Apache
Airflow

# Курс Apache Airflow

# Содержание лекции

1. Назначение Apache Airflow
2. Основные особенности
3. Передача данных между задачами
4. Что такое глобальные переменные в Apache Airflow и зачем они нужны
5. Как создавать глобальные переменные и использование их в коде
6. Основная идея рабочих процессов в управлении данными
7. Поток управления
8. Рабочие нагрузки
9. Передача данных между задачами
10. Jinja

Apache Airflow

# Назначение Apache Airflow

Apache Airflow – платформа для **создания, оркестрации, управления** расписанием и **мониторингом** Workflow-процессов загрузок данных.

Основные сущности рабочего процесса на Apache Airflow:

- **Направленные ациклические графы (DAG)**
- **Планировщик (Scheduler)**
- **Операторы (Operators)**
- **Задачи (Tasks)**

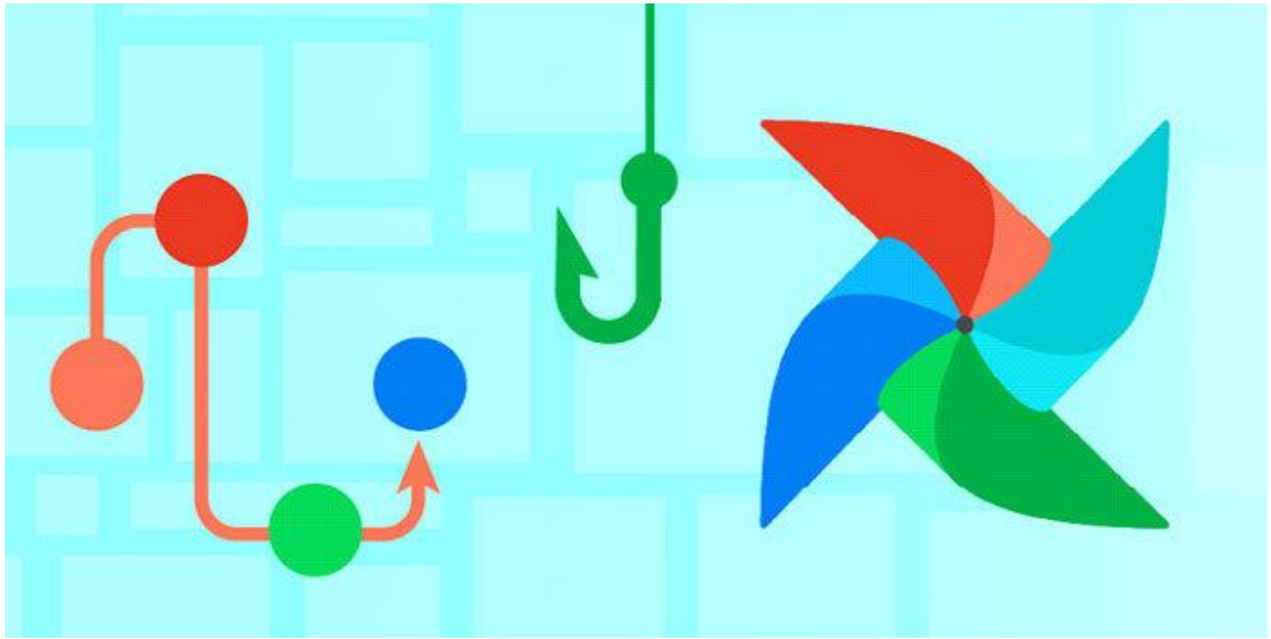

# Основные особенности

Airflow — это платформа для программного создания, планирования и мониторинга рабочих процессов.

- Airflow используется для создания рабочих процессов в виде направленных ациклических графов (DAG) задач.
- Планировщик Airflow выполняет задачи на множестве рабочих процессов, следуя указанным зависимостям.
- Богатые утилиты командной строки упрощают выполнение сложных операций с DAGs.
- Богатый пользовательский интерфейс позволяет легко визуализировать конвейеры, работающие в производственной среде, отслеживать ход выполнения и при необходимости устранять неполадки.

# Передача данных между задачами

**XComs («кросс-коммуникации»)**
система, в которой вы можете задавать задачи для передачи и извлечения небольших фрагментов метаданных (наверно надо написать что только для маленьких данных)

**Загрузка и скачивание больших файлов из общей системы хранения**
(либо запущенной вами, либо части общедоступного облака)


Airflow отправляет задачи для выполнения на рабочих процессах по мере освобождения места (пула ресурсов), поэтому нет гарантии, что все задачи в вашем DAGe будут выполняться на одном Worker или на одной и той же машине.

# ЧТО ТАКОЕ ПЕРЕМЕННЫЕ В APACHE AIRFLOW И ЗАЧЕМ ОНИ НУЖНЫ

Возможность передачи/приема информации через XCom имеется у каждого экземпляра задачи. XCom предназначен для взаимодействия внутри одного DAG’a, в то время как переменные являются глобальными, предназначены для общей конфигурации и существуют только во время выпо

# КАК СОЗДАВАТЬ ГЛОБАЛЬНЫЕ ПЕРЕМЕННЫЕ И ИСПОЛЬЗОВАНИЕ ПЕРЕМЕННЫХ В КОДЕ

- через ключ set:

```
airflow variables set my_key "1"
```

- экспортировать эту переменную в файл JSON:

```
airflow variables export vars.json
```

- достать переменную через Variable:

```
from airflow.models import Variable def result(ti): my_var = Variable.get("my_key")
```

- через шаблоны переменные также просто достаются:

```
ba = BashOperator( task_id="ba", bash_command="echo my_key = {{ var.value.my_key }}" )
```

# Основная идея рабочих процессов в управлении данными

Airflow — это платформа, которая позволяет создавать и запускать рабочие процессы. Рабочий процесс представлен как **DAG** (направленный ациклический граф) и содержит отдельные части работы, называемые задачами, организованные с учетом зависимостей и потоков данных.

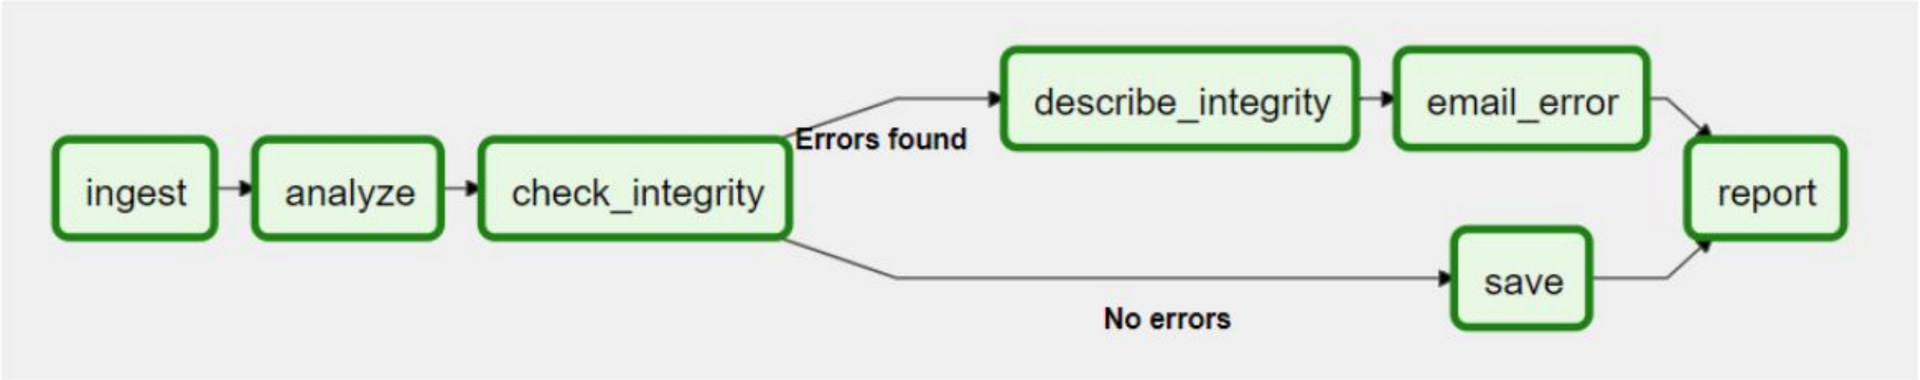


**DAG определяет зависимости между задачами и порядок их выполнения и выполнения повторных попыток**

**Сами задачи описывают, что нужно делать, будь то получение данных, запуск анализа, запуск других систем, скриптов ML, проверки качества данных, e-mail рассылка и т. д.**

# Поток управления

- DAGs предназначены для многократного запуска, и несколько их запусков могут выполняться параллельно.
- DAGs параметризуются, всегда включая интервал, для которого они «выполняются» (интервал данных), но также и с другими необязательными параметрами.
- Задачи имеют зависимости друг от друга. Вы увидите это в DAG либо с помощью операторов >> и <<:

```
first_task >> [second_task, third_task]
fourth_task << third_task
```

- Или с помощью методов set_upstream и set_downstream:

```
first_task.set_downstream([second_task, third_task])
fourth_task.set_upstream(third_task)
```

- Эти зависимости составляют «ребра» графа и то, как Airflow определяет, в каком порядке выполнять задачи. По умолчанию задача будет ждать, пока все ее вышестоящие задачи не будут выполнены успешно, прежде чем она запустится, но это может быть настроено также с помощью таких функций, как Branching, LatestOnly и Trigger Rules.

# Рабочие нагрузки

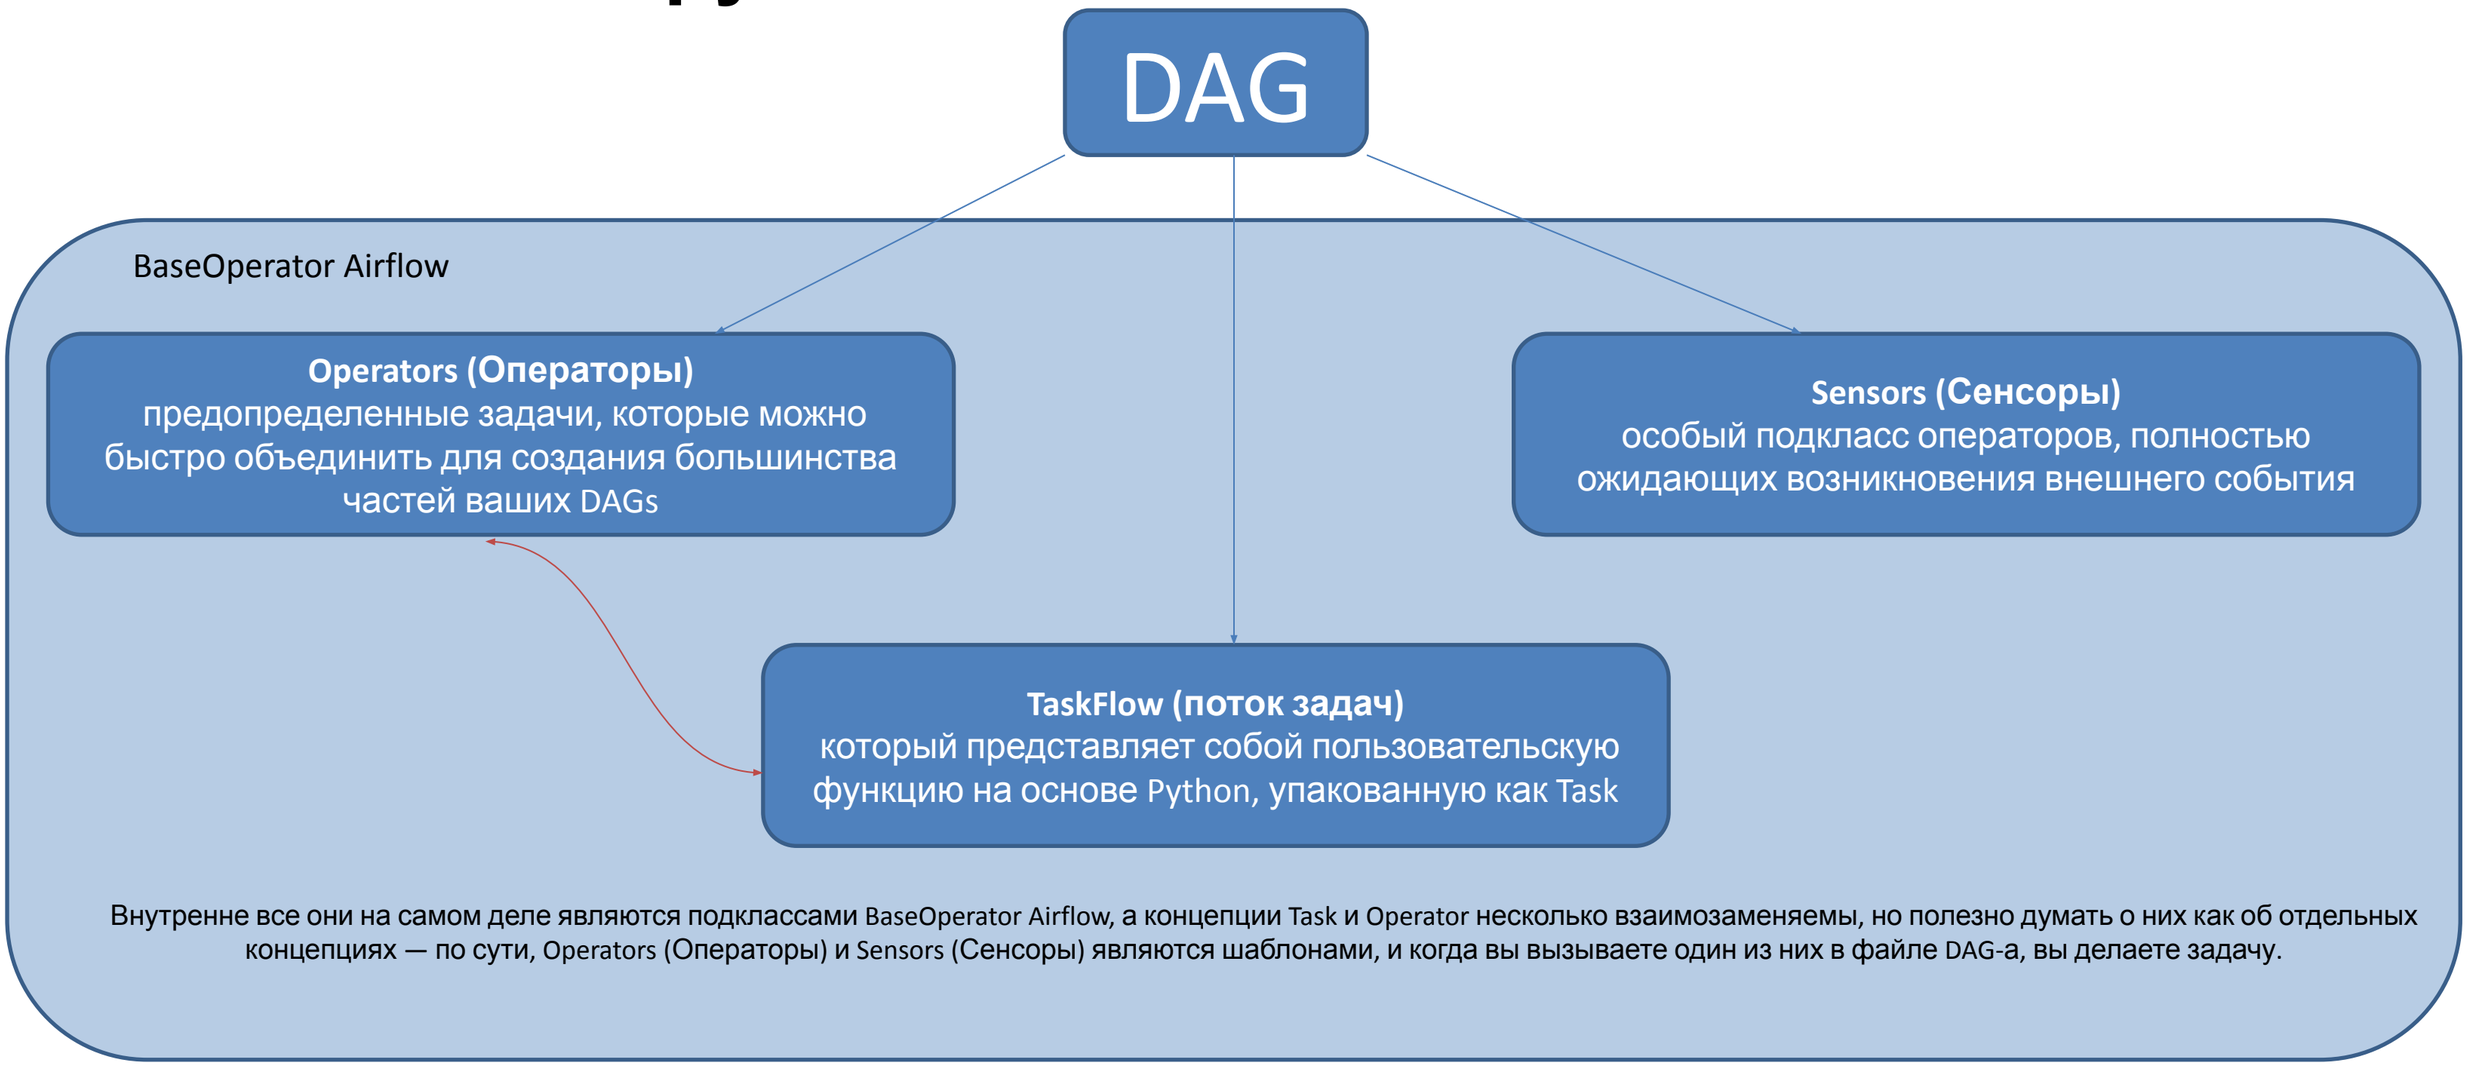

# Передача данных между задачами

По мере того, как вы создаете свои DAG, они становятся очень сложными и большими, поэтому Airflow предоставляет несколько механизмов для того, чтобы сделать это более устойчивым и удобным для восприятия:

**SubDAG**

они позволяют вам создавать «повторно используемые» DAGs, которые вы можете встраивать в другие

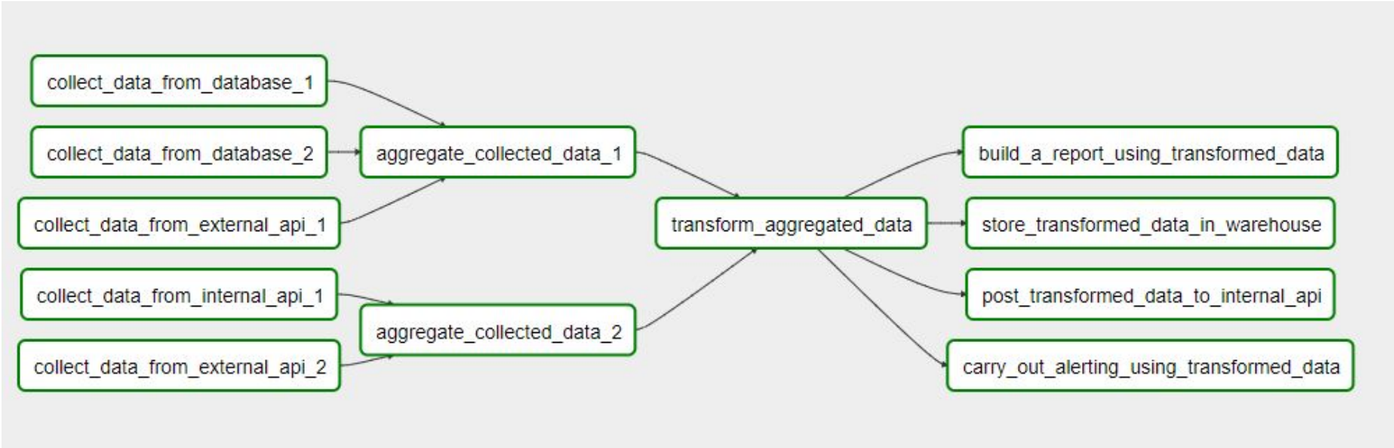


**TaskGroups**

позволяют визуально группировать задачи в пользовательский интерфейс

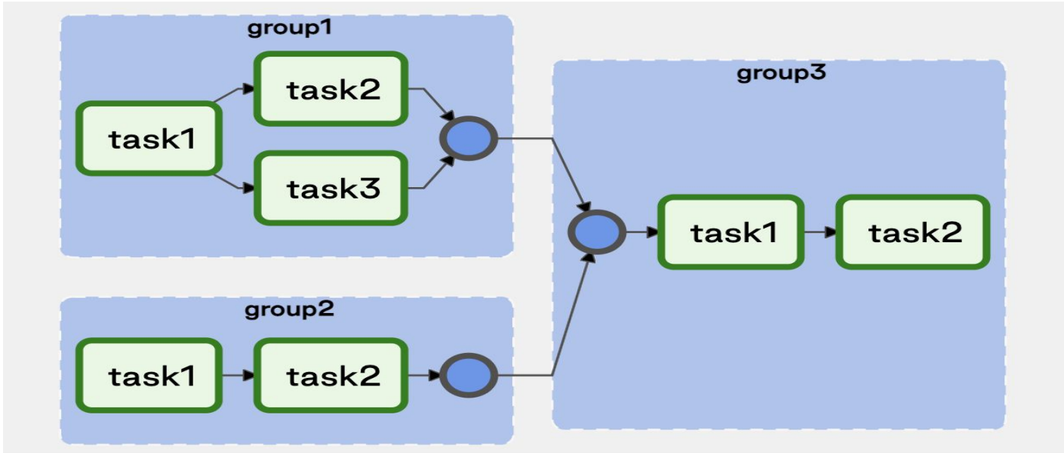


Существуют также функции, позволяющие легко предварительно настроить доступ к центральному ресурсу, такому как хранилище данных, в форме Connections & Hooks, а также для ограничения параллелизма через Pools (пулы)

# Jinja

Воздушный поток в полной мере использует мощь Jinja Templating, которая может быть мощным инструментом для работы с макросами.

Например, предположим, что вы хотите использовать BashOperator для передачи даты выполнения в качестве переменной среды в сценарий Bash.

```
# The execution date as YYYY-MM-DD
date = "{{ ds }}"
t = BashOperator(
    task_id='test_env',
    bash_command='/tmp/test.sh ',
    dag=dag,
    env={'EXECUTION_DATE': date})
```

Здесь {{ds}} является макросом, и поскольку параметр env в BashOperator формируется с использованием Jinja, дата выполнения будет предоставлена в виде переменной среды с именем EXECUTION_DATE в сценарии Bash.

Вы можете использовать шаблоны Jinja с каждым параметром, помеченным как «шаблонный» в документе. Замена шаблона происходит до вызова оператором функции pre_execute.

# Спасибо за внимание!