Feature Store

Хассан Деннис, AmazMe.MLOps

Что такое Feature Store

Feature Store - это персистентное хранилище атрибутов, предназначенное для обмена атрибутами между режимами Offline, NRT, Online и Студии, характеризующееся быстрым доступом к атрибутам по ключу

Какие задачи

- Быстрый доступ к фичам в online-сценариях генерации рекомендаций
- Удобное управления фичами для исполнения моделей и движка бизнес-правил
- Переиспользование фичей между моделями
- Единые правила и способы работы с фичами в online-сценариях
- Реестр фичей и UI для работы с метаданными фичей
- Обновление фичей в NRT-режиме
- Версионирование и тегирование фичей

Какие Feature Store рассматривали

Open Source / On-premise


FEAST


HOPSWORKS

MLRun

{feature{form

SaaS / Cloud


Amazon SageMaker Feature Store

tecton


databricks


iguazio

Принято решение реализовывать свой Feature Store

Сценарии использования

1. Периодическая генерация фичей

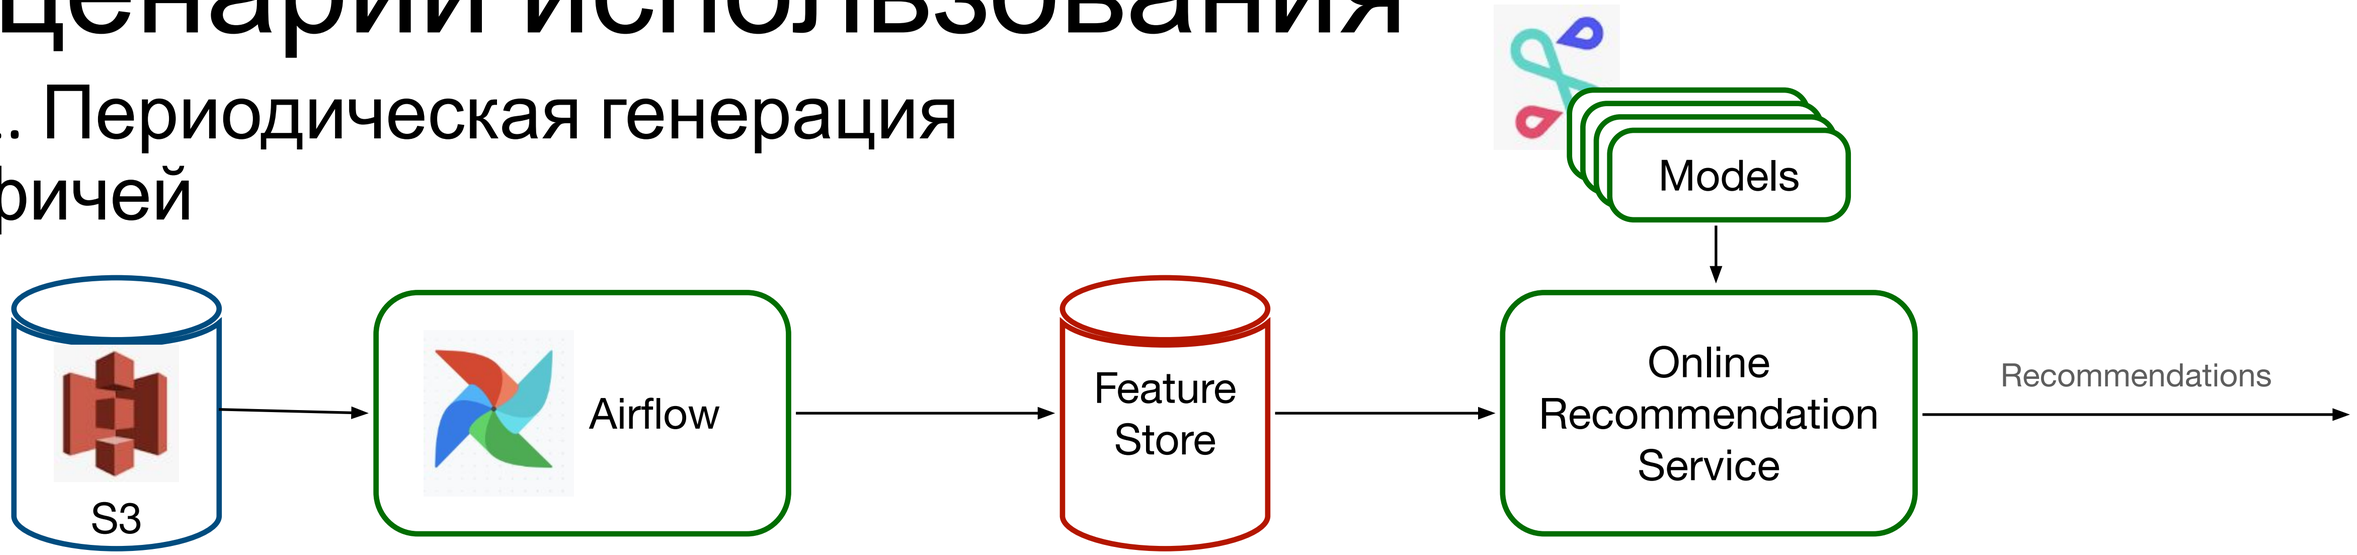

2. Генерация фичей в NRT-режиме

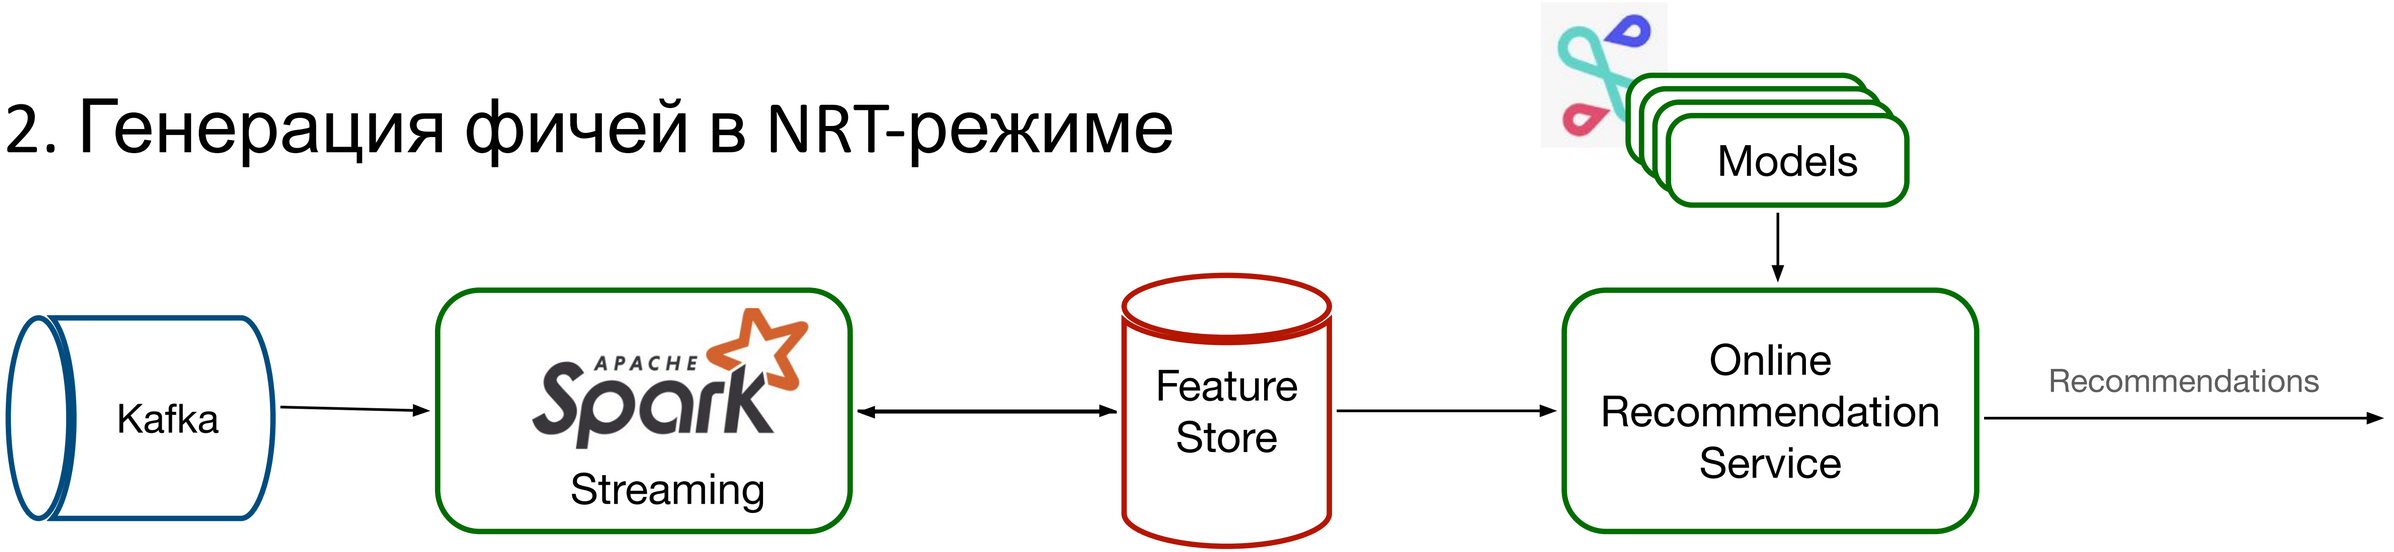

Архитектура

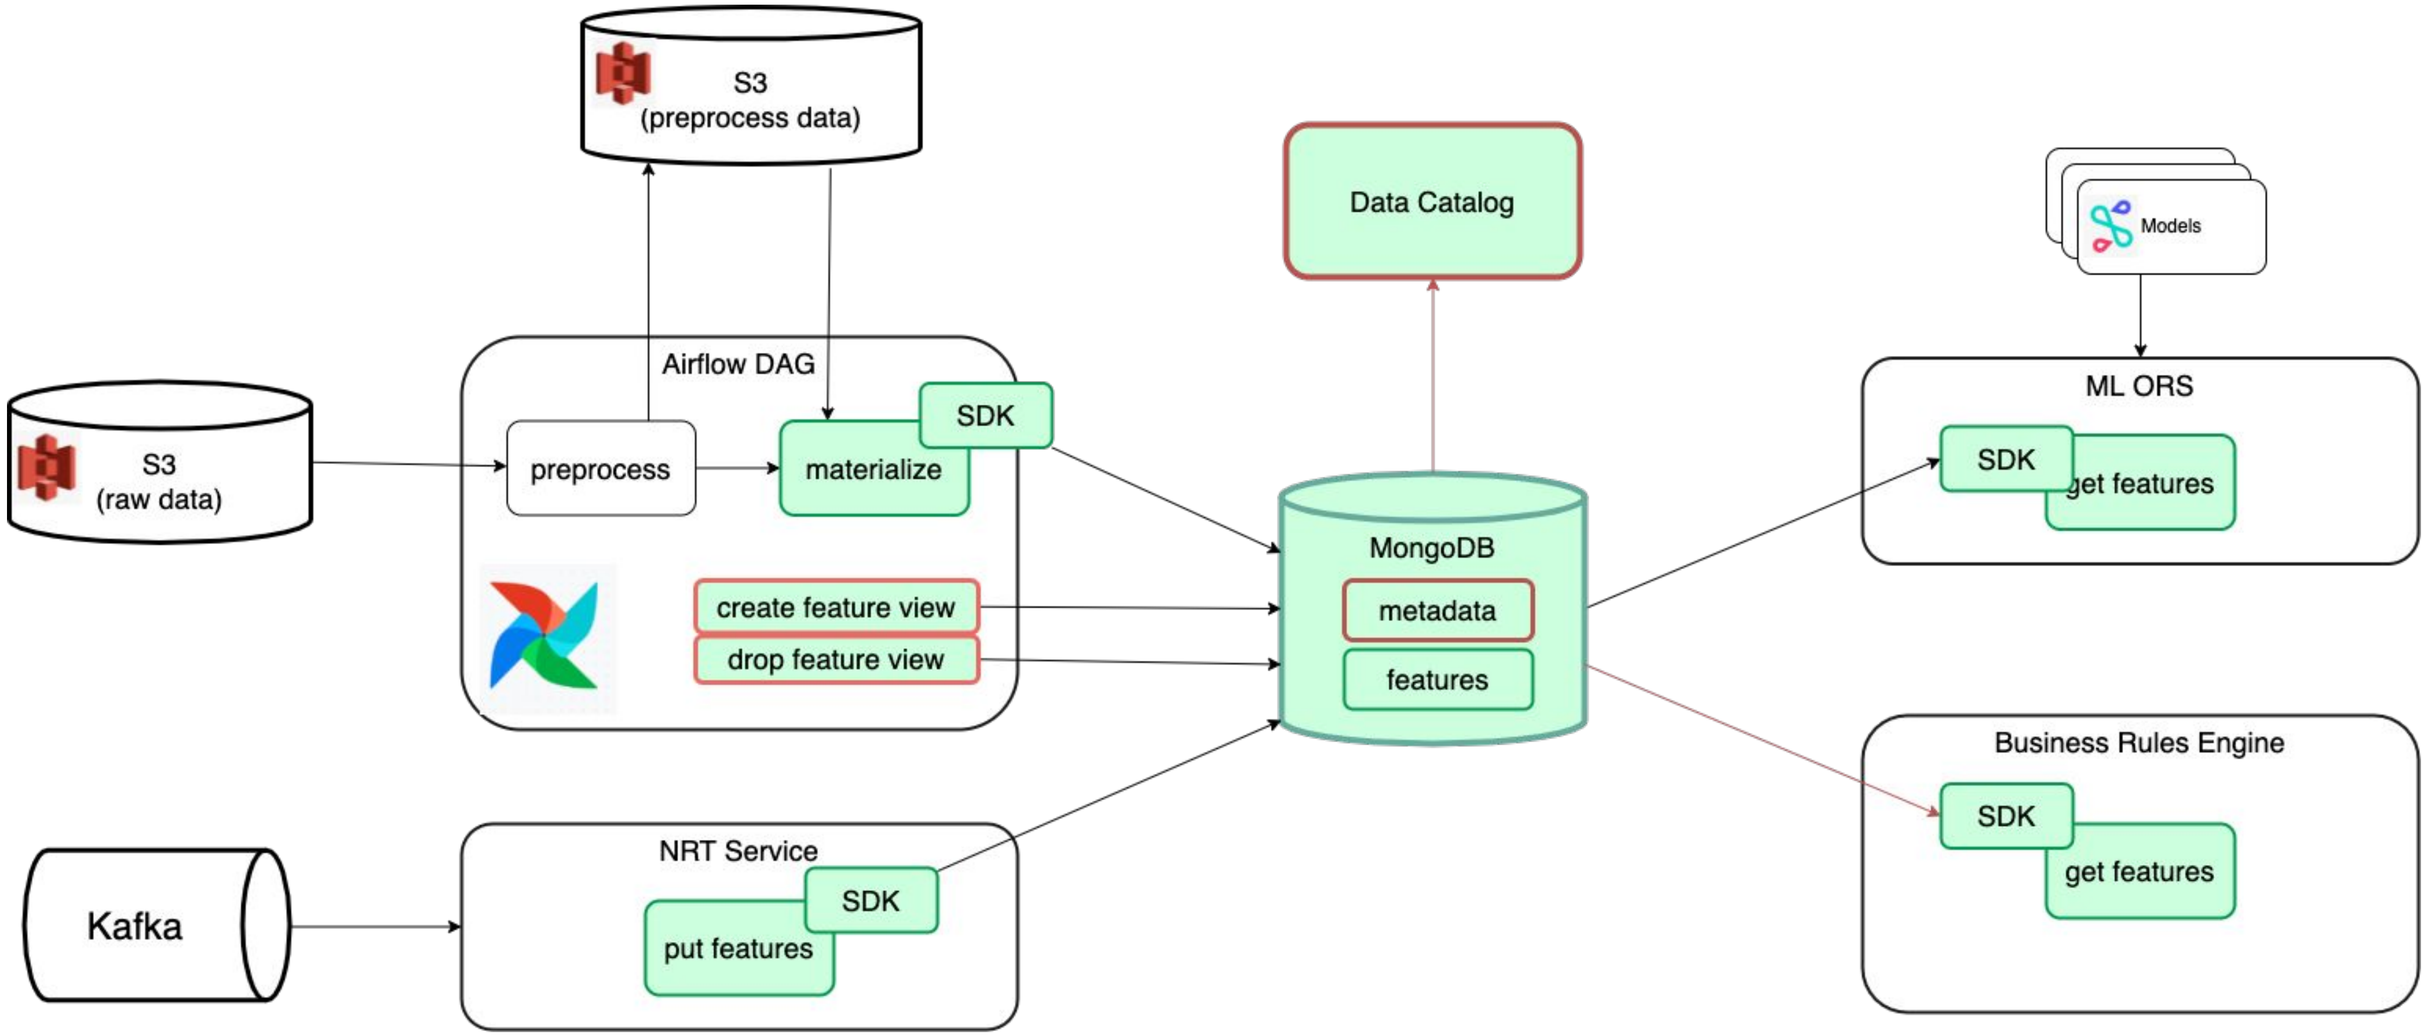

Feature Store на основе MongoDB + Python SDK

Концепции

Feature View
- Name
- Version
- Entity Key
- Features[]
- Metadata
  - Tags[]
  - Owners[]
  - Description
  - TTL

Feature
- Name
- Type
- Description

Python SDK:

- create_feature_view()
- list_feature_view()
- describe_feature_view()
- drop_feature_view()

- materialize_features()
- put_online_features()
- get_online_features()

Customer Journey

Подготовка данных и извлечение признаков

Разработка фичей

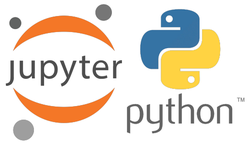

Разработка пайплайна для обновления признаков в Feature Store

Создание Feature View

Разработка NRT обработчика потока данных

Разработка DAG материализации фичей в Feature Store

Использование фичей в online-сценариях

Разработка Online Recommendation Service

Разработка фичей

- Experiments, Feature Engineering
- Разработка Airflow DAG по построению таблицы с фичами

user_id	clicks_90_days	impressions_30_days	gender	country
123	55	122	male	RU
144	33	66	female	US

Создание Feature View

- Включить в DAG этап создания Feature View
- Описать Feature View с помощью Python ML SDK

```
FeatureView(
    feature_view="user_feature_view",
    feature_view_version="v1",
    entity_key="user_id",
    features=[
        Feature(name="clicks_90_days",      full_name="Клики за 90 дней",  description="", type=Int),
        Feature(name="impressions_30_days", full_name="Показы за 30 дней", description="", type=Int),
        Feature(name="gender",              full_name="Пол человека",      description="", type=Str),
        Feature(name="country",             full_name="Страна",            description="", type=Str),
    ],
    ttl_days=60,
    source={"s3_dataset": ["user_feature_view_source"], "kafka": ["users_topic"]},
    tags=['model_1', 'best_features'],
    producers=["dag_id"],
    description="The best feature view you ever had about user"
)
```

Материализация фичей

- Включить в DAG этап материализации фичей

```
df: Union[pandas.DataFrame, pyspark.sql.DataFrame] = get_data()

materialize_features(
    feature_view="user_feature_view",
    feature_view_version="v1",
    entity_key="user_id",
    dataframe=df
)
```

Обновление фичей в NRT

- Включить в NRT-обработку данных запись фичей в Feature Store
- Это можно реализовать через Spark Streaming UDF или собственный NRT-сервис

```
put_online_features(
    entity_id=123,
    feature_values={
        'user_feature_streaming_view:v1:clicks_90_days': 55,
        'user_feature_streaming_view:v1:impressions_30_days': 22,
    },
)
```

Получение фичей в Online Rec Service

- Включить в ORS получение фичей из Feature Store

```
feature_values = get_online_features(
    features=[
        "user_feature_view:v1:clicks_90_days"
        "user_feature_view:v1:impressions_30_days"
        "user_feature_view:v1:gender"
        "user_feature_view:v1:country"
    ],
    entity_id=user_id
)

return model_predict(
    model_name='best_model',
    model_version='1',
    feature_values=feature_values)
```

План

На релиз:

- Хранилище на основе MongoDB
- Python SDK:
  - materialize_features()
  - get_features()
  - put_features()

После релиза:

- Работа с метаданными FeatureView
- Валидация метаданных
- Интеграция с Data Catalog
- Интеграция с движком бизнес-правил
- UI по просмотру метаданных
- TTL данных

Общее сравнение

	Feast	Hopsworks	MLRun	FeatureForm
Feature Catalog / Web UI	+	+	+	+
Data Sources (S3, Kafka)	• S3 • PostgreSQL • Spark (alpha) • Kafka	• S3 • HopsFS	• S3 • PostgreSQL	• S3 • PostgreSQL
Offline Feature Store	• S3 • Spark (alpha)	• S3 • HopsFS	• S3 • PostgreSQL	• S3 • PostgreSQL
Online Feature Store	• Redis • PostgreSQL • Cassandra	• RonDB (MySQL Cluster)	• in-memory dicts	• Redis • PostgreSQL • Cassandra • EmbeddingsHub
KNN/ANN in Online FS	-	-	-	• EmbeddingsHub (RocksDB + hnswlib) (single-node)
Feature Lineage / Transformation	-	+	+	+
Feature tags / versioning	+	+	+	+
Model Feature Tracking	+	+	+	+
Customizing ability	+	-	-	-
Security	-	+/-	-	-

Почему не подошел Feast

1. Нет интеграции с MongoDB
2. Невозможно делать поиск по значению фичей (нужно для движка бизнес правил)
3. Интеграция с Kafka поддерживается только через Spark Streaming
4. Фичи работы в NRT режиме и работы с Spark находятся в Alpha версии и не поддерживаются Maintainer
5. Сравнение по скорости Feast + Redis с собственным решением на Redis показало, что собственная реализация в 3 раза быстрее
6. Чтобы выгрузить датасет с фичами - необходимо подать на вход все Entity ID, что довольно неудобно
7. Невозможно использовать для event-подобных данных (для оффлайн стора), только для классических фичей-характеристик сущностей

Примеры фичей

rails_user_features→	make_train_dataset	rails_item_features→	make_train_dataset	rails_pair_features→	make_train_dataset
user_uid	age_access_type_0	collection_uid	age_access_type_0	user_uid	frame_30_sum_n_pagings
age_access_type_0	age_access_type_12	age_access_type_0	age_access_type_12	rail_uid	frame_30_sum_n_selects
age_access_type_12	age_access_type_16	age_access_type_12	age_access_type_16	date	frame_30_sum_n_watches
age_access_type_16	age_access_type_18	age_access_type_16	age_access_type_18	week_date	frame_30_sum_watched_time
age_access_type_18	age_access_type_6	age_access_type_18	age_access_type_6	watched_time	frame_30_max_pos
age_access_type_6	country_france	age_access_type_6	country_france	is_active	frame_30_cr_stow
country_france	country_germany	country_france	country_germany	frame_30_sum_n_pagings	frame_30_awtpp
country_germany	country_other	country_germany	country_other	frame_30_sum_n_selects	frame_90_sum_n_pagings
country_great-britain	country_russia	country_great-britain	country_russia	frame_30_sum_n_watches	frame_90_sum_n_selects
country_other	genre_287a1485-7a88-4c2f-b	country_other	genre_287a1485-7a88-4c2f-b	frame_30_sum_watched_tim	frame_90_sum_n_watches
country_russia	genre_Action	country_russia	genre_Action	frame_30_max_pos	frame_90_sum_watched_time
country_usa	genre_Adventure	country_usa	genre_Adventure	frame_90_sum_n_pagings	frame_90_max_pos
genre_287a1485-7a88-4c2f-b	genre_Comedy	genre_287a1485-7a88-4c2f-b	genre_Comedy	frame_90_sum_n_selects	frame_90_cr_stow
genre_Action	genre_Drama	genre_Action	genre_Drama	frame_90_sum_n_watches	frame_90_awtpp
genre_Adventure	genre_Family	genre_Adventure	genre_Family	frame_90_sum_watched_time	
genre_Comedy	genre_other	genre_Comedy	genre_other	frame_90_max_pos	
genre_Drama	genre_Sci-Fi	genre_Drama	genre_Sci-Fi		
genre_Family	genre_Thriller	genre_Family	genre_Thriller		
genre_Sci-Fi	release_year_1980	genre_Sci-Fi	mean_rating		
genre_Thriller	release_year_1990	genre_Thriller	n_titles	n_pagings	*Кол-во пролистываний карточек фильмов*
genre_other	release_year_2000	genre_other	release_year_1980	n_selects	*Кол-во заходов на карточку*
release_year_1980	release_year_2010	release_year_1980	release_year_1990	n_watches	*Кол-во просмотров*
release_year_1990	release_year_2015	release_year_1990	release_year_2000	watched_time	*Время просмотра*
release_year_2000	release_year_2017	release_year_2000	release_year_2010	max_pos	*Максимальный заход по пролистываниям*
release_year_2010	release_year_2020	release_year_2010	release_year_2015	cr_stow	*n_watches/n_selects*
release_year_2015	svod_ratio	release_year_2015	release_year_2017	awtpp	*watched_time/pagings*
release_year_2017	user_watch_count	release_year_2017	release_year_2020	svod_ratio	*Доля просмотров по подписке*
release_year_2020		release_year_2020	svod_ratio		
svod_ratio		svod_ratio			
user_watch_count		mean_rating			
		n_titles			