

Система управления данными в SPD Online Filter

Студент

Научный руководитель

Научный консультант

П. А. Коршунова

Е. Ю. Солдатов

Д. А. Олейник




Online Filter

SPD Online Filter - это высокопроизводительная вычислительная система для высокопропускной обработки данных, собранных детектором SPD

Особенностью **высокопропускной обработки** данных является большой объем данных, как первичных, которые необходимо обработать, так и промежуточных, возникающих в процессе обработки

Цель: существенно сократить объем данных для долговременного хранения, последующей обработки и анализа



Архитектура SPD Online Filter

Промежуточное ПО

Система управления данными

- регистрация, каталогизация, контроль целостности


Система управления процессами обработки

- формирование и контроль исполнения этапов обработки данных


Система управления нагрузкой

- реализация этапов обработки (формирование задач, отправка задач пилотам)

Pilot – приложение, работающее на вычислительном узле и исполняющее задачи



Зачем нужна система управления данными?



Система управления данными: задачи

✓ Регистрация новых данных


Интерфейс для приема
заявок на
добавление/удаление
данных в системе

✓ Каталогизация


Интерфейс к каталогу
данных

✓ Контроль целостности и выгрузки файлов,
удаление файлов на хранилищах,
мониторинг хранилища

Набор фоновых задач
для обеспечения
согласованности
хранилища и каталога



Система управления данными



Архитектура DSM

dsm-register

- сервис, принимающий в асинхронном режиме (через очередь сообщений) заявки на добавление/удаление данных в системе

dsm-manager

- сервис, предоставляющий REST API к каталогу данных (размещение данных в каталоге, обращение к каталогу, изменение данных в каталоге)


dsm-inspector

- набор фоновых сервисов для мониторинга и контроля состояния данных в хранилище

Задачи

- ✓ Реализация сервиса *dsm-register* для взаимодействия с системой управления процессами обработки и с системой управления нагрузкой посредством очередей сообщений
- ✓ Реализация сервиса *dsm-inspector* для контроля состояния данных на хранилищах
- ✓ Проведение этапа интеграционного тестирования между системами (выявление неточностей в реализованном функционале и его доработка)

Структура БД



dsm-register: сконфигурированные очереди

Сервис должен слушать очередь сообщений и обрабатывать заявки на добавление/удаление данных в системе.

В качестве AMQP-брокера, который осуществляет маршрутизацию и подписку на нужные очереди, используется [RabbitMQ](#).

The screenshot shows the RabbitMQ web interface for the 'dsm.register' exchange. The 'Bindings' section is expanded, showing a table of bindings. A red box highlights the bindings for 'dataset.delete', 'dataset.input', and 'dataset.upload' under the 'dataset' routing key, and another red box highlights the bindings for 'file.input', 'file.process', and 'file.process.reply' under the 'file' routing key.

RabbitMQ 4.0.7 Erlang 27.3

Overview Connections Channels **Exchanges** Queues and Streams Admin

Exchange: dsm.register

Overview


Bindings

This exchange

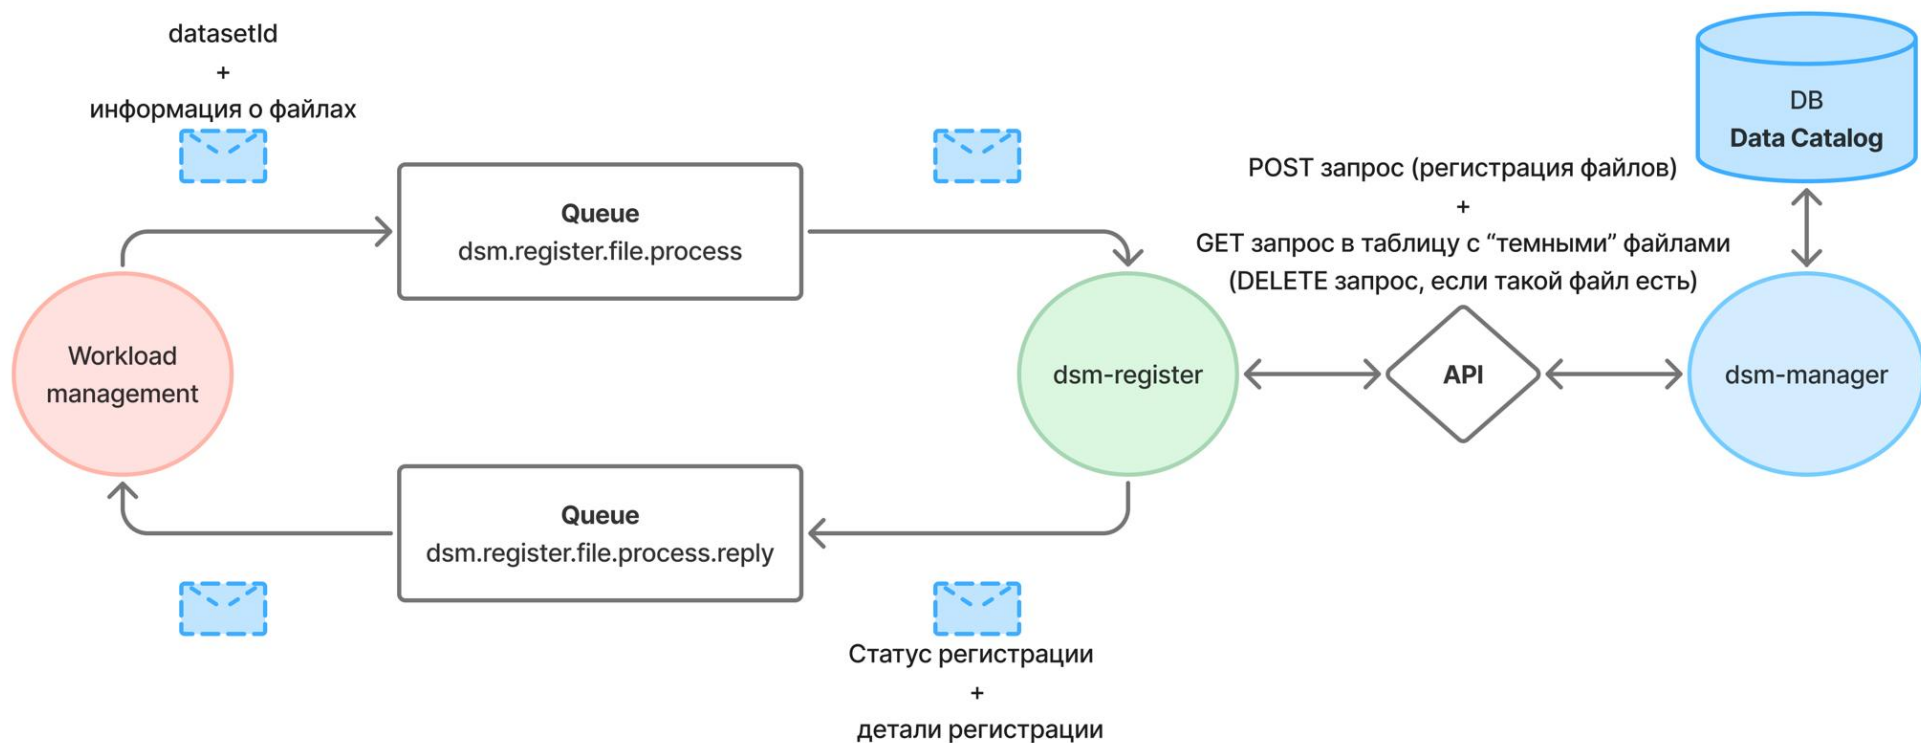
↓

To	Routing key	Arguments	
dsm.register.dataset.close	dataset.close		Unbind
dsm.register.dataset.delete	dataset.delete		Unbind
dsm.register.dataset.input	dataset.input		Unbind
dsm.register.dataset.upload	dataset.upload		Unbind
dsm.register.file.input	file.input		Unbind
dsm.register.file.process	file.process		Unbind
dsm.register.file.process.reply	file.process.reply		Unbind


dsm.register.file.input и dsm.register.dataset.input



dsm.register.file.process и dsm.register.file.process.reply



dsm.register.dataset.delete



dsm-manager: API к БД

file

GET	/api/v1/file/	Get List	✓
POST	/api/v1/file/	Add	✓
GET	/api/v1/file/{file_id}	Get By Id	✓
PUT	/api/v1/file/{file_id}	Update	✓
DELETE	/api/v1/file/{file_id}	Remove	✓
GET	/api/v1/file/file_name/{file_name}	Get By Name	✓

- ✓ Получение содержимого набора
- ✓ Получение списка файлов в определенном статусе



Сервис должен предоставлять REST API к каталогу данных.

В качестве веб-фреймворка используется асинхронный фреймворк **FastAPI**

dataset

GET	/api/v1/dataset/	Get List	✓
POST	/api/v1/dataset/	Add	✓
GET	/api/v1/dataset/{dataset_id}	Get By Id	✓
PUT	/api/v1/dataset/{dataset_id}	Update	✓
DELETE	/api/v1/dataset/{dataset_id}	Remove	✓

- ✓ Получение списка датасетов, в которых есть определенный файл
- ✓ Получение списка датасетов в определенном статусе

dsm-manager: API к БД

storage ^

GET /api/v1/storage/ Get List

POST /api/v1/storage/ Add

GET /api/v1/storage/{storage_id} Get By Id

PUT /api/v1/storage/{storage_id} Update

DELETE /api/v1/storage/{storage_id} Remove

GET /api/v1/storage/type/{storage_type} Get By Type

dark_file ^

GET /api/v1/dark_file/ Get List

POST /api/v1/dark_file/ Add


GET /api/v1/dark_file/{file_name} Get By Name

DELETE /api/v1/dark_file/{file_name} Remove

Сервис состоит из набора **фоновых** задач:


- ✓ Удаление файлов на хранилищах
- ✓ Контроль выгрузки файлов
- ✓ Проверка целостности файлов
- ✓ Контроль использования хранилища

Проверка целостности файлов





Удаление датасетов и файлов

1. Определение списка файлов, подлежащих удалению




2. Удаление файлов в датасетах


2
Удаление файлов с хранилища




3. Удаление датасетов



Удаление темных файлов



Контроль использования хранилища: мониторинг тёмных файлов



Заключение

Текущие результаты:

- ✓ **dsm-manager** полностью функционален для данного этапа реализации
- ✓ **dsm-register** реализован для данного этапа
- ✓ **dsm-inspector** реализован примерно на 50%

Дальнейшие планы:

[dsm-inspector:](#)

Реализовать фоновые сервисы для:

- Контроля выгрузки файлов
- Мониторинга заполненности хранилища

[dsm-register:](#)

Реализовать обработку сообщений из очередей:

- `dsm.register.dataset.close`
- `dsm.register.dataset.upload`

