINED_TOPIC_NAME** • OpenTelemetry configuration: **OTEL_SERVICE_NAME** – имя сервиса для передачи данных телеметрии; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки; **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки

Компоненты	Параметры
	• S3 configuration: **S3_ENDPOINT_URL** – URL S3-хранилища; **S3_ACCESS_KEY** – ключ доступа S3
http-adapter	• Common Kafka configuration: **KAFKA_BROKER_ADDRESS** – адрес брокера Kafka; • Channel-config-http consumer configuration: **CHANNEL_CONFIG_HTTP_REDEFINED_TOPIC_NAME** • Channel-http consumer configuration: **CHANNEL_HTTP_REDEFINED_TOPIC_NAME** • Engine-request producer configuration: **ENGINE_REQUEST_REDEFINED_TOPIC_NAME** • OpenTelemetry configuration: **OTEL_SERVICE_NAME** – имя сервиса для передачи данных телеметрии; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки; **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки • S3 configuration: **S3_ENDPOINT_URL** – URL S3-хранилища; **S3_ACCESS_KEY** – ключ доступа S3
telegram-adapter	• Common Kafka configuration: **KAFKA_BROKER_ADDRESS** – адрес брокера Kafka; • Channel-config-telegram consumer configuration: **CHANNEL_CONFIG_TELEGRAM_REDEFINED_TOPIC_NAME** • Channel-telegram consumer configuration: **CHANNEL_TELEGRAM_REDEFINED_TOPIC_NAME** • Engine-request producer configuration: **ENGINE_REQUEST_REDEFINED_TOPIC_NAME** • OpenTelemetry configuration: **OTEL_SERVICE_NAME** – имя сервиса для передачи данных телеметрии; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки; **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки • S3 configuration: **S3_ENDPOINT_URL** – URL S3-хранилища; **S3_ACCESS_KEY** – ключ доступа S3
max-adapter	• Common Kafka configuration: **KAFKA_BROKER_ADDRESS** – адрес брокера Kafka; • Channel-config-max consumer configuration: **CHANNEL_CONFIG_MAX_REDEFINED_TOPIC_NAME** • Channel-max consumer configuration: **CHANNEL_MAX_REDEFINED_TOPIC_NAME** • Engine-request producer configuration: **ENGINE_REQUEST_REDEFINED_TOPIC_NAME** • OpenTelemetry configuration: **OTEL_SERVICE_NAME** – имя сервиса для передачи данных телеметрии;

Компоненты	Параметры
	OTEL_RESOURCE_ATTRIBUTES – атрибуты ресурсов, которые производят данные трассировки; **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки • S3 configuration: **S3_ENDPOINT_URL** – URL S3-хранилища; **S3_ACCESS_KEY** – ключ доступа S3

AI-сервисы (AutoML)

Компоненты	Параметры
automl-manager	• Service configuration: **SERVICE_ENVIRONMENT** – переменные окружения; • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных телеметрии; • Service specific envs: **AI_REGISTRY_URL** – URL сервиса ai-registry; • Serving image: **K8S_SERVING_IMAGE** – путь до образа; **K8S_SERVING_NAMESPACE** – имя пространства для запуска automl-serving; **K8S_SERVING_SERVICE_ACCOUNT_NAME** – имя аккаунта; **K8S_SERVING_IMAGE_PULL_SECRET** – секрет для работы с образом; • Training image: **K8S_TRAINING_IMAGE** – путь до образа; **K8S_TRAINING_JOB_TTL_SECONDS** – время жизни джобы пайплайна на тренировку модели в секундах. • Kserve configuration: **KSERVE_URL** – URL до сервиса KServe; • Serving batching & scaling configuration: **K8S_SERVING_SCALING__MIN_REPLICAS** – минимальное количество инстансов моделей для развертывания; **K8S_SERVING_SCALING__MAX_REPLICAS** – максимальное количество инстансов моделей для развертывания; **K8S_SERVING_SCALING__SCALE_METRIC** – метрика для масштабирования. Возможные значения: "cpu", "memory"; **K8S_SERVING_SCALING__SCALE_TARGET** – целевое значение метрики для запуска автоскейлинга; **K8S_SERVING_BATCHING__MAX_BATCH_SIZE** – максимальный размер батча для группировки запросов; **K8S_SERVING_BATCHING__MAX_LATENCY** – время набора пачки в мс, по истечении которого запросы отправятся в модель; **K8S_SERVING_BATCHING__TIMEOUT** – таймаут в секундах на выполнение запросов в модели; • MinIO configuration: **S3_BUCKET** – имя бакета для хранения результатов; **S3_CHECKPOINTS_BUCKET** – имя бакета для хранения чекпоинтов; **S3_CHECKPOINTS_PATH** – путь для хранения чекпоинтов; **S3_USER** – имя пользователя Minio;

Компоненты	Параметры
	S3_PASSWORD – пароль; **S3_URI** – URL для подключения к хранилищу S3; • LabelX configuration: **LABELING_URL** – URL до сервиса разметки; **LABELING_JWT_SECRET** – секретный ключ, используемый для подписи и проверки JWT-токена; **LABELING_JWT_ALGORITHM** – алгоритм шифрования, применяемый для подписи JWT-токена; **LABELING_ACCOUNT** – имя аккаунта
automl-gateway	**INSTANCE_URL_TEMPLATE –** шаблон URL для проксирования запросов к модулям инференса (автоматического логического вывода моделей). Пример: "http://%s-%s-<platform_namespace>-predictor.<kserve_inference_namespace>/v1/models/automl-model:predict" • Замените <platform_namespace> на имя namespace, где установлены все сервисы платформы • Замените <kserve_inference_namespace> на имя namespace, содержащего KServe inference (InferenceServices)

AI-сервисы (RAG)

Компоненты	Параметры
shrag	• Processing: **CHUNK_SIZE** – размер чанка для обработки; **CHUNK_OVERLAP** – перекрытие чанков; **MAX_FILE_SIZE_MB** – максимальный размер файла в МБ; **INDEXING_SKIP_S3_DOWNLOAD** – пропуск загрузки в S3 при индексации; **MAX_RETRIES** – максимальное количество попыток для индексации документа • Service configuration: **DEFAULT_EMBEDDING_URL** – URL сервиса эмбеддингов; **DEFAULT_EMBEDDING_MODEL_NAME** – имя модели эмбеддингов; **DEFAULT_EMBEDDING_BATCH_SIZE** – размер батча для эмбеддингов; **EMBEDDING_TIMEOUT** – таймаут запроса к сервису эмбеддингов; **EMBEDDING_CLIENT_TTL** – TTL клиента эмбеддингов • S3 configuration: **S3_ENDPOINT_URL** – URL S3-хранилища; **S3_ACCESS_KEY** – ключ доступа S3 • Milvus configuration: **MILVUS_HOST** –хост Milvus; **MILVUS_PORT** – порт Milvus; **MILVUS_TIMEOUT** – таймаут подключения; **MILVUS_COLLECTION_PREFIX** – префикс коллекций; **MILVUS_DB_NAME** – имя базы данных Milvus; **MILVUS_USERNAME** – пользователь Milvus; **MILVUS_PASSWORD** – пароль Milvus • PostgreSQL configuration: **POSTGRES_HOST** – имя хоста PostgreSQL; **POSTGRES_PORT** – порт PostgreSQL;

Компоненты	Параметры
	POSTGRES_SERVERS – список серверов PostgreSQL; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль; **POSTGRES_DB_NAME** – имя базы данных; • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – адрес для отправки данных трассировки; **OTEL_EXPORTER_OTLP_TRACES_INSECURE** – признак того, что следует экспортировать данные трассировки через небезопасное соединение без https. Возможные значения: **True**, **False**; **OTEL_EXPORTER_OTLP_TRACES_PROTOCOL** – протокол для передачи данных трассировки (grpc, http/protobuf); **OTEL_EXPORTER_OTLP_TRACES_COMPRESSION** – стратегия сжатия передаваемых данных трассировки (gzip или none); **OTEL_SERVICE_NAME** – имя сервиса, отправляющего данные трассировки; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки
cotype	• **GPUUTIL** – доля в использовании GPU (от 0 до 1); **EAGER** – отключает оптимизации CUDA graphs и выполняет вычисления последовательно; **MACHINE_PORT** – номер порта; **ADDITIONAL_ARGS** – дополнительные аргументы • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_TRACES_INSECURE** – признак того, что следует экспортировать данные трассировки через небезопасное соединение без https. Возможные значения: **True**, **False**; **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки; **OTEL_EXPORTER_OTLP_TRACES_PROTOCOL** – протокол для передачи данных трассировки (grpc, http/protobuf); **OTEL_EXPORTER_OTLP_TRACES_COMPRESSION** – стратегия сжатия передаваемых данных трассировки (gzip или none); **OTEL_SERVICE_NAME** – имя сервиса, отправляющего данные трассировки
embedding	• MinIO configuration: **PRIMARY_S3_ENDPOINT_URL** – URL до хранилища с моделями; **PRIMARY_S3_BUCKET** – имя бакета; **PRIMARY_S3_ACCESS_KEY_ID** – идентификатор ключа; **PRIMARY_S3_SECRET_ACCESS_KEY** – ключ доступа; • OpenTelemetry configuration: **OTEL_EXPORTER_OTLP_ENDPOINT** – конечная точка для отправки данных трассировки; **OTEL_RESOURCE_ATTRIBUTES** – атрибуты ресурсов, которые производят данные трассировки

Разметка

Компоненты	Параметры
labelx-web	• **ROOT_URL** – внешний URL сервиса разметки; • **SENTRY_DSN** – URL для отправки алертов (опционально);

Компоненты	Параметры
	• PostgreSQL configuration: **DB_HOST** – имя хоста PostgresSQL; **DB_PORT** – порт PostgresSQL; **DB_NAME** – имя базы данных; **DB_USER** – имя пользователя; **DB_PASS** – пароль

Аналитика и BI

Компоненты	Параметры
data-facade	• Kafka configuration: **KAFKA_BROKER_LIST** – адреса брокеров Kafka; **KAFKA_TOPIC_LIST** – список топиков; **KAFKA_GROUP_NAME** – имя группы; • OpenTelemetry configuration: **TRACING_AGENT_HOST** – адрес для отправки данных телеметрии; **TRACING_AGENT_PORT** – порт для отправки данных телеметрии • ClickHouse secrets: **CLICKHOUSE_SERVER** – URL до сервиса clickhouse; **CLICKHOUSE_PORT** – порт сервиса clickhouse; **CLICKHOUSE_USER** – имя пользователя; **CLICKHOUSE_PASSWORD** – пароль пользователя; **CLICKHOUSE_DATABASE** – имя базы данных; • PostgreSQL configuration – подключение к базе labelx_web: **POSTGRES_HOST** – имя хоста PostgreSQL; **POSTGRES_PORT** – порт PostgreSQL; **POSTGRES_DATABASE** – имя базы данных; **POSTGRES_USER** – имя пользователя; **POSTGRES_PASSWORD** – пароль

Настройка пакетных запросов к модели и автомасштабирования

Сервис automl-manager поддерживает пакетную отправку клиентских запросов в модель (батчинг) и автомасштабирование экземпляров развернутой модели (автоскейлинг). По умолчанию эти функции выключены.

Чтобы включить батчинг, необходимо при развертывании automl-manager задать значения следующим переменным:

- **K8S_SERVING_BATCHING__MAX_BATCH_SIZE**
- **K8S_SERVING_BATCHING__MAX_LATENCY**
- **K8S_SERVING_BATCHING__TIMEOUT**

Чтобы включить автоскейлинг, требуется прописать переменные:

- **K8S_SERVING_SCALING__MIN_REPLICAS**
- **K8S_SERVING_SCALING__MAX_REPLICAS**
- **K8S_SERVING_SCALING__SCALE_METRIC**
- **K8S_SERVING_SCALING__SCALE_TARGET**

При установленном в переменной **K8S_SERVING_SCALING__SCALE_METRIC** значении "cpu" рекомендуется в переменной **K8S_SERVING_SCALING__SCALE_TARGET** установить значение "75".

Для настройки фиксированного масштабирования достаточно задать значение только переменной **K8S_SERVING_SCALING__MIN_REPLICAS**.

Отключение системного датасета при обучении моделей NER

При обучении модели NER пользовательский датасет автоматически обогащается системными (предопределёнными) сущностями. В некоторых случаях это может непреднамеренно влиять на качество обучения, вводя шум (ложные метки), bias (предвзятости) или конфликты с пользовательскими сущностями, снижая точность модели в специализированных доменах.

Отключить системный датасет можно через переменную **NER_TRAINING_SETTINGS__CHECKPOINTS** сервиса automl-manager.

Установите её значение в конфигурации Helm-чарта automl-manager, как указано в примерах, и перезапустите сервис перед обучением.

Пример с включённым обучением на системных сущностях:

NER_TRAINING_SETTINGS__CHECKPOINTS: '[{"NAME":"ruBert-base","JOB_ENV_NAME":"MAIN_CHECKPOINT"},{"NAME":"v1.0.0_tadner_pretrain","JOB_ENV_NAME":"TAD_NER_CHECKPOINT"},{"NAME":"v1.0.0_finetuner_system_ner","JOB_ENV_NAME":"FINETUNER_SYSTEM_NER_CHECKPOINT"}]'

Пример с отключённым обучением на системных сущностях:

NER_TRAINING_SETTINGS__CHECKPOINTS: '[{"NAME":"ruBert-base","JOB_ENV_NAME":"MAIN_CHECKPOINT"},{"NAME":"v1.0.0_tadner_pretrain","JOB_ENV_NAME":"TAD_NER_CHECKPOINT"}]'

Мониторинг

В платформе предусмотрена возможность оценивать текущее состояние сервисов. Для этого в комплект поставки входят архивы с темплейтами (шаблонами) дашбордов в формате JSON. Чтобы отслеживать состояние сервисов с помощью дашбордов, предварительно установите систему сбора метрик Prometheus или VictoriaMetrics, а также платформу мониторинга и анализа данных Grafana (не входит в комплект поставки). Данные на дашбордах позволяют быстро определить работоспособность сервисов и в случае возникновения инцидентов вовремя принять меры.

> В полученном JSON-файле укажите источники данных в виде ссылок в формате используемой системы сбора метрик.

Подробнее о настройках и работе с дашбордами см. в документации Grafana.

Для мониторинга используются:

- **Application Health Dashboard** – дашборд состояния работоспособности сервисов;
- **Application summary** – дашборд с метриками конкретного сервиса. К нему можно перейти из панелей дашборда **Application Health Dashboard**.

Application Health Dashboard

Панели дашборда разделены на группы. На каждой панели отображается информация о состоянии подов конкретного сервиса. Чтобы перейти к дашборду **Application summary** с детальной информацией по сервису, нажмите на кнопку .

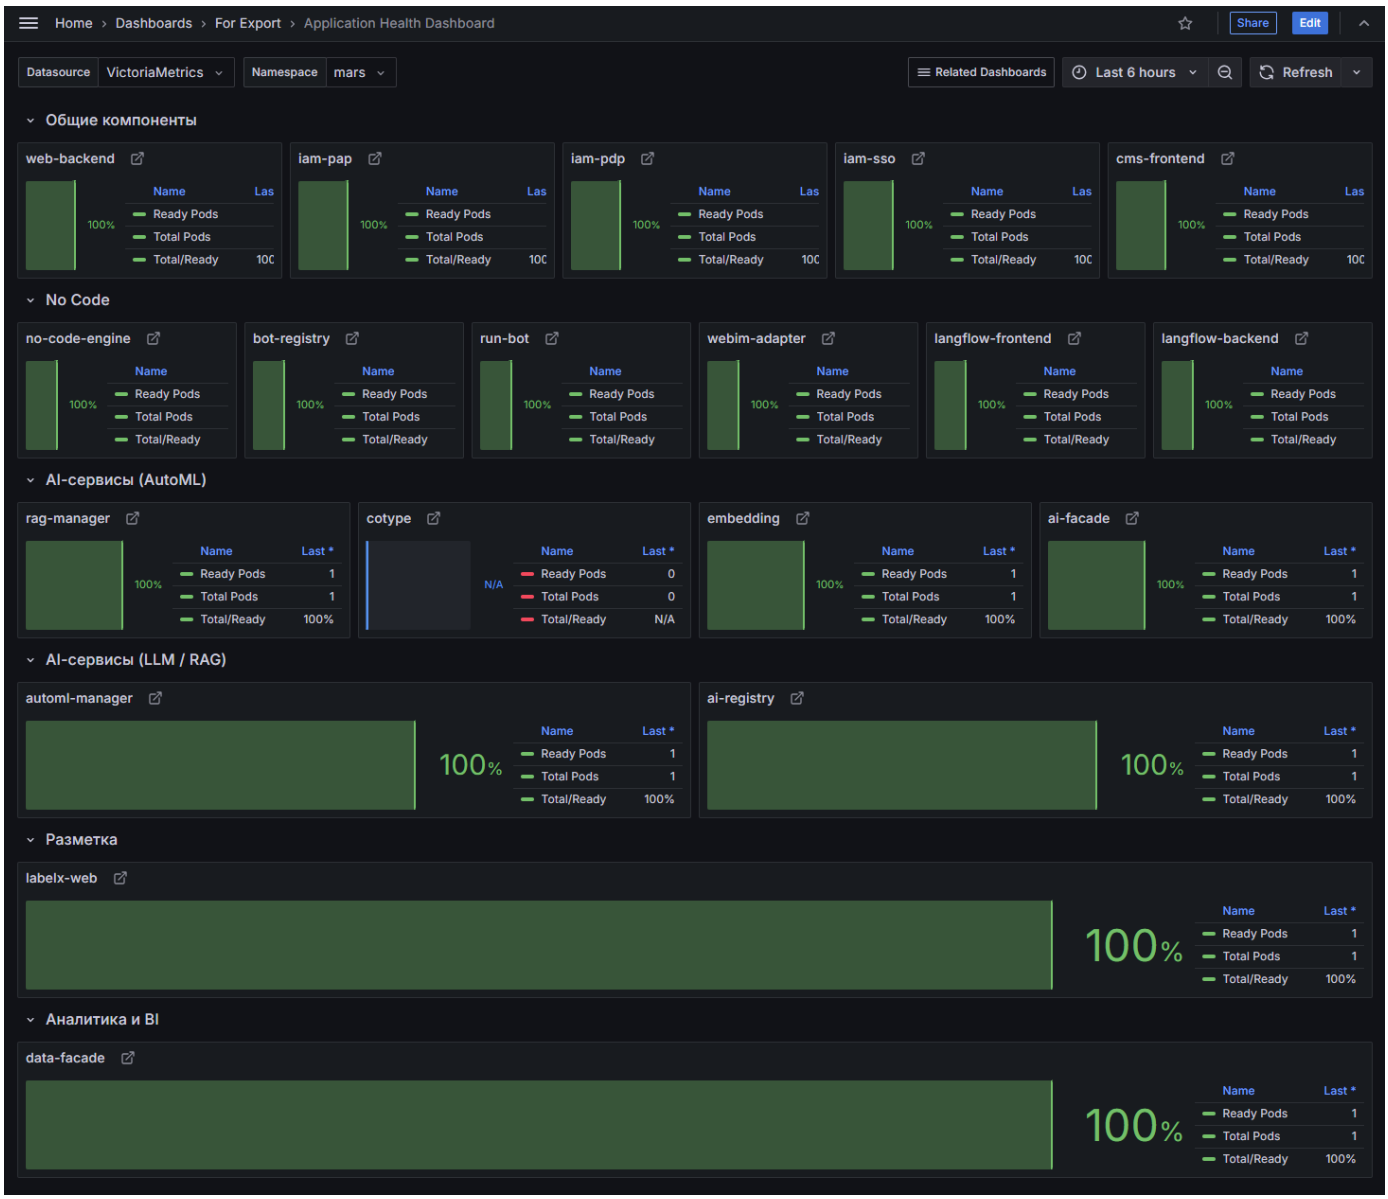

Application summary

На дашборде отображается название сервиса, имя пода и другая информация, например:

- длительность обработки HTTP-запросов и количество ошибок (HTTP Metrics);
- загрузка процессора, оперативной памяти, потребление ресурсов сервисами (Application resource usage);

- ресурсы, потребляемые подами (Pod's resourse usage).

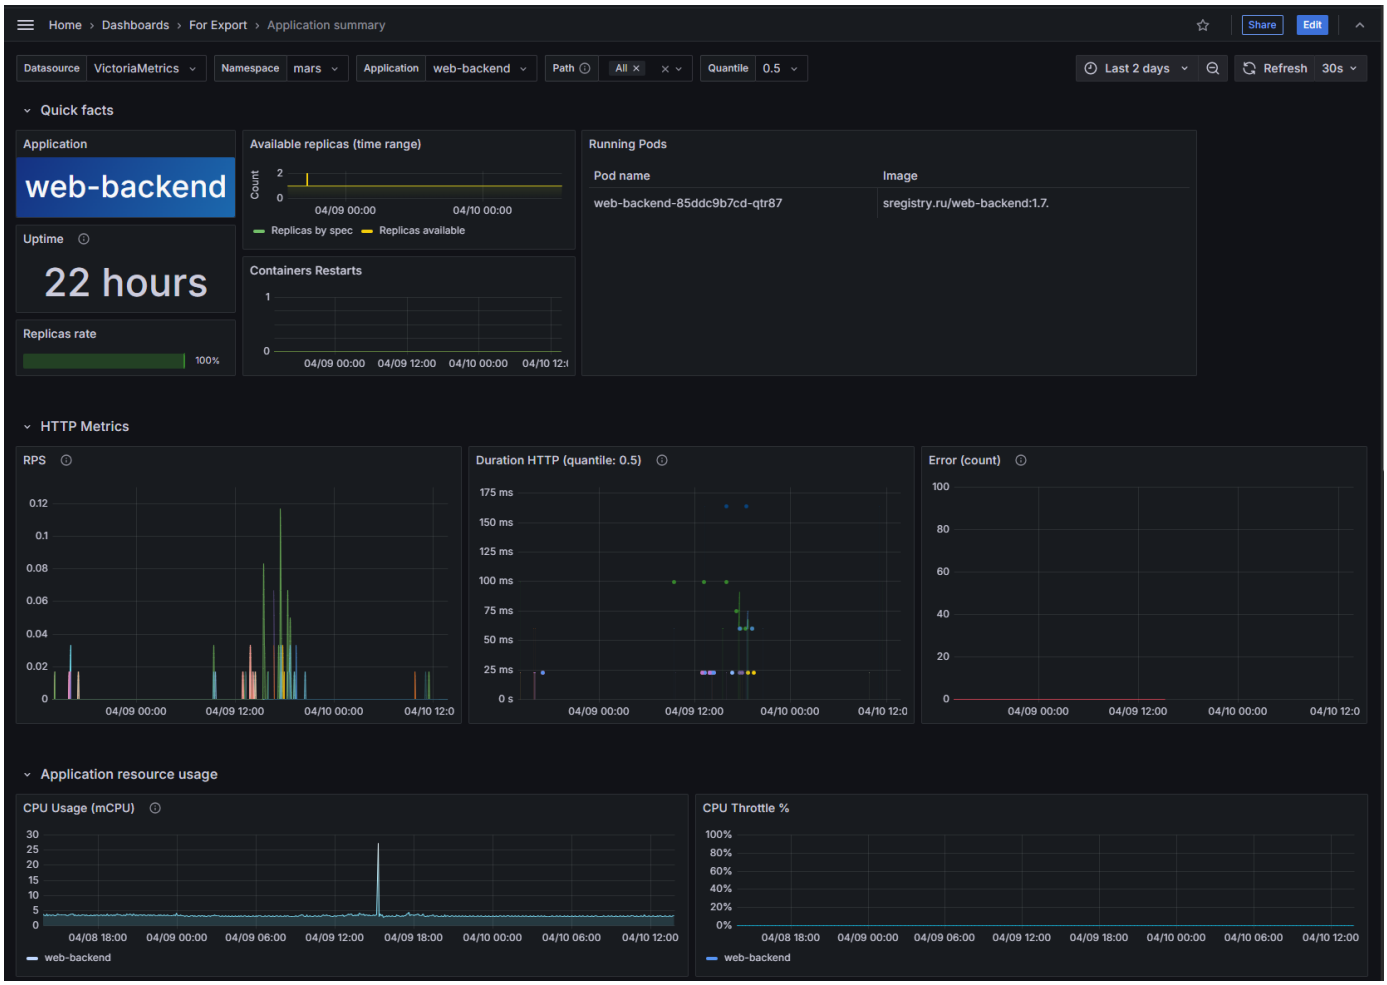

При необходимости отфильтруйте данные по конкретным HTTP-запросам. Для этого выберите нужные эндпоинты методов в выпадающем списке **Path**:

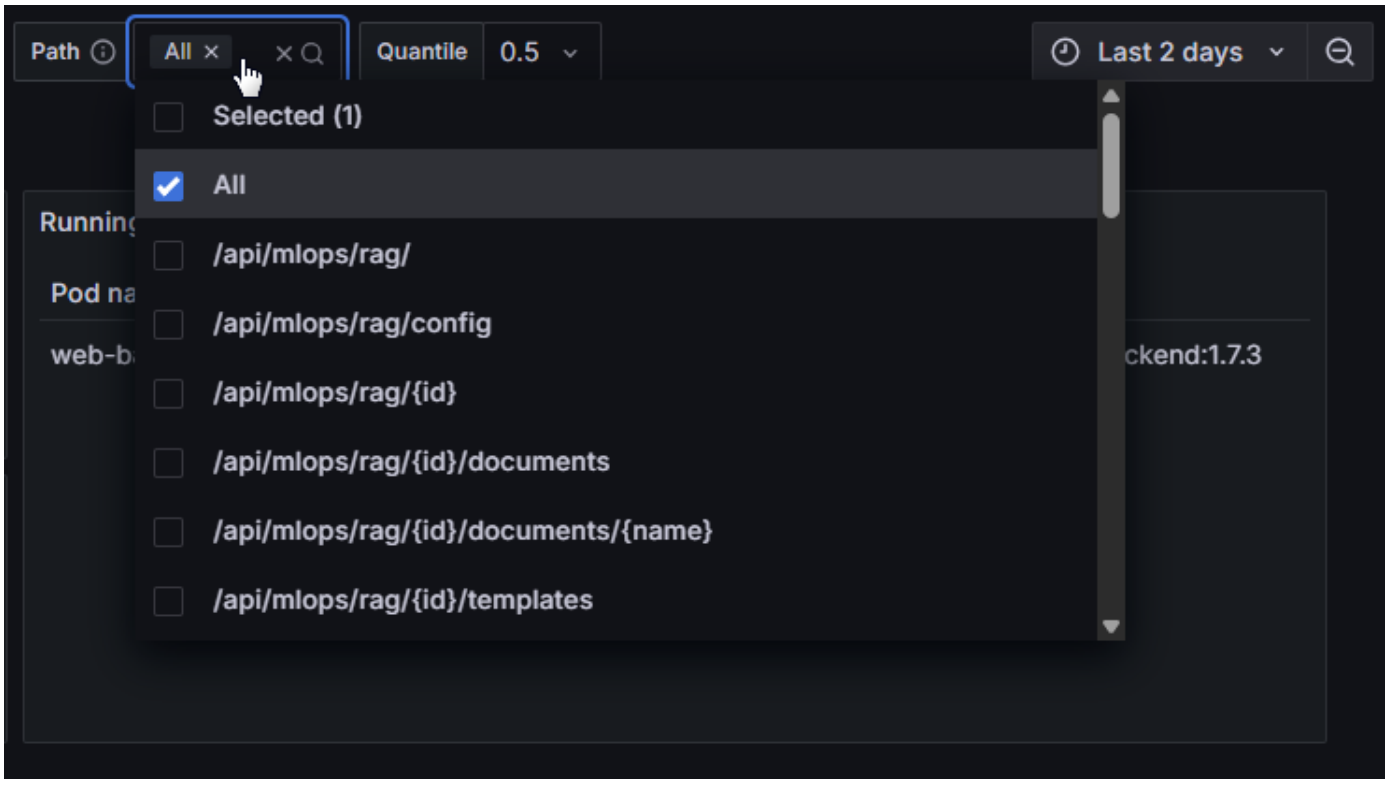

Трассировка

Платформа MWS AI Agents Platform поддерживает систему трассировки. Трассировка предоставляет детализированную информацию о прохождении запросов через различные компоненты платформы. Система основана на инструменте OpenTelemetry. Интеграция с компонентами платформы выполняется через OTLP (OpenTelemetry Protocol), данные о спанах экспортируются по gRPC.

Для просмотра и анализа трассировок используйте Jaeger.

В качестве примера. Метод POST /api/v3/nocode/bots/{bot_id}/bot_versions/{bot_version_id}/engine/ передает метаданные трассировки прохождения запроса через компоненты сценария бота при выполнении запроса в виджете тестирования. Для этого в сервисе реализована генерация и отправка спанов в Jaeger.

Таким образом в Jaeger UI возможно получить и проанализировать детали обработки.

Логирование сервисов

Чтобы своевременно принимать меры по устранению неисправностей, рекомендуется отслеживать лог-файлы системы. Для этого используйте возможности k8s:

```
kubectl logs -n <namespace> deployment/<name-of-component> # logs of deployment
kubectl logs -n <namespace> -f deployment/<name-of-component> # follow logs
```

Логи движка agent-engine

Логи сервиса agent-engine представляют собой последовательную запись процесса выполнения движком сценария бота.

Уровень логирования устанавливается с помощью переменной **LOG_LEVEL** (по умолчанию **LOG_LEVEL=INFO**).
Формат вывода можно задать в переменной **LOG_JSON_FORMAT**.

Вот этапы процесса работы движка, которые можно найти в логах.

Начало выполнения запроса к движку

- Фиксируется начало обработки запроса с уникальным идентификатором (request_id).
- Содержит информацию о сессии, пользователе и тексте сообщения.

Создание новой сессии

- agent-engine создает новую сессию при новом диалоге с ботом.
- Содержится идентификатор сессии (session_id).

Запуск препроцессинга

- Фиксируется запуск сценария (execution_phase=PREPROCESSING).
- Фиксируются выполнение нод и блоков.

Основной сценарий

- Фиксируется старт сценария "Default NoMatch Scenario" (scenario_id: 2947).
- Последовательно фиксируются исполняемые ноды и блоки сценария.

HTTP-запрос

- Фиксируется HTTP-запрос к внешнему сервису, например, классификатору.
- Содержит параметры запроса.
- При ошибках обработки запроса.
- При отправке сообщений на callback URL.

Структура логов

Поле	Описание
message	Текстовое сообщение о происходящем действии. Примеры: • Created new session – начало сессии; • Execute engine call – информация о начале обработки запроса пользователя; • Executing node – выполненная нода в сценарии;

Поле	Описание
	• Executing block – выполненный блока сценария; • Http request succeeded – успешный http запрос; • An error occurred during request – ошибка в ходе обработки запроса; • An error occurred in node {id ноды} block {id блока} – ошибка в ноде и блоке; • Error in block {id блока} – ошибка в блоке; • Error in Agent block {id блока} – ошибка в блоке агента; • Error in Python code execution – ошибка при выполнении блока с python-скриптом
time	Временная метка события в формате yyyy-MM-dd HH:mm:ss
timestamp	Временная метка в формате Unix-время с миллисекундами
logger_name	Имя логгера
level	Уровень логирования (по умолчанию – INFO)
thread_id	Идентификатор потока, в котором выполнялась операция
process_id	Идентификатор процесса
metadata	Метаданные, включая trace_id, для отслеживания запроса в OpenTelemetry
extra	Дополнительная контекстная информация, которая зависит от типа лога
traceback (при LOG_LEVEL = ERROR)	Последовательность вызовов функций, которая привела к ошибке python-скрипта

Значение поля extra

Основные поля	Описание
request_id	Уникальный идентификатор запроса
session_id	Уникальный идентификатор сессии, связанной с данным запросом
user_id	Уникальный идентификатор пользователя, отправившего запрос
message_original_text	Первоначальный текст сообщения, который был отправлен пользователем
channel_id	Идентификатор канала, через который было отправлено сообщение
message_id	Уникальный идентификатор сообщения
solution_id	Идентификатор решения, соответствующий обработке запроса
solution_version_id	Версия решения, соответствующая обработке запроса
node_id	Уникальный идентификатор ноды, когда выполняется нода
node_name	Имя узла, которое имеет значение для описательного контекста

Основные поля	**Описание**
execution_phase	Фаза выполнения сценария: "PREPROCESSING" или "MAIN"
scenario_id	Идентификатор сценария, связанного с текущим запросом
scenario_name	Имя сценария, также используемое для контекстуальности (например, "Запись к врачу")
block_type	Тип блока, который выполняется (например, "VariablesBlock", "AnswerBlock", "HttpRequestBlock")
block_id	Уникальный идентификатор выполняемого блока
status_code	HTTP-статус код, возвращенный при выполнении HTTP-запроса (например, 200 для успешного запроса)