

От Jupyter Notebook → к MLOps pipeline

2023

в связке
с ClearML

для проекта видео
аналитики Антифрод

NAPOLEON IT

О себе

NAPOLEON IT

Team Lead CV (Napoleon IT)

Проекты видеоаналитики

Middle ML Engineer (EPAM SYSTEMS)

ETL/BIG Data проект для Coca-Cola

**Трижды победитель всероссийских
хакатонов hacks.ai**

Самара, Екатеринбург, Санкт-Петербург

Технический эксперт всероссийских

хакатонов hacks.ai

Наша повестка

01

Введение

- Как велась разработка до
- Проект Антифрод
- Почему мы пошли в MLOps

02

MLOps pipeline

- Что это
- Что мы пробовали
- К чему мы пришли
- ClearML overview
- Как работает наш пайп

03

Заключение

- Преимущества и неудобства ClearML
- Как теперь ведется разработка
- Заключение

Введение

- Как велась разработка до
- Проект Антифрод
- Почему мы пошли в MLOps

▸ Как велась разработка до

NAPOLEON IT



~40%
артефактов лежат
локально

~45%
кода лежит локально

~65%
ручной однотипной
работы для релиза

~35%
проекта удовлетворяет
концепциям mlops

► Проект Антифрод

В 2022 году в магазинах увеличилось число краж: чаще всего злоумышленников привлекали кондитерские изделия и колбаса. Зачастую товары уносят без оплаты вместе с корзинкой.

Тренд: хищения на кассах самообслуживания

80

краж в среднем
на 1 маг/мес

1 500 ₽

средняя сумма
кражи

на 34%

рост краж на КСО
в 2022 году



► Проект Антифрод

NAPOLEON IT

Касса самообслуживания—зона, которая нуждается в максимальном контроле. Система CV способна защитить потенциальную точку возникновения фрода, предусматривая множество ситуаций.

01

Перестикеровка товаров

Покупатель взвесил авокадо как чеснок, производит покупку в зоне СО

02

Ошибочные действия

Покупатель увидел акцию “3 товара по цене 2” и пробил всего 2 товара на КСО

03

Вывоз тележки с товаром

Группа покупателей вывезла полную телегу товара через зону СО без оплаты покупки

04

Отсутствие сканирования товара

Покупатель положил в корзину 5 SKU, при этом оплатил только 3 SKU, 2 оставшихся пронес мимо сканера КСО

05

Сговор с ассистентом КСО



Покупатель пришел в зону КСО с товаром, ассистент зоны КСО под видом помощи аннулировал чек и отпустил покупателя

06

Техническая ошибка

Система селфскан выдала ошибку и не смогла добавить товар в корзину. Покупатель не заметил эту ошибку

► Проект Антифрод



▸ Почему мы пошли в MLOps

NAPOLEON IT

01

Поддержка как минимум
4-ех моделей

02

Сроки на разработку

03

Большое количество
данных и экспериментов

MLOps pipeline

- Что это
- Что мы пробовали
- К чему мы пришли
- ClearML overview
- Как работает наш пайп

▶ ЧТО ЭТО

MLOps – это набор процедур, которые направлены на автоматизацию и ускорение процесса разработки новых моделей.


Включает в себя:

- ▶ процесс версионирования кода, данных, артефактов (модели, метрики, параметры)
- ▶ мониторинг
- ▶ возможность удаленного запуска задач

Основные принципы:

- ▶ версионирование (код, артефакты – данные, модели, метрики, эксперименты)
- ▶ автоматизация (уменьшение ручного вмешательства в релизы)
- ▶ взаимодействие с вычислительными мощностями

► ЧТО ЭТО



▸ Что мы пробовали

NAPOLEON IT



оркестратор



версионирование данных



хранение артефактов
и экспериментов

▸ Что мы пробовали



Apache Airflow — это решение с открытым исходным кодом. Это оркестратор, который позволяет наладить разработку, планирование и мониторинг сложных рабочих процессов.

- Написан на Python
- Работает как планировщик ETL/ELT-процессов
- Есть хорошая админка
- Неограниченно расширяем

► Что мы пробовали



Но скрипт для подготовки датасета с помощью AirFlow занимает 459 строк...

```
427     ssh_connection_hook(dag_context, command)
428
429     command = """
430         docker rm -f
431     """
432     ssh_connection_hook(dag_context, command)
433
434     command = """
435         docker rmi -f \
436     """
437
438     ssh_connection_hook(dag_context, command)
439     print("Removed containers and image")
440 else:
441     print("Clean_up skipped")
442
443 (
444     log_the_config()
445     >> login_to_registry()
446     >> update_container()
447     >> download_logs()
448     >> create_dataset_files()
449     >> get_id_to_annotate()
450     >> push_to_platform()
451     >> sensor_task
452     >> get_annotated_dataset()
453     >> upload_dataset_to_dvc()
454     >> dataset_mart()
455     >> clean_up()
456 )
457
458
459 create_dataset_file_dag = create_bristol_dataset()
```

▸ К чему мы пришли

NAPOLEON IT



оркестратор



версионирование данных



хранение артефактов
и экспериментов


▸ ClearML overview

NAPOLEON IT

ClearML — инструмент с открытым исходным кодом для упрощения разработки и ведения экспериментов машинного обучения.

- Отслеживание и загрузка метрик и моделей с помощью нескольких строк кода
- Версионирование данных
- Возможность выстраивания пайплайнов задач
- Удаленный запуск задач
- Воспроизведение экспериментов с помощью UI
- Мониторинг моделей

► ClearML overview




▶ ClearML. Snippet

Скрипт для создания датасета с помощью ClearML занимает 44 строки:

- ▶ Запуск на remote
- ▶ Создание датасета и его версии
- ▶ Повторный запуск через UI
- ▶ Автоматическое логирование

```
1 from clearml import Dataset, Task, TaskTypes
2 from configs.config import DataCreationConfig
3 from src.data_preparation. import process_dataset
4
5
6 def main():
7     config = DataCreationConfig.parse_raw("configs/data_creation.yaml")
8     Task.add_requirements('./requirements.txt')
9
10    task = Task.init(
11        project_name=config.project_name,
12        task_name=config.clearml_task_name,
13        task_type=TaskTypes.data_processing,
14        reuse_last_task_id=True
15    )
16    task.set_base_docker(
17        docker_image=
18        docker_arguments=["--entrypoint=\"\"", "--shm-size=1G"],
19    )
20    task.connect(config, 'Args')
21    if config.release_deploy:
22        print("This task is for deploy -> Done")
23        task.add_tags(config.release_version)
24        task.mark_completed()
25    else:
26        # clearml dataset creation
27        task.execute_remotely("mendelev_0")
28        dataset = Dataset.create(
29            dataset_name=config.dataset_name,
30            dataset_project=config.dataset_project,
31            dataset_version=config.release_version,
32            parent_datasets=config.parent_datasets_id
33        )
34
35        # dataset creation & validation
36        process_dataset(config, dataset_id=dataset.id)
37
38        # data uploading
39        dataset.add_files(config.final_dataset_path)
40        dataset.upload()
41        dataset.finalize()
42
43        task.add_tags(config.release_version)
44        task.set_parameter("Args/dataset_id", dataset.id)
```


► ClearML. Snippet



▶ ClearML. Snippet

Возможные действия с задачами:

- ▶ Просмотр информации (графики, логи и тд)
- ▶ Поместить в очередь на remote
- ▶ Перезапустить с таким же конфигом
- ▶ Сделать read-only
- ▶ Добавить тэг
- ▶ Клонировать
- ▶ Переместить



▸ ClearML. Experiment Manager

NAPOLEON IT

Внутри задачи:

Execution

Конкретная ветка гитлаба и коммит, который запускается в задаче, и изменения в скрипте по отношению к предыдущему

Configuration

Конфигурация задачи

Artifacts


Все артефакты, которые появились в результате выполнения задачи

Info

На каком агенте запускалось, какие у него характеристики (гпу, память и тд), кто запускал, во сколько и тд


► ClearML. Experiment Manager

- Возможность сравнения экспериментов




▶ ClearML. Datasets

- ▶ Версионирование данных
- ▶ Видит отличия одной версии от другой
- ▶ В UI есть возможность предпросмотра датасета
- ▶ Простая логика выгрузки




► ClearML. Pipelines

- Отслеживание прогресса выполнения
- Возможность добавления параллельных этапов
- Возможность повторного запуска через UI




► ClearML. Pipelines




▸ ClearML. Agent

- Режимы pip/poetry/conda/docker
- Dynamic gpu-s
- Взаимодействие через UI
- Кэширование зависимостей
- Мониторинг очередей и агентов




▶ ClearML. Agent




ClearML

ClearML overview



▸ Принцип работы нашего пайпа

- Выгрузка с сервиса разметки CVAT
- Запуск обучения моделей на remote машинах с GPU
- Конвертация моделей




► Принцип работы нашего пайпа

- 21-24 сделаны для деплоя тасок
- Подхватывает актуальный код
- Не выполняет на Gitlab Runner, а только деплоит

```
6 def main():
7     config = DataCreationConfig.parse_raw("configs/data_creation.yaml")
8     Task.add_requirements('./requirements.txt')
9
10    task = Task.init(
11        project_name=config.project_name,
12        task_name=config.clearml_task_name,
13        task_type=TaskTypes.data_processing,
14        reuse_last_task_id=True
15    )
16    task.set_base_docker(
17        docker_image=
18        docker_arguments=["--entrypoint=\"\"", "--shm-size=1G"],
19    )
20    task.connect(config, 'Args')
21    if config.release_deploy:
22        print("This task is for deploy -> Done")
23        task.add_tags(config.release_version)
24        task.mark_completed()
25    else:
26        # clearml dataset creation
27        task.execute_remotely("mendeleev_0")
28        dataset = Dataset.create(
29            dataset_name=config.dataset_name,
30            dataset_project=config.dataset_project,
31            dataset_version=config.release_version,
32            parent_datasets=config.parent_datasets_id
33        )
34
35        # dataset creation & validation
36        process_dataset(config, dataset_id=dataset.id)
37
38        # data uploading
39        dataset.add_files(config.final_dataset_path)
40        dataset.upload()
41        dataset.finalize()
42
43        task.add_tags(config.release_version)
44        task.set_parameter("Args/dataset_id", dataset.id)
```

▸ Принцип работы нашего пайпа

- Деплоим задачи в проект ClearML
- Деплоим пайплайн в ClearML
- Используем механизм `base_parent_project` чтобы пайплайн подхватил последние задеплоенные задачи с родительского проекта



Заключение

- Преимущества и неудобства ClearML
- Как теперь ведется разработка
- Выводы

▸ Преимущества ClearML

NAPOLEON IT

Инструмент конкретно под ML

автоматическое логирование артефактов, датасеты, отображение метрик

Один инструмент содержит обширный функционал

мониторинг моделей, репорты, эксперименты, пайплайны и тд

Активная поддержка community

▸ Неудобства ClearML

NAPOLEON IT

Недоступно разделение
прав пользователей

по проектам, пространствам

Чтобы добавить нового
пользователя нужно
ребутать ClearML Server

Новый, развивающийся
проект = несовпадение
документации

Task в UI не подтягивает
указанный commit

Достаточно
проблематичный дебаг
на remote тачках

▸ Как велась разработка до

NAPOLEON IT



~40%
артефактов лежат
локально


~45%
кода лежит локально

~65%
ручной однотипной
работы для релиза

~35%
проекта удовлетворяет
концепциям mlops

▸ Как ведется разработка сейчас

NAPOLEON IT



0%
артефактов лежат
локально

0%
кода лежит локально

~15%
ручной однотипной
работы для релиза

~85%
проекта удовлетворяет
концепциям mlops

▸ Выводы

NAPOLEON IT

- MLOps – необходимая вещь в компаниях (ClearML – как вариант)
- Сократили необходимое время для релиза новой модели в 3 раза
- Меньше переживаний по поводу потери данных и артефактов из-за непредвиденных ситуаций
- Стало проще отслеживать эксперименты и прогресс моделей



Игорь Терехин
Team Lead CV



Telegram: [spannenberger](https://t.me/spannenberger)
Email: i.terekhin@napoleonit.com