云数据仓库 PostgreSQL

数仓开发

产品文档

腾讯云

版权所有：腾讯云计算（北京）有限责任公司

【版权声明】

©2013-2024 腾讯云版权所有

本文档著作权归腾讯云单独所有，未经腾讯云事先书面许可，任何主体不得以任何形式复制、修改、抄袭、传播全部或部分本文档内容。

【商标声明】

腾讯云

及其它腾讯云服务相关的商标均为腾讯云计算（北京）有限责任公司及其关联公司所有。本文档涉及的第三方主体的商标，依法由权利人所有。

【服务声明】

本文档意在向客户介绍腾讯云全部或部分产品、服务的当时的整体概况，部分产品、服务的内容可能有所调整。您所购买的腾讯云产品、服务的种类、服务标准等应由您与腾讯云之间的商业合同约定，除非双方另有约定，否则，腾讯云对本文档内容不做任何明示或默示的承诺或保证。

文档目录

数仓开发
云上搭建 Airflow

数仓开发
云上搭建 Airflow

最近更新时间：2024-02-19 15:58:16

Apache Airflow 是一款开源的工作流管理系统，集成了编排、调度、监控以及图形化展示等功能。在数据仓库场景，Airflow 则可以应用于 ETL 任务的管理。本文主要介绍如何在云端服务器上搭建 Airflow。

Airflow 默认安装

1. 购买 云服务器。

注意：

本文以 CentOS 8.0 为例。

2. 安装依赖软件

安装 Airflow 前，需安装如下依赖。

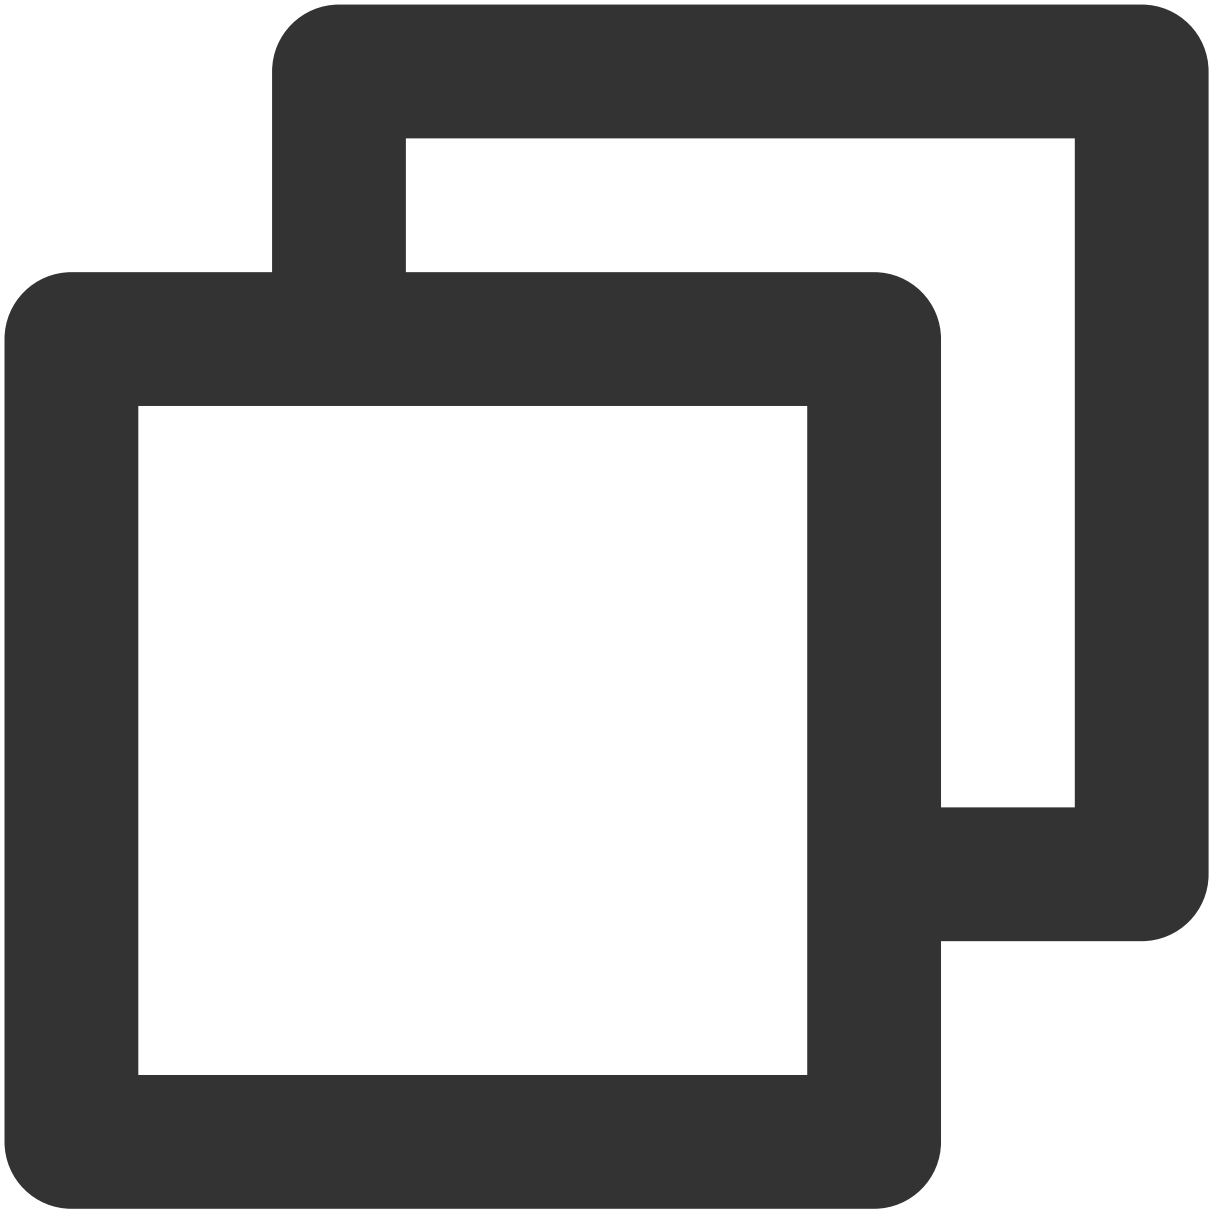

```
yum install redhat-rpm-config -y
yum install mysql-devel -y
yum install python3-devel -y
dnf update gcc annobin -y
```

3. 创建 Home 目录

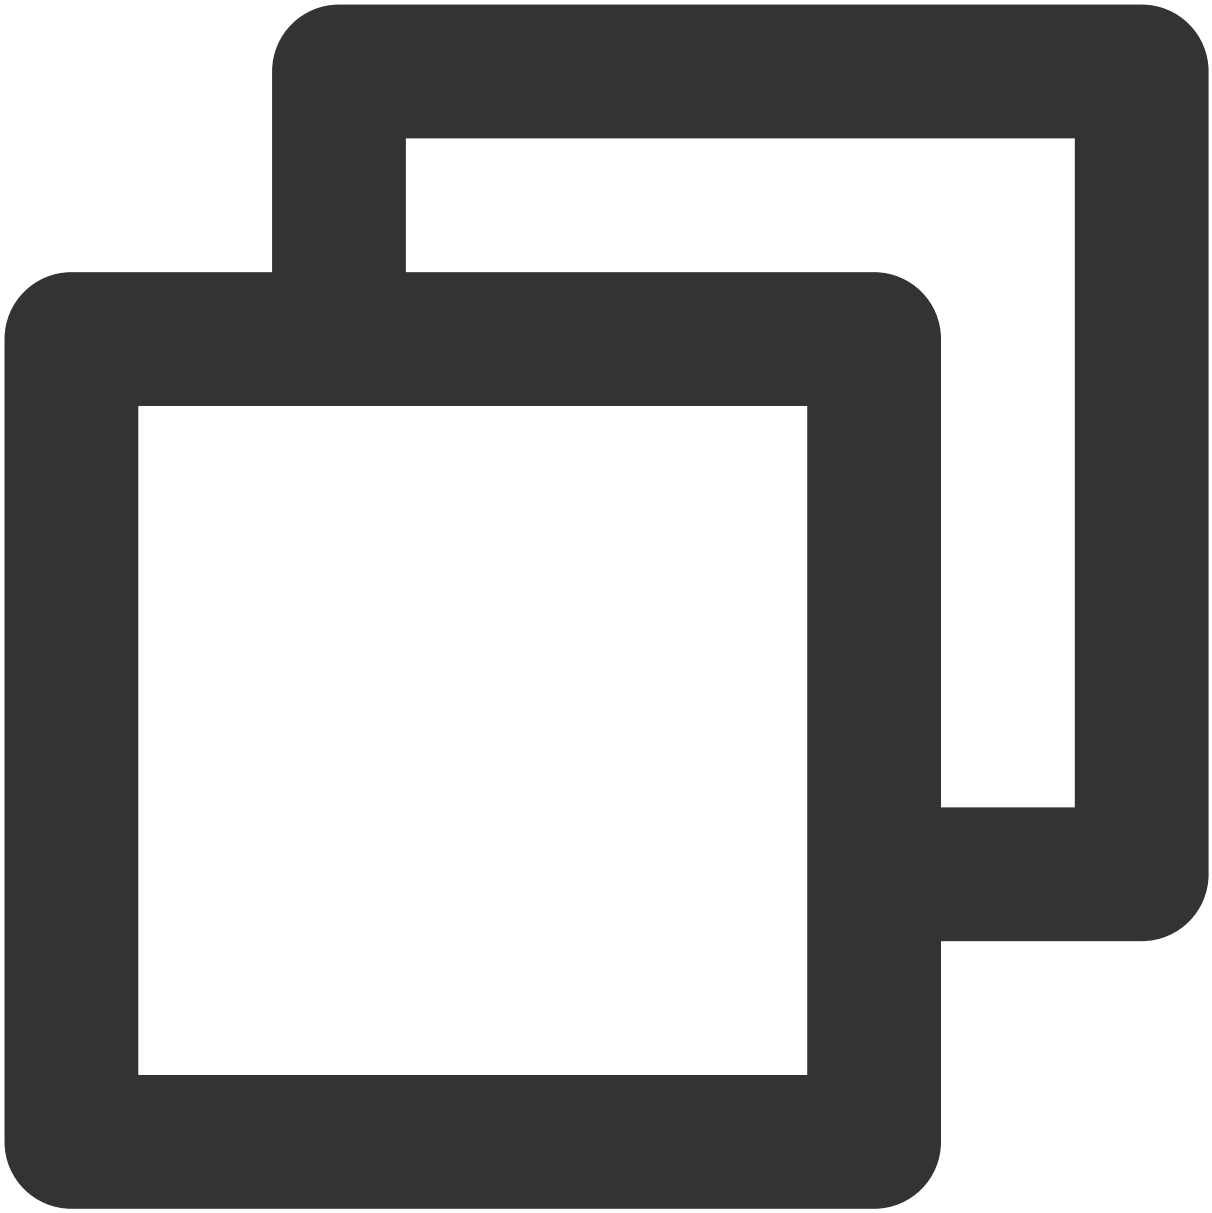

```
mkdir -p /usr/local/services/airflow
export AIRFLOW_HOME=/usr/local/services/airflow
```

AIRFLOW_HOME 变量可以配置到 `/etc/profile` 文件中。

4. 安装 Airflow

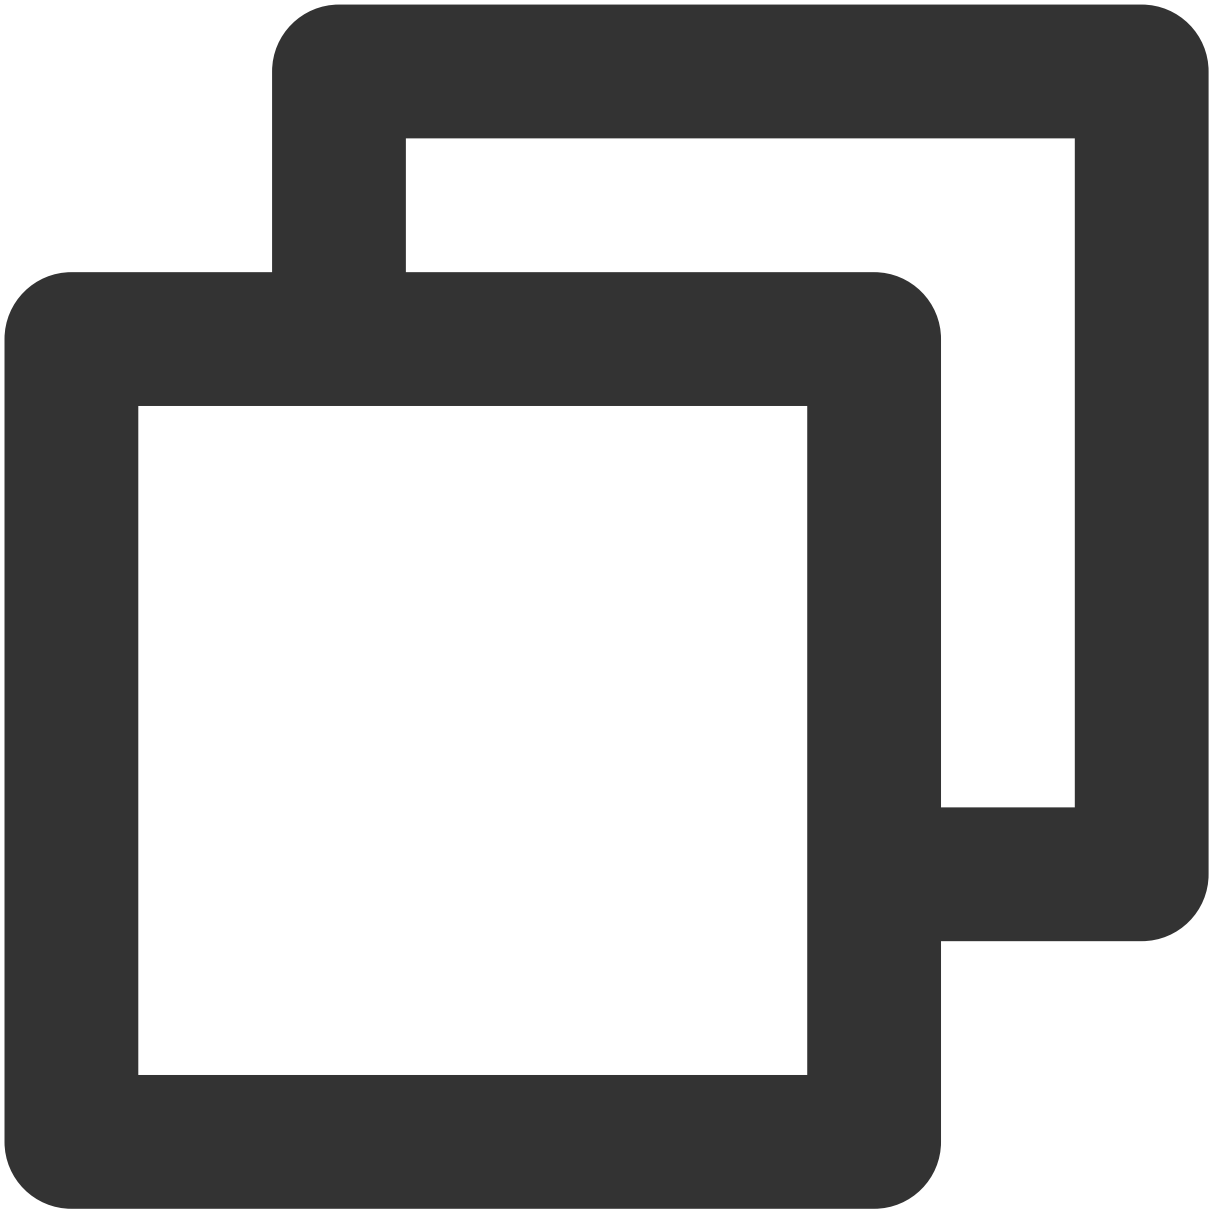

```
pip install apache-airflow[mysql]
```

5. 初始化 DB

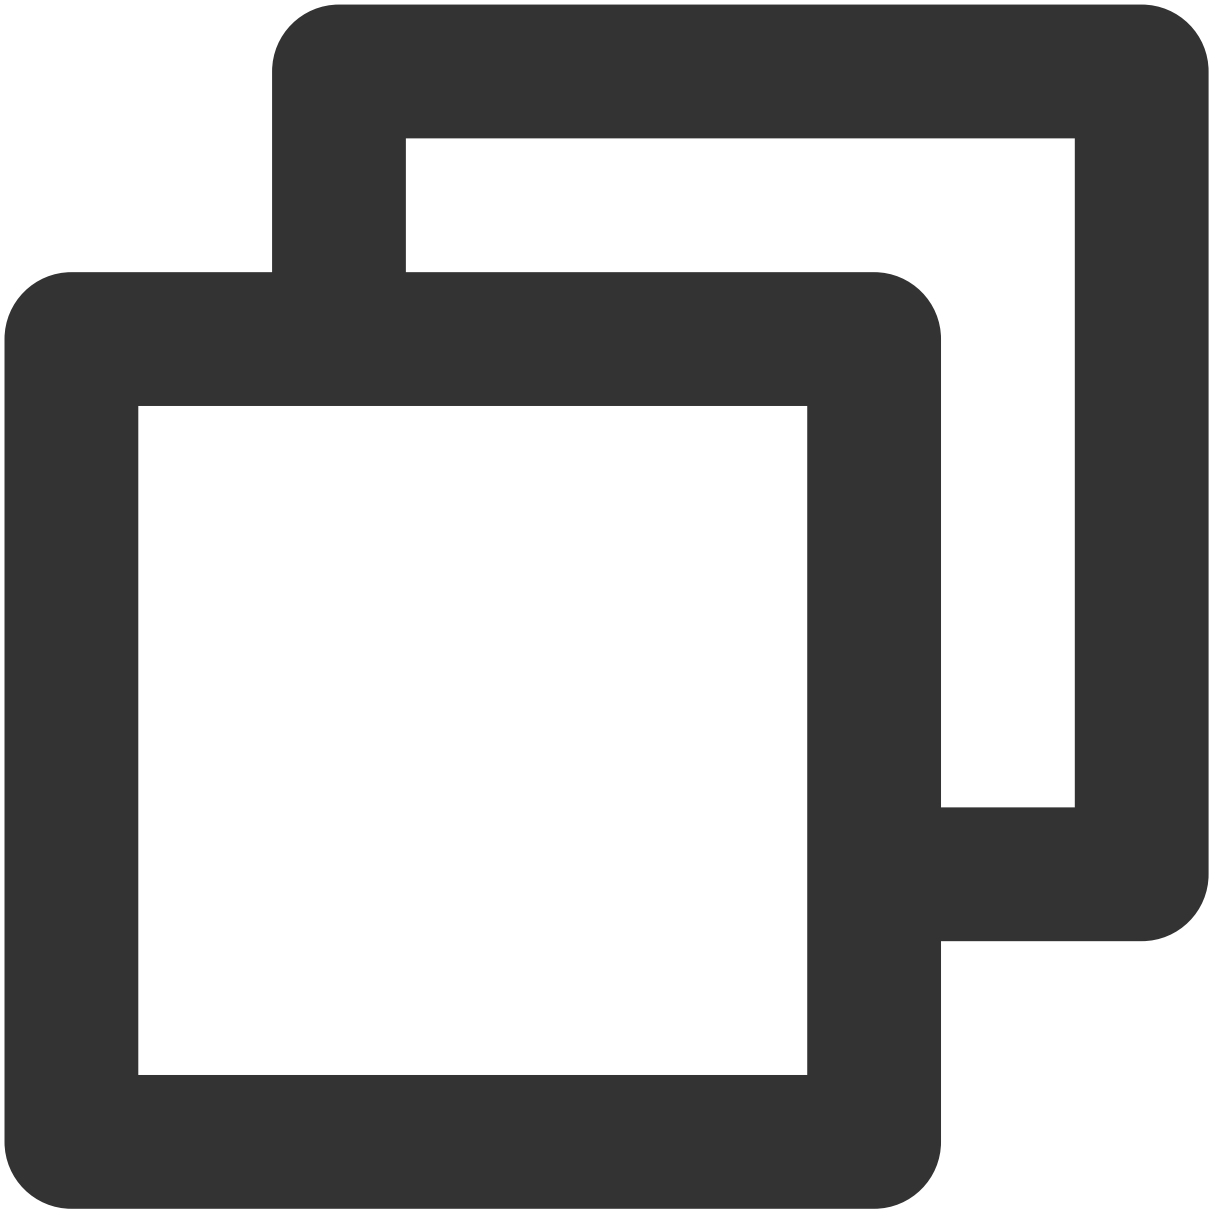

```
airflow initdb
```

6. 配置安全组

Airflow 的 webui 默认启动在8080端口，如果想要通过外网访问，需要打开安全组的8080。

7. 启动 webui

使用如下命令：

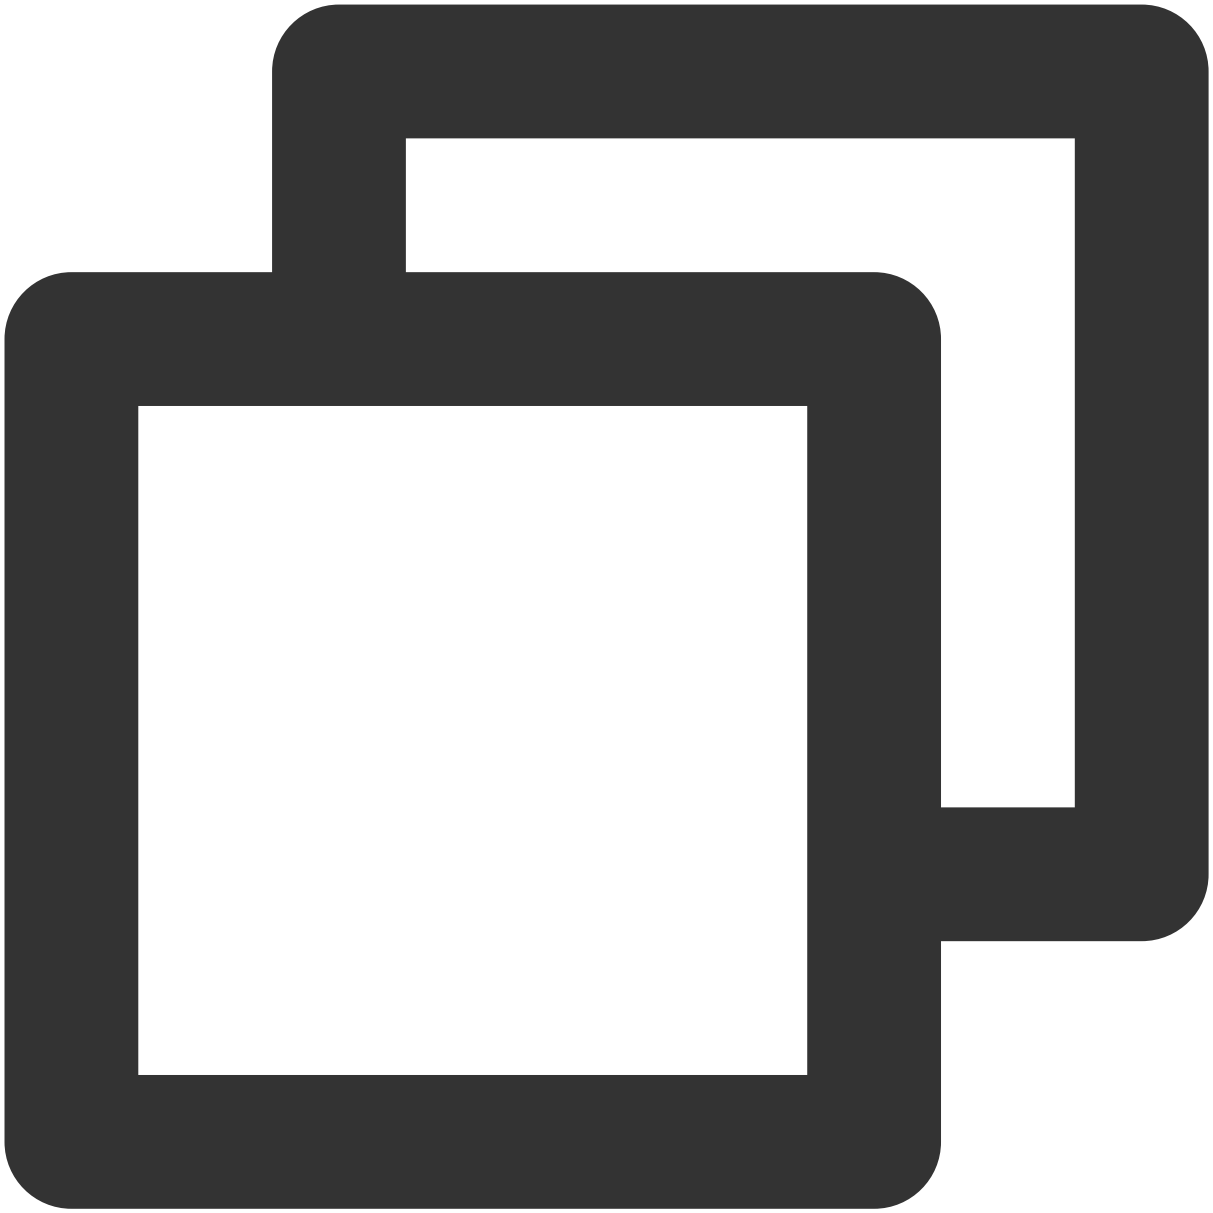

```
airflow webserver -D
```

如果通过 `url http://{ip}:8080/admin/` 可以正常访问页面，则代表配置成功。

处理时区

Airflow 使用 UTC 时间，与北京时间差8个小时，因此需要进行处理，由于 Airflow 写死部分代码，因此除了修改配置文件外，也需要修改源码，步骤如下：

1. 修改 `AIRFLOW_HOME` 下的 `airflow.cfg`

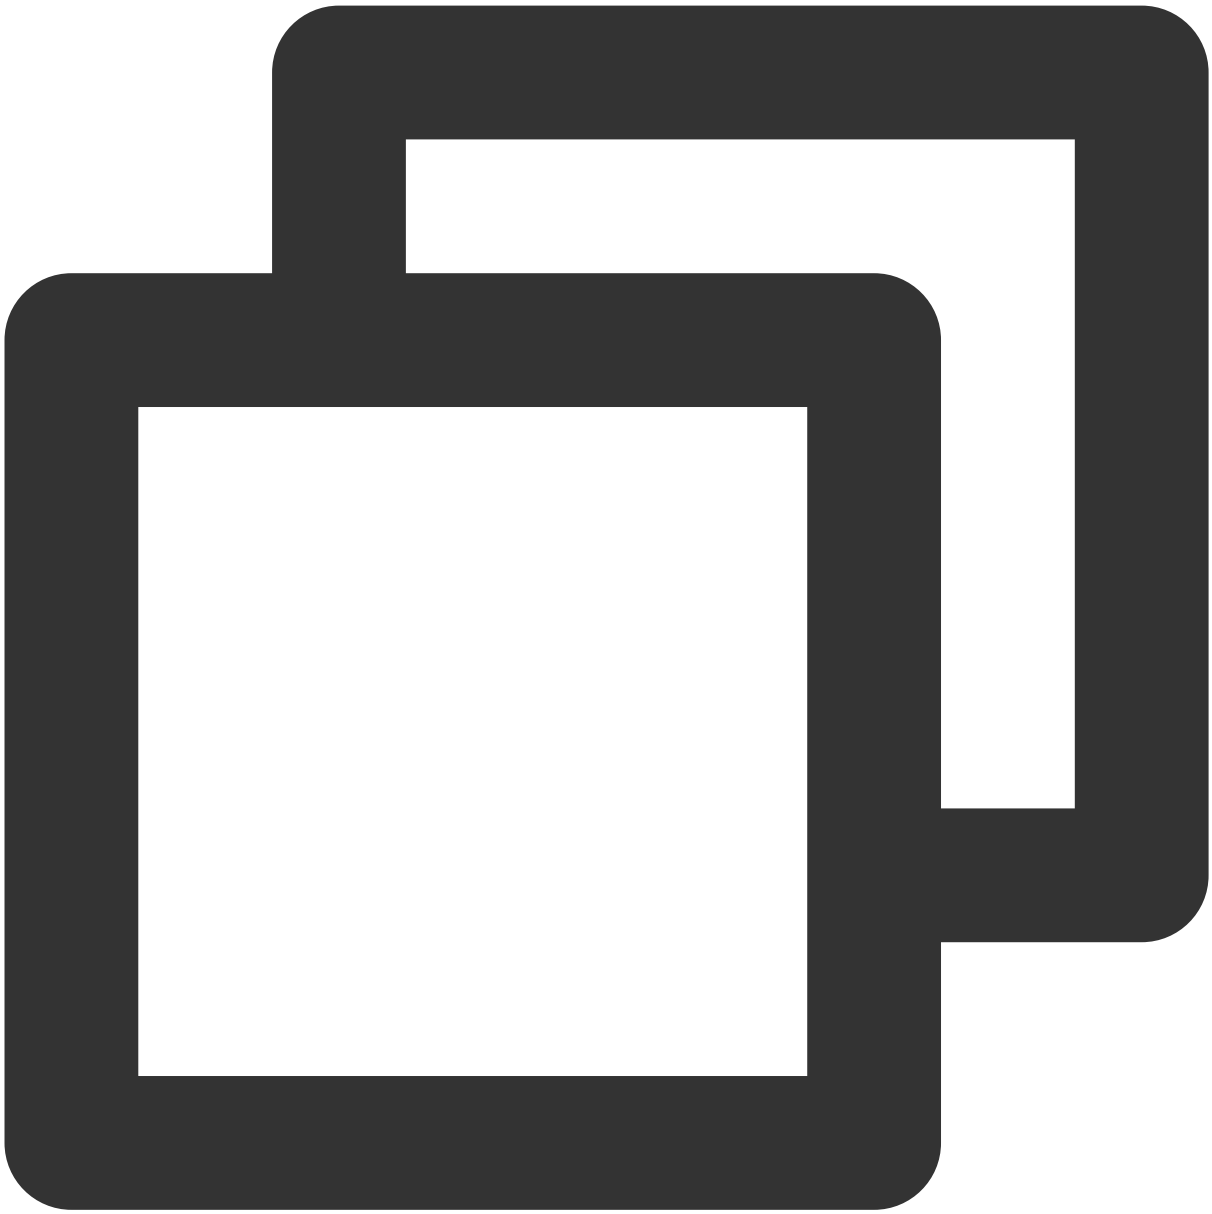

```
default_timezone = utc 修改为 default_timezone = Asia/Shanghai
default_ui_timezone = UTC 修改为 default_ui_timezone = Asia/Shanghai
```

2. 修改文件 `/usr/local/lib/python3.6/site-packages/airflow/utils/timezone.py`
在语句 `utc = pendulum.timezone('UTC')` 下新增如下语句：

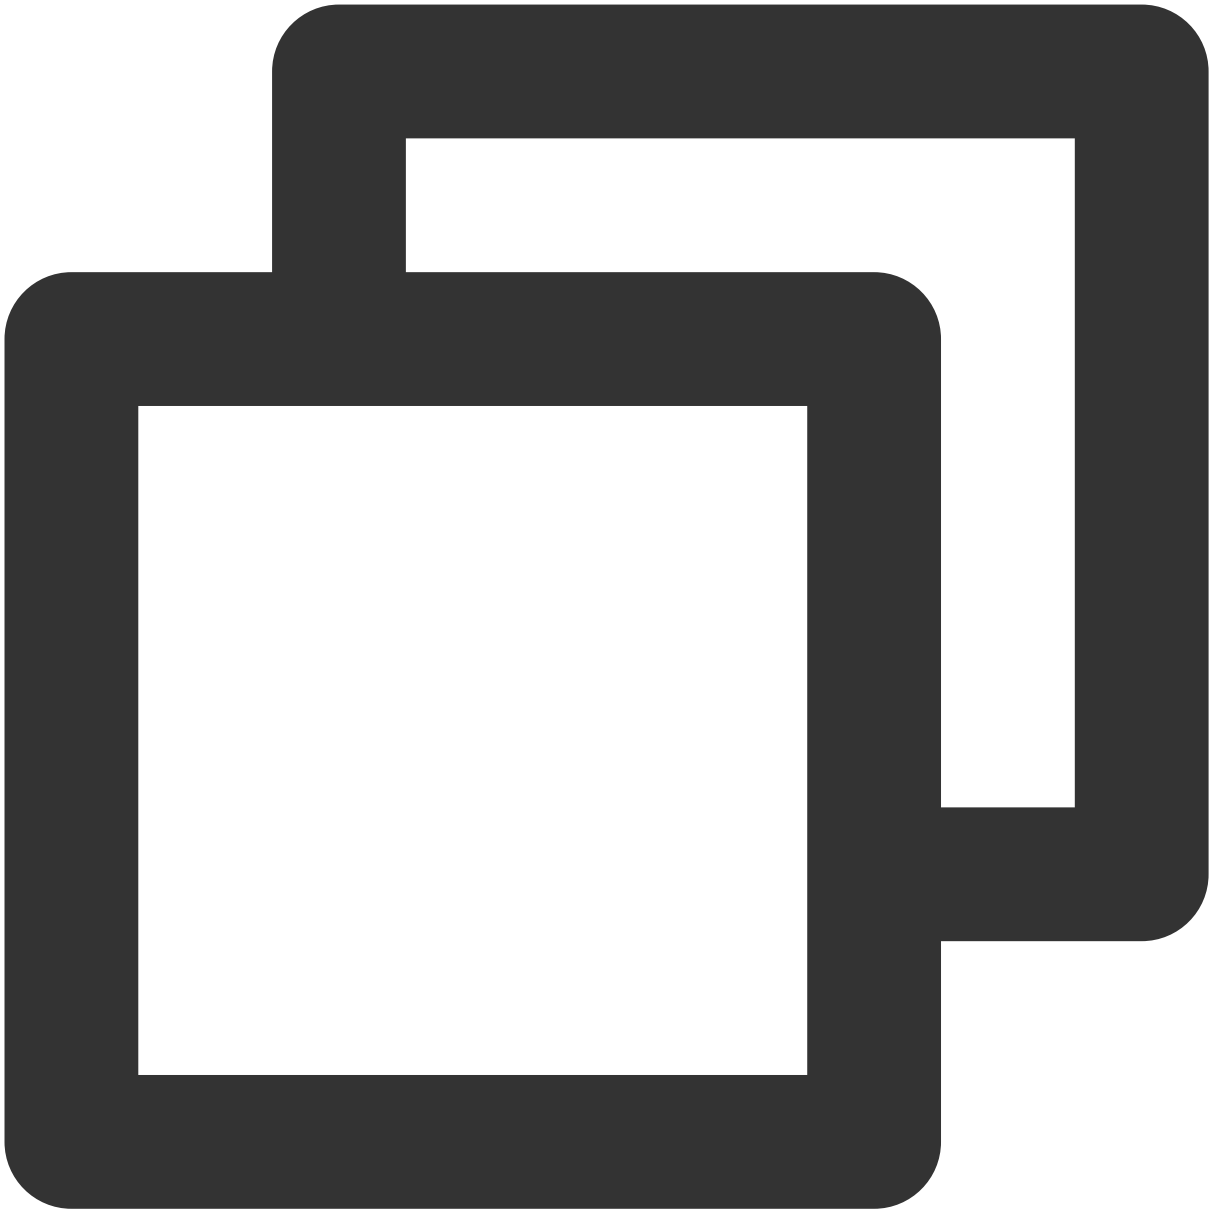

```
from airflow.configuration import conf
try:
 tz = conf.get("core", "default_timezone")
 if tz == "system":
     utc = pendulum.local_timezone()
 else:
     utc = pendulum.timezone(tz)
except Exception:
 pass
```

修改函数 `utcnow()` ：

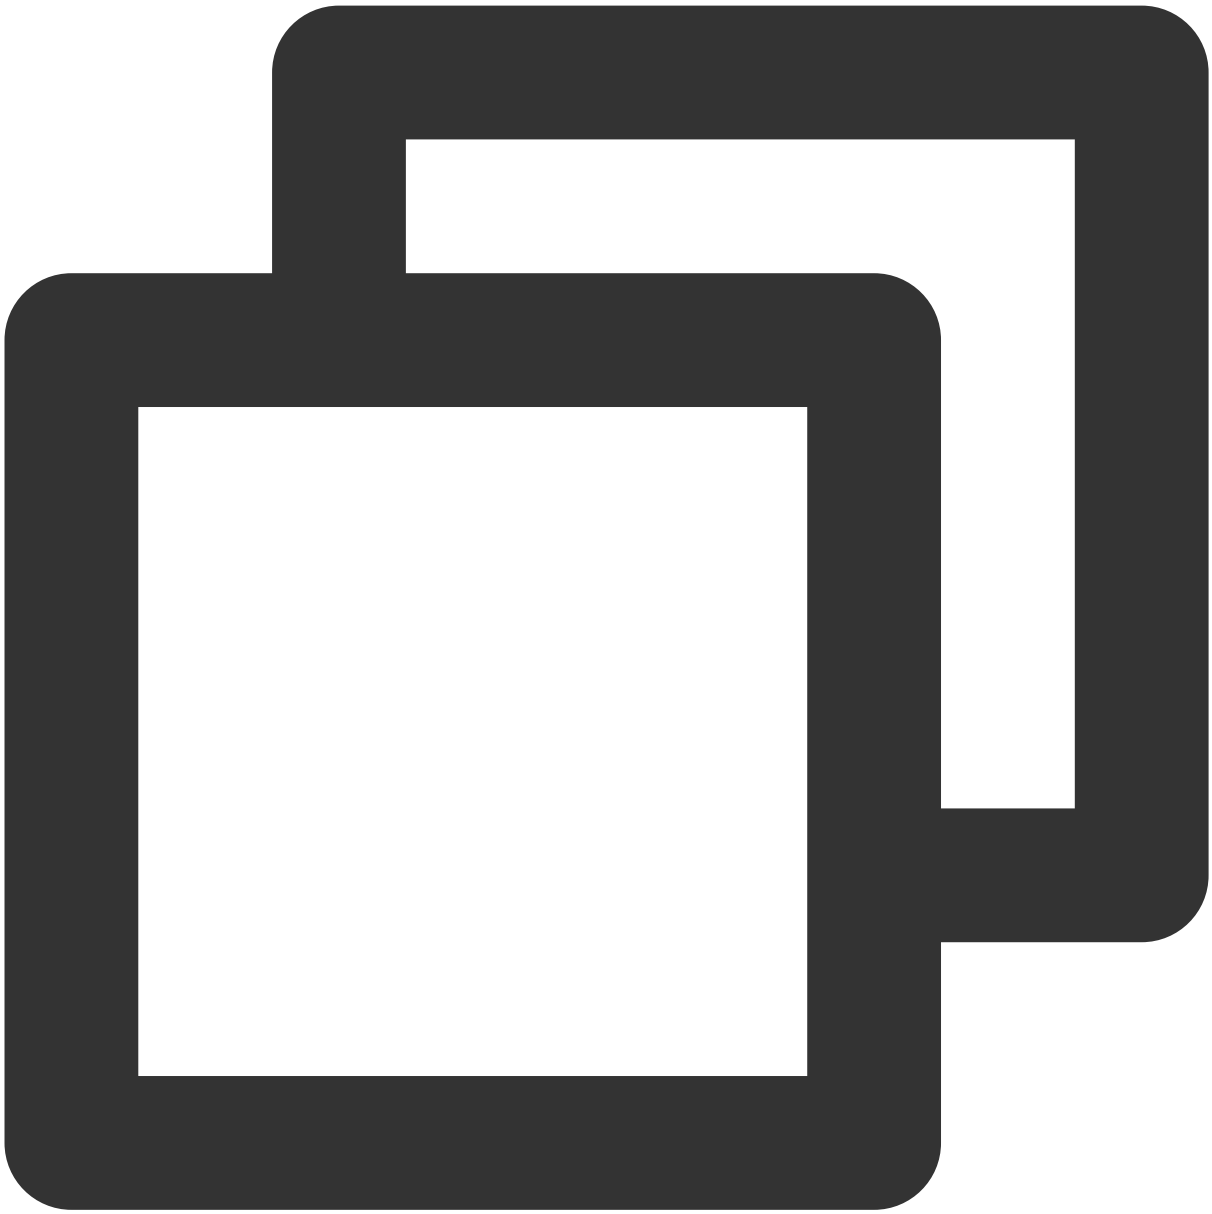

```
d = dt.datetime.utcnow() 修改为 d = dt.datetime.now()
```

3. 修改文件 `/usr/local/lib/python3.6/site-packages/airflow/utils/sqlalchemy.py`
在语句 `utc = pendulum.timezone('UTC')` 下添加如下内容：

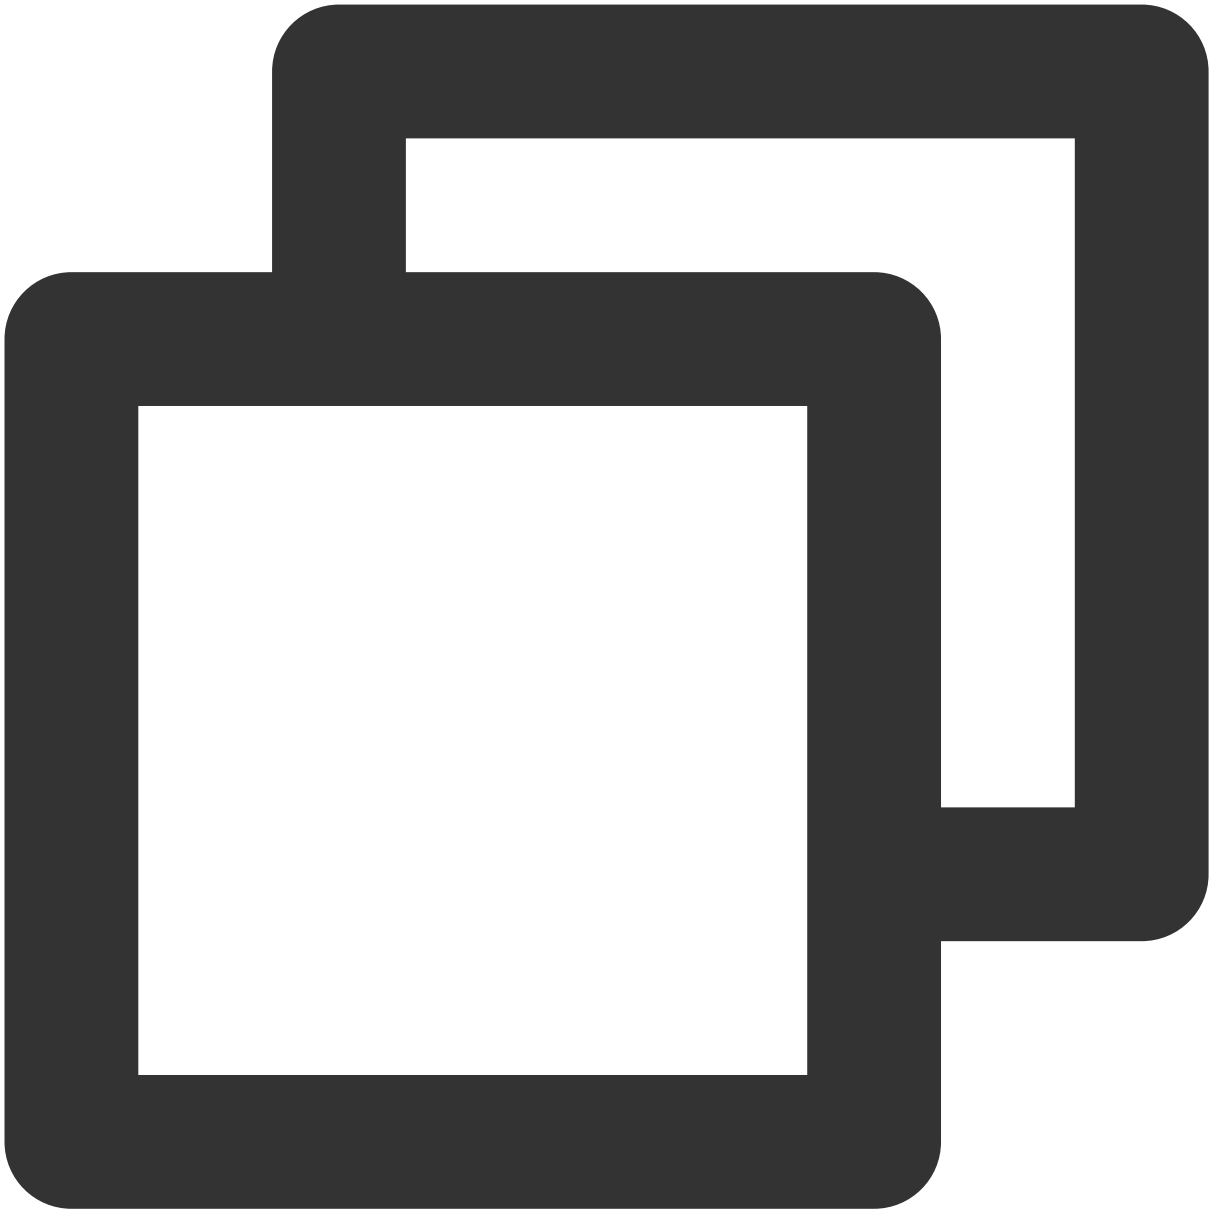

```
from airflow.configuration import conf
try:
 tz = conf.get("core", "default_timezone")
 if tz == "system":
     utc = pendulum.local_timezone()
 else:
     utc = pendulum.timezone(tz)
except Exception:
 pass
```

注释语句：

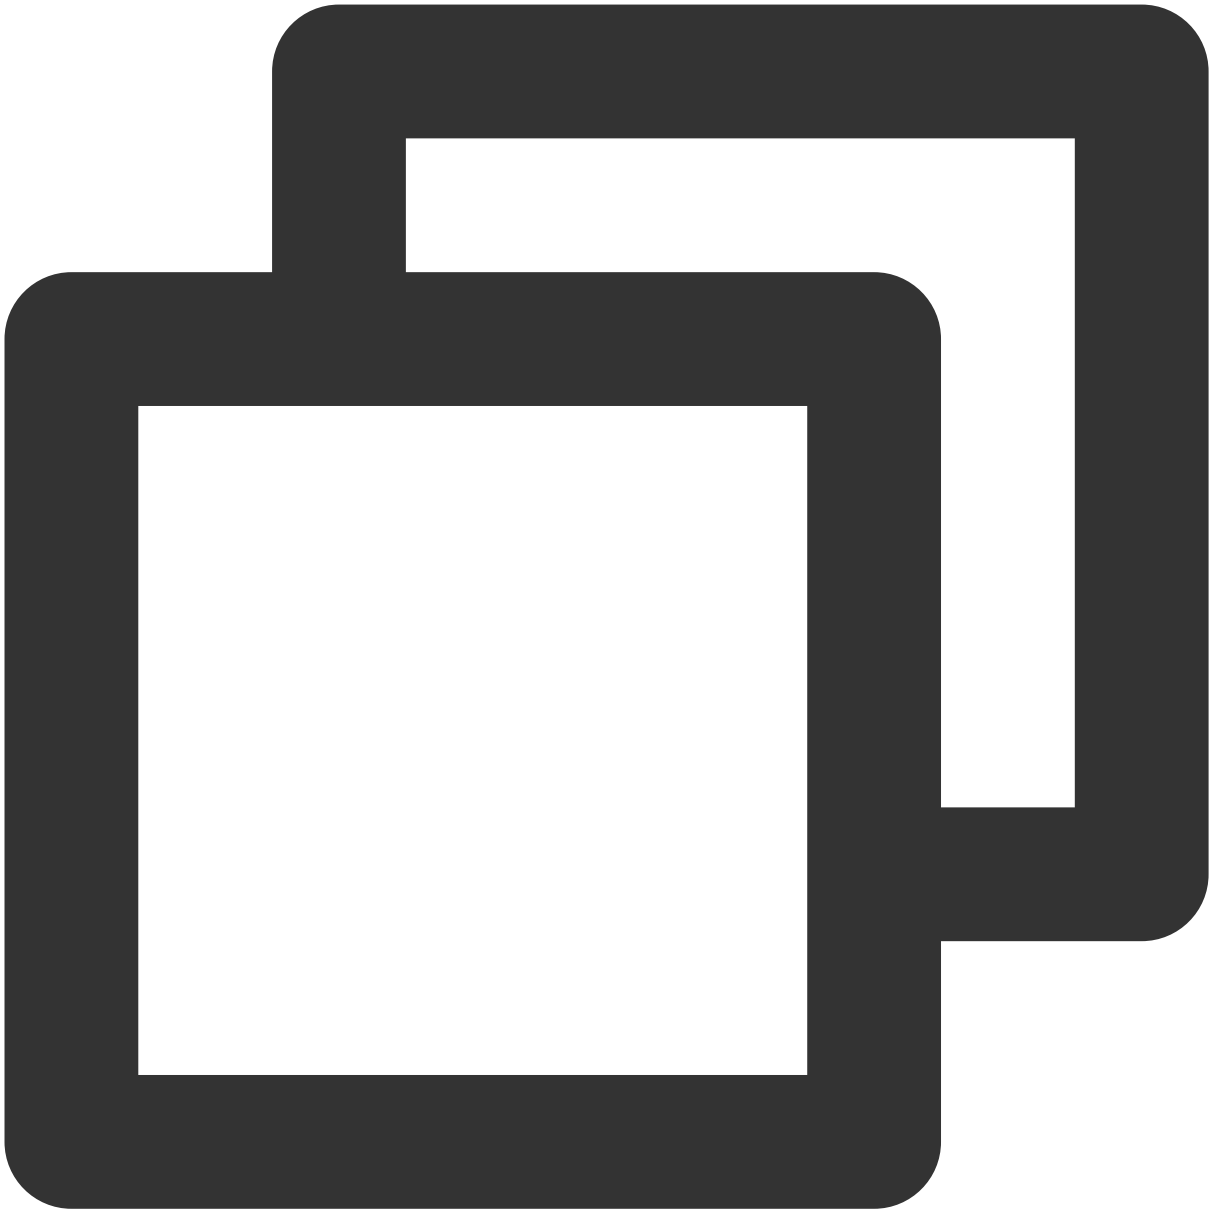

```
cursor.execute("SET time_zone = '+00:00'")
```

4. 修改文件 `/usr/local/lib/python3.6/site-packages/airflow/www/templates/admin/master.html`

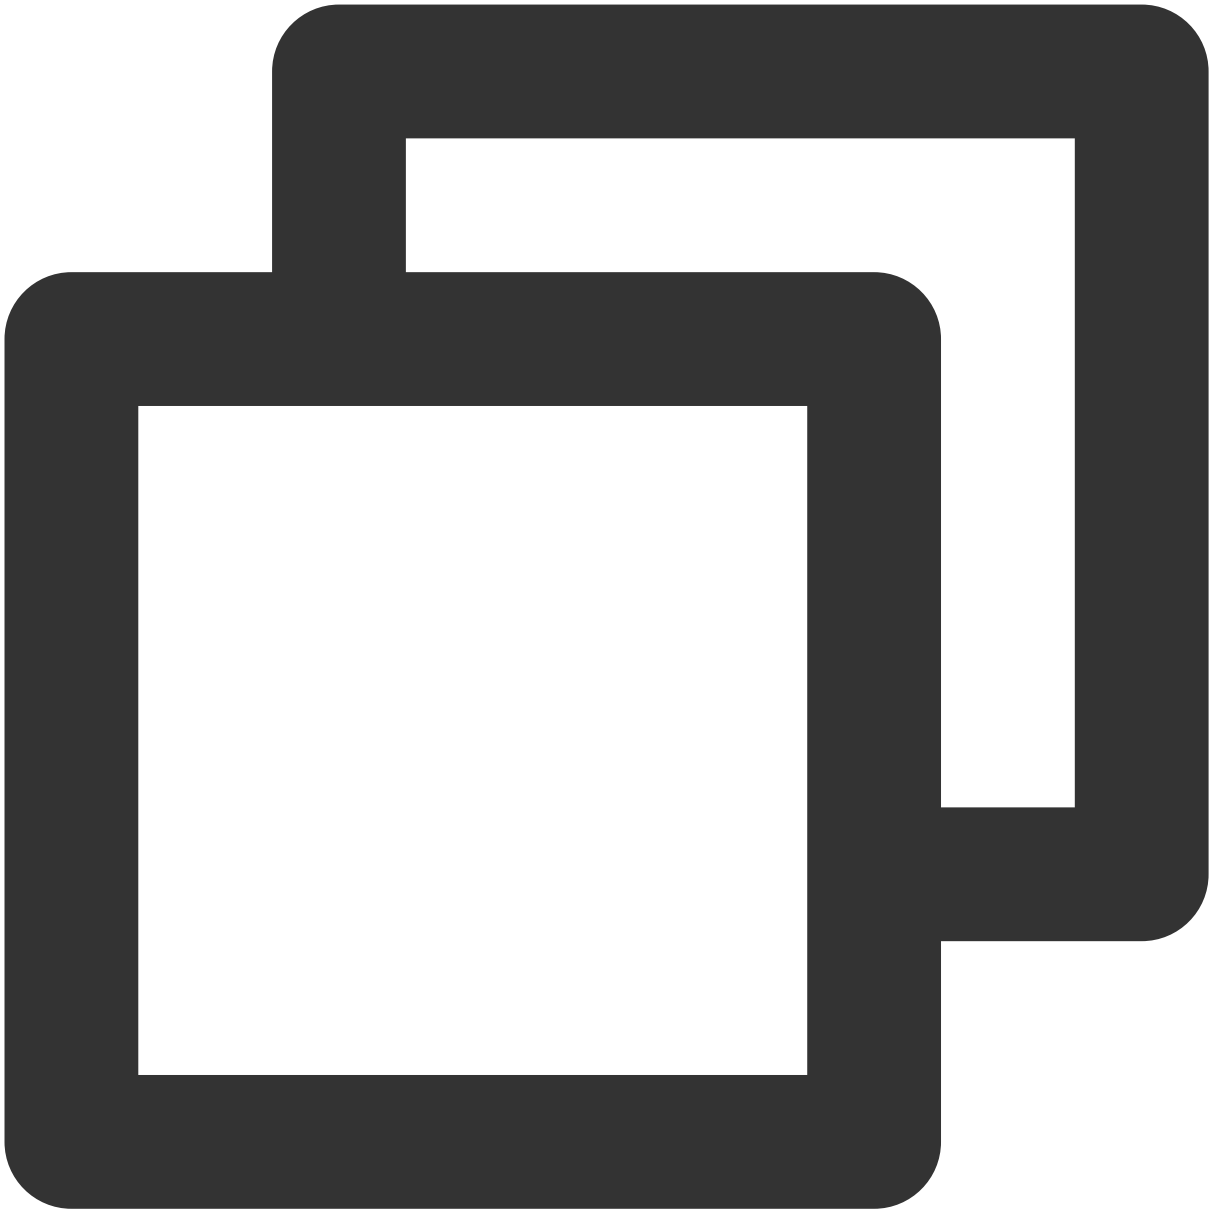

```
var UTCseconds = (x.getTime() + x.getTimezoneOffset()*60*1000);
```
修改为
```
var UTCseconds = x.getTime();
```

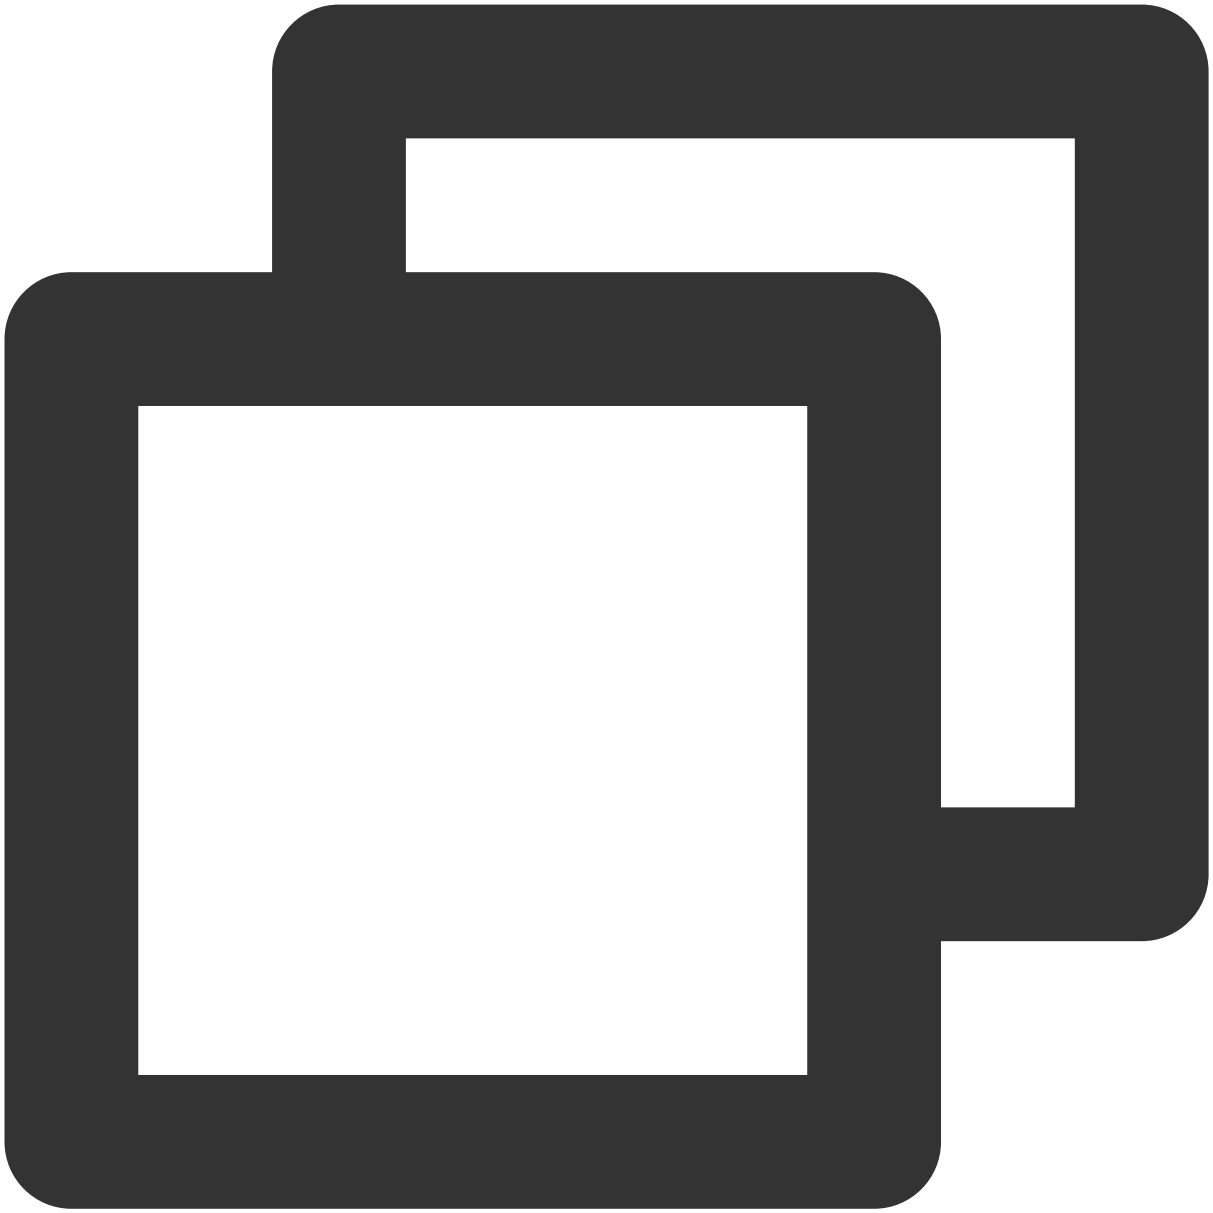

```
"timeFormat":"H:i:s %UTC%",
修改为
"timeFormat":"H:i:s",
```

5. 重启 webserver

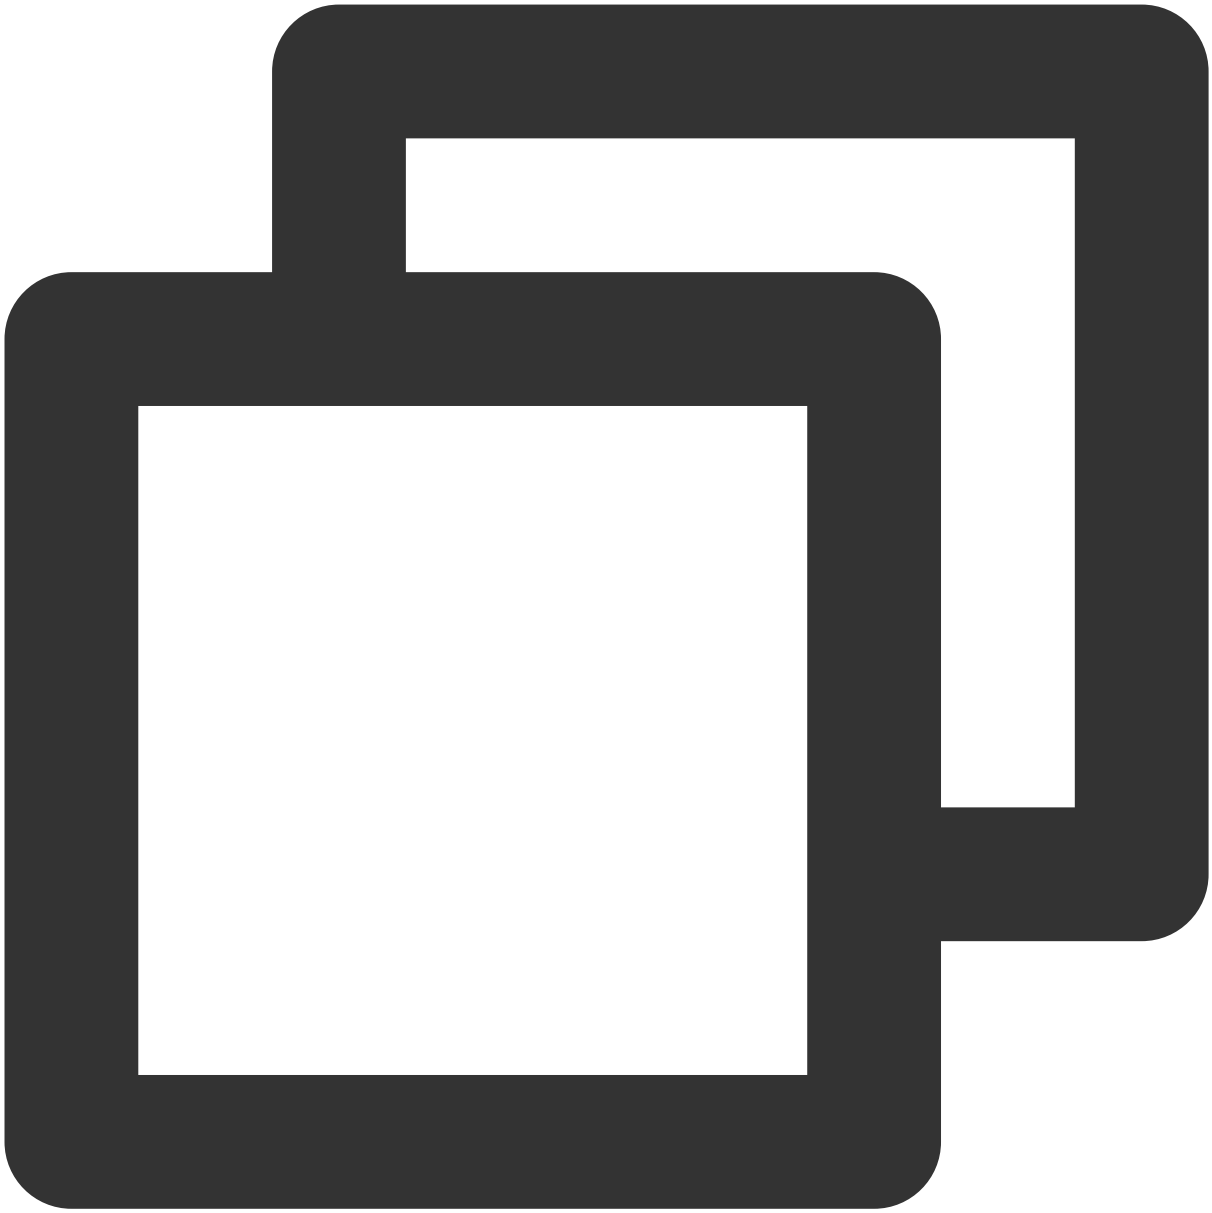

```
cat {AIRFLOW_HOME}/airflow-webserver.pid
kill {pid}
airflow webserver -D
```

使用云数据库 MySQL 存储数据

Airflow 默认使用嵌入式的 Sqlite 存储数据，如果要上生产环境，必须满足高可用的要求，这里以云数据库 MySQL 为例，步骤如下：

1. 购买 云数据库 MySQL

注意：

必须是高可用版或者金融版，基础版由于不支持 explicit_defaults_for_timestamp 参数，因此无法作为 Airflow 的存储。

2. 修改参数

在控制台修改参数 explicit_defaults_for_timestamp 为 ON。

3. 创建 DB 及用户

登录 MySQL，运行如下语句，其中用户名及密码可根据用户情况进行修改。

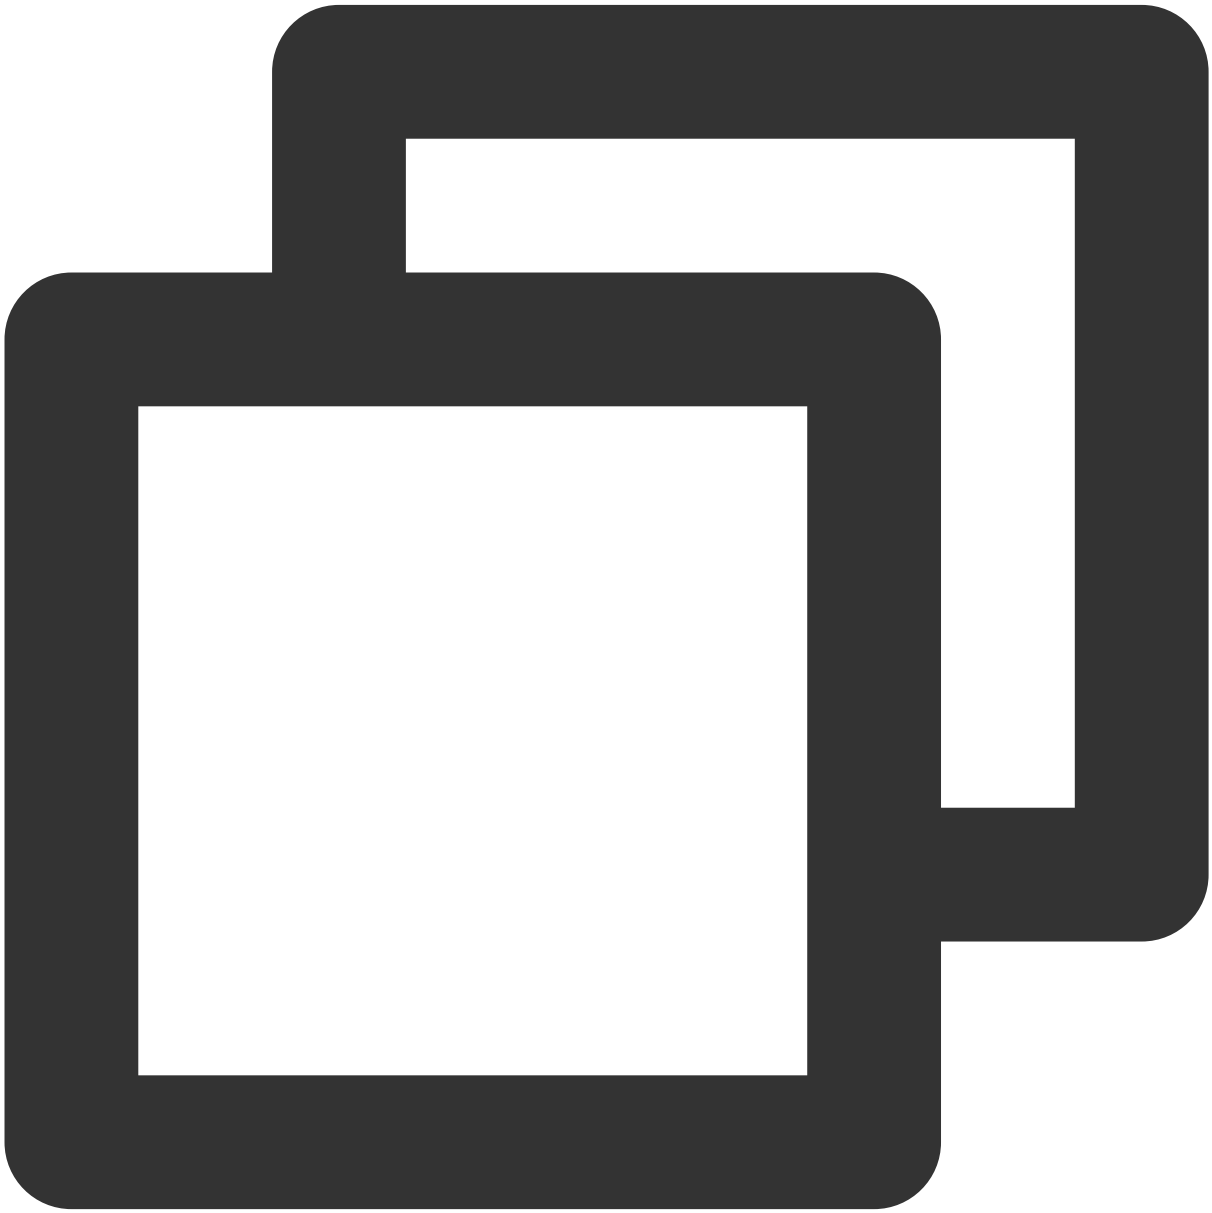

```
create database airflow;
```

```
create user 'airflowuser'@'%' identified by 'pwd123';
grant all on airflow.* to 'airflowuser'@'%';
flush privileges;
```

4. 修改 `{AIRFLOW_HOME}/airflow.cfg` 中的配置

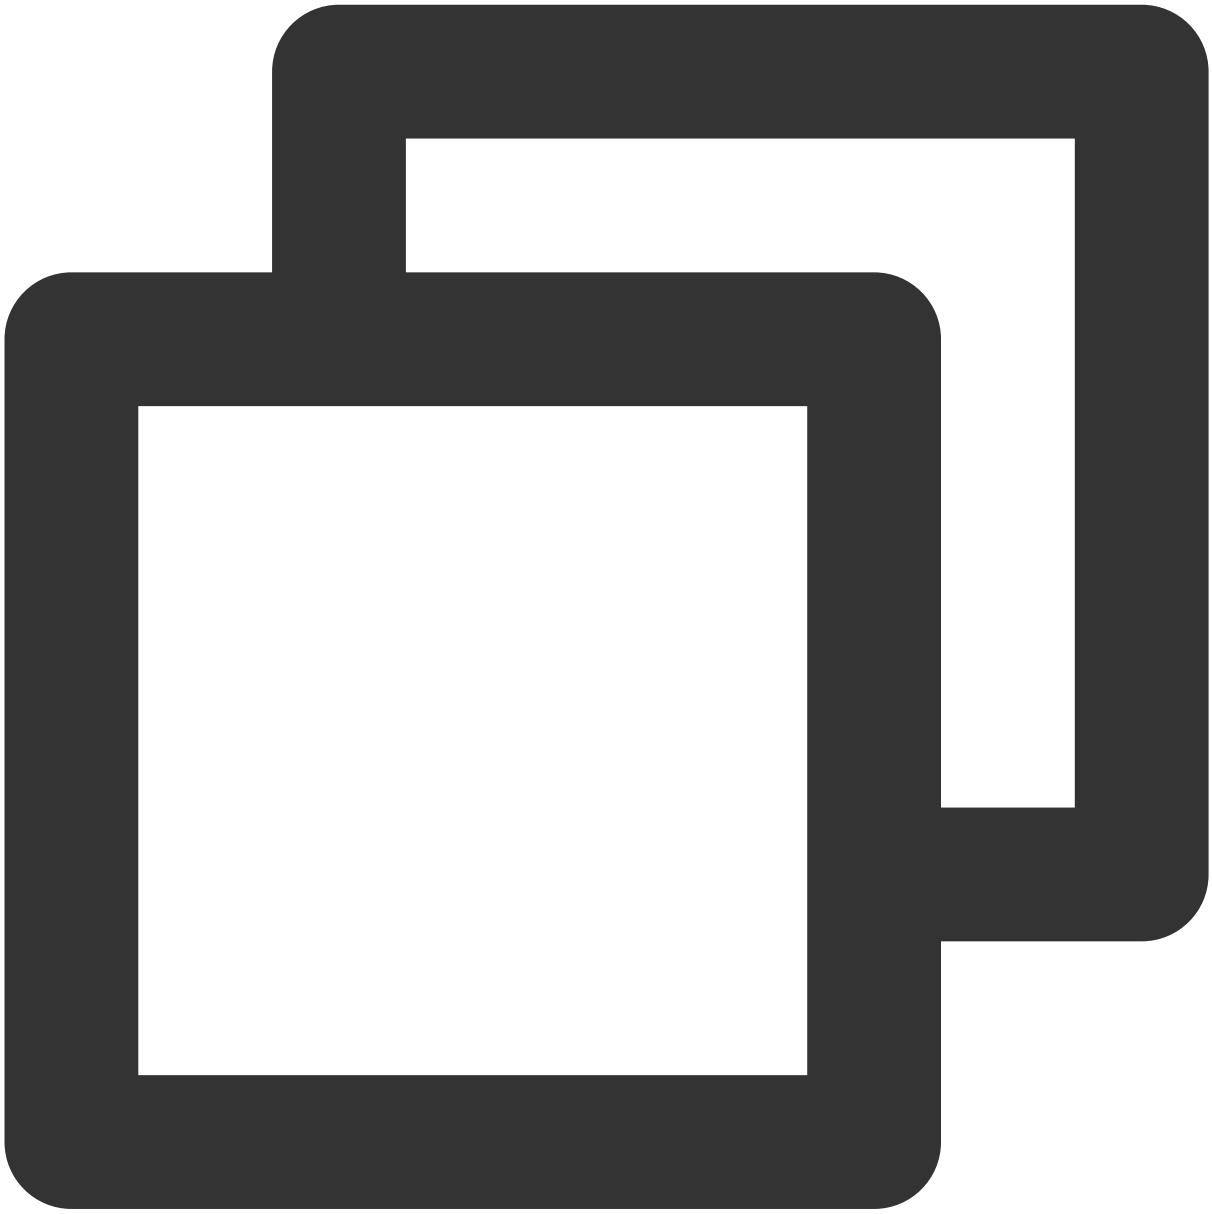

```
sql_alchemy_conn = sqlite:////usr/local/services/airflow/airflow.db
修改为
sql_alchemy_conn = mysql://airflowuser:pwd123@{ip}/airflow
```

5. 重新初始化数据库

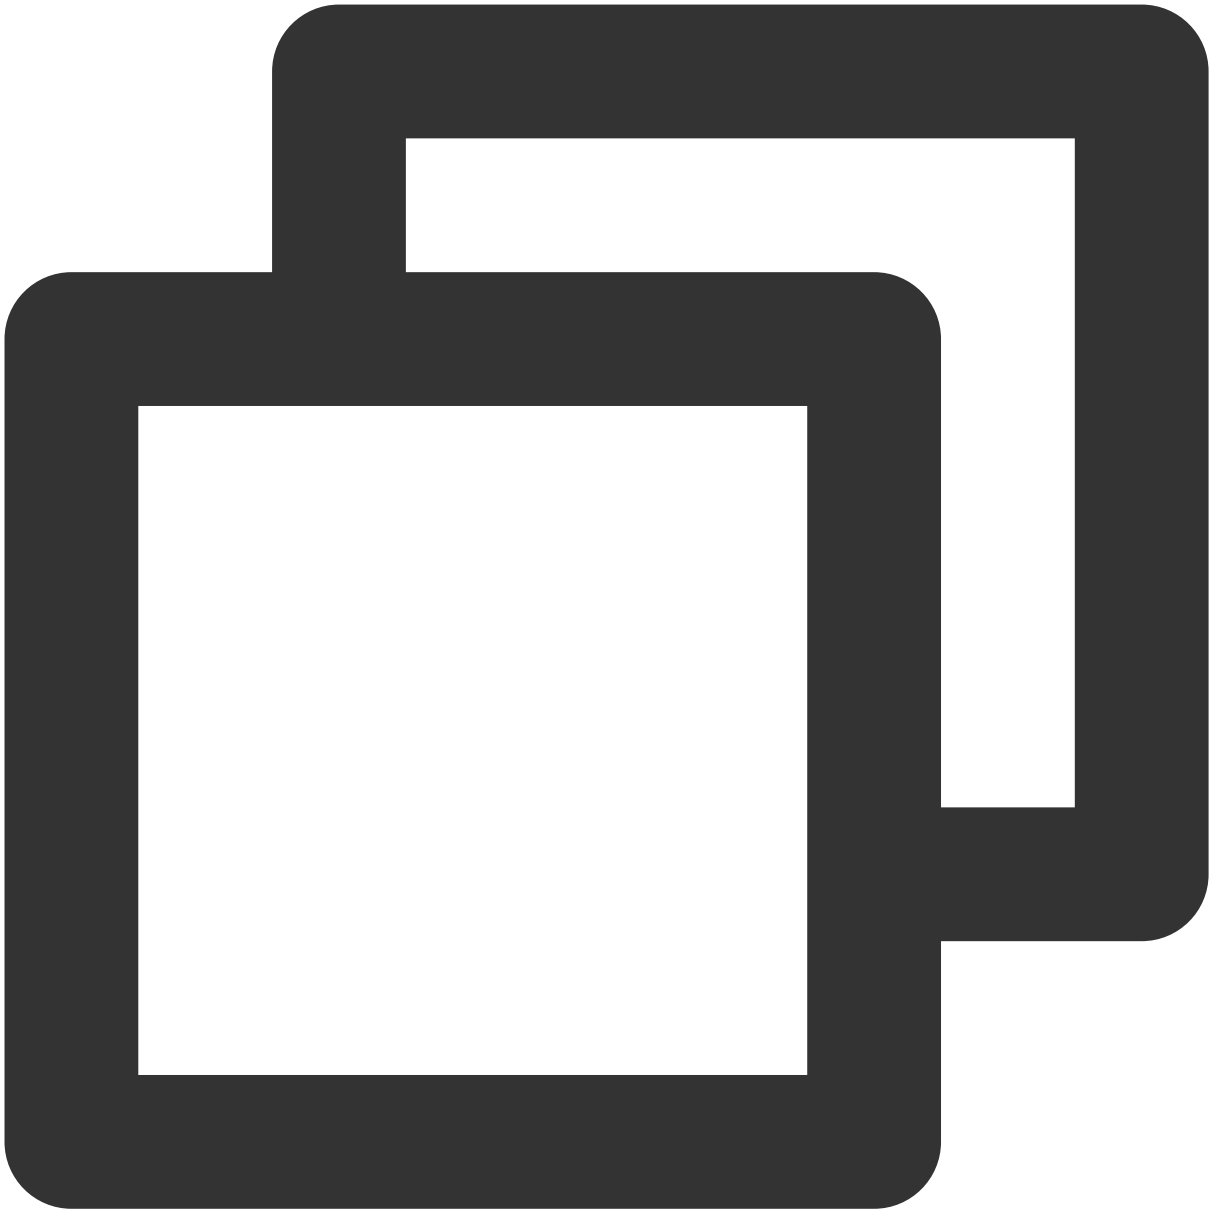

```
airflow initdb
```

如果想保留之前的运行数据，可运行如下命令：

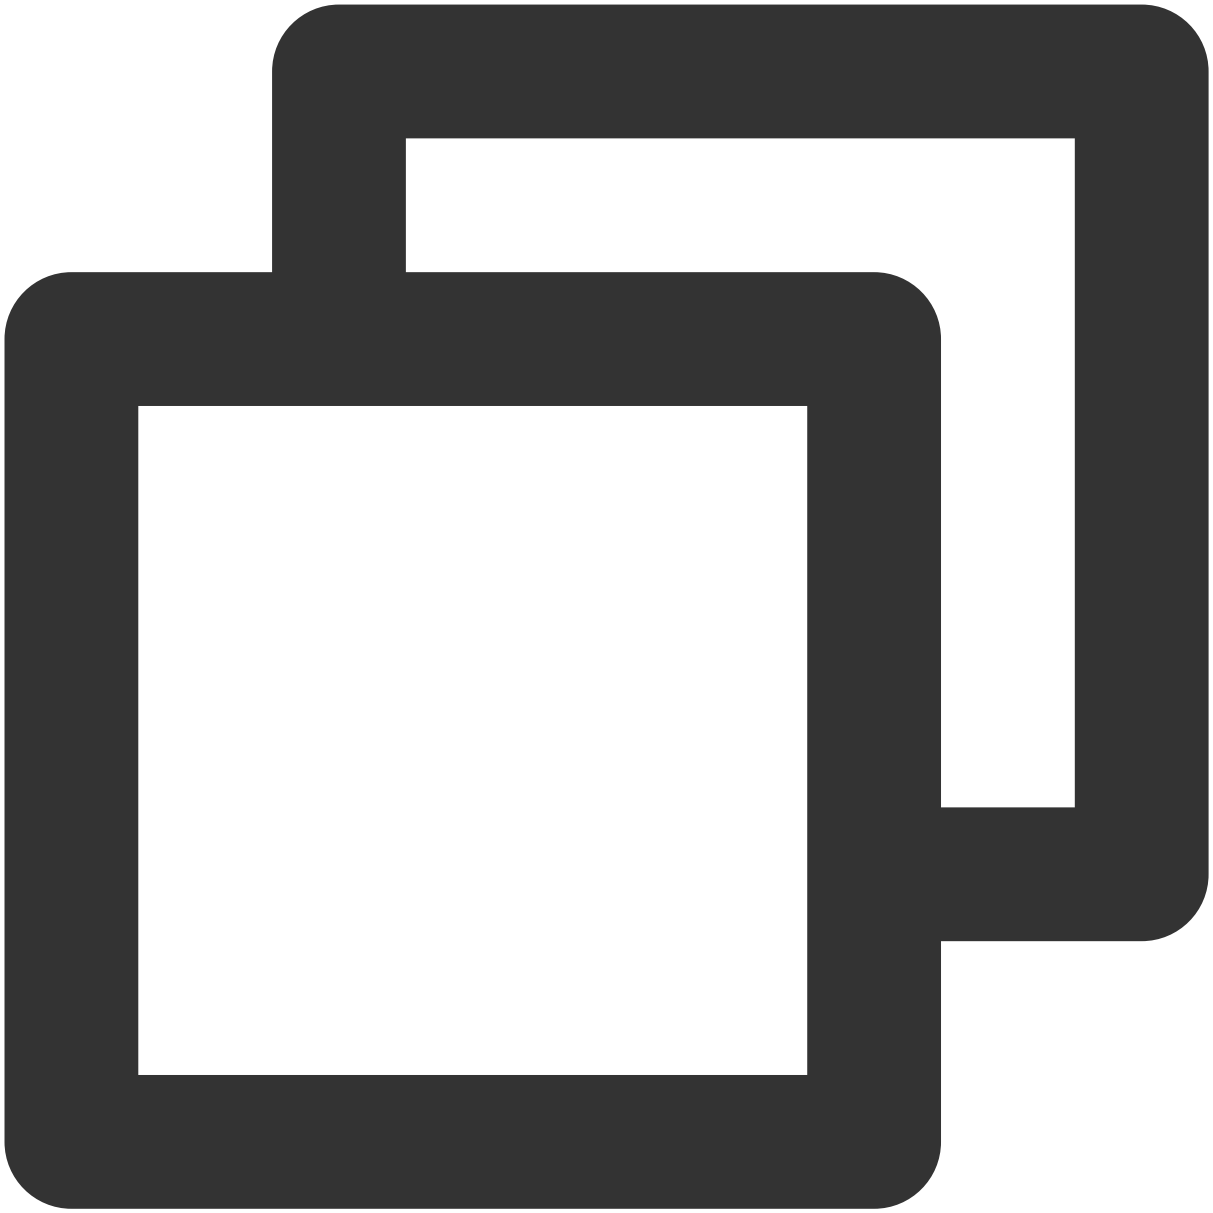

```
airflow resetdb
```