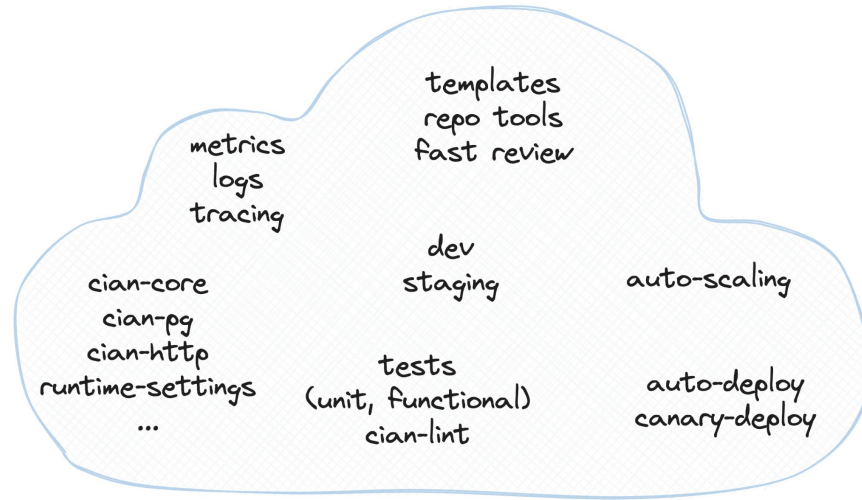


Эволюция MLOps в Циан

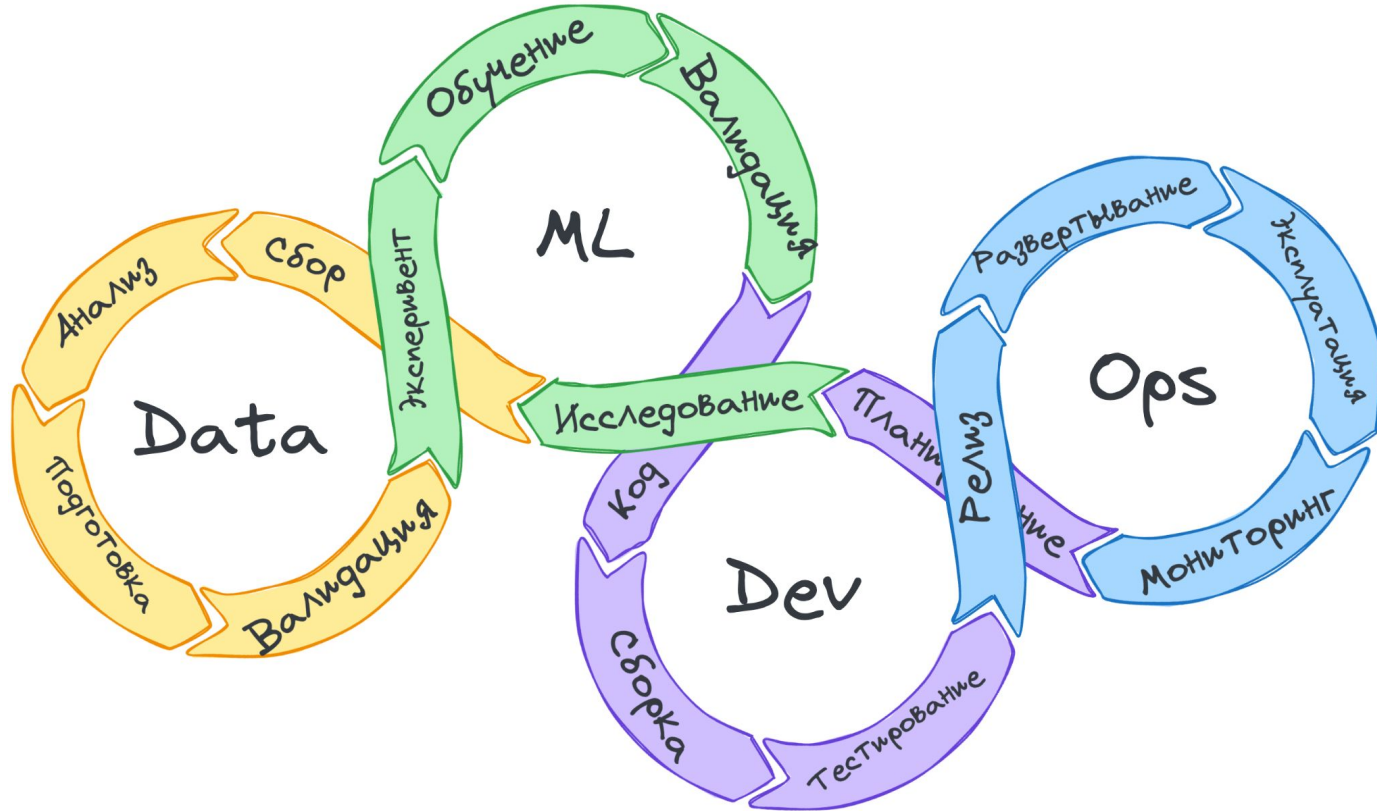
Роман Песков
старший инженер-
разработчик
ML-платформа, Циан



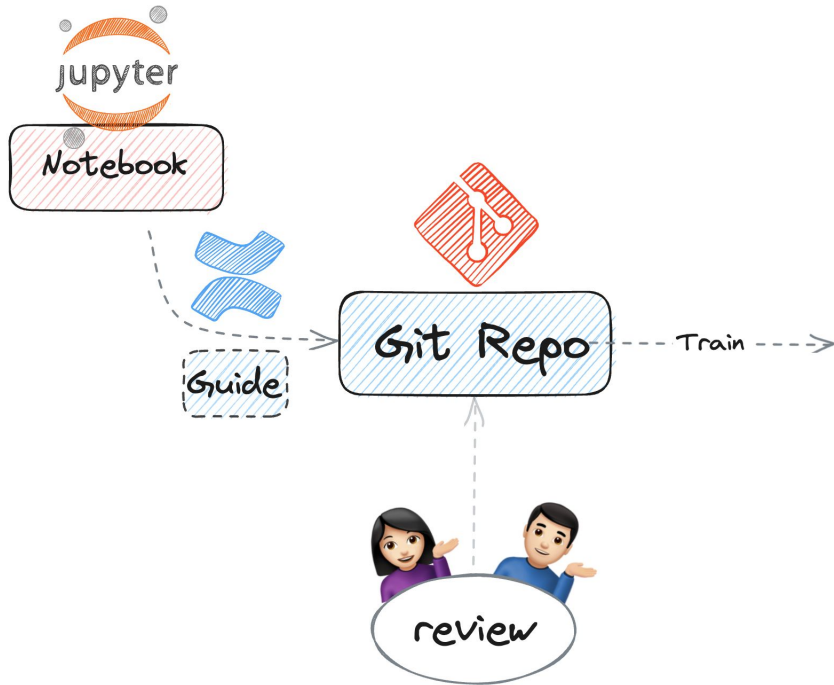
PiterPy / 2023



- шаблоны микросервиса, библиотеки;
- готовые либы для работы с БД, кешем, метриками, логами и т.п.;
- удобное написание функциональных тестов;
- линтеры, формтеры, swagger-check;
- codegen;
- dev/staging среды;
- автодеплой, canary-деплой;
- автоскейлинг;
- ...




Исследование и эксперименты

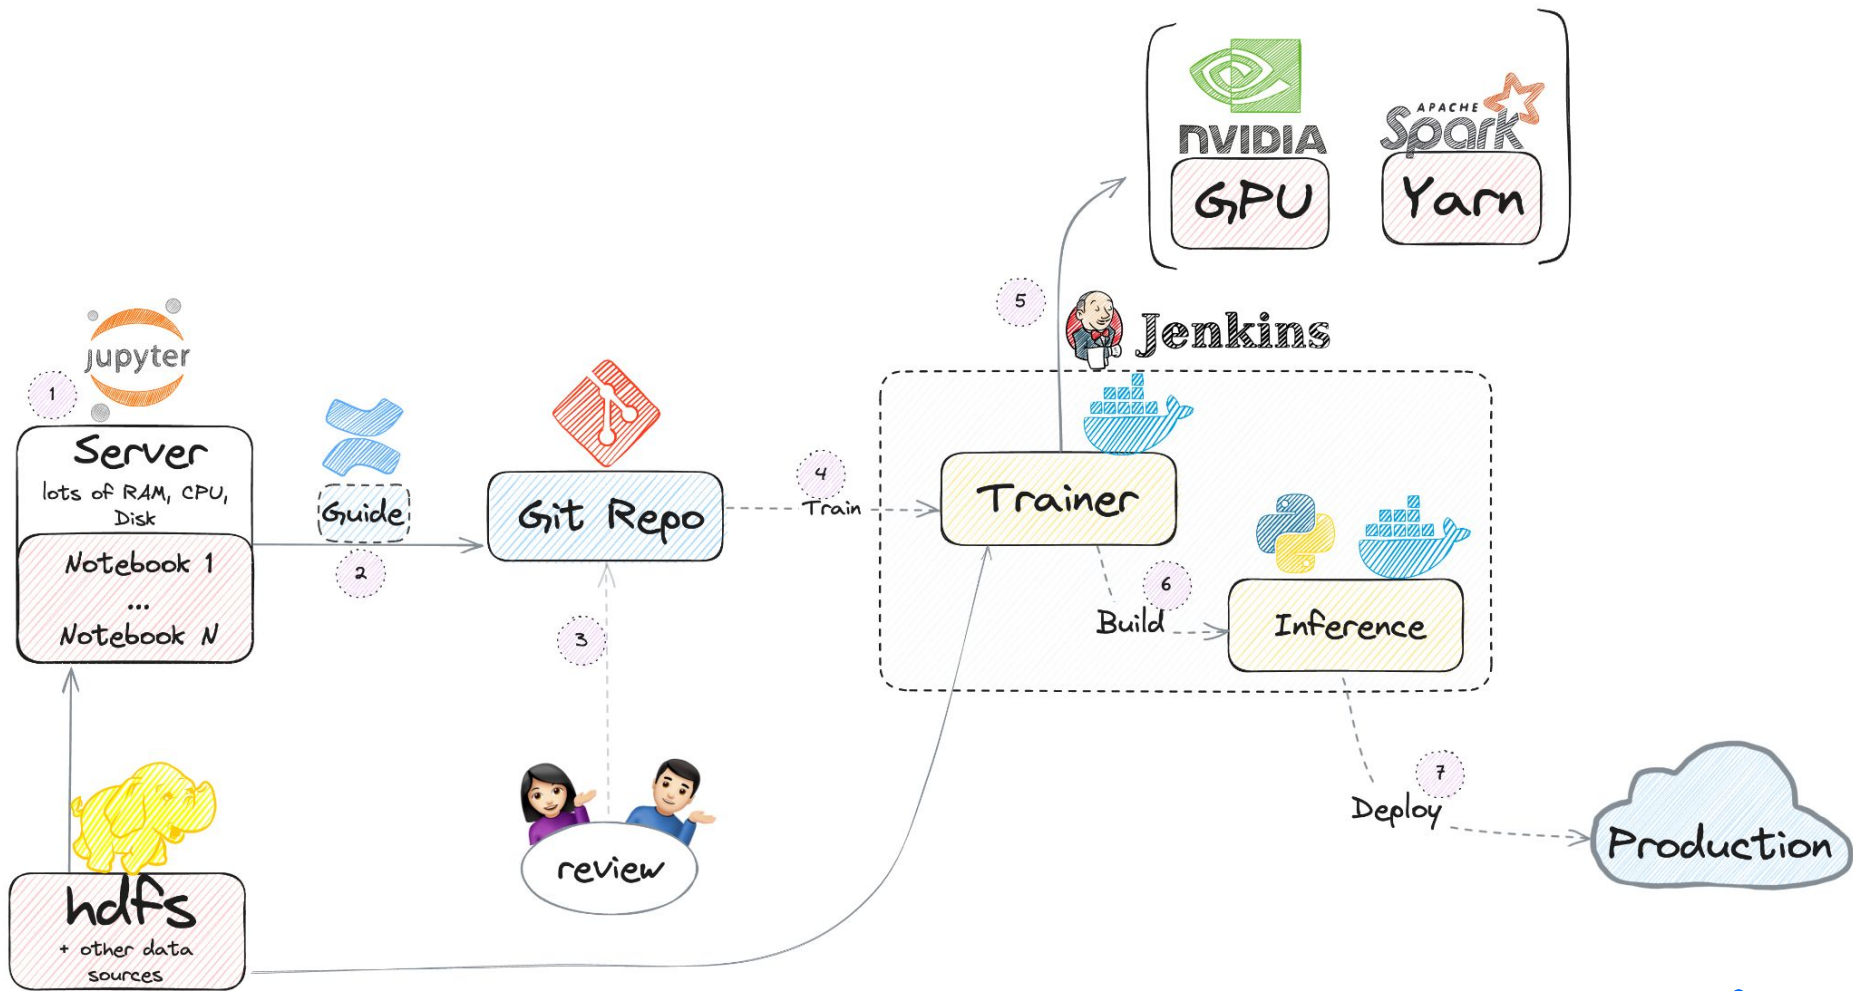


- Исследование и написание кода в личном Jupyter-ноутбуке на сервере с большим количеством ресурсов.
- Оформление Jupyter-ноутбука согласно документации, сохранение в git-репозиторий.
- Ревью «по запросу».


Обучение и Production-этап



- Отдельные джобы обучения под каждую модель.
- Отдельные джобы для сборки образа и деплоя модели в production под каждую модель.
- Ручной запуск.

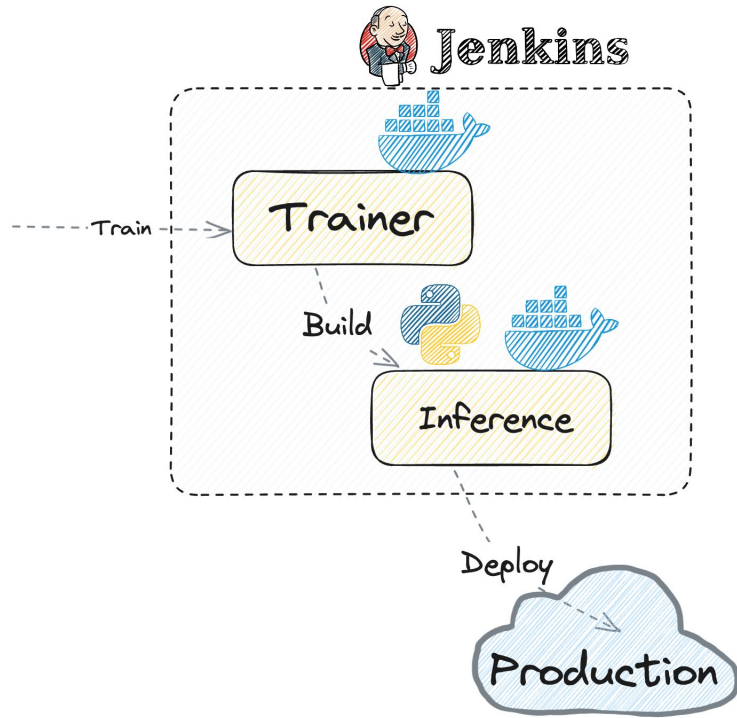


Исследование и эксперименты

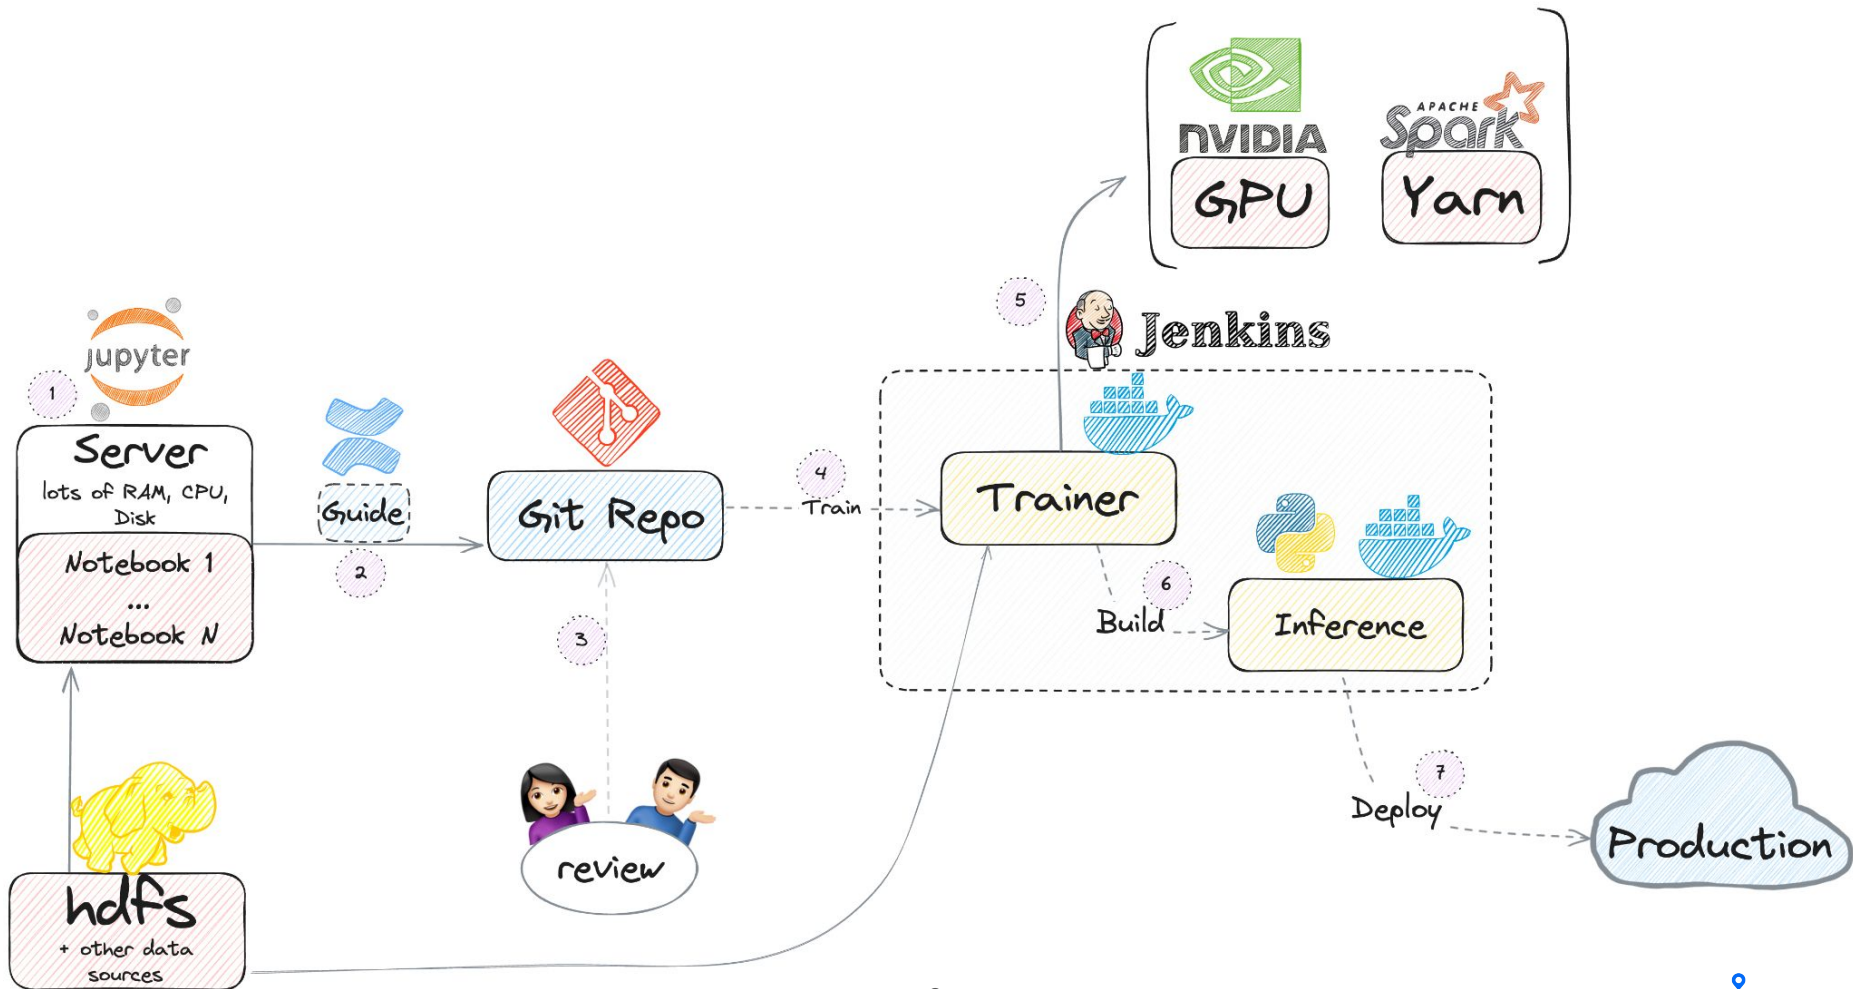


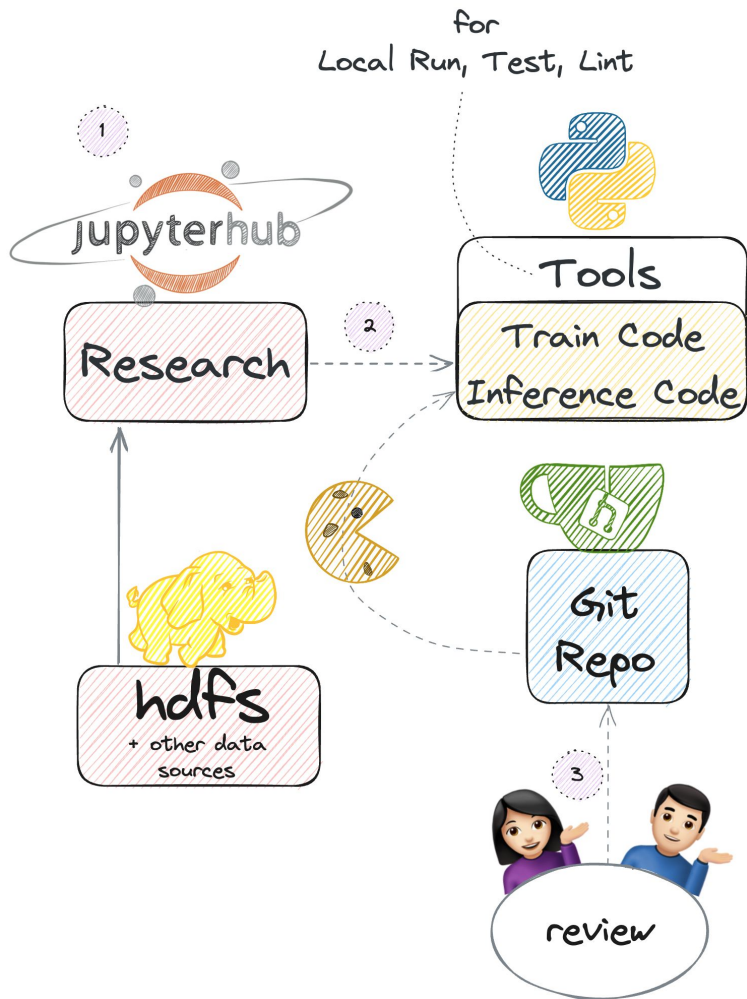
- Борьба за ресурсы.
- Постепенное «замусоривание».
- Слабая изоляция окружений.
- Соблазн, запустить модель для прода там же, где экспериментировали.

Обучение и Production-этап



- Отсутствие автоматизации.
- Нет model registry.
- Нет управления качеством.
- Ручной трейн и деплой.
- Сложности с мониторингом и логами.
- Привыкаешь к «плохому».





- JupyterHub для изоляции Jupyter-ноутбуков.
- Шаблон модели, cookiecutter.
- Инструменты для миграции из ipynb в структуру шаблона.

Шаблон репозитория модели

```
# конфигурация модели
```

```
01  model.toml
```

```
# зависимости для обучения
```

```
02  requirements.txt
```

```
03  train_system_libs.txt
```

```
# зависимости для инференса
```

```
04  inference_requirements.txt
```

```
05  inference_system_libs.txt
```

```
# код модели
```

```
05  ml_model/
```

```
06      train/ # код обучения
```

```
07          train.py
```

```
08      inference/ # код инференса
```

```
09          inference.py
```

```
10      shared/ # общие модули
```

```
# функциональные тесты
```

```
11  tests_functional/
```

```
12      v1_predict/
```

```
13          test_request_01.json
```

Конфигурация модели

```
01 [model]
02 model_name = "ml-model-test"
03 model_version = 1
04 model_type = "classification"
05 team = "ml-platform"

06 [runtime]
07 python_version = "3.10"

08 [inference_resources]
09 cpu_limit = 512
10 memory_limit = 1024
...

11 [train_resources]
12 memory_limit = 2000
13 cpus_number = 1
...
```

```
14 [train_metrics]
15 recall.min = 0.9

16 [dvc]
17 train_dataset_name = "some-dataset"

18 [stat_monitoring]
19 sampling_ratio = 0.5
```

```
# обучаем модель
```

```
01   clf = svm.SVC(gamma='scale')
02   iris = datasets.load_iris()
03   X, y = iris.data, iris.target
```

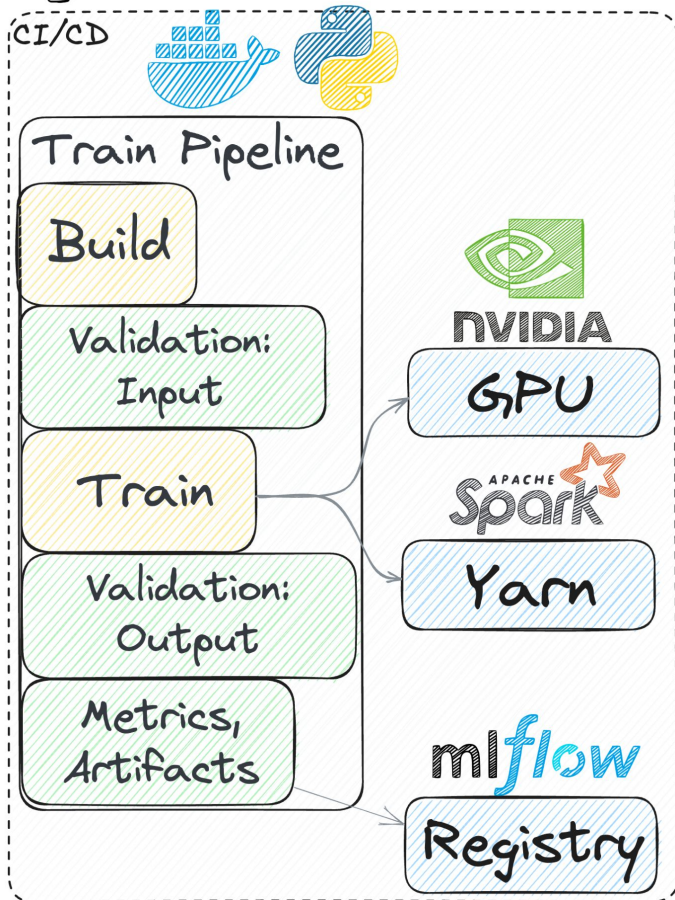
```
# сохраняем модель
```

```
04   with open('sklearn_model.pkl', 'wb') as f:
05       pickle.dump(clf, f)
06   artifacts = {'sklearn_model': 'sklearn_model.pkl'}
```

```
# сохраняем информацию об артефактах в inference_artifacts.json
```

```
07   Path('inference_artifacts.json').write_text(json.dumps(artifacts))
```

Jenkins




- Подготовленные образы тренера GPU/CPU.
- Валидация входных/выходных данных.
- Валидация метрик.
- Сохранение в MLflow.

Inference



Облачные решения



Yandex Cloud

Amazon SageMaker, Google Vertex AI, Azure ML, etc.

- + Удобно, если уже в облаке.
- + Запуск в пару кликов из ноутбука.
- + Масштабируется.
- Управление доставкой изменений, качеством, безопасностью — «отменяют» удобство.
- Ограниченная кастомизация.
- Привязка к конкретному облаку.
- Не всегда очевидное ценообразование.

Готовые решения



Nvidia Inference Server, TorcheServe, Seldon Core, etc.

- + Много возможностей из коробки.
- + Производительность, бенчмарки.



- Может не хватать возможностей.
- Зависимость от решения.
- Может быть избыточным.

Свое решение

FastAPI



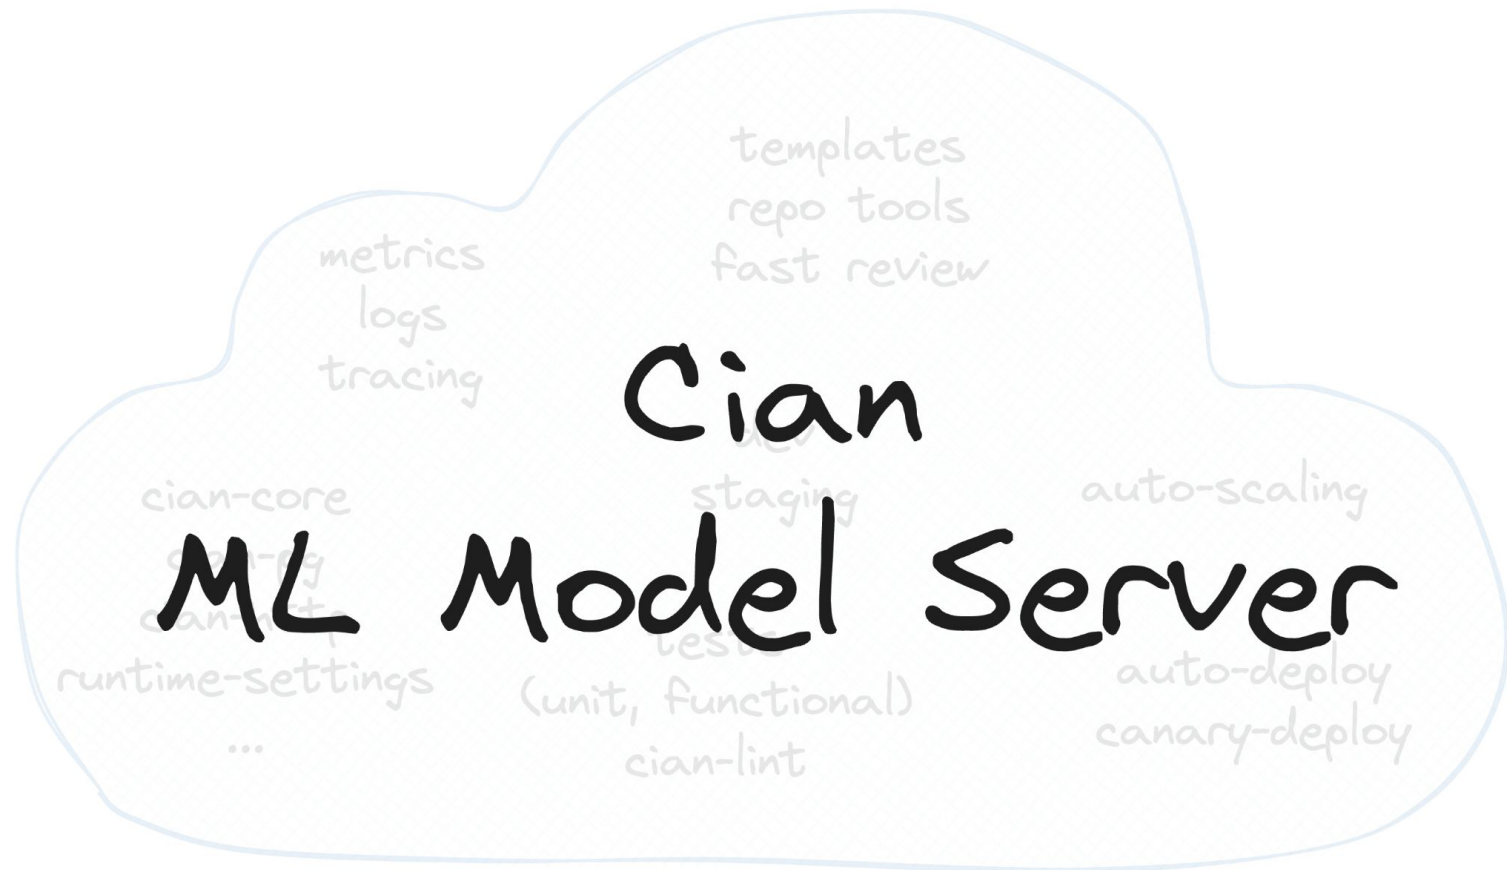

Flask



На основе FastAPI, Flask, Tornado, etc.

- + Гибкость.
- + Практически неограниченные возможности.
- + Совместимость с существующей инфраструктурой.

- Практически неограниченные возможности.



inference.py

```
01 class TestModel(mlflow.pyfunc.PythonModel):
02     def load_context(self, context):
           # На этапе обучения мы сохранили информацию об артефактах
           # Артефакты из inference_artifacts.json будут доступны в context.artifacts
03     with open(context.artifacts['sklearn_model'], 'rb') as f:
04         self.sklearn_model = pickle.load(f)

           # делаем что-то с data, если нужно
05     def transform_input(self, context, data):
           ...

06     def predict(self, context, model_input):
06         return self.sklearn_model.predict(model_input)[: , np.newaxis]
```

schemas

```
01 @dataclass
02 class Image
03     filename: str
04     raw_body: bytes
05     pillow_image: JpegImageFile
```

```
01 @dataclass
02 class ModelResponseSchema
03     # произвольный формат, например:
04     classes: List[str]
```

```
01 @dataclass
02 class UploadedFile:
03     filename: str
04     body: bytes
05     content_type: str
```

model_mcs

```
01 def model_setup():
02     loaded_model = mlflow.pyfunc.load_model(model_uri=get_model_path())
03     model.set(loaded_model)

04 def setup() → None:
05     cian_core.setup(..., additional_setup=model_setup, ...)

...

06 def execute_model_predict(model_input: Any) → Any::
07     ml_model = model.get()
08     with statsd.timer('prediction.model-predict'):
09         predictions = ml_model.predict(model_input)
10     return predictions
```

Тесты

test_request01.json

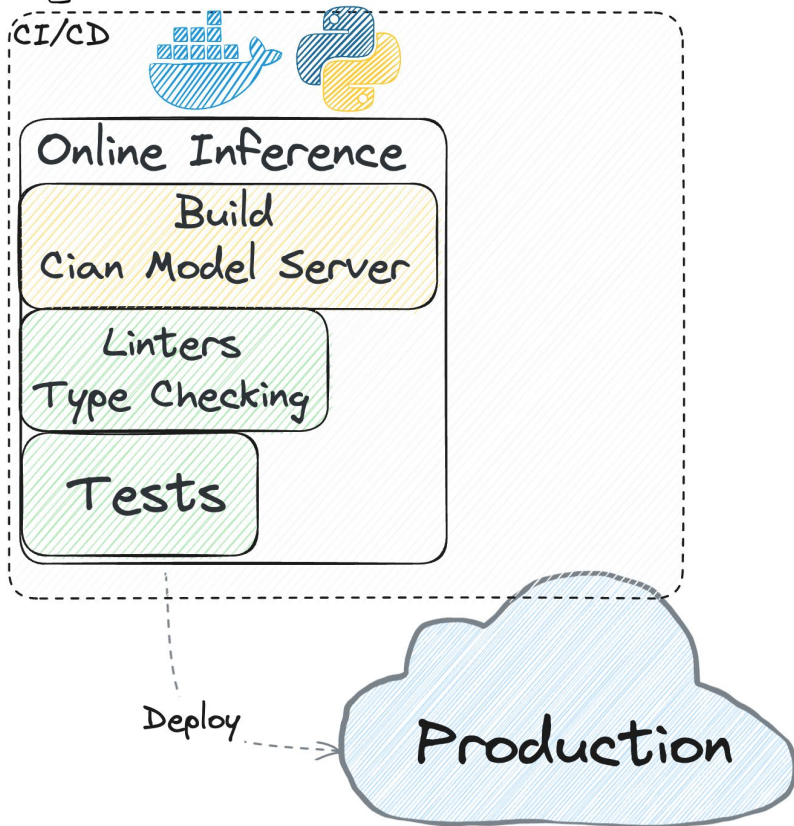
```
{
  "floatData": [[1.0, 2.0]],
  "strData": [["foo", "bar"]]
}
```

test_request01_response.json

```
{
  "predictions": [[3.0, ">60, ≤100"]]
}
```




Jenkins




- Сборка микросервиса с моделью.
- Проверка форматирования, типов.
- Тесты.
- Деплой (+canary).

Production

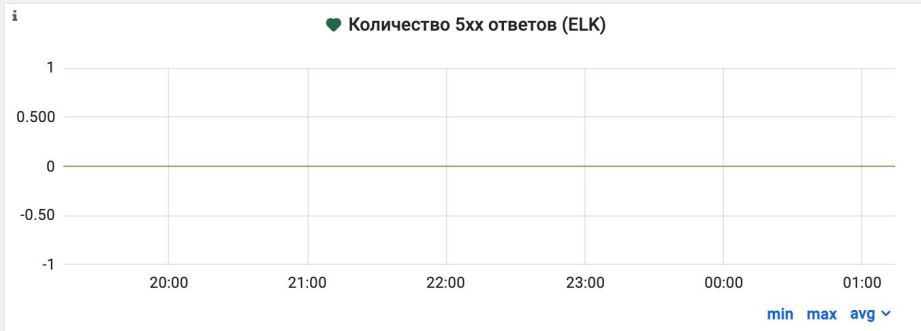
Время выполнения predict (p99)





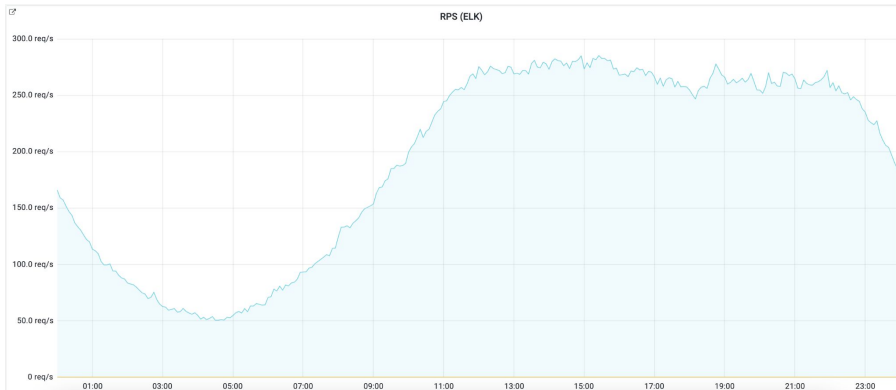
Потребление видеопамяти



- Мониторинг, алерты в grafana.
- Логи в ELK.
- Автоскейлинг.
- Изменение ресурсов на лету.



Автоскейлинг




Управление ресурсами




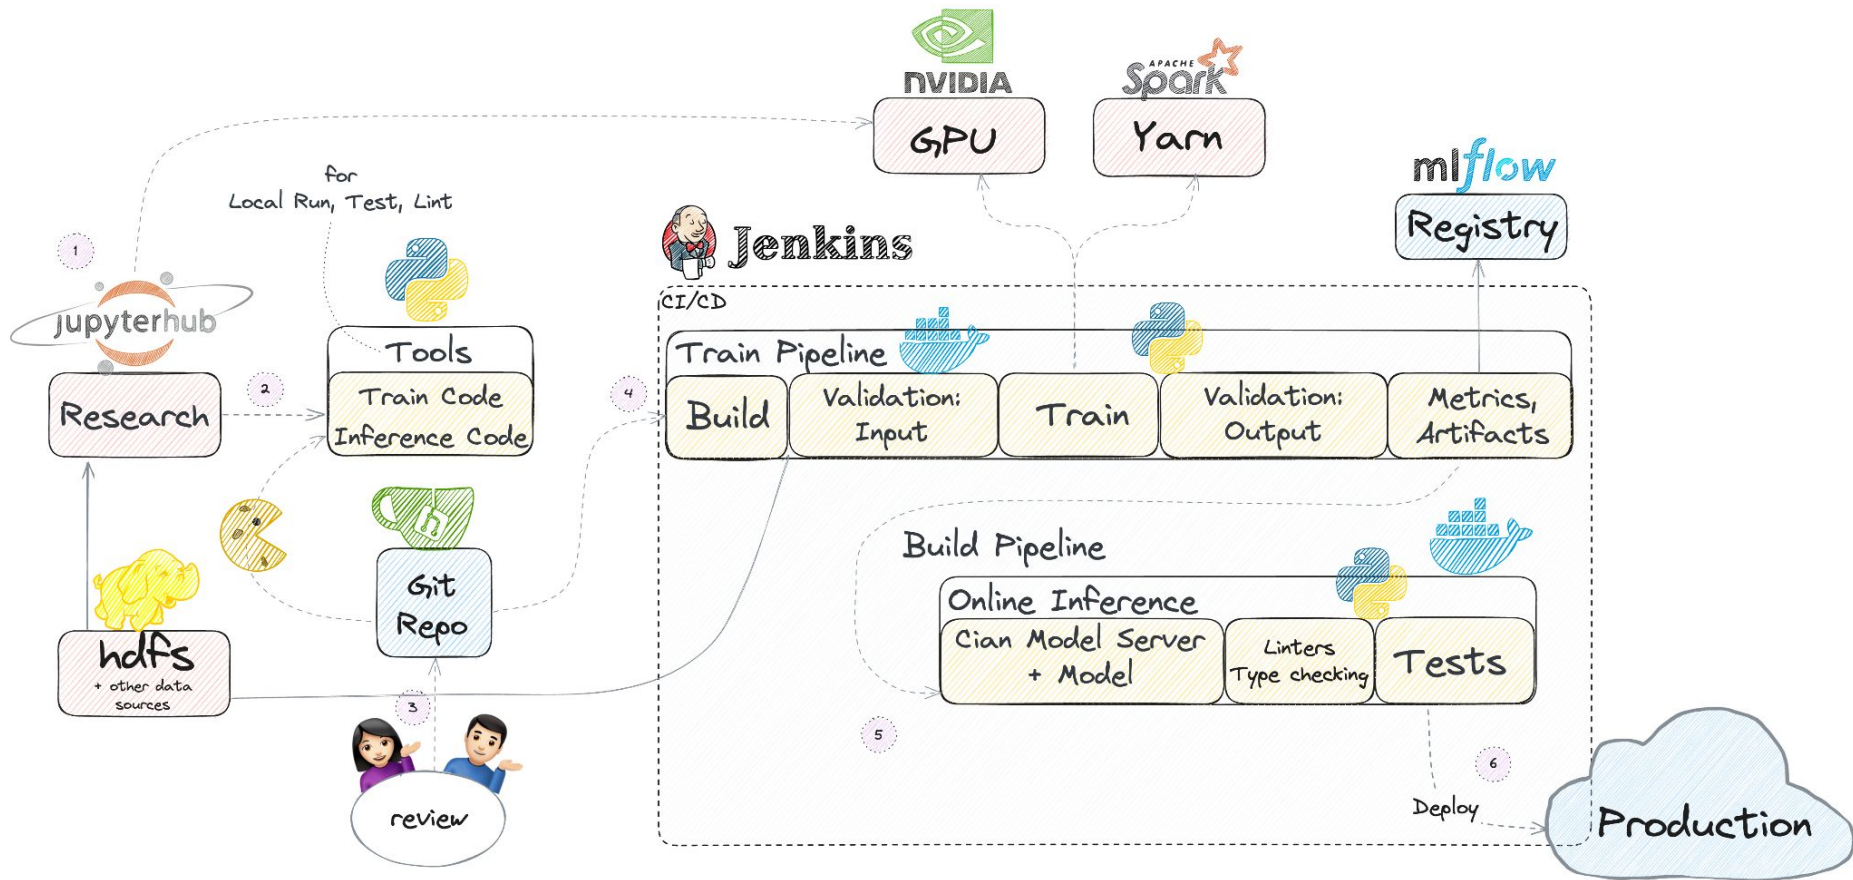
● запрошено

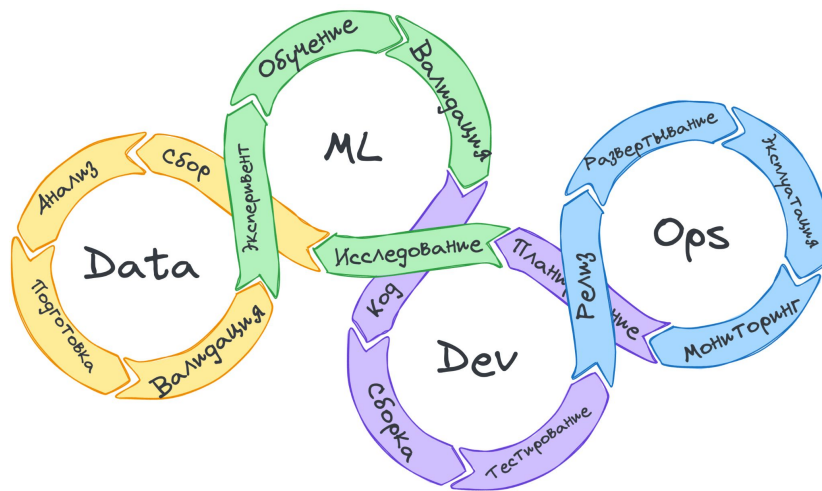
● рекомендовано

● порог для автоскейлинга

 **Alert Bot** APP 13:00
🔥 [ALERTING] Resources / Заявлено cpu больше чем рекомендуется
1 час 23 минуты

 **ml-platform-bot** APP 23:00
Неиспользуемые модели в production
ml-model-empty
my-super-model





Что еще хотелось:

- удобное управление «одной кнопкой»
- интерфейс с результатами каждого этапа
- сбор и анализ метрик времени работы джоб
- количество успешных, неуспешных запусков, классификация причин
- TTM моделей



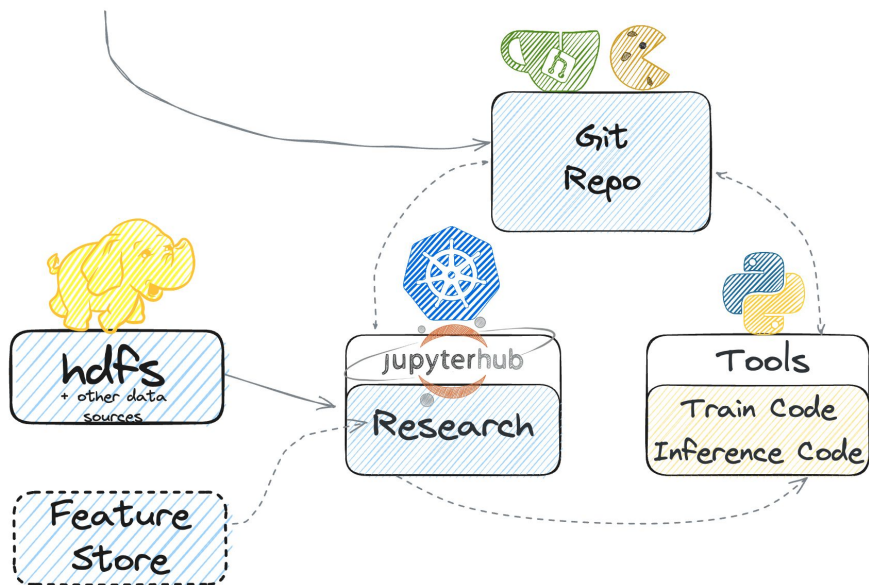
Jira + Comunda

1

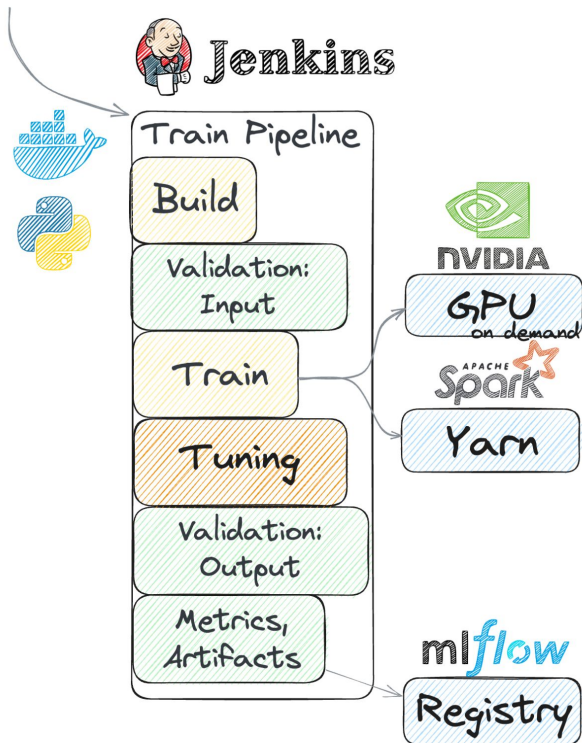


2





- Автоматическое создание репозитория.
- Далее ресерч в JupyterHub k8s.



Robot added a comment -

Обучение модели завершено

[Success] TRAIN_RESULT

- Трейн модели успешно завершен. Артефакты доступны по ссылке в MLflow.

Артефакты:

- MLflow train url.
- yarn_serviceam.log
- yarn_stderr.txt
- yarn_stdout.txt

mi-platform-bot APP 07:12

Train succeeded! 🎉

Model: ml-model-test-gpu v1

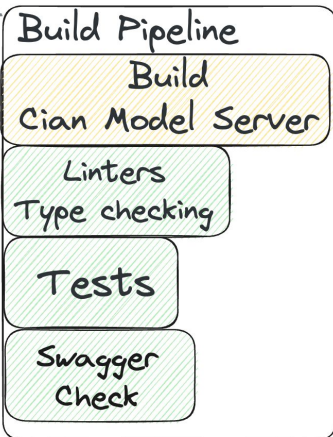
Branch: master

Train metrics:

n/a

[Open job in Jenkins](#)

[Open run in MLFlow](#)



▼ Robot added a comment - 31.10.2023, 11:27

[ERROR] Произошла ошибка
[ERROR] BUILD_RESULT

Артефакты:

- JOBEXTRAOUT_LINK_MCS_HEALTH_WARNINGS

[Failed] TESTING_RESULT

- Перезапустились 2 функциональных теста:
tests_functional.test_built_model.test_built_model_v1_predict.test_built_model_v1_predict[test_input0],
tests_functional.test_built_model.test_built_model_v1_predict.test_built_model_v1_predict[test_input1]
- Проверка Swagger схем сервиса успешно пройдена. Отчет доступен по ссылке.

Артефакты:

- mypy_report.txt (1 errors)
- fmt_report.txt (0 errors)
- swagger report (Errors: 0, Warnings: 0)

Ошибки:

- <<CODE>> Упали тесты, подробности по приложенной ссылке.

▼ Robot added a comment - 31.10.2023, 18:00

Сборка и тесты прошли успешно

[Success] BUILD_RESULT

Артефакты:

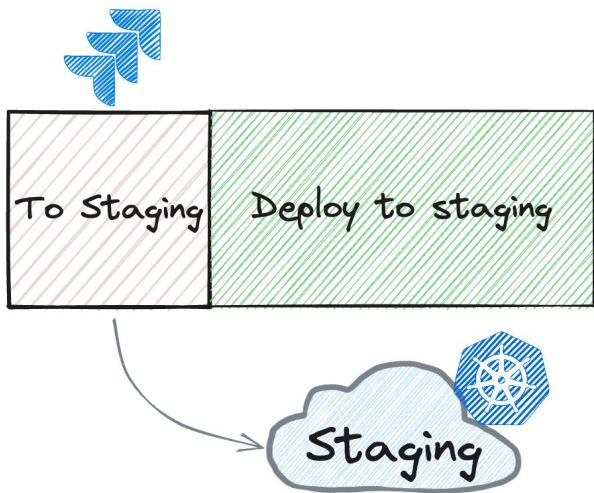
- JOBEXTRAOUT_LINK_MCS_HEALTH_WARNINGS

[Success] TESTING_RESULT

- Проверка Swagger схем сервиса успешно пройдена. Отчет доступен по ссылке.

Артефакты:

- diff-cover.html (100%)
- mypy_report.txt (1 errors)
- Overall coverage (68%)
- fmt_report.txt (0 errors)
- swagger report (Errors: 0, Warnings: 0)



✓ Robot added a comment -

Выкладка завершена

[Success] STAGING_RESULT


- Деплой в staging-окружение завершен. Убедиться, что сервис модели успешно запустился и находится в Healthy/Synced статусе, можно перейдя по ссылке.

Артефакты:

- [Service Url.](#)




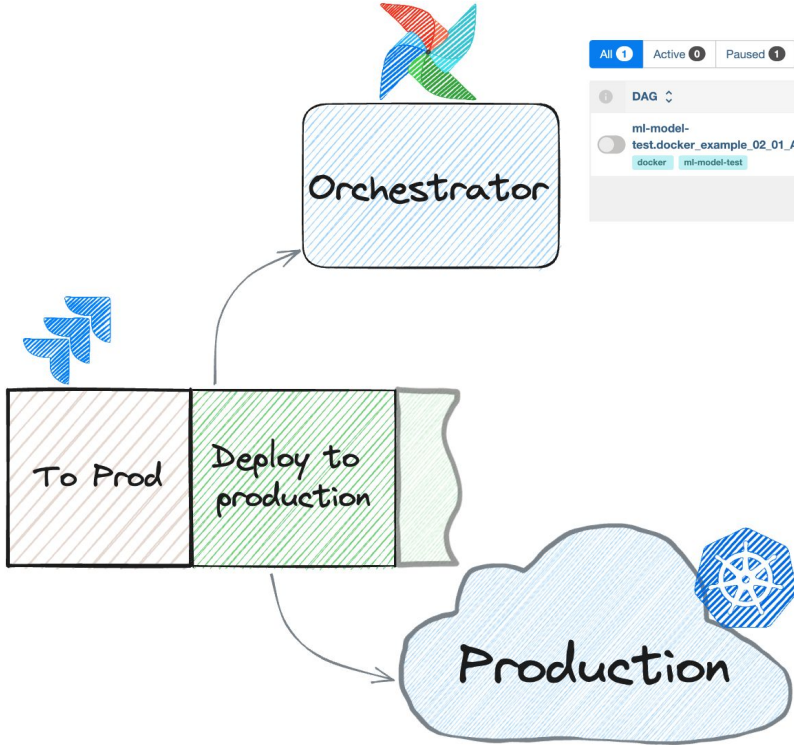
- Автоматическое назначение ревьюеров: один из мейнтейнеров модели/репозитория второй из всего пула ML





Developer:	Иван Иванов
Reviewers:	Андрей Андреев, Мария Машина, Роман Песков ***
Required Reviewers:	Андрей Андреев, Мария Машина

- Уведомления в slack о ревью

The screenshot shows a Slack message from 'Review Bot' (APP) at 10:40. The message text is: 'Тебя выбрали ревьюером задачи NEW-123 [my-super-model] Создать новую модель Developer: @Петр Петров'. Below the text are three buttons: 'PR в my-super-model', 'Задача в Jira', and 'Дашборд в Jira'.



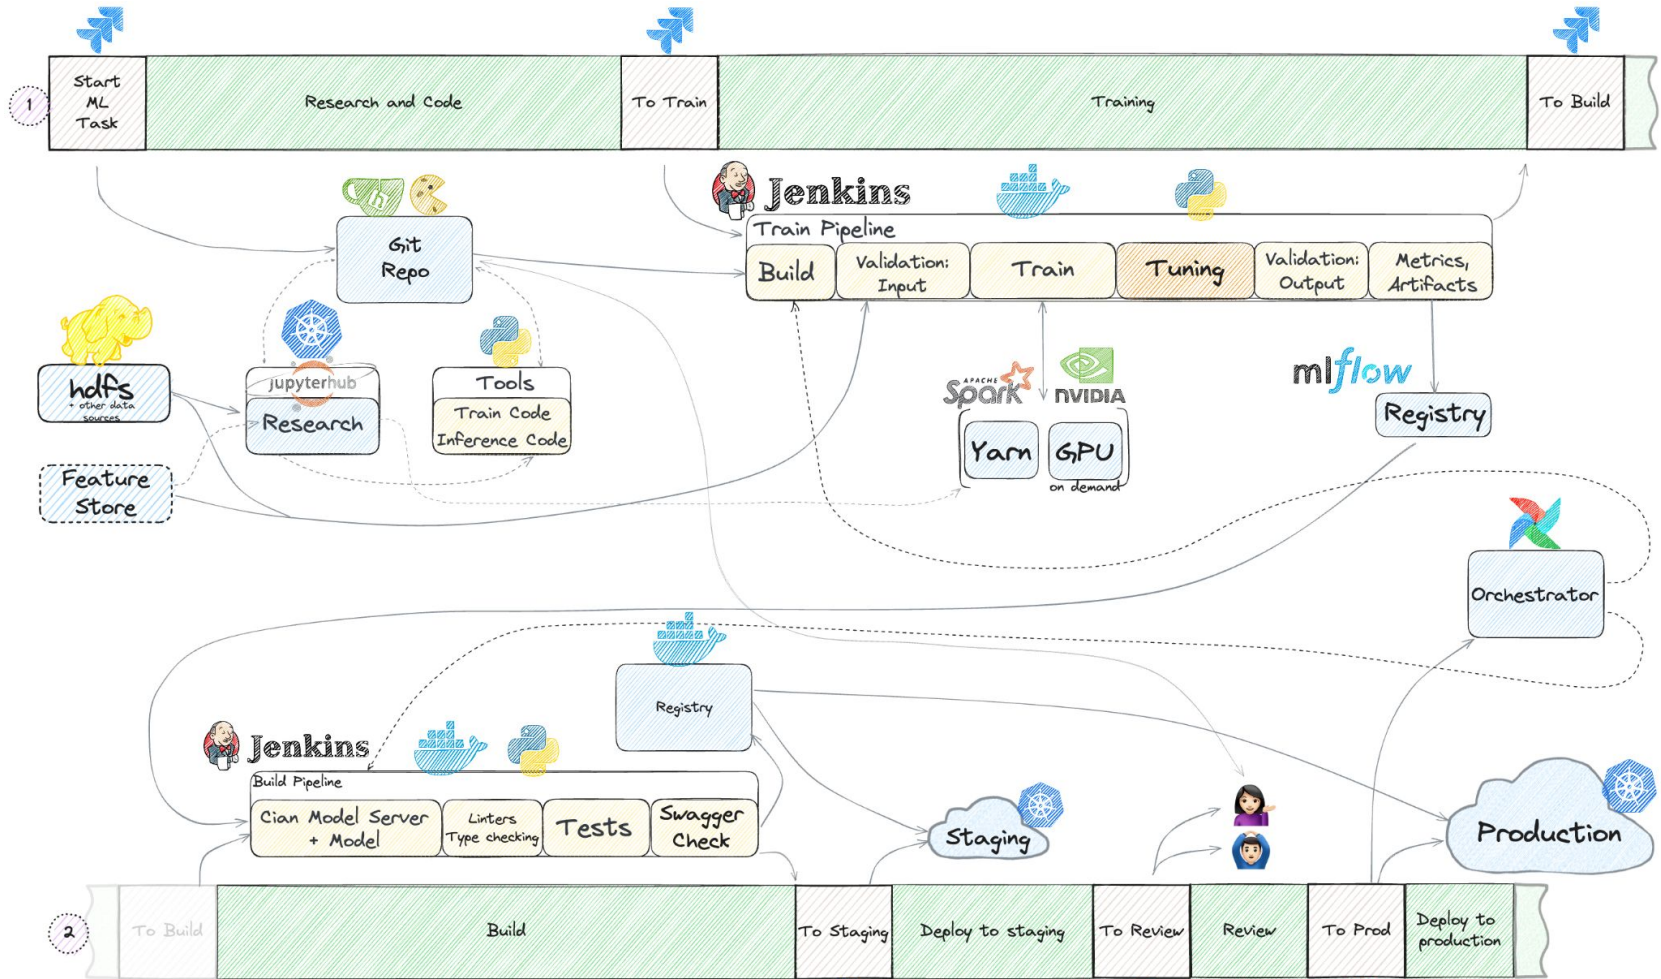
 **RoBot** APP 15:17





 **Сервис развернут в сагау-режиме.**

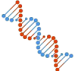


*Мониторинг микросервиса доступен в [Grafana](#).
 Approve станет доступен через 3 минуты после стабилизации

Task [NEW-125345] [my-ml-model] модель с новыми фичами

Инициатор <robot>	Разработчик @Роман Песков
Репозиторий my-ml-model	Процесс в Camunda Процесс в Camunda





- ручные запуски  ~0
- количество задач  x3
- время в ревью  -50%
- время сборки  -15%

- развитие и адаптация 
не останавливаем процессы
легаси, с которым нужно бороться
- для ML-команд 
через обратную связь
борьба с привычками
- экспертиза DI, SRE, DE 
сильно упрощает
нужно договариваться

спасибо



THANK YOU



@peskovrn