

Если вы видите что-то необычное, просто сообщите мне.

Потоковая передача данных PostgreSQL + Kafka + Debezium: Part 1

В этой инструкции мы будем использовать Postgres, Kafka, Kafka Connect, Debezium и Zookeeper для создания маленького API, который отслеживает магазины и крипто покупки во времени.

Введение

Платформа потоковой передачи данных, как Kafka позволяет вам строить системы которые обрабатывают данные в реальном времени. Эти системы имеют мириады случаев использования, проекты могут ранжироваться от простой обработки данных для ETL систем до проектов требующих высокую скорость координации микросервисов требующие все виды Kafka как приемлимое решение.

Один из моих любимых примеров использования Kafka происходит от New Relic инженерный блог. New Relic помогает разработчикам отслеживать производительность их приложений. Их свойства работают в реальном времени, что может быть важно так как множество разработчиков полагаются на него в качестве системы оповещения, когда что-то идет не так. New Relic серьезно использует Kafka для координации микросервисов и связывать их в реальном времени друг с другом.

В то время как Kafka слишком сложна в качестве простого инструмента, который мы собираемся построить сегодня, эта инструкция покажет как настроить Kafka. Мы не будем делить наш API на множество сервисов, но мы будем использовать Kafka внутри нашего

сервиса что того, чтобы просчитать и создать дополнительные данные доступные через API.

Что такое Kafka?

Kafka очень мощная платформа потока событий, которая позволяет обрабатывать массивный набор данных в реальном времени. В добавок, можно сказать, kafka масштабируема и отказоустойчива, делает её популярным выбором для проектов которые требуют скорость обработки данных.

Что такое Debezium?

Реляционная SQL база данных в сердце бесчисленного количества программных проектов. Для примера, если вы хотите использовать Kafka, но часть (или всё) ваших данных существует в Postgres базе данных, Debezium - это инструмент который подключается к Postgres и потоковым образом передает данные в Kafka. Запускается на сервере с базой данных.

Что такое Zookeeper?

ZooKeeper - еще один кусок программного обеспечения от Apache, который использует Kafka для хранения и управления конфигурацией. Для базовой настройки, которую мы будем использовать не требуется глубокое понимание Zookeeper.

Если вы уже закончили установку проекта как этот в боевом окружении, вы захотите узнать гораздо больше о том, как оно работает и как его настроить. В будущем, Kafka не потребует Zookeeper.

Что такое Kafka Connect?

Kafka Connect работает как мост для входящих и исходящих потоковых данных. Вы можете подключить вашу Kafka к различным источникам баз данных. В этой инструкции, мы будем использовать для подключения Debezium, Postgres, но это будет не единственный источник данных для которых Connect может быть полезен. Есть бесконечное количество коннекторов написанных для того, чтобы манипулировать различными данными в Kafka.

Так же экосистема Kafka может быть полезна, вы сможете получить большую отдачу от Kafka в последствии если вложите в Kafka:

Использование Docker для настройки Postgres, Kafka и Debezium

Эта инструкция будет состоять из нескольких частей. Первая, мы настроим маленький API сервер, который позволит вам хранить записи. Затем, используя данные цен, покупок/продаж, данные будут проходить через Kafka и рассчитывать различные общие метрики. Мы так же поэкспериментируем используя Debezium `sink` для потока данных из Kafka обратно в SQL базу данных.

В этой части мы поднимем и запустим Kafka и Debezium. В конце инструкции, у вас будет проект который передает потоковым образом события из таблицы в топик Kafka.

Мы будем использовать Docker и docker-compose чтобы помочь нам запустить Postgres, Kafka и Debezium. Если вы не знакомы с этими инструментами, возможно будет полезно прочитать про инструменты прежде чем продолжить.

Создадим Postgres контейнера с помощью Docker

Первое, настроим базовый Postgres контейнер.

```
version: '3.9'

services:
  db:
    image: postgres:latest
    ports:
      - "5432:5432"
    environment:
      - POSTGRES_PASSWORD=arctype
```

После запуска docker-compose, мы должны иметь рабочую базу данных

```
db_1 | 2021-05-22 03:03:59.860 UTC [47] LOG: database system is ready to accept connections
```

Теперь, проверим, что она работает.

```
$ psql -h 127.0.0.1 -U postgres
Password for user postgres:

postgres@postgres=#
```

После подключения нас приветствует psql консоль.

Добавим Debezium Kafka, Kafka Connect, и Zookeeper образы

Теперь добавим другие образы необходимые для Kafka. Debezium предлагает образы Kafka, Kafka Connect и Zookeeper, которые предназначены специально для работы с Debezium. Поэтому использовать мы будем их.

```
version: '3.9'

services:
  db:
    image: postgres:latest
    ports:
      - "5432:5432"
    environment:
```

- POSTGRES_PASSWORD=arctype

zookeeper:

image: debezium/zookeeper

ports:

- "2181:2181"
- "2888:2888"
- "3888:3888"

kafka:

image: debezium/kafka

ports:

- "9092:9092"
- "29092:29092"

depends_on:

- zookeeper

environment:

- ZOOKEEPER_CONNECT=zookeeper:2181
- KAFKA_ADVERTISED_LISTENERS=LISTENER_EXT://localhost:29092,LISTENER_INT://kafka:9092
- KAFKA_LISTENER_SECURITY_PROTOCOL_MAP=LISTENER_INT:PLAINTEXT,LISTENER_EXT:PLAINTEXT
- KAFKA_LISTENERS=LISTENER_INT://0.0.0.0:9092,LISTENER_EXT://0.0.0.0:29092
- KAFKA_INTER_BROKER_LISTENER_NAME=LISTENER_INT

connect:

image: debezium/connect

ports:

- "8083:8083"

environment:

- BOOTSTRAP_SERVERS=kafka:9092
- GROUP_ID=1
- CONFIG_STORAGE_TOPIC=my_connect_configs
- OFFSET_STORAGE_TOPIC=my_connect_offsets
- STATUS_STORAGE_TOPIC=my_connect_statuses

depends_on:

- zookeeper
- kafka

Настройки переменного окружения для Kafka позволяют нам указать различные сети и протоколы безопасности если у вашей сети есть различные правила для внутреннего брокера подключения в отличии от внешних клиентов подключающихся к Kafka. Наша

простая настройка самостоятельна с созданием сети внутри Docker.

Kafka Connect создает топик в Kafka и использует их для хранения настроек. Вы можете указать имя, которое он будет использовать для топика с переменными окружения. Если у вас есть множество Kafka Connect нод, они могут выполнять работу параллельно когда они имеют одну и ту же `GROUP_ID` и `_STORAGE_TOPIC` потоковые события PostgreSQL

Создадим таблицу чтобы проверить потоковые события.

```
create table test (  
  id serial primary key,  
  name varchar  
);
```

Настроим Debezium Connector для PostgreSQL.

Если мы запустим наш Docker проект, Kafka, Kafka Connect, Zookeeper и Postgres он прекрасно работает. Однако, Debezium требует конкретной настройки коннектора для запуска потоковых данных от Postgres.

Совместный SQL редактор

Прежде чем мы активируем Debezium, нам нужно подготовить Postgres сделав небольшие конфигурационные изменения. Debezium использует нечто встроенное в PostgreSQL, под названием WAL, или упреждающую журнализацию. Postgres использует этот лог чтобы проверить целостность данных и управлять версиями ячеек и транзакций. WAL в Postgres имеет несколько режимов, которые можно настроить, и для работы Debezium WAL режим должен быть указан как `replica`. Давайте это настроим.

```
psql> alter system set wal_level to 'replica';
```

Возможно понадобится рестарт Postgres контейнера для применения настройки.

Есть еще один плагин Postgres не включенный в образ который мы используем, поэтому нам понадобится wal2json. Debezium может работать и с wal2json и с protobuf. Для этой инструкции, мы будем использовать wal2json. Так как он согласно имени переводит Postgres WAL лог в JSON формат.

С помощью запущенного Docker, в ручном режиме установим wal2json используя aptitude. Чтобы добраться до консоли Postgres контейнера, для начала найдем ID контейнера и выполним следующий набор команд:

```
$ docker ps
```

```
CONTAINER ID  IMAGE
c429f6d35017  debezium/connect
7d908378d1cf  debezium/kafka
cc3b1f05e552  debezium/zookeeper
4a10f43aad19  postgres:latest
```

```
$ docker exec -ti 4a10f43aad19 bash
```

Теперь, когда мы внутри контейнера давайте поставим wal2json:

```
$ apt-get update && apt-get install postgresql-13-wal2json
```

Активируем Debezium

Мы можем общаться с Debezium делая HTTP запросы. Для этого нужен POST запрос данные которого отформатированны в JSON формате. JSON определяет параметры коннектора который мы пытаемся создать. Поместим данные в файл и будем его использовать с `cURL`.

У нас есть несколько конфигурационных опций на данный момент. Тут можно использовать белый или черный списки если вы хотите чтобы Debezium отображал только определенные таблицы(или для избежания определенных таблиц)

```
$ echo '{
  "name": "arctype-connector",
  "config": {
    "connector.class": "io.debezium.connector.postgresql.PostgresConnector",
    "tasks.max": "1",
    "plugin.name": "wal2json",
    "database.hostname": "db",
```

```
"database.port": "5432",
"database.user": "postgres",
"database.password": "arctype",
"database.dbname": "postgres",
"database.server.name": "ARCTYPE",
"key.converter": "org.apache.kafka.connect.json.JsonConverter",
"value.converter": "org.apache.kafka.connect.json.JsonConverter",
"key.converter.schemas.enable": "false",
"value.converter.schemas.enable": "false",
"snapshot.mode": "always"
}
}
' > debezium.json
```

Теперь можно отправить эту конфигурацию в Debezium

```
$ curl -i -X POST \
  -H "Accept:application/json" \
  -H "Content-Type:application/json" \
  127.0.0.1:8083/connectors/ \
  --data "@debezium.json"
```

Ответ должен быть со следующим содержанием JSON если это уже не настроенный коннектор.

```
{
  "name": "arctype-connector",
  "config": {
    "connector.class": "io.debezium.connector.postgresql.PostgresConnector",
    "tasks.max": "1",
    "plugin.name": "wal2json",
    "database.hostname": "db",
    "database.port": "5432",
    "database.user": "postgres",
    "database.password": "arctype",
    "database.dbname": "postgres",
    "database.server.name": "ARCTYPE",
    "key.converter": "org.apache.kafka.connect.json.JsonConverter",
    "value.converter": "org.apache.kafka.connect.json.JsonConverter",
```



```
"key.converter.schemas.enable": "false",  
"value.converter.schemas.enable": "false",  
"snapshot.mode": "always",  
"name": "arctype-connector"  
},  
"tasks": [],  
"type": "source"  
}
```

Проверим настройку потоковой передачи Kafka

Теперь после вставки обновления или удаления записей мы будем использовать изменения как новое сообщение в Kafka топике связанной с таблицей. Kafka Connect создаст 1 топик для SQL таблицы. Чтобы проверить что всё работает верно, нам нужно мониторить Kafka топик.

Kafka идет с shell скриптами которые помогают вам вставлять ваши настройки Kafka. Это удобно когда вы хотите проверить вашу конфигурацию и её удобно включать в Docker образ который мы используем. Первый, который мы будем использовать список всех топиков в нашем Kafka кластере. Давайте запустим и проверим что мы видим топик для нашей `test` таблицы.

```
$ docker exec -it \  
$(docker ps | grep arctype-kafka_kafka | awk '{ print $1 }') \  
/kafka/bin/kafka-topics.sh \  
--bootstrap-server localhost:9092 --list  
  
ARCTYPE.public.test  
__consumer_offsets  
my_connect_configs  
my_connect_offsets  
my_connect_statuses
```

Встроенный в инструмент Kafka требует указания `--bootstrap-server`. Он ссылается на bootstrap потому, что вы обычно запускаете Kafka как кластер с несколькими нодами, и вам нужен один из них, который "выставлен наружу" чтобы зайти в кластер. Kafka обрабатывает все остальное самостоятельно.

Вы можете увидеть нашу `test` таблицу в списке `ARCTYPE.public.test`. Первая часть, ARCTYPE - это префикс который мы настроили для `database.server.name` поле в настройках JSON. Вторая часть отражает схему Postgres таблицы в ней, в последней части название таблицы. При добавлении Kafka производителей и приложений с потоковыми данными, количество топиков будет увеличиваться, поэтому удобно указывать префиксы, чтобы проще идентифицировать какой из топиков относится к таблице в бд.

Теперь можно использовать другой инструмент называемый консольный потребитель для слежения за топиками в реальном времени. Называется он "console consumer" потому, что это типа потребителя kafka - утилита которая потребляет сообщения из топика и что-нибудь делает с ним. Потребитель может делать что угодно с данными которые он потребляет и консоль потребителя ничего не делает кроме как выводит эти сообщения в консоль.

```
$ docker exec -it \  
$(docker ps | grep arctype-kafka_kafka | awk '{ print $1 }') \  
/kafka/bin/kafka-console-consumer.sh \  
--bootstrap-server localhost:9092 \  
--topic ARCTYPE.public.test
```

По умолчанию, консольный потребитель, потребляет только сообщения у него уже не было. Если вы хотите увидеть все сообщения в топике нужно добавить ключ `--from-beginning` в команду запуска .

Теперь наш потребитель следить за новыми сообщениями в топике, а мы запустим `INSERT` и посмотрим вывод.

```
postgres=# insert into test (name) values ('Arctype Kafka Test!');  
INSERT 0 1
```

Вернемся к нашему Kafka потребителю:

```
$ docker exec -it $(docker ps | grep arctype-kafka_kafka | awk '{ print $1 }') /kafka/bin/kafka-console-consumer.sh --bootstrap-server localhost:9092 --topic ARCTYPE.public.test
```

...

```
{
  "before": null,
  "after": {
    "id": 8,
    "name": "Arctype Kafka Test!"
  },
  "source": {
    "version": "1.5.0.Final",
    "connector": "postgresql",
    "name": "ARCTYPE",
    "ts_ms": 1621913280954,
    "snapshot": "false",
    "db": "postgres",
    "sequence": "[\"22995096\\\", \"22995096\\\"]",
    "schema": "public",
    "table": "test",
    "txId": 500,
    "lsn": 22995288,
    "xmin": null
  },
  "op": "c",
  "ts_ms": 1621913280982,
  "transaction": null
}
```

В месте с мета данными вы можете увидеть главный ключ поля `name` записки которую вы добавили.

Выводы

Давайте скоординируемся, так как мы имеем Postgres для передачи данных в Kafka кластер. Во второй части, мы построим SQL схему чтобы улучшить наше приложение, для вычисления данных.

Revision #4

Created 14 September 2021 10:25:51 by gasick

Updated 16 April 2023 19:41:31 by gasick