



# HADOOP KLASZTER FELÉPÍTÉSI ÚTMUTATÓ

MTA Cloud felhasználói számára készült Hadoop  
klaszter felépítési útmutató v1.0

## Tartalom

Áttekintés .....	2
Lépések.....	2
Occopus telepítése .....	2
Letöltés .....	2
1. Erőforrás szekció kitöltése.....	3
2. Tűzfalszabály létrehozása .....	3
3. Hitelesítés .....	3
4. Klaszter méterének beállítása .....	4
6. Felépítés .....	4
7. Felépült infrastruktúra .....	4
8. Klaszter ellenőrzése .....	5
9. MapReduce alkalmazás futtatása .....	5
10. Infrastruktúra törlése: .....	5
Hibák, illetve a projekttel kapcsolatos további igények bejelentése .....	5

## Áttekintés

Ez a bemutató áttekintés ad arról, hogy hogyan lehet létrehozni egy skálázható [Apache Hadoop](#) infrastruktúrát az Occopus eszköz segítségével. Az infrastruktúra egy Hadoop Master és számos Hadoop Slave csomópontból állhat, amelynek száma felfelé vagy lefelé módosítható. A Hadoop Slave csomópontok regisztrálásához [Consul-t használtuk](#).

### Jellemzők:

- kétféle csomópont létrehozása kontextualizáció által
- egészség ellenőrzés használata előre definiált porttal szemben (health check)
- skálázási paraméterek használata a Hadoop Slave csomópontok számának korlátozására
- fürtcsomópontok kezelése Consul segítségével

### Előfeltételek:

- felhő elérése valamilyen Occopus kompatibilis felületen (pl. EC2, Nova, OCCI stb.)
  - Az Occopus eszköz képes az MTA Cloud-on virtuális gépeket indítani, ehhez a nova interfész használatát ajánljuk (ennek címe a felületen megtekinthető: Compute/Access & Security / API Access / Identity )
  - **Fontos: az Occopus eszköz használata jelenleg csak az MTA Cloud SZTAKI ágán működik!**
- a célfelhő tartalmaz egy felhőalapú támogatással rendelkező 14.04 alapú Ubuntu OS képfájlt
  - Ez a képfájl a Compute/Images/Public/Ubuntu 14.04 LTS Cloud image alatt megtalálható
- generált ssh kulcspár (vagy tesztelés céljából egy csatolva van)
  - Új kulcspárt az Compute/Access & Security/Key Pairs/Create Key Pair menüpontra kattintva generálhatunk

Tehát ha Ön tagja egy, az MTA Cloud SZTAKI-ági béli projektnek, akkor lehetősége nyílik az Occopus eszköz telepítése után Hadoop infrastruktúra létrehozására.

## Lépések

### Occopus telepítése

Az automatikusan felépülő Apache Hadoop architektúra kiépítése az Occopus eszköz segítségével fog megvalósulni, ezért elsőként telepítenünk kell az Occopus eszközt. Az Occopus orkesztrációs eszközt csupán egyetlen parancs segítségével is telepíteni tudja. A telepítéshez szükséges lépésekről, illetve az Occopus-ról bővebben [az alábbi linken tájékozódhat](#). Javasoljuk, hogy indítson el egy Ubuntu alapú virtuális gépet az MTA Cloud-ban, majd oda telepítse az Occopus eszközt.

### Letöltés

Az Occopus leírók alapján működik. Ezen leírók alapján fogja az Occopus felépíteni a cél felhőben az infrastruktúrát. A Hadoop klaszter telepítéséhez szükséges leírókat elkészítettük a felhasználók számára. Ezeket az alábbi linkről lehet letölteni: [tutorial.examples.hadoop-cluster](#). Az Occopus-t futtató virtuális gépre telepítsük a leírókat.

**Megjegyzés:** Ebben bemutatóban nova felhő erőforrásokat használunk (az alap bemutató részben található nova oktatóanyagok alapján). Ugyanakkor nyugodtan használhat bármilyen Occopus – kompatibilis felhő erőforrást a csomópontok számára, de javasoljuk, hogy az összes csomópontot azonos felhőben építse fel.

## 1. Erőforrás szekció kitöltése

Nyissa meg a nodes/node\_definitions.yaml fájlt és szerkessze a csomópontok „node\_def:” címkével ellátott erőforrás szekcióját:

- Válasszon ki egy [Occopus kompatibilis erőforrás plugin-t](#)
  - Ez az MTA Cloud esetében a bemutatóban szereplő erőforrás plugin-nal azonos, nova erőforrás lesz
- Meghatározhatja [a plugin attribútumainak megfelelő listát](#)
- Követheti a bővítmény [attribútumainak értékeinek összegyűjtésére vonatkozó segítségét](#)
- A plugin-hez tartozó erőforrás sablonokhoz találhat [erőforrás plugin bemutatókat is](#)

Fontos, hogy indítás előtt a node definíciós fájlt személyre kell szabnia a felhasználónak. Ebben a fájlban megadjuk azokat az erőforrás azonosítókat, amelyeket használni fogunk, pld.: projekt ID, virtuális gép mérete stb. Ezeket az azonosítókat nem tudjuk megadni a felhasználó helyett, azonban azokat az MTA Cloud felületéről könnyedén össze lehet szedni. Ehhez részletes segítség [ezen linken](#), vagy az [alábbi dokumentációban](#) található. A példában található letölthető csomag a Nova plugin erőforrás sablont tartalmazza (ezt használjuk az MTA Cloud használatához is).

**Fontos:** Ne módosítsa a kontextualizáció és a health\_check szekció attribútumait!

**Fontos:** Ne adjon „server\_name” attribútumot a Hadoop Slave csomópontnak, így az Occopus eszköz képes lesz automatikusan elnevezni őket, így biztosítva azt, hogy a csomópont nevek egyediek legyenek.

## 2. Tűzfalszabály létrehozása

Az infrastruktúra komponensei egymáshoz kapcsolódnak, ezért több port tartományt is ki kell nyitni a virtuális gépek számára. Jelentkezzünk be az [MTA Cloud OpenStack felületére](#). A „Compute/Access&Security” menüpont alatt létrehozhatunk új tűzfalszabályt a „Create Security Group” gombra kattintva. Létrehozás után szerkeszteni tudjuk a tűzfalszabályt a „Manage Rules/Add Rule” gombra kattintva. Az alábbi portokat adjuk hozzá a tűzfalszabályhoz:

- TCP 22
- TCP 8025
- TCP 8042
- TCP 8088
- TCP 8300–8600
- TCP 9000
- TCP 50000–51000

## 3. Hitelesítés

Az Occopus számára szükség van az MTA Cloudban használt felhasználónév/jelszó párosra, hogy az hitelesíteni tudja magát és képes legyen virtuális gépeket/infrastruktúrákat létrehozni egy adott projekt alatt. Kérjük, ellenőrizze, hogy az Occopus telepítése során helyesen adta-e meg a hitelesítési adatait! Az autentikációs adatok megadásához [az alábbi linken](#) talál segítséget.

## 4. Klaszter méterének beállítása

Ha szükséges, frissítse a Hadoop Slave csomópontok számát. Ehhez szerkessze az infra-occpus-hadoop.yaml fájlt és módosítsa a „min” és „max” paramétereiket 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.

Az infrastruktúra leíróban (infra-hadoop-cluster.yaml) személyre szabhatjuk, hogy mennyi worker node induljunk el minimálisan és maximálisan a klaszterben.

```
- &S
  name: hadoop-slave
  type: hadoop_slave_node
  scaling:
    min: 2
    max: 10
```

**Fontos:** Ne feledje, hogy az Occopusnak legalább egy csomópontot el kell indítania minden egyes csomóponttípusból, hogy az infrastruktúra megfelelően működjön, valamint a skálázás csak a Hadoop Slave csomópontokra alkalmazható ebben a példában!

## 5. Importálás

Importáljuk a személyre szabott leírókat az Occopus adatbázisába:

```
occpus-import nodes/node_definitions.yaml
```

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:

```
source occpus/bin/activate
```

**Megjegyzés:** A nodes mappában található cloud init fájlok szerkesztésével a haladó felhasználók személyre szabhatják a Hadoop konfigurációs fájljait (cloud\_init\_hadoop\_master.yaml, cloud\_init\_hadoop\_slave.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 (pld.: kontextualizációs) fájl megváltozik!

## 6. Felépítés

Az alábbi parancs segítségével megkezdhetjük a Hadoop klaszter felépítését:

```
occpus-build infra-hadoop-cluster.yaml
```

## 7. Felépült infrastruktúra

Sikeres lefutás után a virtuális gépek IP címei, node ID -jai, valamint az infrastruktúra azonosítója megjelenik a log üzenetek alján, listába szedve. Az infrastruktúra azonosító elmenthető, vagy lekérdezhető az **occpus-maintain** parancs segítségével:

```
List of nodes/ip addresses:
hadoop-master:
  192.168.xxx.xxx (3116eaf5-89e7-405f-ab94-9550ba1d0a7c)
```

```
hadoop-slave:
  192.168.xxx.xxx (23f13bd1-25e7-30a1-c1b4-39c3da15a456)
  192.168.xxx.xxx (7b387348-b3a3-5556-83c3-26c43d498f39)

14032858-d628-40a2-b611-71381bd463fa
```

## 8. Klaszter ellenőrzése

Ellenőrizheti a Hadoop klaszter helyes működését, statisztikáit az alábbi weblapokon:

```
Health of nodes: "http://<HadoopMasterIP>:50070"
Job statistics: "http://<HadoopMasterIP>:8088"
```

## 9. MapReduce alkalmazás futtatása

MapReduce alkalmazás futtatásához másolja az input és a végrehajtható fájlokat a Hadoop Master csomópontra és végezze el [az itt leírt lépéseket](#). A Hadoop Master csomópontba történő bejelentkezéshez használja a bemutatócsomaghoz mellékelte privát kulcsot:

```
ssh -i builtin_hadoop_private_key hduser@[HadoopMaster ip]
```

## 10. Infrastruktúra törlése:

Végül, lebonthatja az infrastruktúrát az occopus-build által visszaadott infrastruktúraazonosító használatával:

```
occopus-destroy -i 14032858-d628-40a2-b611-71381bd463fa
```

## Hibák, illetve a projekttel kapcsolatos további igények bejelentése

Az MTA Cloud szolgáltatással kapcsolatos kommunikáció és támogatás e-mail formájában történik. A közös e-mail cím: [info@cloud.mta.hu](mailto:info@cloud.mta.hu). Az erre az e-mail címre bejelentett hibákból, igényekből egy bejelentési űrlap generálódik, melyet az MTA Cloud csapat kijelölt tagja kezel.