

РУКОВОДСТВО ПОЛЬЗОВАТЕЛЯ

BI.QUBE

METASTAGING

Компонент разработан ООО «БИАЙ КУБ»

Приказ № _____ от «___»____ 20____ г.

Акт сдачи № _____ от «___»____ 20____ г.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	3
ГЛОССАРИЙ.....	3
1. ЦЕЛИ И НАЗНАЧЕНИЕ METASTAGING	5
2. УСТАНОВКА И ЗАПУСК	5
2.1. Доступ к площадке.....	Ошибка! Закладка не определена.
2.2. Запуск компонента на linux.....	Ошибка! Закладка не определена.
2.3. Запуск компонента на windows	Ошибка! Закладка не определена.
3. ИСТОЧНИКИ META STAGING	6
4. АРХИТЕКТУРА METASTAGING	6
4.1. Описание компонентов системы	6
4.1.1. Утилита шифрования.....	8
4.1.2. Генерация JSON для поля Credentials в таблице stg.source	9
4.1.3. Экстрактор	10
4.1.4. Формирование слоя хранения данных в Greenplum.....	11
4.2. Структура проекта MetaStaging в файловой системе.....	14
4.3. Структура Базы данных.....	15
4.3.1. Настроочные таблицы MetaStaging	16
4.3.2. Таблицы логов MetaStaging	20
4.3.3. Таблицы дескрипторы	24
4.3.4. Хранимые процедуры и функции MetaStaging	25
5. СЦЕНАРИИ РАБОТЫ С METASTAGING	27
5.1. Предварительная настройка компонента	27
5.2. Полная загрузка	27
5.3. Полная загрузка с сохранением истории.....	31
5.4. Инкрементальная загрузка	31
6. ИНФОРМАЦИЯ ДЛЯ ПРОВЕРКИ.....	34

ВВЕДЕНИЕ

Компонент MetaStaging позволяет консолидировать в стейджинговом слое хранилища данные из гетерогенных источников с поддержанием целостности и унифицированности метаданных, также уменьшает нагрузку на операционные базы при выполнении запросов, а кроме того, обеспечивает надежное подключение различных БД из разнородных источников для помещения данных в единый слой стэйджинга (staging area) с поддержанием целостности метаданных в системе-назначения.

В документе приведено описание компонента и принципы работы с ним. Рассмотрены примеры загрузки данных с помощью компонента из разных источников.

Изучение данного документа позволит понять принцип работы компонента.

ГЛОССАРИЙ

1.	MetaStaging - BI.Qube	Инструмент, предназначенный для транспортировки данных.
2.	Хранимая процедура	Объект базы данных, представляющий собой набор SQL-инструкций, который компилируется один раз и хранится на сервере
3.	Представление	Виртуальная таблица, содержимое которой определяется запросом
4.	Бизнес-представление	Представление, в котором собраны Hub, Satellite и Link для сущности
5.	Материализация	Процесс сохранения результата запроса бизнес-представления в таблицу для ускорения выборки.
6.	Инкрементальная загрузка (загрузка с параметрами)	Регулярная загрузка данных в Greenplum. Извлекаются актуальные данные с даты последней загрузки. В таблице stg.session базы данных settings.db можно отследить историю всех загрузок.
7.	Полная загрузка (снэпшоты)	Загрузка данных в Greenplum без параметризации. Применяется, когда необходима полная перезагрузка всех данных в таблице на источнике (например, при отсутствии столбца, подходящего для секционирования).
8.	Полная загрузка с сохранением истории	Загрузка данных в Greenplum без параметризации. Но представления на Greenplum перенацеливаются на новые Parquet-файлы, а старые не удаляются из S3.
9.	Профиль	Добавляются в таблице stg.profile

10.	Экстрактор	Компонент системы для извлечения данных из источников в S3. Исполняемый файл находится в директории LoadingToS3. Вызывается в Airflow в соответствии с командами в настроечной БД (settings.db).
11.	External Table (ET)	Вид таблицы в Greenplum, обеспечивающий доступ к внешним источникам данных, как к объекту самой БД Greenplum. В системе используется для получения доступа к файлам в S3. Используется фреймворк PXF.
12.	Сервисные процедуры	Процедуры, вызываемые автоматически в процессе работы компонента.

1. ЦЕЛИ И НАЗНАЧЕНИЕ METASTAGING

Цель MetaStaging – обеспечить транспортировку данных из систем источников в файловое S3-совместное хранилище данных (HDFS, ObjectStorage) с автоматической генерацией в СУБД Greenplum объектов типа «представление» на каждый полученный файл хранилищем.

Компонент MetaStaging, предназначен для передачи данных из различных источников, как правило, из учетных систем в целевое корпоративное хранилище данных (КХД) с поддержкой целостности метаданных систем-источников, при формировании промежуточного физического слоя хранения учитываются особенности целевой платформы.

Компонент MetaStaging входит в состав системы BI.Qube и может эксплуатироваться как отдельный компонент, так и в составе системы, так и под управлением компонента MetaOrchestrator, в такой конфигурации использование компонента является наиболее эффективной.

2. УСТАНОВКА И ЗАПУСК

Компонент MetaStaging для развертывания, функционирования и настройки использует различные программные инструменты и фреймворки. Обязательным условием является наличие у них открытого исходного кода.

Поддерживаемые операционные системы: Linux (различные дистрибутивы, такие как Ubuntu, Mint, РЕД ОС), другие Unix-подобные системы, а также есть возможность развернуть компонент под Windows.

Настроочные данные компонента могут хранится посредством СУБД: PostgreSQL (9.0 и позднее) / Postgres Pro (10.22 и позднее) / Arenadata Postgres (ADPG) (14.2.1) / Greenplum на выбор заказчика.

Для тестирования корректности загрузки данных в S3 хранилище с помощью файлов «.parquet» использовались инструменты s3-browser и parquet-viewer.

Инструменты разработки DBeaver, Visual Studio Code

Среды выполнения Python, «.Net Core».

В качестве библиотек для взаимодействия с системами источниками и назначениями, а также для обеспечения интеграции данных используются:

- AWSSDK.S3 - Amazon Simple Storage Service для Amazon S3 ([nuget.org](https://www.nuget.org))
- CommandLineParser - Terse syntax C# command line parser for .NET.
- ExcelDataReader - Lightweight and fast library written in C# for reading Microsoft Excel files
- Google.Cloud.BigQuery.V2 - Recommended Google client library to access the BigQuery API.
- Microsoft.Data.SqlClient - Provides the data provider for SQL Server.

- MySql.Data
 - Newtonsoft.Json - Json.NET high-performance JSON framework for .NET
 - Npgsql - is the open source .NET data provider for PostgreSQL.
 - ParquetSharp - .NET library for reading and writing Parquet files.
 - YandexDisk.Client - .NET library wrapper of Yandex Desktop RestAPI.
 - Встроенные модули из стандартной библиотеки Python.
 - Psycopg2 – PostgreSQL database adapter for the Python programming language.
- В связи с высокой сложностью развертывания компонента в среде целевой СУБД установку компонента осуществляет вендор.

3. ИСТОЧНИКИ МЕТА STAGING

В компоненте MetaStaging реализована поддержка следующих источников:

- Rest API
- SQL Server
- PostgreSQL
- MySQL
- Excel (файлы, находящиеся в YandexDisk)

В таблице ниже приведены поддерживаемые типы данных на стороне источников данных.

Источник	Поддерживаемые типы	Неподдерживаемые типы
SQL Server	tinyint, smallint, int, bigint, smallmoney, money, decimal, numeric, bit, real, float, date, time, smalldatetime, datetimeoffset, datetime, datetime2, char, varchar, nchar, nvarchar, text, ntext, binary, varbinary, image, uniqueidentifier, xml	geometry, geography
PostgreSQL	bigint, bigserial, bit varying, boolean, box, bytea, character varying, character, cidr, circle, date, double precision, inet, integer, interval, line, lseg, macaddr, money, numeric, path, point, polygon, real, smallint, text, time without time zone, time with time zone, timestamp without time zone, timestamp with time zone, uuid, xml, json, jsonb	составные типы, диапазонные типы (int8range, datarange), enum,s array, tsquery, tsvector, txid_snapshot
MySQL	all	enum (x,y ...), set
Rest API, Excel	all	

4. АРХИТЕКТУРА METASTAGING

4.1. Описание компонентов системы

Принцип работы MetaStaging сводится к взаимодействию программных блоков, которые отображены на рисунке ниже.




Рисунок 4. Компоненты системы MetaStaging

Краткое описание и назначение основных блоков компонента MetaStaging:

- Блок инициации процесса. Представляет собой Python3-скрипт и отвечает за запуск и координацию остальных блоков для интеграции данных.
- Блок извлечения и загрузки данных (Экстрактор). Представляет собой сборку «.Net Core». Загрузка может осуществляться в S3-совместимое хранилище в файлы «.Parquet».
- Блок генерации представлений. Отвечает за генерацию External tables и представлений в Greenplum, поддерживающих метаданные источников.
- Настрочная БД. Хранит информацию, необходимую для загрузки данных. Также служит интерфейсом для взаимодействия пользователя с MetaStaging. (см. п. *Структура Базы данных*).
- Утилиты. Предназначены для упрощения процесса заполнения настроек таблиц
 - CertificateManager (Утилита шифрования) (см. п. *Утилита шифрования*).
 - CredentialsToJsonSerializer (Генератор Json для credentials источника) (см. п. *Генерация JSON для поля Credentials в таблице stg.source*).

4.1.1. Утилита шифрования

Шифрование ключей, паролей, строк подключения производится в ручном режиме с помощью программы CertificateManager. Программа расположена в директории /home/itpro_admin/CertificateManager/. Публичный и приватные ключи находятся в директории /home/itpro_admin/keytabs/

```
itpro_mgmt@prd-biel1-01:~/CertificateManager$ ./CertificateManager --help
CertificateManager 1.0.0
Copyright (C) 2022 CertificateManager

  encrypt      Зашифровать текст
  decrypt      Расшифровка текста
  generate     Генерация двух ключей
  help         Display more information on a specific command.
  version      Display version information.
```

Рисунок 5. Пример применения утилиты

Пример команды для шифрования текста:

```
~/CertificateManager$ ./CertificateManager encrypt --public-key
./keytabs/public.crt --text "text to encrypt"
```

```
itpro_mgmt@prd-biel1-01:~/CertificateManager$ ./CertificateManager encrypt --public-key ..//keytabs/public.crt --text "text to encrypt"
Зашифрованный текст: 'fePw4my/Ru8Iec0yda4SsAGU1BDSgsBk9obxtVb0ASKHRAQP+oRyYAC4qf3Up7LiXbzhIEvOuZw0d0gmn/z+NLuNK1lP4mm2w1
9at+HugxJ7AzkGM0LDyaj9NB05DbgC6UnH621zrpvyTGAyRR00Q+zvf0ygtPzEngKp15CvzT2b1H0ju5VCYdwFzhNVKCPngzy/wqt1NBpC6320h7UhrReXN
bdUuDjyPmVJnpGwqx/k7ToxSaPE618VKAwAqKo1Pmn51vr7X9M+MPFqGSpP9e73I62EZBu0kXaPv+Vzt0j+i4dqbaNKJZCK7x1mf4xFISXeod0FbNYeNwx1
1HkiLF7q7p0Xy97o51xgQJw3WKhszwIY+xUNtOrStmg7sKptEfuxi+1lHv9j+eg5Wn6j9crNaNKPGh+9UgX1gfZnezb9mxRvrYzeG/Q0Z405gmy2AAKiH2+
5Q6ycwtGv3kKVarC6U6U5wfDZFyYnsRLQ00ecYRR2BQn+1tIBtCdc4pgZQfwfW/iW/namLq5y07NykFgu0fdqDG0SEHXfRcfhC9BPg8R0EBLc5+Cnthalw4wA90
6ESKGWcdq6qizbyejAw26o8wf/hWDJS2MyfICNwHIhiRl3GFpEYOBHkRiz9LREd1SKbfk0Z5HNSgNgXaWR++xiVNMCZ2FCA1lgnIgxZ58='
```

Рисунок 6. Пример применения утилиты

Пример команды для расшифровки текста:

```
~/CertificateManager$ ./CertificateManager decrypt --private-key
./keytabs/private.key --text "text"
```

```
itpro_mgmt@prd-biel1-01:~/CertificateManager$ ./CertificateManager decrypt --private-key ..//keytabs/private.key --text "
fePw4my/Ru8Iec0yda4SsAGU1BDSgsBk9obxtVb0ASKHRAQP+oRyYAC4qf3Up7LiXbzhIEvOuZw0d0gmn/z+NLuNK1lP4mm2w19at+HugxJ7AzkGM0LDyaj9
NB05DbgC6UnH621zrpvyTGAyRR00Q+zvf0ygtPzEngKp15CvzT2b1H0ju5VCYdwFzhNVKCPngzy/wqt1NBpC6320h7UhrReXNbdUuDjyPmVJnpGwqx/k7To
oXSaPE618VKAwAqKo1Pmn51vr7X9M+MPFqGSpP9e73I62EZBu0kXaPv+Vzt0j+i4dqbaNKJZCK7x1mf4xFISXeod0FbNYeNwx11HkiLF7q7p0Xy97o51xgQJ
w3WKhszwIY+xUNtOrStmg7sKptEfuxi+1lHv9j+eg5Wn6j9crNaNKPGh+9UgX1gfZnezb9mxRvrYzeG/Q0Z405gmy2AAKiH2+5Q6ycwtGv3kKVarC6U6U5wf
DZFyYnsRLQ00ecYRR2BQn+1tIBtCdc4pgZQfwfW/iW/namLq5y07NykFgu0fdqDG0SEHXfRcfhC9BPg8R0EBLc5+Cnthalw4wA906ESKGWcdq6qizbyejAw26o
8wf/hWDJS2MyfICNwHIhiRl3GFpEYOBHkRiz9LREd1SKbfk0Z5HNSgNgXaWR++xiVNMCZ2FCA1lgnIgxZ58='
Расшифрованный текст: 'text to encrypt'
```

Рисунок 7. Пример применения утилиты

Данные, которые будут зашифрованы утилитой, помещаются в настроечную БД. В экстракторе они дешифруются и используются для подключения к внешним системам.

Шифруются следующая информация:

- Поля key и secret в таблице *stg.subscription* для подключения к S3-хранилищу.
- Отдельные элементы JSON в поле credentials таблицы *stg.source*.

- Для реляционных источников (PostgreSQL, MySQL, SQL Server) атрибутами являются ConnectionString и ConnectionStringSecure. В 1 передается нешифрованная часть строки подключения, во 2 – шифрованная.

Например, если необходимо зашифровать только пароль, выполняется следующая команда:

```
~/CertificateManager$ ./CertificateManager encrypt --public-key
..../keytabs/public.crt --text "Password=iii435iaf2Ma"
```

Результат передается в элемент **ConnectionStringSecure** для поля credentials.

```
"{
    "ConnectionString": "Server=192.168.72.109;Database=Tests;User
        Id=itpro_admin;TrustServerCertificate=true;",
    "ConnectionStringSecure": "<Результат выполнения утилиты>"
}"
```

- Для других источников обязательно прописывать флаг, указывающий зашифрован ли атрибут.

Пример заполнения поля credentials для RestAPI (можно зашифровать логин и пароль отдельно):

```
"{
    "User": "user@itprocomp.ru",
    "UserEncryption": false,
    "Password": "<Результат выполнения утилиты>",
    "PasswordEncryption": true,
    "AuthType": 1
}"
```

4.1.2. Генерация JSON для поля **Credentials** в таблице stg.source

Для подключения к источникам и указания учетных данных (логинов, паролей, строк подключения) необходимо заполнить поле Credentials таблицы source.

Для упрощения процесса заполнения данного поля необходим воспользоваться программой CredentialsToJsonSerializer, предварительно задав параметры, специфичные для источника. Программа расположена в директории */home/itpro_admin/CredentialsToJsonSerializer/*.

```
itpro mgmt@prd-biel1-01:~/CredentialsToJsonSerializer$ ./CredentialsToJsonSerializer --help
CredentialsToJsonSerializer 1.0.0
Copyright (C) 2022 CredentialsToJsonSerializer

  sqlserver      SqlServer
  postgresql     PostgreSQL
  mysql          MySql
  onedriveexcel  OneDriveExcel
  restapi        RestApi
  yandexdiskexcel YandexDiskExcel
  bigquery       BigQuery
  help           Display more information on a specific command.
  version        Display version information.

itpro mgmt@prd-biel1-01:~/CredentialsToJsonSerializer$
```

Рисунок 8. Пример использования программы

Данная программа преобразует текст в формат, который необходим для успешной загрузки из источника. При помощи ключа --help можно получить дополнительную информацию по любому источнику:

```
itpro_mgmt@prd-bietl-01:~/CredentialsToJsonSerializer$ ./CredentialsToJsonSerializer restapi --help
CredentialsToJsonSerializer 1.0.0
Copyright (C) 2022 CredentialsToJsonSerializer

--user           Required. Имя пользователя для доступа к ресурсу
--user-enc       (Default: false) Зашифровано ли имя пользователя
--password      Required. Пароль для доступа к ресурсу
--password-enc   (Default: false) Зашифрован ли пароль
--auth          Required. Тип аутентификации Rest
--help          Display this help screen.
--version       Display version information.
```

Рисунок 9. Пример использования программы

Пример команды для источника restapi:

```
itpro_mgmt@prd-bietl-01:~/CredentialsToJsonSerializer$ ./CredentialsToJsonSerializer restapi --user abc --password abcd
--password-enc --auth 1
JSON:
>{"User":"abc","UserEncryption":false,"Password":"abcd","PasswordEncryption":true,"AuthType":1}
itpro_mgmt@prd-bietl-01:~/CredentialsToJsonSerializer$
```

Рисунок 1. Пример использования программы

~/CredentialsToJsonSerializer\$./CredentialsToJsonSerializer restapi --user abc --password abcd --password-enc --auth 1

4.1.3. Экстрактор

При вызове блока инициации процесса (python-скрипт, описанный в начале главы) из БД settings автоматически подтягиваются все включенные запросы для всех включенных источников. На основе этого списка генерируются вызовы исполняемого файла экстрактора *GetFromSourceToParquetConsole*.

Путь к файлу – /home/itpro_admint>LoadingToS3.

Таким образом, для пользователя нет необходимости взаимодействовать с этим компонентом, вся нагрузка лежит на блоке инициации процесса или на специализированном оркестраторе (например, MetaOrchestrator, входит в состав системы BI.Qube). В некоторых случаях может потребоваться запустить вручную данный файл, например, чтобы протестировать запрос отдельно. Аналогично предыдущим компонентам работает --help в командной строке.

Перечислим параметры, которые необходимо передать скрипту для взаимодействия с источниками и назначениями:

- Source – необходим для указания модулю типа источника, из которого извлекаются данные. Поле name в таблице *stg.source_type*..
- BatchSize – количество записей при пакетной загрузке данных. Поле batch_size в таблице *stg.command*.
- Command – запрос на получение данных к источнику. Конструкция запроса предполагает SQL-подобную инструкцию Select с

возможностью определения полей и фильтров. Поле *command* в таблице *stg.command*.

- Credentials – реквизиты для подключения к источнику в формате JSON. Опционально реквизиты можно хранить в зашифрованном виде.

Поле *credentials* в таблице *stg.source*.

- FileName – путь к файлу Parquet в S3-хранилище для записи данных из источников. Поле *sink_filename* в таблице *stg.command*.
- Key, Secret, Region, BucketName, Address – прочие параметры, специфичные для загрузки в S3 object storage. Таблицы *subscription* и *bucket*.
- Metadata-json-path – путь к файлам JSON с версиями метаданных запросов.

4.1.4. Формирование слоя хранения данных в Greenplum

Для этой задачи разработан блок генерации внешних таблиц и представлений. Внешние таблицы (external table, ET) позволяют обращаться к файлам формата Parquet как к объектам БД. Представления (view) позволяют поддерживать оригинальные наименования и типы данных источников.


Генератор вызывается на последнем этапе пайплайна (блок инициации процесса). Сборка расположена в директории */home/itpro_admin/DbEntitiesGenerator/*.

В ходе работы генератора на каждый файл в S3-совместимом хранилище создаются внешние таблицы в схеме “*back*”. Если таблицы уже существуют, то пересоздания не происходит.

Загрузка этих таблиц может быть 3 типов (*подробнее в главе 5*):

1. инкрементальная,
2. снэпшоты (полная загрузка),
3. снэпшоты (полная загрузка) с сохранением истории.

Каждый запрос из инкрементальной загрузки представлен в Greenplum перечнем ET (1 загрузка в parquet = 1 ET). Наименование для ET состоит из следующих частей:



Поверх ET формируются представления 2 типов:

1. представление, включающее ET, удовлетворяющие последней версии метаданных (к названию добавляется постфикс, указывающий на номер версии “v003”);
2. общее представление, включает в себя первую версию данных. Далее дополняется вручную пользователем.

```

> bq_marketing_datalake_analytics_255573231_events
> bq_marketing_datalake_analytics_255573231_events_v001
> bq_marketing_datalake_analytics_255573231_events_v002
> bq_marketing_datalake_analytics_255573231_events_v003

```

Аналогичный сценарий с версиями используется для снэпшотов. Файлы Parquet либо перезаписывается, либо обновляется с сохранением истории в S3

Пример SQL-запроса для генерации внешней таблицы:

CREATE EXTERNAL TABLE

```

monopolysun.public.20221104002_MS_DocumentsInsurance (
    id text,
    Sum numeric
)
LOCATION (
    'pxf://monopoly-sun-
temp/incremental/*/*/*/DocumentsInsurance_*.parquet?PROFILE=s3:parquet&accesskey=YCAJEcQEeeSmEXJ2wUXJK_NyO&secretkey=YCO9wLy5_O8C9mA3CgcV4kXn
QrJCddd6ZLklp4&endpoint=storage.yandexcloud.net&SERVER=storage'
) ON ALL
FORMAT 'CUSTOM' (FORMATTER='pxfwrifiable_import')
ENCODING 'UTF8';

```

Пример SQL-запроса для генерации представлений:

```

CREATE OR REPLACE VIEW public.pg_prdflpg01_fuelsupplyschemes_v001
AS SELECT q.id,
    q.updatedat,
    q.filledtype,
    q.servicemethod
FROM
(
    SELECT
        "20171231001_pg_prdflpg01_fuel_fuelsupplyschemes"."Id"::uuid AS id,
        to_timestamp(("20171231001_pg_prdflpg01_fuel_fuelsupplyschemes"."Updated
        At"/ 1000000)::double precision)::timestamp without time zone AS updatedat,
        "20171231001_pg_prdflpg01_fuel_fuelsupplyschemes"."FilledType" AS
        filledtype,
        "20171231001_pg_prdflpg01_fuel_fuelsupplyschemes"."ServiceMethod" AS
        servicemethod
    FROM back."20171231001_pg_prdflpg01_fuel_fuelsupplyschemes"
) q
WHERE
    q.updatedat >= '1900-01-01 00:00:00'::timestamp without time zone
    AND
    q.updatedat < '2017-12-31 21:00:00'::timestamp without time zone;

```




Рисунок 2. Алгоритм формирования слоя в Greenplum

Условие “WHERE” в данном случае помогает оптимизатору Greenplum не сканировать все ЕТ, когда нужно взять из одной конкретной ЕТ. Чтобы данное условие было добавлено необходимо заполнить `partition_column`.

На рисунке ниже представлен полный путь перекладки данных из источников в назначение.

Внешние таблицы ссылаются на файлы с помощью протокола PXF, рекомендуемого для чтения из S3-хранилища в документации Yandex-Cloud. Список поддерживаемых типов данных PXF и сопоставление с Greenplum можно посмотреть здесь:

[Reading and Writing HDFS Parquet Data | Pivotal Greenplum Docs](#)

4.2. Структура проекта MetaStaging в файловой системе

Путь к файлам MetaStaging на Windows и на Linux отличается.




Рисунок 3. Путь в файловой системе Windows

Файлы MetaStaging на Linux находятся в папке home пользователя itpro_admin.

В общем виде структура проекта выглядит следующим образом:




Рисунок 4. Файловая система компонента

CertificateManager – это «Утилита шифрования», описанная в предыдущем разделе.

CredentialsToJSON – содержит сборку утилиты «Генерация JSON для поля Credentials».

DbEntitiesGenerator – это сборка для «Формирования слоя хранения данных на Greenplum».

Json_schema – данный каталог содержит JSON-файлы с метаданными запросов из источника, которые выполнялись в рамках конкретных сессий. Эти данные записываются в БД в таблицу *stg.last_command_metadata*.

Keytabs – данный каталог содержит ключи для шифрования и расшифрования конфиденциальной информации. Каталог используется экстрактором (в файле app.config проекта указан путь к каталогу) и утилитой CertificateManager.

LoadingToS3 – содержит сборку с экстрактором.

MetastagingExecutor – содержит python-скрипт инициации процесса.

4.3. Структура Базы данных

Таблицы MetaStaging делятся на три категории:

- *Настроочные таблицы* – данные вносит пользователь в соответствии с правилами заполнения.
- *Таблицы логов (заполняются автоматически)* – данные вносит система по итогам выполнения очередной сессии.
- *Таблицы дескрипторы (заполнены разработчиком)* – данные внесены предварительно в соответствии с реализованным функционалом.




Рисунок 5.Структура таблиц MetaStaging

4.3.1. Настроочные таблицы *MetaStaging*

1. «**stg.subscription**» – список ключей необходимых для доступа к сервисам S3. Можно записывать как в шифрованном, так и в незашифрованном виде.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
subscription_id	int	Автоинкрементен	Идентификатор ключа для доступа к сервисам
key	varchar	Вручную	Ключ
secret	varchar	Вручную	Секретный ключ
address	text	Вручную	Адрес хоста с установленным S3 MinIO

WHERE ORDER BY			
subscription_id	key	secret	address
1	2	-	https://s3.yandexcloud.net
2	1 gAPnn0e0rvfBu0j4bcKVw667...	i0168zdLrhLMloEwfA07ygfZZGU9MW/CfEloWPYJrRFQINYC1...	http://192.168.72.47:9000

Рисунок 6. Таблица «*stg.subscription*»

2. «**stg.bucket**» – список каталогов S3-хранилища, доступных для размещения файлов parquet.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
bucket_id	int	Автоинкремент	Идентификатор каталога
name	text	Вручную	Имя каталога
region	text	Вручную	Регион, в котором создаются бакеты (для MinIO не указывается)
subscription_id	int	Вручную	Идентификатор ключа для доступа к сервисам

WHERE ORDER BY			
bucket_id	name	region	subscription_id
1	2 rosreestr	<null>	1

Рисунок 7. Таблица «*stg.bucket*»

3. «**stg.source**» – информация, необходимая системе для доступа к источникам данных.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
source_id	int	Автоинкремент	Идентификатор источника

name	varchar	Вручную	Название источника, не влияет на загрузку данных
description	text	Вручную	Описание источника, необязательное поле
credentials	json	Вручную	Учетные данные для подключения определенного источника в формате JSON
enabled	bool	Вручную	Метка о необходимости выполнения/игнорирования всех запросов к данному источнику
max_connections	int	Вручную	Максимальное количество одновременных запросов на выполнение, разрешенных для источника
source_type_id	int	Вручную	Ссылка на тип источника

source_id	name	description	credentials	enabled	max_connections
2	Arenadata-pg-kinopoisk		7 {"ConnectionString":	• true	8
1	test_postgre	Тест загрузки данны...	7 {"ConnectionString":	• true	8
3	MySQL-view	Компиляция отзывов...	4 {"ConnectionString":	• true	8
4	SQL Server	<null>	6 {"ConnectionString":	• true	8

Рисунок 8. Таблица «stg.source»

4. «stg.command» – список запросов к источникам.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
command_id	int	Автоинкремент	Идентификатор команды
batch_size	int	Вручную	Количество строк выгружаемых из источников в файл Parquet за одну итерацию при пакетной загрузке
command	text	Вручную	Текст запроса с возможностью параметризации. Используется Select-подобный синтаксис, при работе экстрактора запрос корректируется в соответствии с требованиями источника
description	text	Вручную	Описание команды
full_name	text	Вручную	Полное наименование команды
name	varchar	Вручную	Наименование команды, длина до 51 символа! Влияет на наименование файла Parquet
sink_filename	text	Вручную	Путь к Parquet-файлу в S3-совместимом хранилище
source_id	int	Вручную	Ссылка на источник
partition_column	text	Вручную	Поле в запросе, по которому выполняется секционирование на представлениях Greenplum. Если данное поле задано (например, <i>UpdatedAt</i>), в запросе можно писать так <code></*!{partition_column}*/ >= /*{datefrom}*/></code>
partition_column_convert	text	Вручную	Поле содержит логику конвертации для значения в partition_column. Данная логика будет отражена в представлении на Greenplum. Пример: <code>cast(*{partition_column}*/ as bigint)</code>

		command_id	source_id	name	description	command	sink_filename	batch_size	bucket_id	load_type_id
1	2	1	Футболисты	Перечень футболистов	select id, name from football			10000	2	2
2	3	2	Kinopoisk	Русскоязычные Отзывы	select * from kinopoisk_rus_reviews			1000	2	2
3	4	3	Multilang	Представление - языки	select * from multilanguage_reviews			100000	2	2
4	5	4	Dialogs-exp	<null>	select * from dialogs_expanded			10000	2	2

Рисунок 9. Таблица «stg. command»

5. «stg.profile» – список профилей загрузки. На основе данной таблицы (совместно с profile_command) запросы к источникам будет разделены на несколько DAG'ов в оркестраторе.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
profile_id	int	Автоинкремент	Идентификатор профиля
name	varchar	Вручную	Название профиля
description	varchar	Вручную	Описание профиля
enabled	bool	Вручную	Метка о необходимости выполнения/игнорирования данного профиля
owner	varchar	Вручную	Владелец графа выполнения (<i>используется только при наличии оркестратора</i>)
scheduler_interval	varchar	Вручную	Интервал запуска DAG'ов, может принимать в себя явное cron выражение, алиас (@daily, @monthly и тд) или спец-слово None, что приведет к отключению автоматического планирования и запуска задач по расписанию (<i>используется только при наличии оркестратора</i>)
start_date	date	Вручную	Дата начала профиля

		profile_id	name	description	owner	start_date	enabled	shceduler_interval	tags	catch_up
1		test_rosreestr	<null>	Дьячков Никита	2022-11-20	true	None	<null>	<null>	

Рисунок 19. Таблица «stg.profile»

6. «profile_command» – соответствие выполняемых команд профилям загрузки. Одна команда может использоваться несколькими профилями, один профиль может выполнять несколько команд.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
profile_command_id	int	Автоинкремент	Идентификатор профиля, команды
profile_id	int	Вручную	Идентификатор профиля
command_id	int	Вручную	Идентификатор команды
enabled	bool	Вручную	Метка о необходимости выполнения/игнорирования данного запроса

	WHERE	ORDER BY			
	profile_command_id	profile_id	command_id	enabled	
1		1		2	false
2		2		3	false
3		4		5	true
4		3		4	false

Рисунок 10. Таблица «profile_command»

7. **«parameter»** – список параметров для использования в запросах к источникам.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
parameter_id	int	Автоинкремент	Идентификатор параметра
name	text	Вручную	Наименование параметра, указывается в запросе
value	text	Вручную	Значение параметра, подставляется в запрос при работе экстрактора
evaluated_expression	text	Вручную	SQL-выражение, которое преобразует value к требуемому формату.
is_max_date	bool	Вручную	Указание экстрактору, ссылаться ли на value в запросе или не указывать в нем верхнюю границу (брать актуальные данные, начиная от конкретной даты)
is_prev_depend	text	Вручную	Указание экстрактору, ссылаться ли на value или использовать дату, зависящую от последней сессии

WHERE	ORDER BY					
parameter_id	name	value	is_prev_depend	is_max_date	evaluated_expression	

Рисунок 11. Таблица «parameter»

8. **command_parameter** – ссылки на таблицы command и parameter.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
command_parameter_id	int	Автоинкремент	Идентификатор параметра, команды
command_id	int	Вручную	Идентификатор команды
parameter_id	int	Вручную	Идентификатор параметра

WHERE		ORDER BY		
	command_parameter_id	command_id	parameter_id	
1	3	8	1	
2	4	8	2	

Рисунок 12 Таблица «command_parameter»

4.3.2. Таблицы логов MetaStaging

Данные таблицы заполняются в процессе работы компонента

1. «session» – список запусков пайплайна.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
sessionID	int	Автоинкремент	Идентификатор сессии
start_ts	timestamp	Автоматически	Дата и время запуска работы MetaStaging
date_to	timestamp	Автоматически	Дата окончания сессии
success	bool	Автоматически	Идентификатор успешности загрузки в рамках данной сессии
dag_id	varchar	Автоматически	Наименования графа загрузки (<i>используется только при наличии оркестратора</i>)
local_session_id	int	Автоматически	Локальный идентификатор сессии относительно дня (когда запрос выполняется несколько раз за день)

WHERE		ORDER BY				
	session_id	start_ts	date_to	success	dag_id	local_session_id
1	1	2022-11-20 23:1...	2022-11-20 00:00:00.00...	false	test_rosreestr	1
2	2	2022-11-22 21:5...	2022-11-20 00:00:00.00...	false	test_rosreestr	2
3	3	2022-11-27 20:1...	2022-11-27 23:12:26.87...	false	test_rosreestr	1
4	4	2022-11-27 20:1...	2022-11-27 23:17:17.37...	false	test_rosreestr	2
5	5	2022-11-27 20:2...	2022-11-27 23:24:38.60...	false	test_rosreestr	3
6	6	2022-11-27 20:2...	2022-11-27 23:28:39.71...	false	test_rosreestr	4
7	7	2022-11-27 20:4...	2022-11-27 20:47:44.03...	false	test_rosreestr	5
8	8	2022-11-28 06:4...	2022-11-28 06:43:39.94...	false	test_rosreestr	1
9	9	2022-11-28 10:2...	2022-11-28 00:00:00.00...	false	test_rosreestr	2
10	10	2022-11-28 07:4...	2022-11-28 10:48:43.91...	false	test_rosreestr	3
11	11	2022-11-28 08:2...	2022-11-28 11:29:54.78...	false	test_rosreestr	4
12	12	2022-11-28 14:4...	2022-11-28 14:46:56.62...	false	test_rosreestr	5
13	13	2022-11-28 14:4...	2022-11-28 14:48:16.60...	false	test_rosreestr	6
14	14	2022-11-29 14:3...	2022-11-29 14:38:04.91...	false	test_rosreestr	1
15	15	2022-11-29 14:3...	2022-11-29 14:39:55.95...	false	test_rosreestr	2
16	16	2022-11-29 14:5...	2022-11-29 14:50:03.97...	false	test_rosreestr	3
17	17	2022-11-29 14:5...	2022-11-29 14:51:39.87...	false	test_rosreestr	4
18	18	2022-11-29 15:0...	2022-11-29 15:00:14.37...	false	test_rosreestr	5
19	19	2022-11-29 15:1...	2022-11-29 15:12:30.46...	false	test_rosreestr	6

Рисунок 13. Таблица «session»

2. «session_command» – список запросов для извлечения данных из источников в S3-хранилище. Запросы разделены на секции, в рамках которых выполнялись.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
session_comm and ID	int	Автоинкремент	Идентификатор строки
commad_with_parameters	text	Автоматически	Окончательный текст запроса, отправляемого на источник данных
success	bool	Автоматически	Метка об успешном выполнении запроса
sink_filename_with_parameters	text	Автоматически	Полный путь к файлу parquet в рамках S3-совместимого хранилища.
session ID	int	Автоматически	Идентификатор сессии
commad ID	int	Автоматически	Идентификатор команды

▼ WHERE ORDER BY session_command_id					
	session_command_id	session_id	command_id	command_with_parameters	success
1	1	1	2	SELECT id, "Name", age, nationalit...	false
2	2	2	2	SELECT id, "Name", age, nationalit...	true
3	3	3	2	SELECT id, "Name", age, nationalit...	false
4	4	4	2	SELECT id, "Name", age, nationalit...	false
5	5	5	2	SELECT id, "Name", age, nationalit...	false
6	6	6	2	SELECT id, "Name", age, nationalit...	false
7	7	7	2	SELECT id, "Name", age, nationalit...	false
8	8	8	2	SELECT id, "Name", age, nationalit...	false
9	9	9	2	SELECT id, "Name", age, nationalit...	false
10	10	10	2	SELECT id, "Name", age, nationalit...	false
11	11	11	2	SELECT id, "Name", age, nationalit...	false
12	12	12	2	select id, "Name", age, nationalit...	false
13	13	13	2	select id, name, age, nationality,...	true
14	14	14	2	select id, name, age, nationality,...	true
15	15	15	2	select id, name, age, nationality,...	true
16	16	16	2	select id, name, age, nationality,...	true
17	17	17	2	select id, name, age, nationality,...	true
18	18	18	2	select id, name, age, nationality,...	true

Рисунок 14. Таблица «session_command»

3. «command_version» – список существующих версий для конкретных команд с указанием периода их действия.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
command_version ID	int	Автоинкремент	Идентификатор версии
date_from	timestep	Автоматически	Фактическая дата начала загрузки
date_to	timestep	Автоматически	Фактическая дата окончания загрузки
version num	int	Автоматически	Номер версии запроса к источнику
command_id	int	Автоматически	Ссылка на команду


▼ WHERE ORDER BY command_version_id					
	command_version_id	date_from	date_to	version_num	command_id
1	1	2022-11-24 19:18:37.144075	9999-01-01 00:00:00.000000	1	2
2	2	2022-12-01 09:00:49.148210	9999-01-01 00:00:00.000000	1	3
3	3	2022-12-01 16:03:02.410113	9999-01-01 00:00:00.000000	1	4

Рисунок 15. Таблица «command_version»

4. «**command_metadata**» – список наименований и типов данных полей, включенных в запросы к источникам за всю историю выполнений этих запросов.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
command_metadata ID	int	Автоинкремент	Идентификатор метаданных команды
command_version ID	int	Автоматически	Идентификатор команды, версии
field_source_name	text	Автоматически	Наименование поля в источнике
field_type	text	Автоматически	Тип данных поля на различных этапах интеграции
field_parquet_name	text	Автоматически	Наименование поля, допустимое для записи в Parquet и чтения в Greenplum через External Table (замена пробелов и специальных символов)
version_num	int	Автоматически	Версия метаданных запроса. По умолчанию равна 1. При изменении метаданных значение увеличивается
field_num	int	Автоматически	Номер поля в запросе к источнику, используется для сохранения порядка полей в Greenplum относительно порядка в источнике



The screenshot shows a table with 18 rows of data from the 'command_metadata' table. The columns are: command_metadata_id, command_version_id, field_source_name, field_parquet_name, field_type, and stage_id. The data includes various field names like id, name, age, nationality, club, and their corresponding types such as integer, System.Int32, character varying, String, ByteArray, and System.String.

	WHERE	ORDER BY	command_metadata_id	command_version_id	field_source_name	field_parquet_name	field_type	stage_id
1			1	1	id	id	integer	
2			2	1	id	id	System.Int32	
3			3	1	id	id	Int(bitWidth=32, isSigned=true)	
4			4	1	id	id	Int32	
5			5	1	name	name	character varying	
6			6	1	name	name	System.String	
7			7	1	name	name	String	
8			8	1	name	name	ByteArray	
9			9	1	age	age	integer	
10			10	1	age	age	System.Int32	
11			11	1	age	age	Int(bitWidth=32, isSigned=true)	
12			12	1	age	age	Int32	
13			13	1	nationality	nationality	character varying	
14			14	1	nationality	nationality	System.String	
15			15	1	nationality	nationality	String	
16			16	1	nationality	nationality	ByteArray	
17			17	1	club	club	character varying	
18			18	1	club	club	System.String	

Рисунок 16. Таблица «command_metadata»

5. «**last_command_metadata**» – список наименований и типов данных полей при последнем выполнении конкретного запроса. Здесь всегда хранится актуальная версия метаданных. При формировании представлений на Greenplum данные из этой таблицы сравниваются с данными из таблицы *command_metadata* для проверки изменений (добавлено поле, изменен тип и тд).

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
last_command_metadata_id	int	Автоинкремент	Идентификатор строки
field_source_name	text	Автоматически	Наименование поля в источнике
field_type	text	Автоматически	Тип данных поля на этапах интеграции
field_parquet_name	text	Автоматически	Наименование поля, допустимое для записи в Parquet и чтения в Greenplum через External Table (замена пробелов и специальных символов)
field_num	int	Автоматически	Номер поля в запросе к источнику, используется для сохранения порядка полей в Greenplum относительно порядка в источнике

1	509	sentence_uuid	sentence_uuid	VARCHAR		1	4		
2	510	sentence_uuid	sentence_uuid	System.String		2	4		
3	511	sentence_uuid	sentence_uuid	String		3	4		
4	512	sentence_uuid	sentence_uuid	ByteArray		4	4		
5	513	sentence_text	sentence_text	VARCHAR		1	4		
6	514	sentence_text	sentence_text	System.String		2	4		
7	515	sentence_text	sentence_text	String		3	4		
8	516	sentence_text	sentence_text	ByteArray		4	4		
9	517	language	language	VARCHAR		1	4		
10	518	language	language	System.String		2	4		
11	519	language	language	String		3	4		
12	520	language	language	ByteArray		4	4		
13	521	domain	domain	VARCHAR		1	4		
14	522	domain	domain	System.String		2	4		
15	523	domain	domain	String		3	4		
16	524	domain	domain	ByteArray		4	4		
17	525	labelled	labelled	VARCHAR		1	4		
18	526	labelled	labelled	System.String		2	4		

Рисунок 17. Таблица «last_command_metadata»

6. «session_parameter» – информация о параметрах запросов, выполняемых в рамках сессии.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
session_parameter_id	int	Автоинкремент	Идентификатор строки
session_id	int	Автоматически	Ссылка на сессию
Parameter_id	int	Автоматически	Ссылка на параметр
Parameter_value	text	Автоматически	Значение параметра
Is_prev_depend	bool	Автоматически	Поле, аналогичное полю из <i>stg.parameter</i>
Is_max_date	bool	Автоматически	Поле, аналогичное полю из <i>stg.parameter</i>
Command_id	int	Автоматически	Ссылка на команду
Parameter_name	text	Автоматически	Наименование параметра из таблицы <i>stg.parameter</i>

	session_parameter_id	session_id	parameter_id	parameter_value	is_prev_depend	is_max_date	command_id	parameter_name
1	1	32	1	2020	false	false	7	year_from
2	2	32	2	2022	false	false	7	year_to
3	3	33	1	2020	false	false	7	year_from
4	4	33	2	2022	false	false	7	year_to
5	5	34	1	2020	false	false	7	year_from
6	6	34	2	2022	false	false	7	year_to
7	7	35	1	'1900-01-01 00:00:00'	true	false	8	date_from
8	8	35	2	'2022-12-05 08:51:23'	false	true	8	date_to
9	9	36	1	'2022-12-05 08:51:23'	true	false	8	date_from
10	10	36	2	'2022-12-05 14:45:15'	false	true	8	date_to
11	11	37	1	'2022-12-05 08:51:23'	true	false	8	date_from
12	12	37	2	'2022-12-06 14:11:21'	false	true	8	date_to

Рисунок 18. Таблица «session_parameter»

4.3.3. Таблицы дескрипторы

Данные в этих таблицах описывают функциональные части компонента. Они заполняются автоматически при развертывании MetaStaging. И используются только в качестве ссылок при заполнении настроек таблиц.

1. «stage» – список этапов интеграции данных.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
Stage_ID	int	Автоинкремент	Идентификатор строки
name	text	Автоматически	Наименование этапа интеграции <i>source</i> – метаданные системы-источника, <i>logical</i> – логический тип хранения в Parquet, <i>physical</i> – физический тип хранения Parquet, <i>dotnet</i> – тип данных «.Net Core» используемый в экстракторе для извлечения из источника

stage_id	name
1	source
2	logical
3	physical
4	dotnet

Рисунок 29. Таблица «stage»

2. «load_type» – список режимов загрузки данных из источников.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
load_type_id	int	Автоинкремент	Идентификатор строки

name	text	Автоматически	Наименование типа загрузки
WHERE			
			ORDER BY
		load_type_id	name
1			1 Секционированная загрузка
2			2 Полная загрузка
3			3 Полная загрузка с сохранением истории

Рисунок 19. Таблица «load_type»

3. «source_type» – список поддерживаемых источников.

Поля таблицы:

Имя столбца	Тип данных	Источник	Назначение
source_type_id	int	Автоинкремент	Идентификатор строки
name	varchar	Автоматически	Наименование источника
credentials_template	json	Автоматически	Справочная информация – JSON шаблон заполнения поля credentials в stg.source
short_name	varchar	Автоматически	Краткое наименование

WHERE	ORDER BY
	source_type_id
	name
	credentials_template
	short_name
1	1 bigquery
2	2 onedriveexcel
3	3 yandexdiskexcel
4	4 mysql
5	5 restapi
6	6 sqlserver
7	7 postgresql

Рисунок 20. Таблица «source_type»

4.3.4. Хранимые процедуры и функции *MetaStaging*

Представленные далее процедуры и функции являются сервисными, то есть, вызов пользователями запрещен.

stg.init_session – инициализирует новую сессию загрузки данных, и выполняет подстановку параметров в запросы к источникам, заполняя таблицы логов (stg.session_command).

Параметры:

- profile_id – идентификатор профиля загрузки.

- `start_ts_var` – дата запуска сессии.
- `dag_id` – название профиля (при отсутствии оркестратора, можно передавать любое текстовое значение).

Возвращает:

- JSON с данными, необходимыми для запуска экстрактора (см. раздел 4.1.3.), включая `id` новой сессии и список запросов к источникам (`id` команды, текст команды, путь к файлу в S3-хранилище).

stg.get_sample_commands

Параметры:

- `profile_id` – идентификатор профиля загрузки.

Возвращает:

- JSON с данными, необходимыми для создания каталога в файловой системе «`json_schema`» (п. Генерация JSON для поля `Credentials` в таблице `stg.source`) и для запуска экстрактора (п. Экстрактор).

stg.compare_metadata – вызывается для конкретного запроса к источнику с целью проверки изменения метаданных текущей таблицы с таблицей, загруженной в прошлой сессии. Заполняет таблицы `stg.command_version` и `stg.command_metadata`.

Параметры:

- `command_id` – идентификатор запроса к источнику.

Возвращает:

- Номер актуальной версии метаданных.

stg.mark_command_success – Помечает запросы, которые были выполнены корректно (включая создание представлений на Greenplum), как успешные: `none success в stg.session_command = True`.

Параметры:

- `command_id`

stg.mark_session_success - Помечает сессии, которые были выполнены корректно как успешные: `none success в stg.session = True`.

Параметры:

- `command_id`

5. СЦЕНАРИИ РАБОТЫ С METASTAGING

MetaStaging предназначен для организации процесса передачи данных из различных источников. На рисунке ниже приведена общая схема движения данных в процессе работы компонента MetaStaging.




Рисунок 21. Алгоритм работы MetaStaging

Для того, чтобы MetaStaging осуществил указанную выше интеграцию, необходимо заполнить настроечные таблицы. В зависимости от типа загрузки данных (инкрементальная загрузка, полная загрузка, полная загрузка с сохранением истории) алгоритм заполнения этих таблиц меняется:

5.1. Предварительная настройка компонента

Предварительная настройка компонента (заполнение БД для тестового запуска) осуществляется разработчиком, что позволяет пользователю сразу приступить к решению своих задач, не вдаваясь в подробности настройки.

При необходимости пользователь может протестировать MetaStaging на собственных:

- S3-совместимом хранилище,
- системе источнике
- произвольных запросах к различным системам.

5.2. Полная загрузка

1. Необходимо заполнить таблицу «`stg.profile`». Поля «`name`» «`description`» «`owner`» должны содержать информацию об имени, описании и владельце профиля соответственно. В поле «`start_date`» вносится дата начала работы с профилем. Поле «`enabled`» «включает» тот или иной профиль.

WHERE		ORDER BY				
	profile_id	name	description	owner	start_date	enabled
1		test_rosreestr	<null>	Дьячков Никита	2022-11-20	true

Рисунок 22. Таблица «stg.profile»

2. Для доступа к S3-хранилищу заполняется таблица «stg.subscription». В поле «key» указывается ключ, в поле «secret» указывается секретный ключ, они хранятся в зашифрованном виде, поле «address» заполняется по адресу сервера, на котором установлен S3. Исходные ключи передаются отдельно по запросу для тестирования метакомпонента, как правило, эти данные хранятся в настройках S3 хранилища.

WHERE		ORDER BY		
	subscription_id	key	secret	address
1	2	-	-	https://s3.yandexcloud.net
2	1	gAPnn0e0rvfBu0j4bcKV...	i0168zdLrhLMloEwfA07ygfZZGU9MW/CfEloWPYJrRFQINYC1qiF72bDkpmEy...	http://192.168.72.47:9000

Рисунок 23. Таблица «stg.subscription»

3. Заполняется «name» в таблице «stg.bucket» и в колонке «subscription_id» задается ссылка на таблицу «stg.subscription» (в данном случае в нем указано значение «1», что в данном случае соответствует идентификатору ключа для доступа к сервисам), при этом «bucket_id» задается автоматически.

WHERE		ORDER BY		
	bucket_id	name	region	subscription_id
1	2	rosreestr	<null>	1

Рисунок 24. Таблица «stg.bucket»

4. Необходимо заполнить таблицу «stg.source». В поле «name» нужно задать имя источника (целесообразно указывать имя источника из таблицы «source_type»), в поле «source_type_id» необходимо указать id источника из таблицы «stg.source_type».

WHERE		ORDER BY		
	source_id	name	description	source_type_id
1	2	Arenadata...		7
2	1	test_postg...	Тест загрузки данных...	7
3	3	MySQL-view	Компиляция отзывов ...	4
4	4	SQL Server	<null>	6
5	7	REST	Загрузка отзывов по ...	5
6	8	Yandex-Dism...	Загрузка данных о пр...	3

Рисунок 25. Таблица «stg.source»

Поле «credentials» содержит данные для подключения к системе-источнику, а также указание экстрактору о необходимости шифрования/дешифрования отдельных элементов.

В зависимости от источника формат строки может отличаться. Для преобразования к формату JSON необходимо использовать программу «`CredentialsToJsonSerializer`» (см. п. Генерация JSON для поля `Credentials` в таблице `stg.source`).

Чтобы правильно заполнить «`credentials`» нужно ввести в консоль:

```
Host = 192.168.72.52; Port = 5432; Database = postgres; User = postgres;
Password = ****
```

```
itpro_admin@biqube-etl-01:~$ ./CredentialsToJsonSerializer postgresql
--cstring "Host=192.168.72.52;Port=5432;Database=postgres;User=postgres;
s;Password=MNBrewq123;" --cstring-secure ""
```

Рисунок 26. Пример работы с консолью

Полученный результат необходимо внести в поле «`credentials`» в таблицу «`stg.source`». В зависимости от источника в поле «`credentials`» могут быть разные записи:

Наименование источника (таблица <code>stg.source.type</code>)	« <code>credentials</code> »
yandexdiskexcel	{ "Token": "<token> Get Yandex token URL: https://oauth.yandex.ru/authorize?response_type=token&client_id=6105ac8902804c838a5892404c0b39a2", "TokenEncryption": false, "RootFolder": "disk:/<put your path>", "RootFolderEncryption": false }
mysql	{ "ConnectionString": "server=<server_name>;uid=<user_name>;pwd=<password>;database=<db_name>;default command timeout=200;", "ConnectionStringSecure": "" }
restapi	{ "User": "<User>", "UserEncryption": true, "Password": "<Password>", "PasswordEncryption": true, "AuthType": 1 }
sqlserver	{ "ConnectionString": "Data Source=<servername>;TrustServerCertificate=Yes;Initial Catalog=cargoowner;Trusted_Connection=True", "ConnectionStringSecure": "" }
postgresql	{ "ConnectionString": "Data Source=<servername>;TrustServerCertificate=Yes;Initial Catalog=cargoowner;Trusted_Connection=True", "ConnectionStringSecure": "" }

В поле «`enabled`» необходимо задать «`true`». В поле «`max_connections`» задается максимальное желаемое количество запросов к источнику.

	source_id	name	description	source_type_id	credentials	enabled	max_connections
1	2	Arenadata-pg...		7	{"ConnectionString": "Ho...}	true	8
2	1	test_postgre	Тест загрузки данных из Postgr...	7	{"ConnectionString": "Ho...}	true	8
3	3	MySQL-view	Компиляция отзывов с зарубежн...	4	{"ConnectionString": "se...}	true	8
4	4	SQL Server	<null>	6	{"ConnectionString": "S...}	true	8
5	7	REST	Загрузка отзывов по REST-API	5	{"User": "none", "User...}	true	1

Рисунок 27. Таблица «stg.source»

5. Необходимо заполнить таблицу «stg.command». Поля «name» и «description» заполняются по наименованию добавляемого объекта и описания соответственно.

	command_id	source_id	name	description	command	sink_filename	batch_size	bucket_id
1	2	1	Футболисты мира	Перечень футболисто...	select id, nam...	football	10000	2
2	9	7	REST-reviews	<null>	select * from ...	rest_reviews	1000	2
3	4	3	Multilanguage-rev...	Представление - 0,5...	select * from ...	multilanguage_rev...	100000	2
4	8	2	Movies-tickets	Продажа билетов	select * from ...	movie_tickets	10000	2
5	7	2	Movies-appear	Фильмы и даты их вы...	select * from ...	movies_appear	10000	2
6	3	2	Kinopoisk-rus-rev...	Русскоязычные Отзы...	select * from ...	kinopoisk_rus_rev...	1000	2
7	6	2	Ivi-rus-reviews	Русскоязычные отзывы	Select * from ...	ivi_rus_reviews	10000	2
8	5	4	Dialogs-eng	<null>	select * from ...	dialogs_expanded	10000	2

Рисунок 39. Таблица «stg.command»

Для каждого источника правила написания запроса для поля «command» отличаются:

Наименование источника (таблица stg.source.type)	Запрос для поля «command» таблицы «stg.command»		
yandexdiskexcel	<code>select * from file 'D:\file.xlsx:[ЛИСТИ]' with (HaveHeader, LoadFirstRow)</code>		
mysql	Любой SELECT запрос, который поддерживает СУБД MySQL		
restapi	POST-запрос	<code>Select * from 'Ссылка на ресурс' where body = 'JSON с параметрами'</code>	
	GET-запрос	<code>Select * from 'Ссылка на ресурс'</code>	
sqlserver	Любой SELECT запрос, который поддерживает СУБД SQL Server		
postgresql	Любой SELECT запрос, который поддерживает СУБД PostgreSQL		

В поле «sink_filename» необходимо задать путь к Parquet-файлу в S3-совместимом хранилище. Поле «bucket_size» необходимо указать количество строк выгружаемых из источников в файл Parquet за одну итерацию при пакетной загрузке. В «bucket_id» необходимо указать из таблицы «stg.bucket». Поле «load_type_id» определяет тип загрузки («2» - полная загрузка).


6. Далее необходимо заполнить таблицу «profile_command». В колонке «profile_command_id» указывается id из таблицы «profile_command». При этом в поле «enabled» необходимо выставлять значение «true» только на актуальные загрузки.

Поле «profile_id» необходимо заполнить id профиля, с которого вносится изменение из таблицы «stg.profile».

7. Запуск процесса интеграции данных можно вызвать либо на Windows, либо на Linux.

Процесс запуска с виртуальной машины linux (см. п. Запуск компонента на linux), в появившемся окне необходимо ввести python скрипт:

```
sudo python MetaStagingExecutor/ MetaStagingExecutor.py
```



```
CertificateManager 1.0.0
Copyright (C) 2022 CertificateManager

  --public-key    Required. Публичный ключ
  --text          Required. Текст для шифрования
  --help          Display this help screen.
  --version       Display version information.

itpro_admin@biquebe-ctl-01:~/CertificateManager$ ./CertificateManager encrypt --public-key /home/itpro_admin/keytabs/public.crt --text "MNBeerw123!"
Зашифрованный текст: 'FgqrgizGLT7ezkLwR8oLpNaT8hyCElnhR0dX4iDhuhKpAj1BJGu1wXn60NNMCBEHpsGoIBa+d4YTmJ3sUBUJrdwTEZPkMG0YGSwqvG0XcEB6Za7Nyj19QZ5obzUdvqKyelBAYd82lhzBQbhVQNl0qcao//EYro8GYwrhX853LpickBj//DiEju9Zmcodt/Iw9WQqrV8sLqduqKLNPXL21+cTURZaSi6eU9sR+S203bY69bafD0gl/W1UKM+gonNMjR+j+r0fGEhrxueLE9yymntBjUpgFFkwLGQe/dhEqOxrvQR1PBkA8nU2Phgw3qzsM0qfUiXywG8sMhGj9RaKutnf942ycUEkgUH0cStGh9kX2P6i5+3r8nVSzlwcc/rBWKgvdoXehmiyNa60t+2X34W/c7N/eyY7y0HZWLSF/pJrAIcwu1bu8HxV+vI8pwl/9zSDoA7fQYK9anc9NMmq2I6lmZBk01J27yW4koIM9Tkzam6RAb/vFcRY6khdB5niDEUG0Lz8TlWa6+HhI6soFHMIEFK6GRV16chgnkNi1DOGiugR5PuQkpd/GpVaB6k1LL6+D2o/ihg7nKOFje5ntqd4Kx+DogzLgn2wY3LIYSF7L+AgczDxlpjV+SD95hGVXMZicKNPyuVKq/Lxrp6kNOKW0GnZqnUD6JPajnkY='
itpro_admin@biquebe-ctl-01:~/CertificateManager$ cd ./
-bash: cd: ./: No such file or directory
itpro_admin@biquebe-ctl-01:~/CertificateManager$ cd ../
itpro_admin@biquebe-ctl-01:~/CertificatesToJson/
itpro_admin@biquebe-ctl-01:~/CertificatesToJson$ ./CertificatesToJsonSerializer postgresql --cstring "Host=192.168.72.52;Port=5432;Database=postgres;User=postgres;Password=MNBeerw123;" --cstring-secure ""
JSON:
>{"ConnectionString": "Host=192.168.72.52;Port=5432;Database=postgres;User=postgres;Password=MNBeerw123;", "ConnectionStringSecure": ""}
itpro_admin@biquebe-ctl-01:~/CertificatesToJson$ sudo python3 MetastagingExecutor/MetastagingExecutor.py
```

Рисунок 28.Консоль

В результате должны появиться итоговые представления на Greenplum с данными из источников (см. п. Информация для проверки).

Процесс запуска с виртуальной машиной Windows (см. п. Запуск компонента на windows), в появившемся окне необходимо ввести скрипт:

```
python3 "C:\MetaStaging\MetaStagingExecutor\MetastagingExecutor.py"
```

5.3. Полная загрузка с сохранением истории

Повторяет алгоритм полной загрузки. Отличается только в части заполнения поля «load_type_id», таблицы «stg.command», которое определяет тип загрузки. В данном случае нужно поставить («3» - полная загрузка с сохранением истории).

5.4. Инкрементальная загрузка

1. Для инкрементальной загрузки данных следует повторить первых 4 пункта описанный в п. Полная загрузка

2. Запрос для инкрементальной загрузки (или загрузки с параметрами) данных отличается от полной запросом в строке «command» таблицы «stg.command». Любая команда прописываемая с условием для

секционированной загрузки должна отражать это же условие в таблице «stg.parameter».

id	source_id	name	description
1	2	1 f	select id, name, age, nationality, club, value, wage, position, dribbling, reactions, jumping, s...
2	4	3 Multilanguage-review_all	Pредст... select * from multilanguage_review_all
3	8	2 Movies-tickets	Продаж... select * from public.cinematicket_params where date between /*{date_from}*/ and /*{date_to}*/
4	6	2 Ivi-rus-reviews	Русско... Select * from public.ivi_rus_review
5	3	2 Kinopoisk-rus-review	Русско... select * from public.kinopoisk_rus_review
6	7	2 Movies-appear	Фильмы... select * from public.movies_appear where "Year" between 2000 and 2022
7	9	7 REST-reviews	<null> select * from 'http://jsonplaceholder.typicode.com/posts'
8	5	4 Dialogs-eng	<null> select * from [Tests].[dbo].[dialogs_expanded]
9	10	8 Movie-rental-excel	<null> select * from webfile 'Прокат.xlsx':[Лист1] with (HaveHeader, LoadFirstRow)

Рисунок 29. Таблица «stg.command»

Так же в таблице command важно указывать «load type id», он задается в соответствии с условием в таблице «stg.load type» (в данном случае «1»)

id	sink_filename	batch_size	bucket_id	load_type_id	full_name	partition
1	nationality, club, value, wage...	football	10000	2	2 football	<null>
2	language_review_all	multilanguage_review_all	100000	2	2 multilanguage_review_all	<null>
3	cinematicket_params where date ...	movie_tickets	10000	2	1 movie_tickets	date
4	/ivi_rus_review	ivi_rus_reviews	10000	2	2 ivi_rus_reviews	<null>
5	kinopoisk_rus_review	kinopoisk_rus_reviews	1000	2	2 kinopoisk_rus_reviews	<null>
6	movies_appear where "Year" betw...	movies_appear	10000	2	2 movies_appear	
7	jsonplaceholder.typicode.com/p...	rest_reviews	1000	2	2 rest_reviews	<null>
8	[dbo].[dialogs_expanded]	dialogs_expanded	10000	2	2 dialogs_expanded	<null>
9	'Прокат.xlsx':[Лист1] with (Ha...	movie_rental	100	2	2 movie_rental	<null>

Рисунок 30. Таблица «stg.command»

3. Необходимо заполнить таблицу «stg.parameter»

Поле parameter id заполняется автоматически, значение в поле name должно соответствовать плейсхолдеру, который указана в таблице «stg.command», в поле «command».

В случае если у источника есть временные рамки необходимо задать «true» в таблицах «is prev depend» и «is max date»

parameter_id	name	value	is_prev_depend	is_max_date
1	date_from	2000	true	false
2	date_to	2022	false	true

Рисунок 31. Таблица «stg.parameter»

4. Далее необходимо связать запросы с источниками с параметрами в таблице «stg.command_parameter». Для этого нужно взять «id command» в таблице «stg.command», а «id parameter» в таблице «stg.parameter».

WHERE		ORDER BY		
	command_parameter_id		command_id	parameter_id
1		3		8
2		4		8

Рисунок 32. Таблица «stg.command_parameter»

5. Для запуска процесса интеграции данных нужно вызвать перейти на виртуальную машину linux (см. п. Запуск компонента на linux), в появившемся окне необходимо ввести python скрипт:

sudo python MetaStagingExecutor/ MetaStagingExecutor.ru

```
CertificateManager 1.0.0
Copyright (C) 2022 CertificateManager

--public-key    Required. Публичный ключ
--text          Required. Текст для шифрования
--help          Display this help screen.
--version       Display version information.

itpro_admin@biquebe-ctl-01:~/CertificateManager$ ./CertificateManager encrypt --public-key /home/itpro_admin/keytabs/public.crt --text "MNIBrewq123"
Зашифрованный текст: 'FgqrgiZGLT7ezklR8oLpNaT8hyCElnhR0dX4iDhuhKpAj1BjGu1WXn6OWMCBEHpsGoIBa+d4YTmJ3sUBUJrdwTEZPkMGOYGSwqvGIKcEB6Za7Nyj19QZ5obzUdvqKYelAydB2fhz8QbHvQN10qcao//EYro8GwvhX85JLpickBj//DiEju92mcodt/1w9hWQqrv8sLqdqkKLNPXL21+cTURZaSi6eU9sR+S203bY69bajFDgb1/WlUKM+gonNW0rJ+r0fGEhrxuelE9ymnTBjUpgFFkwUGQe/dVhEqDxrwQR1PBkA8nU2Phgw3qzsMQqfUiXywG8sMhGj9RaKutnf942ycUEkgUH0cStGh9kX2P615+3r8mVSzW0cc/rBwKgvdoXehmiyNa60t+2X34W/c7N/eyY7y0H2wLSF/pJrAIcwu1bu8HxV+v18pwL/9zSDoA7fQYK9anc9NMmq2I6LmZBk01J22yN4koIM9Tkzam6RAb/vFcRY6kbdB5niIDEUG0Lz8TWLa6+HhI6soFHWiEFK6GRV16chgnkNi1DDGiuaqR5PuQkpd/GpVaB6k1LL6+D2o/ing7nKOFje5ntqd4Kx+Dog2Lgn2w3LIYSF7L+AgczDxlpjV+SD95hGVXMZicKNPyuVKq/Lxrpb6kNOKW0GnZqnUD6JPajnkY='
itpro_admin@biquebe-ctl-01:~/CertificateManager$ cd ./
-bash: cd: ./: No such file or directory
itpro_admin@biquebe-ctl-01:~/CertificateManager$ cd ../
itpro_admin@biquebe-ctl-01:~$ cd CredentialsToJson/
itpro_admin@biquebe-ctl-01:~/CredentialsToJson$ ./CredentialsToJsonSerializer postgresql --cstring "Host=192.168.72.52;Port=5432;Database=postgres;User=postgres;Password=MNIBrewq123;" --cstring-secure ""
JSON:
>{"ConnectionString": "Host=192.168.72.52;Port=5432;Database=postgres;User=postgres;Password=MNIBrewq123;", "ConnectionStringSecure": ""}
itpro_admin@biquebe-ctl-01:~/CredentialsToJson$ sudo python3 MetastagingExecutor/MetastagingExecutor.py
```

Рисунок 33.Консоль

В результате должны появиться итоговые представления на Greenplum с данными из источников (см. п. Информация для проверки).

6. ИНФОРМАЦИЯ ДЛЯ ПРОВЕРКИ

Для проверки корректности заливки в S3-содержимое хранилище можно использовать программу S3-Browser:




Рисунок 34. S3 хранилище

Отсюда можно скачать любой **файл с данными и проверить его содержимое** в программе ParquetViewer:




Рисунок 35. ParquetViewer

Конечные представления в Greenplum проверяются через DBeaver также, как и настроечная БД. В схеме «back» лежат внешние таблицы, которые через PXF обращаются к файлам в S3, а в схеме «public» лежат итоговые представления с данными последней загрузки и с данными за все загрузки.




Рисунок 36. Представление в Greenplum

В результате должны появиться итоговые представления на Greenplum с данными из источников:

column	question	answer	question_as_int
1	Well, I thought we'd start with pronunciation, if that's okay with you.	Not the hacking and gagging and spitting part. Please.	[54, 67, 74, 74, 12,
2	Not the hacking and gagging and spitting part. Please.	Okay... then how 'bout we try out some French cuisine. Saturday? Night.	[45, 77, 82, 1, 82,
3	You're asking me out. That's so cute. What's your name again?	Forget it.	[56, 77, 83, 8, 80,
4	No, no, it's my fault -- we didn't have a proper introduction ---	Cameron.	[45, 77, 82, 1, 76,
5	Gosh, if only we could find Kat a boyfriend...	Let me see what I can do.	[58, 77, 81, 70, 12,
6	C'tesc ma tete. This is my head	Right. See? You're ready for the quiz.	[34, 8, 67, 81, 65,
7	That's because it's such a nice one.	Forget French.	[51, 70, 63, 82, 8,
8	How is our little Find the Wench A Date plan progressing?	Well, there's someone I think might be --	[39, 77, 85, 1, 71,
9	You have my word. As a gentleman	You're sweet.	[56, 77, 83, 1, 70,
10	What's the worst?	You get the girl.	[54, 70, 63, 82, 8,
11	Hey -- do you mind?	Not at all!	[39, 8, 67, 81, 13,
12	Sure have.	I really, really, really wanna go, but I can't. Not unless my sister g...	[50, 83, 80, 67, 1,
13	I really, really, really wanna go, but I can't. Not unless my sister g...	I'm workin' on it. But she doesn't seem to be goin' for him.	[40, 1, 60, 67, 65,
14	So that's the kind of guy she likes? Pretty ones?	Who knows? All I've ever heard her say is that she'd dip before dating...	[50, 77, 1, 82, 70,
15	You know Chastity?	I believe we share an art instructor	[56, 77, 83, 1, 73,
16	Well, no...	Then that's all you had to say.	[54, 67, 74, 74, 12,
17	do you listen to this crap?	What crap?	[66, 77, 1, 87, 77,
18	What crap?	Me. This endless ...blonde bubble. I'm like, boring myself.	[54, 70, 63, 82, 1,
19	Me. This endless ...blonde bubble. I'm like, boring myself.	Thank God! If I had to hear one more story about your coiffure...	[44, 67, 14, 1, 1,
20	I figured you'd get to the good stuff eventually.	What good stuff?	[40, 1, 68, 71, 69,
21	What good stuff?	The "real you".	[54, 70, 63, 82, 1,
22	The "real you".	Like my fear of wearing pastels?	[51, 70, 67, 1, 3, 88,
23	She okay?	I hope so.	[50, 70, 67, 1, 77,
24	They do to!	They do not!	[51, 70, 67, 87, 1,
25	Is he oily or dry?	Combination. I don't know -- I thought he'd be different. More of a g...	[40, 81, 1, 70, 67,
26	I have to be home in twenty minutes.	I don't have to be home 'til two.	[40, 1, 70, 63, 84,
27	It's more	Expensive?	[40, 1, 68, 71, 69,
28	Exactly So, you going to Bogey Lowenbrau's thing on Saturday?	Hopefully...	[40, 82, 8, 81, 1, 75,
29	Queen Harry?	It's a gay cruise line, but I'll be, like, wearing a uniform and stuff.	[48, 83, 67, 67, 75,
30	Hey, sweet cheeks.	Hi, Joey.	[39, 67, 87, 12, 1,
31	Hi, Joey.	You're concentrating awfully hard considering it's gym class.	[39, 71, 12, 1, 41,

Рисунок 49. Представление в Greenplum