Spark referencia architektúra az ELKH Cloudon

Emődi Márk

emodi.mark@sztaki.hu

Bemutatkozás

Emődi Márk

SZTAKI PERL – Tudományos segédmunkatárs, kutató

emodi.mark@sztaki.hu

Apache Spark

	Hadoop MR Record	Spark Record	Spark 1 PB
Data Size	102.5 TB	100 TB	1000 TB
Elapsed Time	72 mins	23 mins	234 mins
# Nodes	2100	206	190
# Cores	50400 physical	6592 virtualized	6080 virtualized
Sort rate	1.42 TB/min	4.27 TB/min	4.27 TB/min
Sort rate/node	0.67 GB/min	20.7 GB/min	22.5 GB/min

- Nyílt forráskódú
- Általános célú
- Hibatűrő
- Elosztott keretrendszer párhuzamos számítások egyszerű megvalósítására
- 2014: Új világrekord (2014 Gray Sort)
  - 100 TB adat rendezés
  - 3 x gyorsabb rendezés 10 x kevesebb gépszám mellett
- 2016: Új világrekord hatékonyságban
  - 1,44 $ / TB rendezési költség a korábbi 4,51 $ / TB helyett

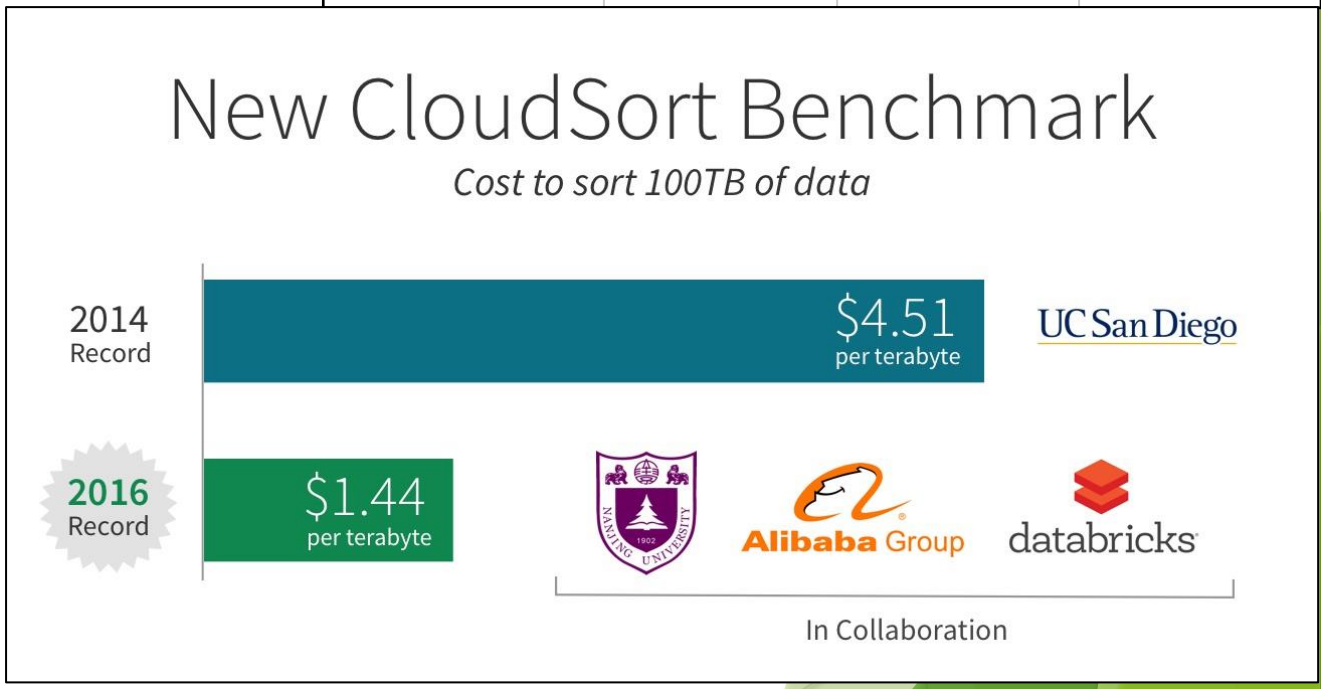

https://databricks.com/blog/2016/11/14/setting-new-world-record-apache-spark.html

Apache Spark funkcionalitás

- Adatok memóriából történő használata (szemben a korábban ismert Hadoop architektúrával)
- Scala, Python, Java és R programozási nyelv támogatás
- Fejlesztők, elemzők azonos rendszeren tudnak dolgozni
- Széles körben használt (Baidu, eBay, Yahoo, …) *https://spark.apache.org/powered-by.html*
- Lusta kiértékelés: a kiértékelések késleltetése, amíg nincs rá szükség
- „Valós idejű” feldolgozás alacsony késleltetés mellett
  - Memóriában tárolt adatok gyors hozzáférése
- Széles körű tárolóegység támogatása (HDFS, Apache Cassandra, Apache HBase, Apache Hive, …)
- Gépitanulás támogatása
  - GPU gyorsítás lehetséges

Referencia architektúrák célja

- Komplex virtuális infrastruktúrák kiépítése automatizált módon az ELKH Cloud-on. Az alábbi kritériumoknak magas minőségben való megfelelés:
  - Elosztott
  - Hibatűrő
  - Biztonságos
  - Skálázható
- Egyszerűsített felhasználás tesztrendszer és élesrendszer felépítésére
  - Minimális LINUX és felhő ismereti tudás szükséges!

Occopus leírók

Infrastruktúra leíró (infrastructure description)

- Csomópontok
- Változók
- Skálázás
- Függőségek

```
infra_name: spark-cluster
user_id: somebody@somewhere

nodes:
  - &M
    name: spark-master
    type: spark_master_node
  - &W
    name: spark-worker
    type: spark_worker_node
    scaling:
      min: 2
      max: 10

variables:
  HADOOP_VERSION: 3.3.0
  SPARK_VERSION: 3.0.1
  SPARK_HADOOP_VERSION: 3.2
  CONSUL_VERSION: 1.9.3
  CONSUL_TEMPLATE_VERSION: 0.25.1

dependencies:
  -
    connection: [ *W, *M ]
```

Occopus leírók

Infrastruktúra leíró (infrastructure description)

- Csomópontok
- Változók
- Skálázás
- Függőségek

Csomópont leíró (Node definition)

- Erőforrás definiálás
- Kontextualizáció
- Állapot ellenőrzés
- Konfigurációs menedzsment

```
'node_def:spark_master_node':
  -
    resource:
      type: nova
      endpoint: replace_with_endpoint_of_nova_interface_of_your_cloud
      project_id: replace_with_projectid_to_use
      user_domain_name: Default
      image_id: replace_with_id_of_your_image_on_your_target_cloud
      network_id: replace_with_id_of_network_on_your_target_cloud
      flavor_name: replace_with_id_of_the_flavor_on_your_target_cloud
      key_name: replace_with_name_of_keypair_or_remove
      security_groups:
        - replace_with_security_group_to_add_or_remove_section
      floating_ip: add_yes_if_you_need_floating_ip_or_remove
      floating_ip_pool: replace_with_name_of_floating_ip_pool_or_remove
    contextualisation:
      type: cloudinit
      context_template: !yaml_import
        url: file://cloud_init_spark_master.yaml
    health_check:
      ports:
        - 8080
      timeout: 1000
...
```

```
...
'node_def:spark_worker_node':
  -
    resource:
      type: nova
      endpoint: replace_with_endpoint_of_nova_interface_of_your_clou
      project_id: replace_with_projectid_to_use
      user_domain_name: Default
      image_id: replace_with_id_of_your_image_on_your_target_cloud
      network_id: replace_with_id_of_network_on_your_target_cloud
      flavor_name: replace_with_id_of_the_flavor_on_your_target_clou
      key_name: replace_with_name_of_keypair_or_remove
      security_groups:
        - replace_with_security_group_to_add_or_remove_section
    contextualisation:
      type: cloudinit
      context_template: !yaml_import
        url: file://cloud_init_spark_worker.yaml
    health_check:
      ping: False
```

Occopus leírók

Infrastruktúra leíró (infrastructure description)

- Csomópontok
- Változók
- Skálázás
- Függőségek

Csomópont leíró (Node definition)

- Erőforrás definiálás
- Kontextualizáció
- Állapot ellenőrzés
- Konfigurációs menedzsment

Cloud-init fájlok

- A virtuális gép konfiguráláshoz szükséges lépések:
  - Felhasználó kezelés
  - Komponensek telepítése/beállítása
  - Szolgáltatások telepítése/konfigurálása/indítása
  - Szolgáltatások elindítása

A megoldás architektúrája

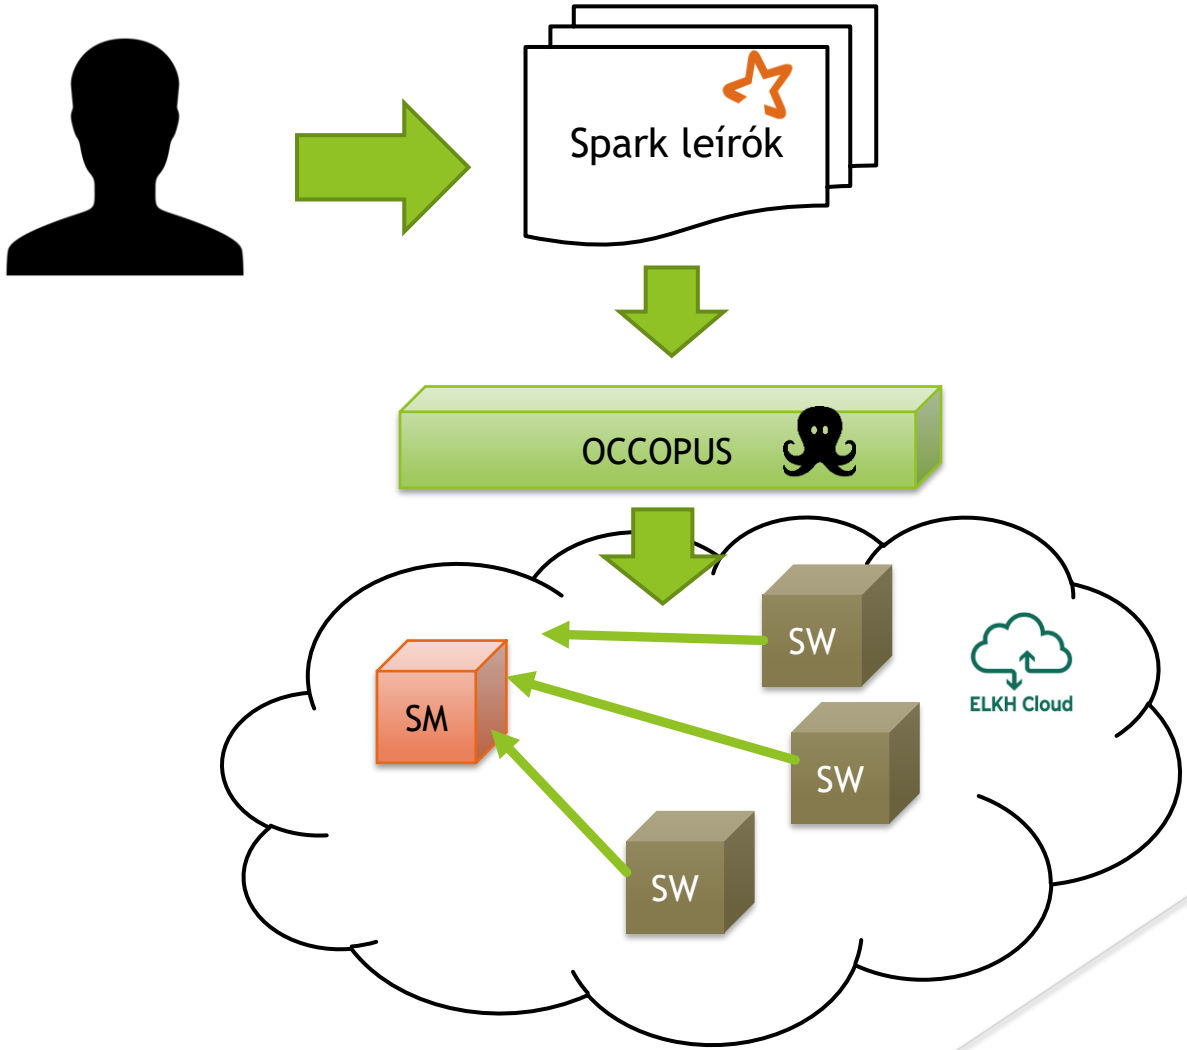

Megoldás használatának lépései

Felhasználó feladatköre:

0. Lépés: **Előkészítés** (ELKH Cloud projekt, Üres Ubuntu VM elindítás)

1. Lépés: **Occopus telepítés/konfigurálás a virtuális gépen**

2. Lépés: **Leírók letöltése a virtuális gépre**
   Occopus/ELKH Cloud weboldala

3. Lépés: **Tűzfalszabályok létrehozása**
   ELKH Cloud OpenStack felületén

4. Lépés: **Leírók személyre szabása a virtuális gépen**

5. Lépés: **Occopus aktiválása**
   $ source ~/occopus/bin/activate

6. Lépés: Leírók importálása Occopus számára
   $ occopus-import nodes/node_definitions.yaml

7. Lépés: **Infrastruktúra kiépítése**
   $ occopus-build --parallelize infra-spark-cluster.yaml

8. Lépés: **Infrastruktúra használata**

(9. Lépés: **Infrastruktúra leállítása**)

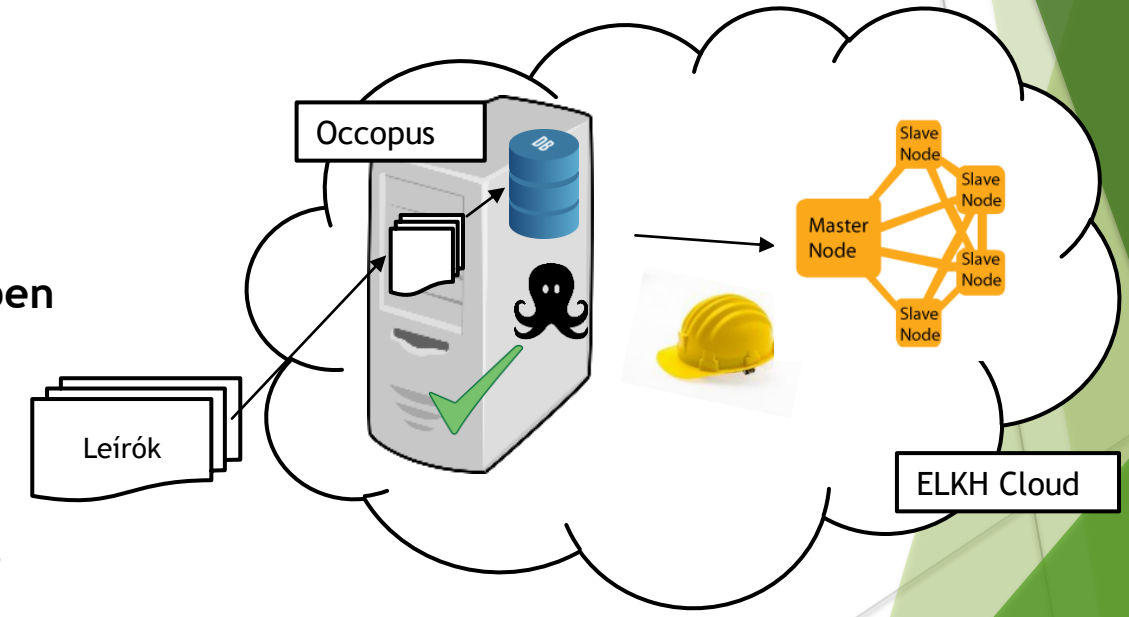

A megoldás használata

A szolgáltatások telepítésének és elindításának lépései a következők:

0. **Lépés:** Előkészítés (Üres Ubuntu virtuális gép indítása a saját projekten)
1. **Lépés:** Occopus telepítés/konfigurálás a virtuális gépen
2. **Lépés:** Leírók letöltése a virtuális gépre
3. **Lépés:** Tűzfalszabályok létrehozása ELKH Cloud OpenStack felületén
4. **Lépés:** Occopus leírók személyre szabása a virtuális gépen
5. **Lépés:** Occopus aktiválása
6. **Lépés:** Leírók importálása Occopus számára
7. **Lépés:** Szolgáltatás kiépítése
8. **Lépés:** A kiépített szolgáltatás használata

1x

(Aktuális VM-en az aktuális referencia architektúra esetén)

egy-egy sor kód

Rövid és hosszú felhasználás is támogatott

2. lépés: leírók letöltése

1

kozás | **Szolgáltatások** | Hírek | GYIK | Projektek | Dokumentumok

Címlap

Felhasználást segítő szolgáltatá

- DataAvenue
- Cloud alkalmazásokat támogató portál indítása
- Occopus cloud orchestrator indítása
- Apache Hadoop klaszter kiépítése
- Apache Spark klaszter RStudio stack-el
- Apache Spark klaszter Python stack-el *(Frissítés: MTA Cloud - Micr*
- Docker-Swarm klaszter kiépítése *(Frissítés: MTA Cloud - Microsoft*
- Flowbster - Autodock Vina
- TensorFlow, Keras, Jupyter Notebook stack
- TensorFlow, Keras, Jupyter Notebook GPU stack *(Frissítés: MT támogatással)*
- Kubernetes klaszter
- CQueue klaszter
- JupyterLab

https://science-cloud.hu/felhasznalast-segito-szolgaltatasok

Apache Spark klaszter Python stack-el

2

Áttekintés:

Ez a bemutató áttekintés ad arról, hogy hogyan lehet létrehozni egy skálázható Apache Spark infrastruktúrát az Occopus eszköz segítségével. Az Apache Spark egy gyors és általános célú klaszter keretrendszer. Magas szintű API-kat biztosít Java, Scala, Python és R programnyelvekhez. Továbbá számos magas szintű eszközt támogat, többet között a Spark SQL-t a strukturált adatfeldolgozáshoz, MLlib-et a gépi tanuláshoz, GraphX-et a gráf feldolgozáshoz, és Spark Streaming-et a nagy mennyiségű adatok valós idejű feldolgozásához. További információkért látogasson el az Apache Spark hivatalos weboldalára.

Az Apache Spark klaszter a HDFS-el (Hadoop Distributed File System) együtt a Big Data és a a gépi tanulási alkalmazások egyik legfontosabb eszköze, amely lehetővé teszi a nagy adatállományok párhuzamos feldolgozását több virtuális gépen, amelyek a Spark Workerek. Azonban, egy Spark klaszter létrehozása a HDFS-el a felhőben nem egyszerű, a felhő rendszerek és az Apache Spark architektúrájának mély ismeretét igényli. Azért, hogy a kutatókat megóvjuk ettől a munkától, létrehoztuk és közzétettük azokat a szükséges infrastruktúra leírókat, amelyek segítségével az Occopus automatikusan építi a Spark klasztert, a felhasználó által megadott Workerek számával. A Spark egy "MLlib" nevű speciális könyvtárat biztosít a gépi tanulási alkalmazások támogatására. Hasonlóképpen, az R-orientált Spark környezethez, kifejlesztettük az infrastruktúra-leírókat a gépi tanulási környezet létrehozásához a felhőben. Itt, a programozási nyelv a Python és a felhasználói programozási környezet a Jupyter Notebook. A teljes gépi tanulási környezet a következő összetevőkből áll: Jupyter, Python, Spark és HDFS. Ezt a gépi tanulási környezetet az Occopus automatikusan építi ki és a Spark Workerek számát a felhasználó határozhatja meg.

Ez a bemutató egy teljes Apache Spark infratstruktúrát hoz létre, amely integrálva van a HDFS, a Python és a Jupyter Notebook-al. Tartalmaz egy Spark Master csomópontot és Spark Worker csomópontokat, amelyek számát felfelé vagy lefelé lehet skálázni.

Használati és telepítési útmutató

https://occopus.readthedocs.io/en/latest/tutorial-bigdata-ai.html#apache-spark-cluster-with-jupyter-notebook-and-pyspark

2. lépés: leírók letöltése

ELKH Cloud

Apache Spark klaszter Jupyter notebook és PySpark Stack leírása:
https://occopus.readthedocs.io/en/latest/tutorial-bigdata-ai.html#apache-spark-cluster-with-jupyter-notebook-and-pyspark

Apache Spark R Stack leírása:
https://occopus.readthedocs.io/en/latest/tutorial-bigdata-ai.html#apache-spark-cluster-with-rstudio-stack

Apache Spark cluster with RStudio Stack

This tutorial sets up a complete Apache Spark (version **3.0.1**) infrastructure with HDFS (Hadoop Distributed File System) (version **3.3.0**) and RStudio server. Apache Spark is a fast and general-purpose cluster computing system. It provides high-level APIs in Java, Scala, Python and R, and an optimized engine that supports general execution graphs. It also supports a rich set of higher-level tools including Spark SQL for SQL and structured data processing, MLlib for machine learning, GraphX for graph processing, and Spark Streaming. For more information visit the official Apache Spark page .

This tutorial sets up a complete Apache Spark infrastructure integrated with HDFS, R, RStudio and sparklyr. It contains a Spark Master node and Spark Worker nodes, which can be scaled up or down.

Features

- creating two types of nodes through contextualisation
- utilising health check against a predefined port
- using scaling parameters to limit the number of Spark Worker nodes

Download

You can download the example as tutorial.examples.spark-cluster-with-r .

3. lépés: Tűzfalszabályok összegzése

Ajánlott tűzfalszabály Hadoop és Spark architektúrákra

	Direction	IP Protocol	Port Range	Remote IP Prefix
1	Egress	Any	Any	0.0.0.0/0
2	Egress	Any	Any	::/0
3	Ingress	TCP	1 - 65535	Your IP address 123.45.67.89/32
4	Ingress	TCP	1 - 65535	192.168.0.0/24
5	Ingress	TCP	22 (SSH)	0.0.0.0/0
6	Ingress	TCP	8080	Occopus VM - Floating IP

Kimenő forgalom

Pl. lekérdezés (harmadik féltől)

$ curl ifconfig.me
92.21.242.26

Spark kommunikáció

SSH hozzáférés

Occopus állapot ellenőrzés

4. lépés: Leírók személyre szabása

Csomópont definíciós fájl (**nodes/node_definition.yaml**)

Nova erőforrás szekció:

```
'node_def:spark_master_node':
  -
    resource:
      type: nova
      endpoint: replace_with_endpoint_of_nova_interface_of_your_cloud
      project_id: replace_with_projectid_to_use
      user_domain_name: Default
      image_id: replace_with_id_of_your_image_on_your_target_cloud
      network_id: replace_with_id_of_network_on_your_target_cloud
      flavor_name: replace_with_id_of_the_flavor_on_your_target_cloud
      key_name: replace_with_name_of_keypair_or_remove
      security_groups:
        - replace_with_security_group_to_add_or_remove_section
      floating_ip: add_yes_if_you_need_floating_ip_or_remove
      floating_ip_pool: replace_with_name_of_floating_ip_pool_or_remove
    contextualisation:
      type: cloudinit
      context_template: !yaml_import
        url: file://cloud_init_spark_master.yaml
    health_check:
      ports:
        - 8080
      timeout: 1000
...
```

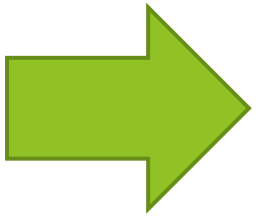

```
'node_def:spark_master_node':
  -
    resource:
      type: nova
      endpoint: https://sztaki.cloud.mta.hu:5000/v3
      project_id: caml6db63ddf47a98045ef9c726vgqbp
      user_domain_name: Default
      image_id: zgsf1dc3-b6d5-4b15-942e-61e0ef2l8dk
      network_id: 3yqqqe1c-858c-4047-a48a-e2fab0nd547
      flavor_name: 3
      key_name: key_name
      security_groups:
       - f7d8dc12-fd7a-4d69-ba8d-c1f11c9b5b73
      floating_ip: yes
    contextualisation:
      type: cloudinit
      context_template: !yaml_import
        url: file://cloud_init_spark_master.yaml
    health_check:
      ports:
        - 8080
      timeout: 1000
...
```

https://occopus.readthedocs.io/en/latest/user-doc-collecting-resources.html#openstack-horizon-nova

4. lépés: Leírók személyre szabása – klaszter méretének beállítása

Ha szükséges, frissítse a Spark dolgozó (worker) csomópontok számát!

Ehhez szerkessze át az infra-spark-cluster.yaml fájlt és módosítsa a „min” és „max” paramétereket a „scaling” kulcsszó alatt.

- A skálázás az az intervallum, amelyben a csomópontok száma megváltozhat (min, max). Jelenleg a minimális érték 2-re van állítva (ami az indításkor a kezdeti szám lesz), és a maximális értéke 10.
- Ne feledje, hogy az Occopusnak legalább egy csomópontot el kell indítania minden egyes csomóponttípusból, hogy az infrastruktúra megfelelően működjön, valamint a skálázás csak a Spark dolgozó (worker) csomópontokon alkalmazható ebben a példában!
- Később: manuális skálázás

```
nodes:
    - &M
        name: spark-master
        type: spark_master_node
    - &W
        name: spark-worker
        type: spark_worker_node
        scaling:
          min: 2
          max: 10
dependencies:
    -   connection: [ *W, *M ]
```

5. lépés: occopus aktiválása

Győződjön meg róla, hogy a megfelelő virtualenv aktiválva van!

Amennyiben ezt még nem tette volna meg korábban, az alábbi parancs segítségével aktiválható az Occopus virtuális környezete:

```
ubuntu@occo:~/spark-cluster-with-python$ source $HOME/occopus/bin/activate

(occopus) ubuntu@occo:~/spark-cluster-with-python$
```

6. lépés: leírók importálása

Importáljuk a személyre szabott leírókat az Occopus adatbázisába:

```
$ occopus-import nodes/node_definitions.yaml
Successfully imported nodes: spark_master_node, spark_worker_node
```

- **Megjegyzés:** A nodes mappában található cloud init fájlok szerkesztésével a haladó felhasználók személyre szabhatják a Spark konfigurációs fájljait (cloud_init_spark_master.yaml, cloud_init_spark_worker.yaml).
- **Fontos:** Az Occopus akkor veszi fel a csomópont definíciókat az adatbázisból, amikor felépíti az infrastruktúrát, így mindig importálásra van szükség, ha a node definíciós fájl, vagy bármelyik (pl.: kontextualizációs) fájl megváltozik!

7. lépés: infrastruktúra kiépítése

Az alábbi parancs segítségével megkezdhetjük a klaszter felépítését:
`$ occopus-build --parallelize infra-spark-cluster.yaml`

Tipp: occopus-build **--parallelize** infra-spark-cluster.yaml (párhuzamos VM kiépítés, az egymástól független VM-ek esetében)

```
$ occopus-build --parallelize infra-spark-cluster.yaml

** 2021-02-17 17:07:21,391      Creating node 'spark-master'/'0b8269fe-78ec-47fc-8cdb-7195209e5123’

...

** 2021-02-17 17:25:04,184      Health checking for node 'spark-master'/'0b8269fe-78ec-47fc-8cdb-7195209e5123'
** 2021-02-17 17:25:05,360        Checking node reachability (0b8269fe-78ec-47fc-8cdb-7195209e5123):
** 2021-02-17 17:25:05,371          193.224.59.67 => ready
** 2021-02-17 17:25:05,371        Checking port availability (0b8269fe-78ec-47fc-8cdb-7195209e5123):
** 2021-02-17 17:25:05,373          8080 => ready
** 2021-02-17 17:25:05,373      Health checking result: ready
** 2021-02-17 17:25:05,376      Node 'spark-master'/'0b8269fe-78ec-47fc-8cdb-7195209e5123' is ready.
** 2021-02-17 17:25:05,409      Creating node 'spark-worker'/'50c7cfe9-4c3c-4928-81e6-d58323b1e2b2'
** 2021-02-17 17:25:05,413      Creating node 'spark-worker'/'98a82e45-6bf2-4cb9-9ead-953be4435bd7'
```

7. lépés: infrastruktúra kiépítése

ELKH Cloud

1

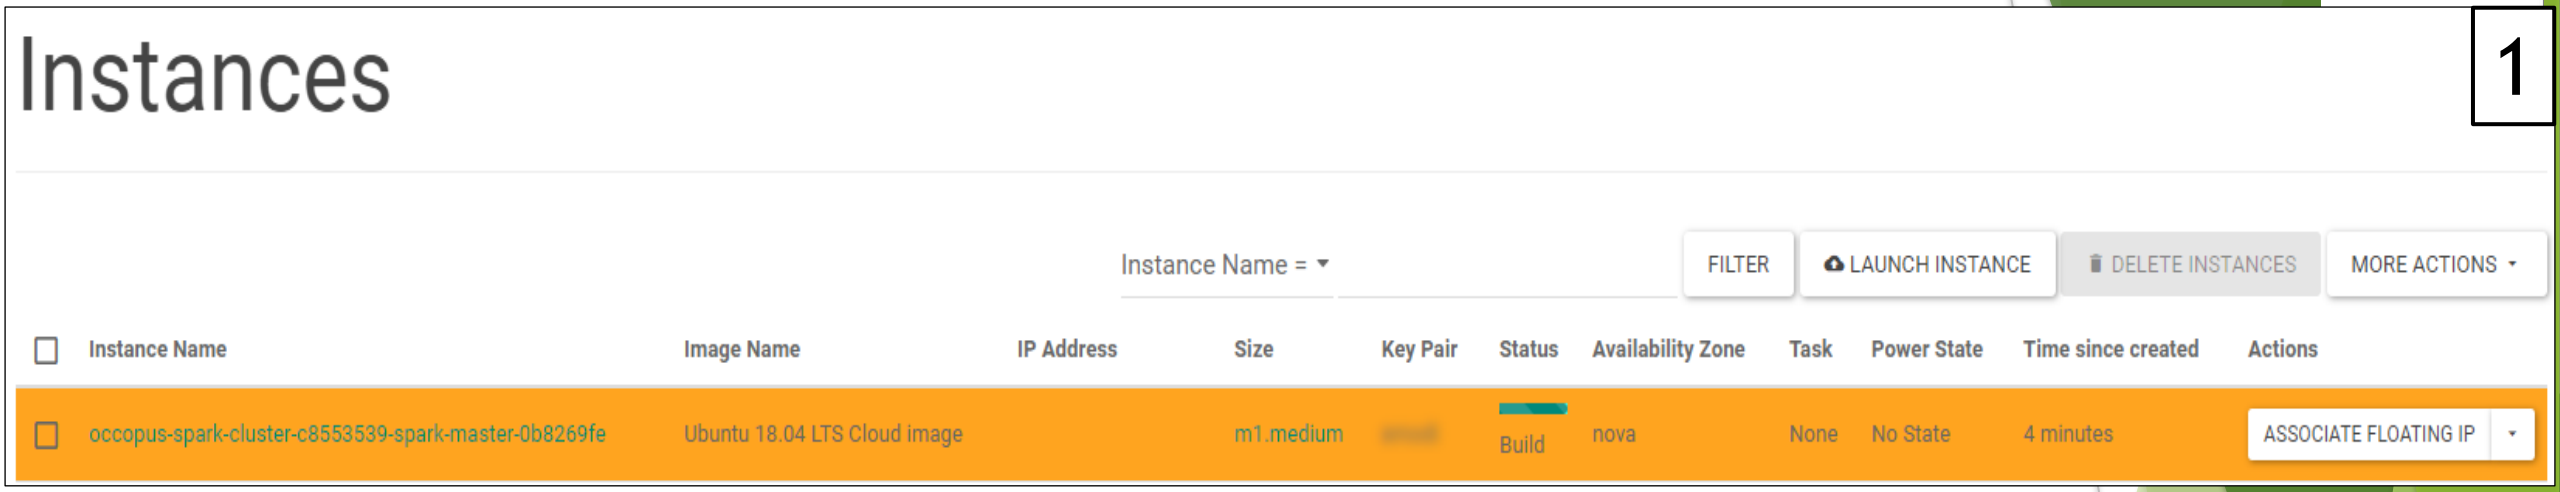

2

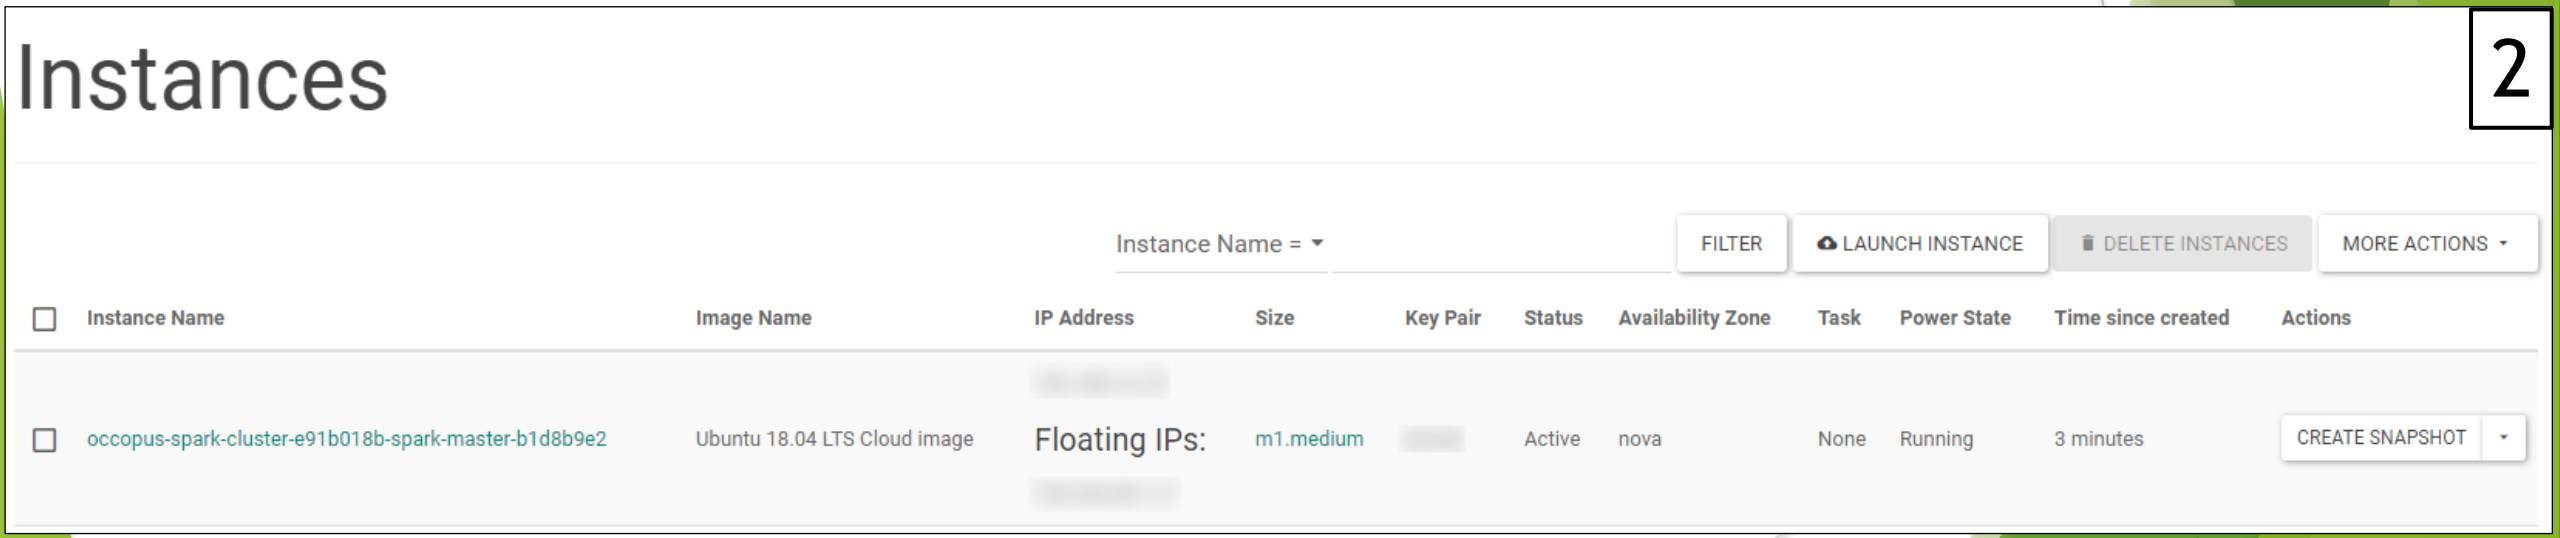

7. lépés: infrastruktúra kiépítése

ELKH Cloud

3

Instances

Instance Name = | FILTER | LAUNCH INSTANCE | DELETE INSTANCES | MORE ACTIONS

Instance Name	Image Name	IP Address	Size	Key Pair	Status	Availability Zone	Task	Power State	Time since created	Actions
occopus-spark-cluster-b68c5d40-spark-worker-7399ea46	Ubuntu 18.04 LTS Cloud image		m1.medium		Active	nova	None	Running	1 minute	CREATE SNAPSHOT
occopus-spark-cluster-b68c5d40-spark-worker-303b0625	Ubuntu 18.04 LTS Cloud image		m1.medium		Active	nova	None	Running	2 minutes	CREATE SNAPSHOT
occopus-spark-cluster-b68c5d40-spark-master-ac15312f	Ubuntu 18.04 LTS Cloud image	Floating IPs:	m1.medium		Active	nova	None	Running	11 minutes	CREATE SNAPSHOT

7. lépés: infrastruktúra kiépítése

Sikeres lefutás után a virtuális gépek IP címei, node ID –jai, valamint az infrastruktúra azonosítója megjelenik a log üzenetek alján, listába szedve.

Az infrastruktúra azonosítója elmenthető, vagy lekérdezhető az occopus-maintain parancs segítségével:

```
** 2021-02-17 17:26:33,041      Submitted infrastructure: 'c8553539-42c9-40b1-97bc-d53ab8947ca7'
** 2021-02-17 17:26:33,127      List of nodes/instances/addresses:
** 2021-02-17 17:26:33,127      spark-worker:
** 2021-02-17 17:26:33,128        50c7cfe9-4c3c-4928-81e6-d58323b1e2b2:
** 2021-02-17 17:26:33,128          198.124.39.182
** 2021-02-17 17:26:33,128        98a82e45-6bf2-4cb9-9ead-953be4435bd7:
** 2021-02-17 17:26:33,128          198.124.39.144
** 2021-02-17 17:26:33,129      spark-master:
** 2021-02-17 17:26:33,129        0b8269fe-78ec-47fc-8cdb-7195209e5123:
** 2021-02-17 17:26:33,129          198.124.39.67
c8553539-42c9-40b1-97bc-d53ab8947ca7
```

8. lépés: infrastruktúra használata

- Ellenőrizheti a Spark klaszter helyes működését, statisztikáit az alábbi weblapokon:
- Application UI: "http://<SparkMasterIP>:4040"
- Spark UI: "http://<SparkMasterIP>:8080"
- Jupyter UI: "http://<SparkMasterIP>:8888"
- HDFS UI: "http://<SparkMasterIP>:9870"

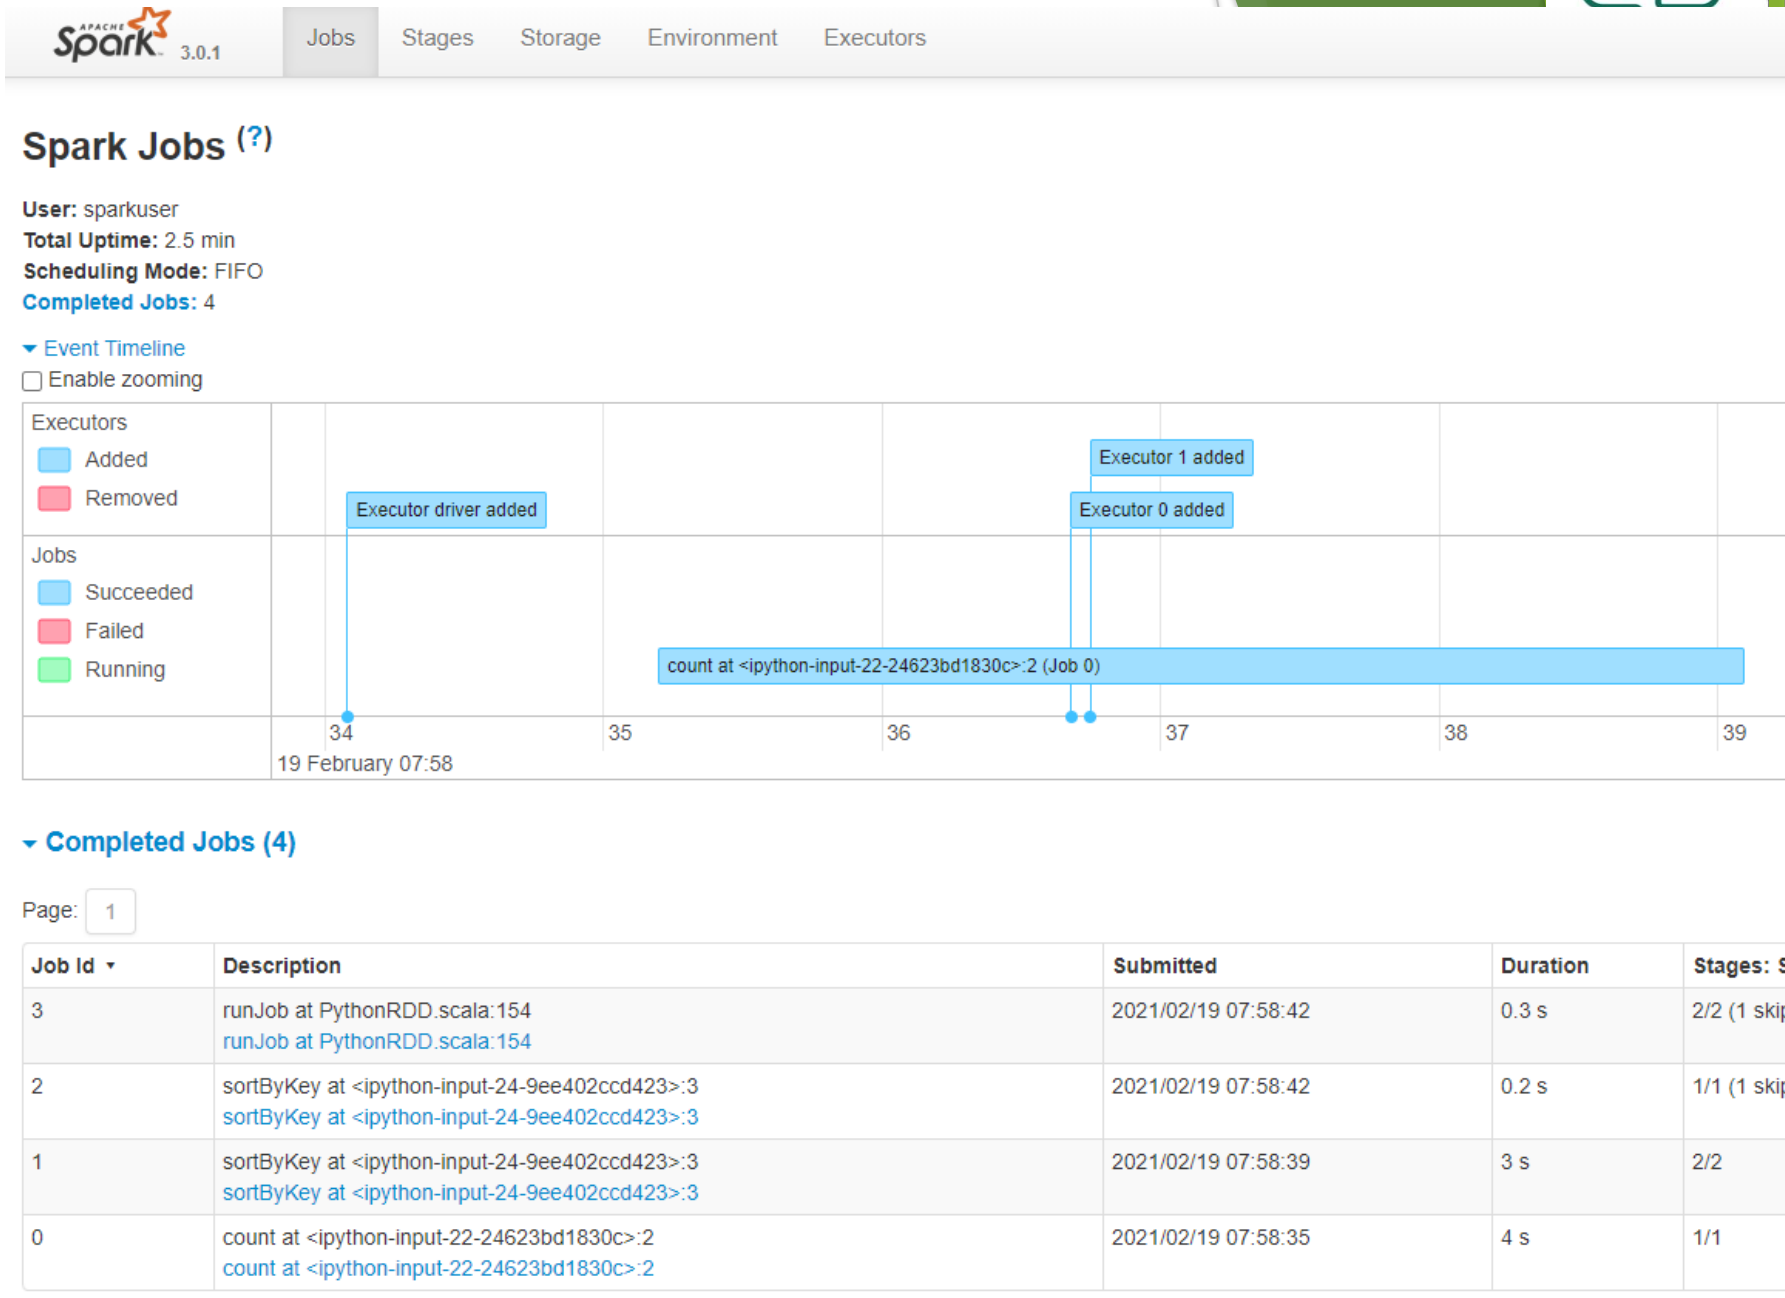

8. lépés: infrastruktúra használata

- Ellenőrizheti a Spark klaszter helyes működését, statisztikáit az alábbi weblapokon:
- Application UI: "http://<SparkMasterIP>:4040"
- Spark UI: "http://<SparkMasterIP>:8080"
- Jupyter UI: "http://<SparkMasterIP>:8888"
- HDFS UI: "http://<SparkMasterIP>:9870"

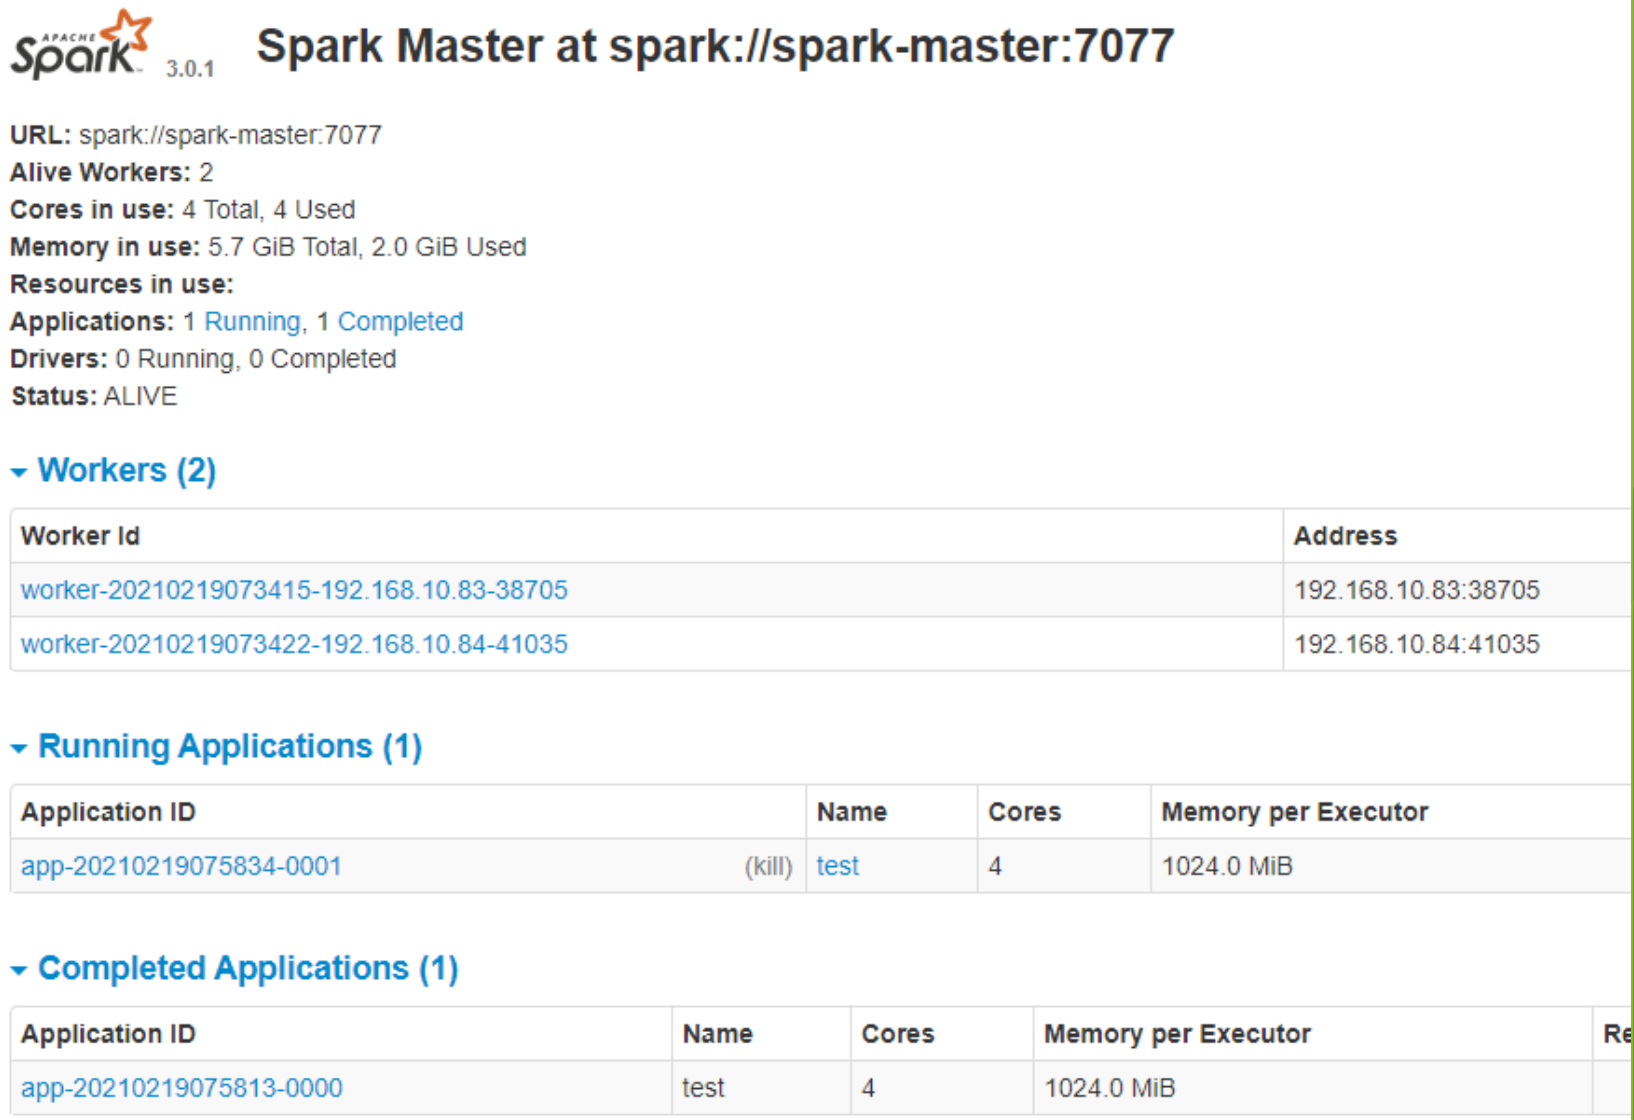

Spark 3.0.1 **Spark Master at spark://spark-master:7077**

URL: spark://spark-master:7077
Alive Workers: 2
Cores in use: 4 Total, 4 Used
Memory in use: 5.7 GiB Total, 2.0 GiB Used
Resources in use:
Applications: 1 Running, 1 Completed
Drivers: 0 Running, 0 Completed
Status: ALIVE

Workers (2)

Worker Id	Address
worker-20210219073415-192.168.10.83-38705	192.168.10.83:38705
worker-20210219073422-192.168.10.84-41035	192.168.10.84:41035

Running Applications (1)

Application ID		Name	Cores	Memory per Executor
app-20210219075834-0001	(kill)	test	4	1024.0 MiB

Completed Applications (1)

Application ID	Name	Cores	Memory per Executor	Re
app-20210219075813-0000	test	4	1024.0 MiB	

8. lépés: infrastruktúra használata

- Ellenőrizheti a Spark klaszter helyes működését, statisztikáit az alábbi weblapokon:
- Application UI: "http://<SparkMasterIP>:4040"
- Spark UI: "http://<SparkMasterIP>:8080"
- Jupyter UI: "http://<SparkMasterIP>:8888"
- HDFS UI: "http://<SparkMasterIP>:9870"

Test Spark Cluster

Import python libraries

In [1]:
```
from pyspark import SparkContext, SparkConf
```

In [2]:
```
SparkMasterIP="192.168.10.8"
```

Start Spark Application

In [3]:
```
# Start Spark local mode
# sc = SparkContext(appName="test", master="local")

# Start Spark cluster mode

sc = SparkContext(appName="test", master="spark://"+SparkMasterIP+":7077")
```

In [4]:
```
sc
```

Out[4]:

SparkContext

Spark UI

Version
`v3.0.1`

Master
`spark://192.168.10.8:7077`

AppName
`test`

In [5]:
```
import sys
from random import random
from operator import add
from pyspark.sql import SparkSession
```

8. lépés: infrastruktúra használata

- Ellenőrizheti a Spark klaszter helyes működését, statisztikáit az alábbi weblapokon:
- Application UI: "http://<SparkMasterIP>:4040"
- Spark UI: "http://<SparkMasterIP>:8080"
- Jupyter UI: "http://<SparkMasterIP>:8888"
- HDFS UI: "http://<SparkMasterIP>:9870"

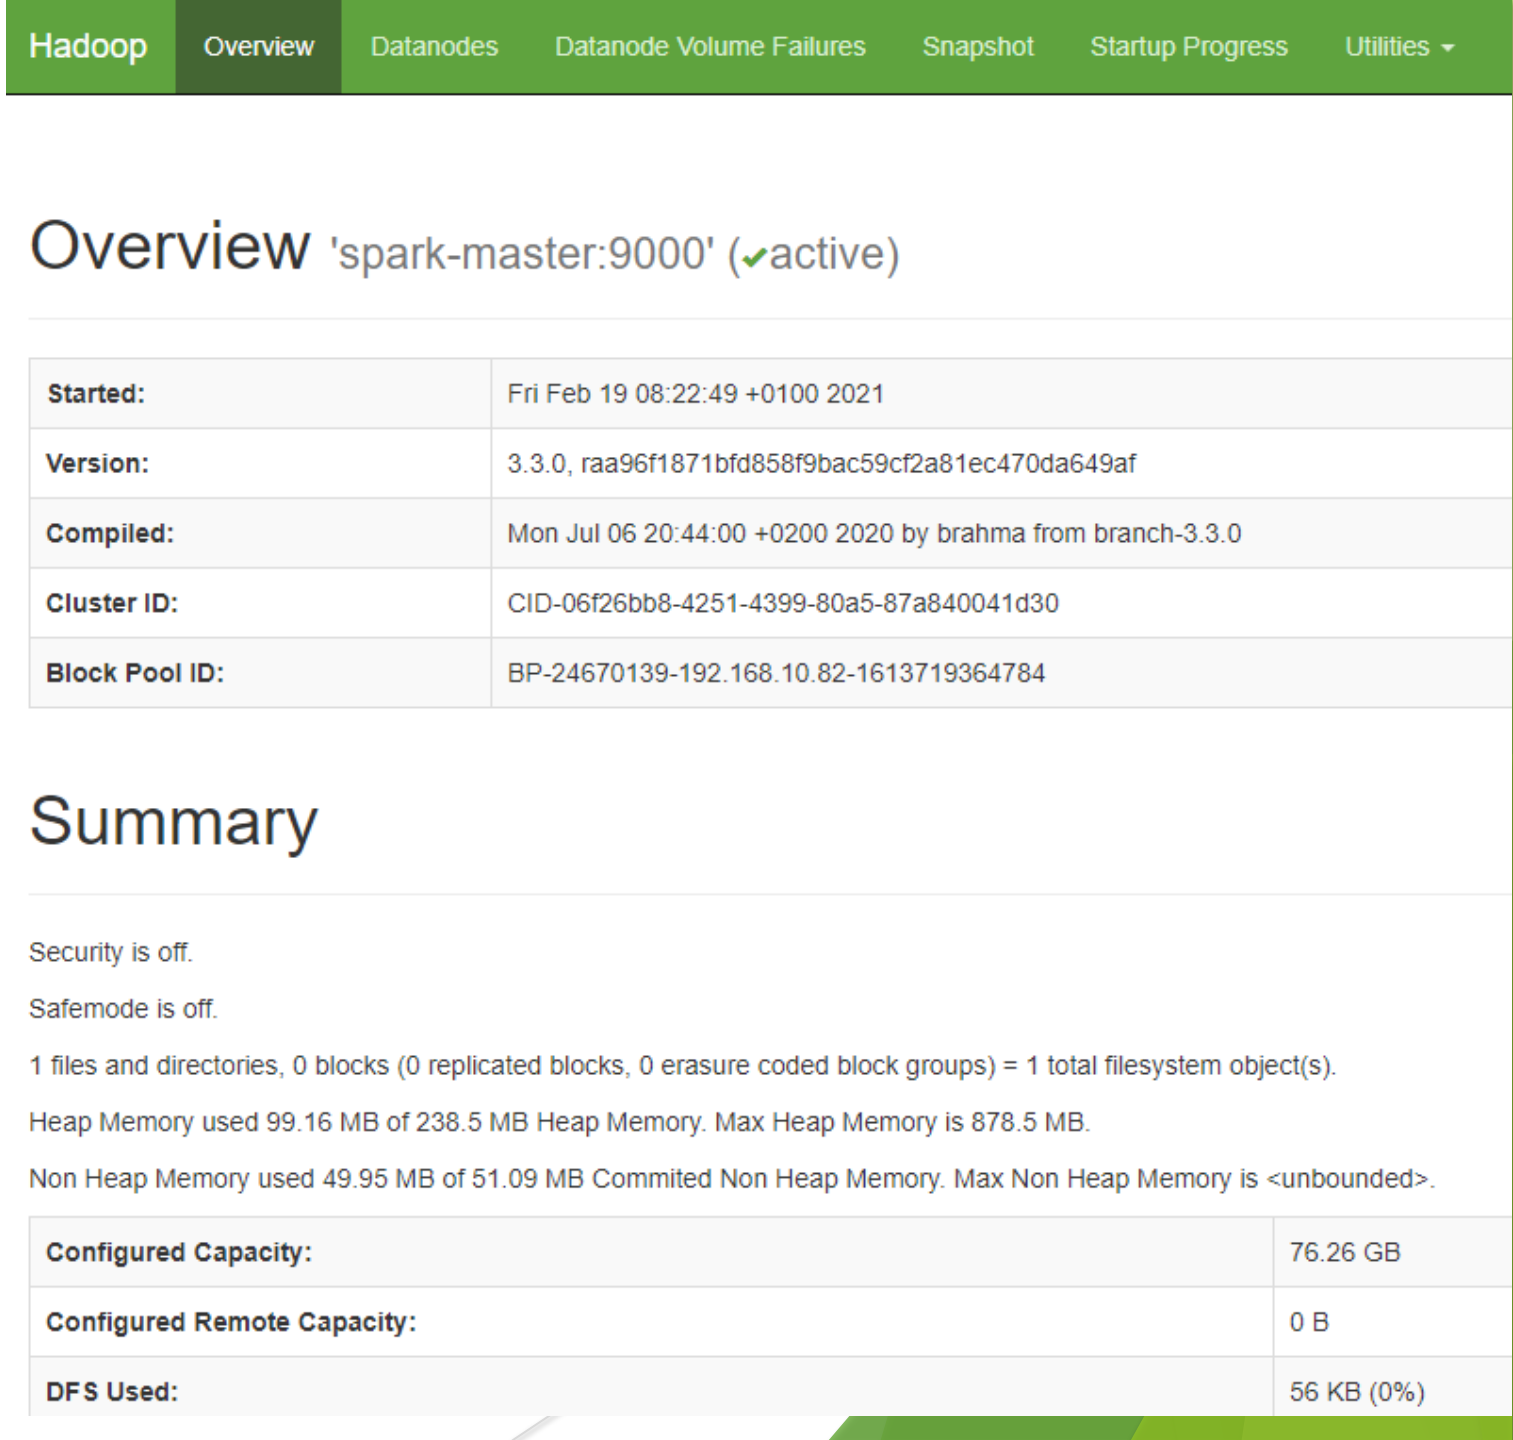

Infrastruktúra skálázás

Az Occopus eszköz lehetővé teszi a virtuális infrastruktúrák manuális fel- vagy leskálázását. A skálázás egy kétfázisú művelet: elsőként regisztráljuk a skálázási kérést, és ezután fel- vagy le skálázzuk a kiválasztott infrastruktúrát, új csomópontok építésével vagy meglévő csomópontok törlésével.

1. A skálázási kérelmet az **$ ocopus-scale** paranccsal tudjuk megadni.
   Pl.: `$ occopus-scale -n spark-slave -c COUNT -i INFRA_ID`, ahol:
   - -n (node): a skálázandó csomópont neve
   - -c (count): egy pozitív vagy negatív szám, amely megadja a skálázás irányát és annak nagyságát
   - -i (infrastructure): a cél infrastruktúra azonosítója ($occopus-maintain -l parancs segítségével lekérdezhető)
2. A skálázást az occopus-scale parancs kiadása után, az **$ occopus-maintain** paranccsal hajthatjuk végre a kéréseket. Példa: $ occopus-maintain – i INFRA_ID, ahol:
   - -i (infrastructure): a cél infrastruktúra azonosítója

Infrastruktúra törlése

- Az infrastruktúra lebontásához szükségünk lesz az infrastruktúra ID-ra. Az ID-nak a beszerzésére az alábbi módokon van lehetőség:
  - Az infrastruktúra felépítés végénél az Occopus kiírja:

```
** 2021-02-17 17:26:33,127      spark-worker:
** 2021-02-17 17:26:33,128        50c7cfe9-4c3c-4928-81e6-d58323b1e2b2:
** 2021-02-17 17:26:33,128          198.124.39.182
** 2021-02-17 17:26:33,128        98a82e45-6bf2-4cb9-9ead-953be4435bd7:
** 2021-02-17 17:26:33,128          198.124.39.144
** 2021-02-17 17:26:33,129      spark-master:
** 2021-02-17 17:26:33,129        0b8269fe-78ec-47fc-8cdb-7195209e5123:
** 2021-02-17 17:26:33,129          198.124.39.67
c8553539-42c9-40b1-97bc-d53ab8947ca7
```

  - Az Occopus által menedzselt infrastruktúrák lekérése: $ occopus-maintain -l

```
(occopus) ubuntu@occo:~$ occopus-maintain -l
Using default configuration file: '/home/ubuntu/.occopus/occopus_config.yaml'
Using default authentication file: '/home/ubuntu/.occopus/auth_data.yaml'
** 2021-02-19 07:45:09,861      Starting up; PID = 12555
List of active infrastructure:
c8553539-42c9-40b1-97bc-d53ab8947ca7
```

Infrastruktúra törlése

Az infrastruktúrát az **$ occopus-destroy -i <infraID>** paranccsal törölhetjük ki.

```
(occopus) ubuntu@occo:~$ occopus-destroy -i c8553539-42c9-40b1-97bc-d53ab8947ca7
Using default configuration file: '/home/ubuntu/.occopus/occopus_config.yaml'
Using default authentication file: '/home/ubuntu/.occopus/auth_data.yaml'
** 2021-02-17 19:26:21,112      Starting up; PID = 1787
** 2021-02-17 19:26:21,114      Start dropping infrastructure c8553539-42c9-40b1-97bc-d53ab8947ca7
** 2021-02-17 19:26:21,259      Dropping node 'spark-worker'/'50c7cfe9-4c3c-4928-81e6-d58323b1e2b2'
** 2021-02-17 19:26:22,440      Dropping node 'spark-worker'/'98a82e45-6bf2-4cb9-9ead-953be4435bd7'
** 2021-02-17 19:26:23,309      Dropping node 'spark-master'/'0b8269fe-78ec-47fc-8cdb-7195209e5123'
** 2021-02-17 19:26:24,184      Finished dropping infrastructure c8553539-42c9-40b1-97bc-d53ab8947ca7
```

Spark példakódok

- Pi

```
In [8]: # Set a partition number
        partitions = 10
```

```
In [9]: n = 100000 * partitions
```

```
In [10]: def f(_):
             x = random() * 2 - 1
             y = random() * 2 - 1
             return 1 if x ** 2 + y ** 2 <= 1 else 0
```

```
In [11]: count = spark.sparkContext.parallelize(range(1, n + 1), partitions).map(f).reduce(add)
         print("Pi is roughly %f" % (4.0 * count / n))
```

```
Pi is roughly 3.141772
```

```
Enter the total number of points: 100
The value of pi is:
3.08
```

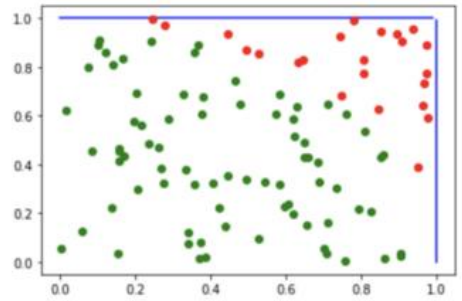

```
Enter the total number of points: 1000
The value of pi is:
3.112
```

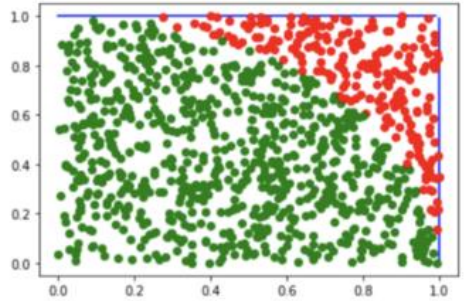

```
Enter the total number of points: 10000
The value of pi is:
3.1212
```

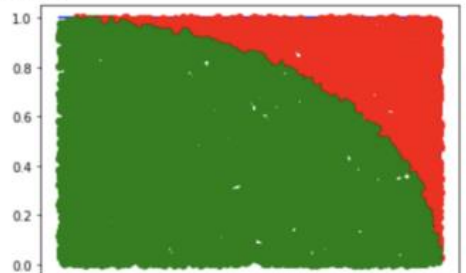

```
Enter the total number of points: 100000
The value of pi is:
3.14264
```

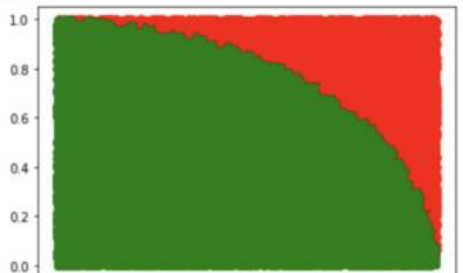

Spark példakódok

- WordCount

```
In [20]: !/home/sparkuser/hadoop/bin/hdfs dfs -put /home/sparkuser/text.txt /
```

```
In [21]: sc = SparkContext(appName="test", master="spark://"+SparkMasterIP+":7077")
         distFile = sc.textFile("hdfs://"+SparkMasterIP+":9000/text.txt")
```

```
In [22]: nonempty_lines = distFile.filter(lambda x: len(x) > 0)
         print('Nonempty lines', nonempty_lines.count())
```

```
Nonempty lines 484
```

```
In [23]: words = nonempty_lines.flatMap(lambda x: x.split(' '))
```

```
In [24]: wordcounts = words.map(lambda x: (x, 1)) \
                           .reduceByKey(lambda x, y: x+y) \
                           .map(lambda x: (x[1], x[0])).sortByKey(False)
         print('Top 100 words:')
         print(wordcounts.take(100))
```

```
Top 100 words:
[(2313, ''), (435, 'the'), (143, 'and'), (115, 'of'), (115, 'to'), (96, 'a'), (90, 'for'), (88, 'is'), (81, 'Spark'), (78,
'..'), (69, '-'), (63, 'you'), (58, 'in'), (56, '#.'), (56, 'can'), (48, 'with'), (48, 'on'), (43, '|'), (40, 'your'), (37, 'b
```

Összefoglalás

- Cél, hogy a magyar kutatók minél gyorsabban kezdhessék el az Big Data és MI-hez kapcsolódó kutató munkát az ELKH Cloud-on
- A különböző működőképes Big Data/MI környezetek létrehozását automatizáltan, az Occopus eszköz segítségével építjük ki
- A kiépítéshez nem szükséges mély informatikai, hálózati, vagy a szoftverek telepítéséhez és konfigurációjához szükséges tudás
- Az eddig összeállított környezetek (Hadoop, Spark, Tensorflow, Rstudio, Slurm, DataAvenue, Horovod, Kafka) referencia architektúra formájában elérhetők és kipróbálhatók az ELKH Cloud-on
- ELKH Cloud technikai support:

  info@science-cloud.hu

Köszönöm a figyelmet!