Nestrukturirana pohrana

Pristup podacima iz programskog koda 25/26

Ishod učenja 2

Drugi dio kolegija - obrada podataka

Projekt No.2 - **Dioniz**

- (+) Rad s nestrukturiranom (S3) pohranom
- (+) Rad s NoSQL bazama
- (+) Tekstualni podaci + TEME IZVAN ISHODA

Nestrukturirana pohrana

Generalna podjela podataka na strukturirane i nestrukturirane podatke

Nestrukturirana pohrana (ujedno i objektna pohrana)

S3 sučelje za komunikaciju s pohranom

Objektna pohrana

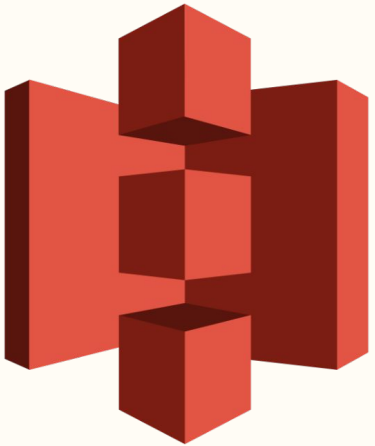

→ upravlja, odnosno pohranjuje podatke kao **objekte**:

→ datoteke (podaci)

→ datum i vrijeme kreiranja, naziv, veličina (meta-podaci)

AWS-ov **S3** (Simple Storage Service) je utemljeio standardizirani API za interakciju s objektima u pohrani

MiniO

→ MiniO je objektna pohrana otvorenog koda (eng. *open source*)

→ **S3 kompatibilna pohrana**

→ moguće ju je postaviti u različitim okruženjima (privatni server, Docker, Kubernetes...)

MinIO

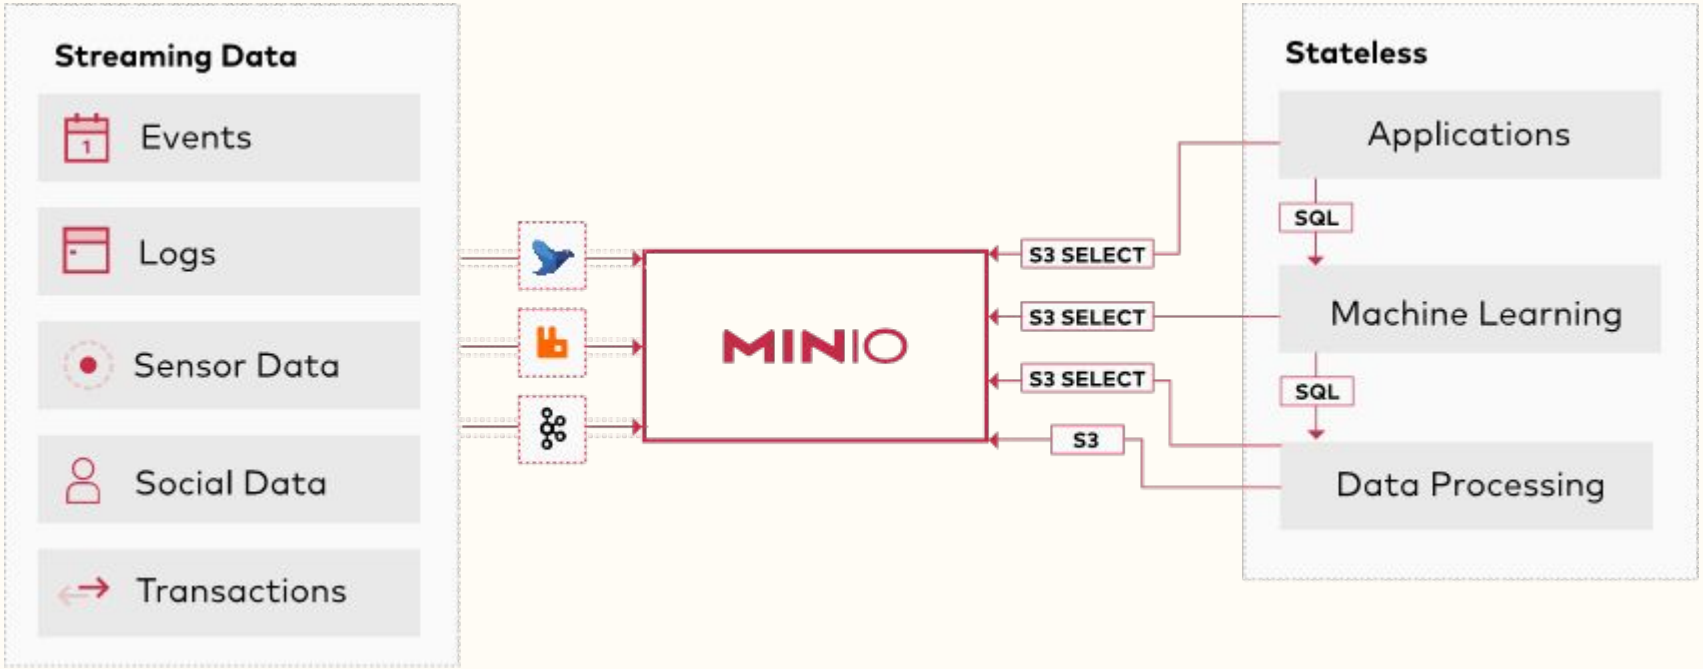
Streaming Data
Events
Logs
Sensor Data
Social Data
Transactions
MINIO
S3 SELECT
S3 SELECT
S3 SELECT
S3
Stateless
Applications
SQL
Machine Learning
SQL
Data Processing

Koncepti

Object

Bucket (kanta)

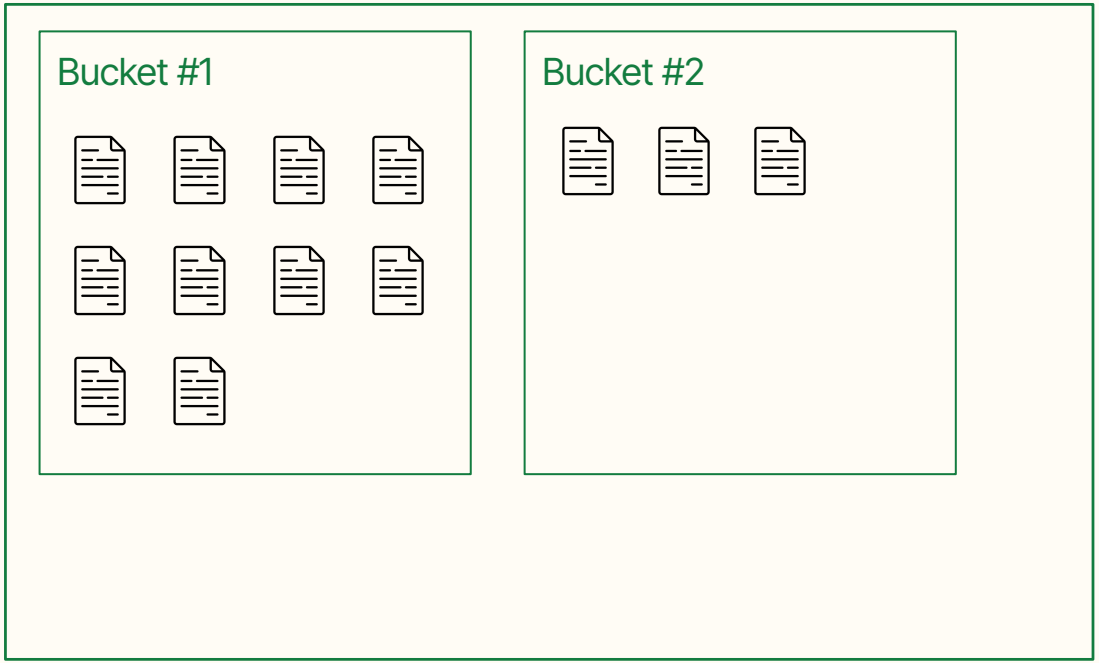

Objekt

Objekt u S3 pohrani je jedna datoteka i njeni metapodaci (vrijeme nastanka, tip sadržaja, dozvole, itd.) Objekt je definiran s tri stavke:

(1) object data (blob) - podatak o datoteci, može biti bilo koji nestrukturirani podatak (slike, dokumenti, videi, backupi, itd.)

(2) ključ objekta (object key) - jedinstevni identifikator objekta u bucketu

(3) ostali metapodaci

Bucket

→ grupirani objekti

→ analogno mapama (direktorijima) na *lokalnom* datotečnom sustavu

→ svaki bucket ima jedinstveno ime na instanci pohrane

→ omogućava logičku raspodjelu podataka odnosno objekata (po projektu, odjelu, itd.)

S3 API

Buckets

```
+  ListBuckets
+  CreateBucket
+  DeleteBucket

   …
```

Objects

```
+  GetObjects
+  GetObject
+  PutObject
+  DeleteObject

   …
```

MiniO setup

→ MiniO može biti postavljen kao jedinstvena ili distribuirana pohrana

→ moguće je postaviti MiniO iza load balancera

→ najlakše postavljanje omogućuju **kontejneri** (lokalno i u serverskom okruženju)

Postavljanje kroz Docker

```
docker run -d -p "9000:9000" -p "9001:9001"
    --name minio
     -e "MINIO_ROOT_USER=root"
     -e "MINIO_ROOT_PASSWORD=password"
    quay.io/minio/minio
    server /home/shared --address :9000 --console-address :9001
```

Minio - Upravljačka ploča

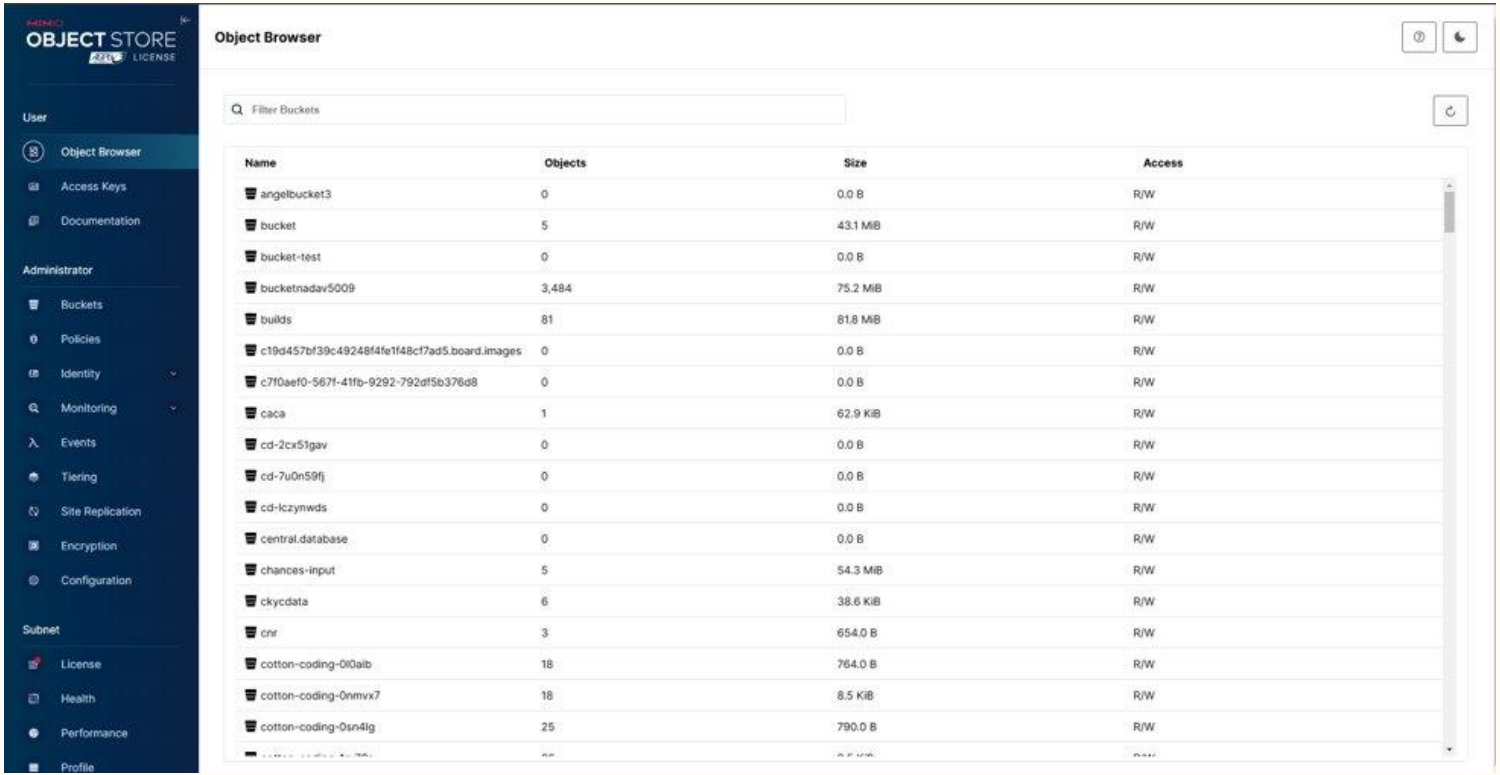

Rad s Pythonom

(+) interpretirani jezik

(+) “lagan, ali spor” (?)

(+) trenutna verzija - **3.14** (pi)

Packet manager

Kao i u drugim jezicima, koristimo packet manager (`pip`) kako bismo instalirali dodatne pakete (biblioteke)

Virtualno i okruženje

Kako bismo lakše organizirali pakete i okruženje koje koristimo za Python projekt, koristit ćemo virtualno okruženje:

(+) venv

(+) conda

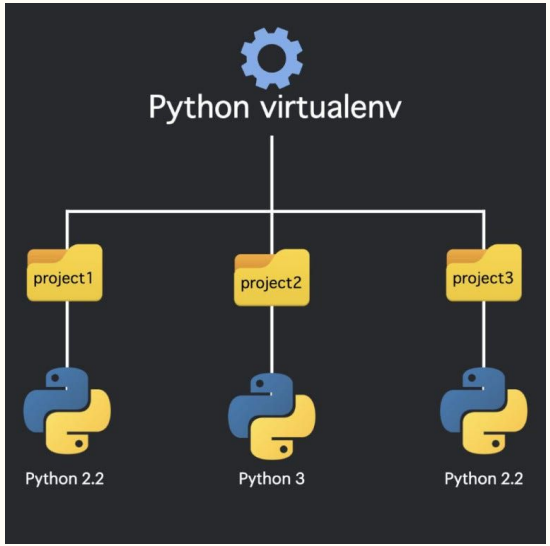

CONDA®

Primjer

Napravite direktorij i inicijalizirate virtualno okruženje:

```
python -m venv ./venv
./venv/scripts/Activate
```

Aktiviranje virtualnog okruženja će postaviti putanju za izvršavanje komandi `python` i `pip`

Primjer

(1) potrebno je instalirati `boto3` paket *

(2) potrebno je definirati sljedeće pristupne podatke:

+ ENDPOINT
+ ACCES_KEY
+ SECRET_KEY

Primjer

→ moguće je koristiti korisničko ime i lozinku admin korisnika

→ poželjnije je na upravljačkoj ploči definirati **ACCESS_KEY** i **SECRET_KEY**

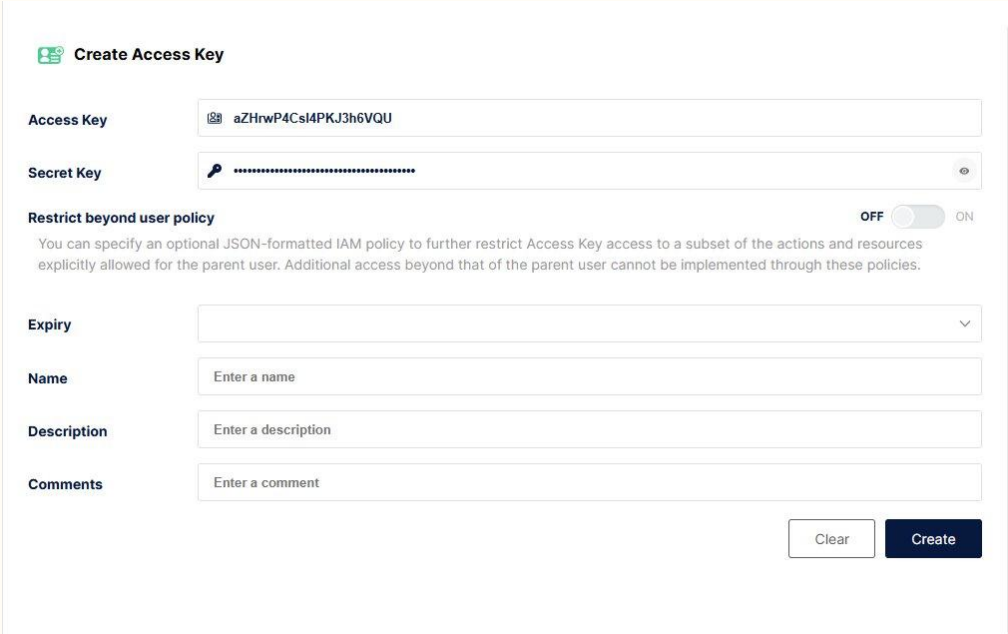

Primjer

```
s3 = boto3.client(
    "s3",
    endpoint_url="https://my-endpoint.example.com",
    aws_access_key_id="ACCESS",
    aws_secret_access_key="SECRET"
)
```

Primjer

1 - Izradite jednostavnu skriptu koja prenosi datoteke u bucket.

2 - Izradite jednostavnu skriptu koja dohvaća podatke u bucketu

Pokušajte pročitati ulazne podatke kao i definiciju direktorija za preuzimanje kroz komandno-linijske argumente

Primjer - HINT

S3 definira sljedeće važne metode:

+ `upload_file(Filename, Bucket, Key)`
  korisno kada se prenosi datoteka na lokalnoj putanji.

+ `upload_fileobj(Fileobj, Bucket, Key)`
  korisno kada postoji datotečni tok (eng. *stream*), recimo prilikom web uploada

+ `download_file(Bucket, Key, Filename)`
  Korisno za dohvat datoteke u lokalni `Filename`

+ `download_fileobj(Bucket, Key, Fileobj)`
  Korisno za dohvat datotečno toka u Fileobj

Zadatak

Istražite kako biste napravili jednostavnu aplikaciju s REST API sučeljem koje omogućuje prijenos i dohvat objekata (preko jedinstvenog ključa)

Možete koristiti biblioteke poput:

- Django (djangorestframework)
- Flask
- FastAPI