



Dr. Hegedűs Péter, Dr. Ferenc Rudolf

Nagyméretű adatbázisok

Jelen tananyag a Szegedi Tudományegyetemen
készült az Európai Unió támogatásával.

Projekt azonosító: EFOP-3.4.3-16-2016-00014

Apache Flume

Összefoglalás

Az olvasó ebből a kombinált videó és olvasóleckéből gyakorlati tudást szerezhet az Apache Flume rendszer felépítéséről, valamint alapvető felhasználásának módjáról. Áttekintjük az eszköz architektúráis felépítését, valamint az alapvetően támogatott komponenseit. Több konkrét példa konfiguráció segítségével bemutatjuk, hogyan használható a Flume különböző adat forrásokkal (hálózat, könyvtár) és adatnyelőkkel (konzol, HDFS).

A lecke fejezetei:

- 1. fejezet: **Az Apache Flume eszköz felépítésének áttekintése, alapvető adatforrások és nyelők típusai (olvasó)**
- 2. fejezet: **Az Apache Flume eszköz telepítése, futtatása és Hello World példa beüzemelése (olvasó)**
- 3. fejezet: **Komplexebb Apache Flume konfiguráció, HDFS sink bemutatása (videó)**

Téma típusa: **gyakorlati**


Olvasási idő: **35 perc**

1. fejezet

Az Apache Flume eszköz

Az Apache Flume egy elosztott, megbízható és nagy rendelkezésre állású szolgáltatás nagy mennyiségű napló adat gyűjtéséhez, egyesítéséhez és mozgatásához. Az architektúrája egyszerű és rugalmas, amely adatok folyamatos átvitelére (stream) lett tervezve (lásd lenti ábra). A Flume robusztus, hibátűrő és megbízható számos beépített mechanizmus által. Egyszerű és könnyen bővíthető adatmodellt alkalmaz.

A Flume segítségével adat forrásokat (source) és adatnyelőket (sink) definiálhatunk, az adat forrásokból stream szerűen érkeznek az események, amelyeket egy csatorna az adatnyelőhöz vezet, ami eltárolja azt. A Flume számos adatforrást [1] és adatnyelőt támogat [2], ami persze bővíthető is. Számunkra a legérdekesebb a HDFS adatnyelő, amely tetszőleges stream forrás adatait valós időben tárolni tudja HDFS-re (lásd ábra). A Flume agent működéséről és a konfigurációjának módjáról a következő fejezetek tartalmaz további hasznos információt.




Flume alapvető működése


A Flume adatfolyam alapvető eleme az esemény (event), amely nem más, mint egy hasznos adatot tartalmazó bájtsorozat opcionális string attribútumokkal. A Flume ügynök (agent) egy JVM folyamat, amely futtatja a Flume komponenseket, amelyek segítségével a külső forrásból érkező események eljutnak a következő adat nyelőig (egy ugrás, vagy hop).

A Flume adat forrás elkapja és továbbítja azokat az eseményeket, amelyek valamilyen külső forrásból érkeznek hozzá, pl. egy web szervertől. A külső forrás olyan formátumban küldi az eseményeket a Flume adat forráshoz, amit az felismer. Azaz több speciális, előre implementált adat forrás típus és adatnyelő létezik, például egy Apache Avro [3] source az Apache Avro rendszer kliense által küldött, vagy másik vezeték Avro target-jéből származó eseményeket tudja kezelni. Amint egy Flume source fogad egy eseményt, azt azonnal egy vagy több csatornán (channel) továbbítja. A csatorna egy passzív tároló, amely addig tárolja az eseményeket, amíg azt egy Flume sink fel nem dolgozza. A fájl csatorna egy példa a csatornára, ami egy lokális fájlban tárolja az eseményeket. A sink eltávolítja az eseményt a csatornából és egy külső tárolóba helyezi, mint például a HDFS (a Flume HDFS sink segítségével), vagy továbbítja egy másik Flume source felé a következő Flume agent (következő ugrás, next hop) számára az folyamban. Egy ügynökön belül a forrás és nyelő aszinkron módon működnek, ahol a csatorna biztosítja az események pufferelesét. A Flume tetszőleges ugrás számú komplex adatfolyamok definiálását is lehetővé teszi. További technikai részletekért tekintsük át a hivatalos dokumentációt [4].

A Flume által támogatott főbb adat források és nyelők típusai az alábbi két ábrán láthatók. Természetesen lehetőség van teljesen egyedi, saját forrás és nyelő implementálására is a megfelelő interfészek megvalósítása által.



<https://d2h0cx97tjks2p.cloudfront.net/blogs/wp-content/uploads/sites/2/2018/02/types-of-flume-sources.jpg>



<https://d2h0cx97tjks2p.cloudfront.net/blogs/wp-content/uploads/sites/2/2018/02/types-of-flume-sinks.jpg>

2. fejezet

Apache Flume Hello World példa

Lássuk hogyan működik gyakorlatban az Apache Flume. Mielőtt telepítenénk a Flume ügynököt és létrehoznánk a megfelelő konfigurációt, indítsuk el a Docker alapú Hadoop klasztert, amit a `3g_BigData-hadoop-SPOC` olvasólecke 1. fejezetében ismertettünk. Ezután lépünk be a `namenode` container-re egy `bash`-t futtatva:

```
$ docker exec -it namenode bash
```

Erre a csomópontra fogjuk telepíteni az Apache Flume ügynököt kényelmi okok miatt (a HDFS fájlrendszert `localhost`-on keresztül elérjük), de más, tetszőleges hálózaton belüli gépre is telepíthető lenne. A telepítés menete:

1. Töltsük le az Apache Flume-ot a következő URL-ről: <http://xenia.sote.hu/ftp/mirrors/www.apache.org/flume/1.9.0/apache-flume-1.9.0-bin.tar.gz>

```
root@b055549cdaca:/# curl
http://xenia.sote.hu/ftp/mirrors/www.apache.org/flume/1.9.0/apache-flume-1.9.0-
bin.tar.gz -o apache-flume-1.9.0-bin.tar.gz
```

2. Csomagoljuk ki a letöltött Flume disztribúciót

```
root@b055549cdaca:/# tar xzf apache-flume-1.9.0-bin.tar.gz
```

3. Állítsuk be a `FLUME_HOME` környezeti változót

```
root@b055549cdaca:/# export FLUME_HOME=/apache-flume-1.9.0-bin
```

4. Teszteljük, hogy a Flume agent megfelelően működik a következő parancs segítségével

```
root@b055549cdaca:/# $FLUME_HOME/bin/flume-ng version
```

Amennyiben látjuk a képernyőre kiírva, hogy `Flume 1.9.0`, a telepítés sikeres (a folyamatot az alábbi ábra mutatja).

```
root@b055549cdaca:/# curl http://xenia.sote.hu/ftp/mirrors/www.apache.org/flume/1.9.0/apache-flume-1.9.0-bin.tar.gz -o apache-flume-1.9.0-bin.tar.gz
% Total % Received % Xferd Average Speed Time Time Time Current
Dload Upload Total Spent Left Speed
100 64.7M 100 64.7M 0 0 31.4M 0 0:00:02 0:00:02 --:--:-- 31.5M
root@b055549cdaca:/# ls
KEYS bin dev etc hadoop-data lib media opt root run.sh srv tmp var
apache-flume-1.9.0-bin.tar.gz boot entrypoint.sh hadoop home lib64 mnt proc run sbin sys usr
root@b055549cdaca:/# tar xzf apache-flume-1.9.0-bin.tar.gz
root@b055549cdaca:/# ls apache-flume-1.9.0-bin
CHANGELOG DEVNOTES LICENSE NOTICE README.md RELEASE-NOTES bin conf doap_Flume.rdf docs lib tools
root@b055549cdaca:/# export FLUME_HOME=/apache-flume-1.9.0-bin
root@b055549cdaca:/# flume-ng version
bash: flume-ng: command not found
root@b055549cdaca:/# $FLUME_HOME/bin/flume-ng version
/opt/hadoop-3.2.1/libexec/hadoop-functions.sh: line 2401: HADOOP_ORG.APACHE.FLUME.TOOLS.GETJAVAPROPERTY_USER: bad substitution
/opt/hadoop-3.2.1/libexec/hadoop-functions.sh: line 2366: HADOOP_ORG.APACHE.FLUME.TOOLS.GETJAVAPROPERTY_USER: bad substitution
/opt/hadoop-3.2.1/libexec/hadoop-functions.sh: line 2461: HADOOP_ORG.APACHE.FLUME.TOOLS.GETJAVAPROPERTY_OPTS: bad substitution
Flume 1.9.0
Source code repository: https://git-wip-us.apache.org/repos/asf/flume.git
Revision: d4fcab4f501d41597bc616921329a4339f73585e
Compiled by fszabo on Mon Dec 17 20:45:25 CET 2018
From source with checksum 35db629a3bda49d23e9b3690c80737f9
root@b055549cdaca:/#
```

Sikeres telepítés után hozzuk létre az első Flume adat folyamunkat. Ehhez egy egyszerű ügynököt konfigurálunk be, amelyik a hálózat egy bizonyos portján figyeli az adatokat (netcat source), és minden ott beérkező üzenetet (event) a képernyőre ír ki egy konzol logger segítségével (logger sink). Az átviteli csatorna memóriában tárolja az eseményeket. Az `example.conf` tartalma legyen a következő (saját gépen tetszőleges szövegszerkesztővel készítsük el, majd másoljuk át a docker container-be).

```
# example.conf: A single-node Flume configuration
```

```
# Name the components on this agent
```

```
a1.sources = r1
```

```
a1.sinks = k1
```

```
a1.channels = c1
```

```
# Describe/configure the source
```

```
a1.sources.r1.type = netcat
```

```
a1.sources.r1.bind = localhost
```

```
a1.sources.r1.port = 44444
```

```
# Describe the sink
```

```
a1.sinks.k1.type = logger
```

```
# Use a channel which buffers events in memory
```

```
a1.channels.c1.type = memory
```

```
a1.channels.c1.capacity = 1000
```

```
a1.channels.c1.transactionCapacity = 100
```

```
# Bind the source and sink to the channel
```

```
a1.sources.r1.channels = c1
```

```
a1.sinks.k1.channel = c1
```

Miután elkészítettük a specifikációnak megfelelő Flume adatfolyam leíró, másoljuk át a fájlt a `namenode` docker container-be a megfelelő Flume konfigurációs könyvtárba:

```
$ docker cp example.conf namenode:/apache-flume-1.9.0-bin/conf/example.conf
```

Ezután készen állunk arra, hogy elindítsuk az ügynök szolgáltatást (Flume agent service) a következő utasítással:


```
root@b055549cdaca:/apache-flume-1.9.0-bin# bin/flume-ng agent --conf conf --
conf-file conf/example.conf --name a1 -Dflume.root.logger=INFO,console
```

A paraméterekkel megadjuk az agent nevét és a konfiguráció helyét, valamint mivel nincs log4j konfigurációnk, egy JVM paraméterrel beállítjuk, hogy konzolra történjen a log üzenetek kiírása (azaz az eventek kiírása). Az agent az elindulás után a `namnode` 44444-es portján figyel, és minden odaérkező üzenetet (event) elkap, majd a csatornán keresztül a sink felé továbbít, ami log üzenetben kiírja a kapott event-et. Tesztelés gyanánt nyissunk egy újabb terminál ablakot, és kapcsolódjunk a `namenode` container-hez a fenti módon, majd küldjünk egy `Hello world!` üzenetet a `localhost:44444`-es címre `netcat` program segítségével:

```
$ docker exec -it namenode bash
root@b055549cdaca:/# netcat localhost 44444
Hello world!
OK
```

Ennek hatására az ügynököt futtató terminálban azt kell látnunk, hogy a konzolra log üzenetben kiíródott a `Hello world!` üzenet!

```
2020-08-16 16:06:12,261 (conf-file-poller-0) [INFO - org.apache.flume.conf.FlumeConfiguration$AgentConfiguration.addComponentConfig(FlumeConfiguration.java:1203)] Processing:k1
2020-08-16 16:06:12,261 (conf-file-poller-0) [INFO - org.apache.flume.conf.FlumeConfiguration$AgentConfiguration.addComponentConfig(FlumeConfiguration.java:1203)] Processing:r1
2020-08-16 16:06:12,261 (conf-file-poller-0) [INFO - org.apache.flume.conf.FlumeConfiguration$AgentConfiguration.addComponentConfig(FlumeConfiguration.java:1203)] Processing:k1
2020-08-16 16:06:12,262 (conf-file-poller-0) [WARN - org.apache.flume.conf.FlumeConfiguration$AgentConfiguration.validateConfigFilterSet(FlumeConfiguration.java:623)] Agent configuration for 'a1' has no configfilters.
2020-08-16 16:06:12,279 (conf-file-poller-0) [INFO - org.apache.flume.conf.FlumeConfiguration.validateConfiguration(FlumeConfiguration.java:163)] Post-validation flume configuration contains configuration for agents: [a1]
2020-08-16 16:06:12,280 (conf-file-poller-0) [INFO - org.apache.flume.node.AbstractConfigurationProvider.loadChannels(AbstractConfigurationProvider.java:151)] Creating channels
2020-08-16 16:06:12,285 (conf-file-poller-0) [INFO - org.apache.flume.channel.DefaultChannelFactory.create(DefaultChannelFactory.java:42)] Creating instance of channel c1 type memory
2020-08-16 16:06:12,290 (conf-file-poller-0) [INFO - org.apache.flume.node.AbstractConfigurationProvider.loadChannels(AbstractConfigurationProvider.java:205)] Created channel c1
2020-08-16 16:06:12,291 (conf-file-poller-0) [INFO - org.apache.flume.source.DefaultSourceFactory.create(DefaultSourceFactory.java:41)] Creating instance of source r1, type netcat
2020-08-16 16:06:12,296 (conf-file-poller-0) [INFO - org.apache.flume.sink.DefaultSinkFactory.create(DefaultSinkFactory.java:42)] Creating instance of sink: k1, type: logger
2020-08-16 16:06:12,298 (conf-file-poller-0) [INFO - org.apache.flume.node.AbstractConfigurationProvider.getConfiguration(AbstractConfigurationProvider.java:120)] Channel c1 connected to [r1, k1]
2020-08-16 16:06:12,303 (conf-file-poller-0) [INFO - org.apache.flume.node.Application.startAllComponents(Application.java:162)] Starting new configuration:{sourceRunners:{r1=EventDrivenSourceRunner: { source:org.apache.flume.source.NetcatSource(name:r1,state:IDLE) }} sinkRunners:{k1=SinkRunner: { policy:org.apache.flume.sink.DefaultSinkProcessor@331d3c25 counterGroup:{ name:null counters:{} }} } channels:{c1=org.apache.flume.channel.MemoryChannel(name: c1)} }
2020-08-16 16:06:12,306 (conf-file-poller-0) [INFO - org.apache.flume.node.Application.startAllComponents(Application.java:169)] Starting channel c1
2020-08-16 16:06:12,349 (lifecycleSupervisor-1-0) [INFO - org.apache.flume.instrumentation.MonitoredCounterGroup.register(MonitoredCounterGroup.java:119)] Monitored counter group for type: CHANNEL, name: c1: Successfully registered new MBean.
2020-08-16 16:06:12,349 (lifecycleSupervisor-1-0) [INFO - org.apache.flume.instrumentation.MonitoredCounterGroup.start(MonitoredCounterGroup.java:95)] Component type: CHANNEL, name: c1 started
2020-08-16 16:06:12,350 (conf-file-poller-0) [INFO - org.apache.flume.node.Application.startAllComponents(Application.java:196)] Starting Sink k1
2020-08-16 16:06:12,350 (conf-file-poller-0) [INFO - org.apache.flume.node.Application.startAllComponents(Application.java:207)] Starting Source r1
2020-08-16 16:06:12,352 (lifecycleSupervisor-1-2) [INFO - org.apache.flume.source.NetcatSource.start(NetcatSource.java:155)] Source starting
2020-08-16 16:06:12,362 (lifecycleSupervisor-1-2) [INFO - org.apache.flume.source.NetcatSource.start(NetcatSource.java:166)] Created serverSocket:sun.nio.ch.ServerSocketChannelImpl[/127.0.0.1:44444]
2020-08-16 16:10:58,372 (SinkRunner-PollingSinkProcessor) [INFO - org.apache.flume.sink.LoggerSink.process(LoggerSink.java:95)] Event: { headers :{} body: 48 65 6C 6F 20 57 6F 72 6C 64 21 Hello World! }
```

3. fejezet

Adat stream mentése HDFS-re

Ebben a fejezetben a HDFS sink-re koncentrálunk. Az alábbi videó lecke bemutatja, hogyan kell módosítani a 2. fejezetben összeállított Flume konfigurációt ahhoz, hogy a forráson érkező eseményeket ne egyszerűen kiírassuk logger-rel, hanem egyenesen HDFS-re tároljuk. A videóban használt konfigurációs állomány (`example-hdfs.conf`) az alábbi:

```
# example-hdfs.conf: A single-node Flume configuration

# Name the components on this agent
a1.sources = r1
a1.sinks = k1
a1.channels = c1

# Describe/configure the source
a1.sources.r1.type = netcat
a1.sources.r1.bind = localhost
```

```
a1.sources.r1.port = 44444

# Describe the sink HDFS
a1.sinks.k1.type = hdfs
a1.sinks.k1.hdfs.path = hdfs://localhost:9000/flume/testdata
a1.sinks.k1.hdfs.rollInterval = 0
a1.sinks.k1.hdfs.fileType = DataStream

# Use a channel which buffers events in memory
a1.channels.c1.type = memory
a1.channels.c1.capacity = 1000
a1.channels.c1.transactionCapacity = 100

# Bind the source and sink to the channel
a1.sources.r1.channels = c1
a1.sinks.k1.channel = c1
```



video/4g_BigData-hdfs-sqoop-flume-SPOC/flume-hdfs.mp4

✓ További feladatok

1. Készítsünk egy olyan Flume konfigurációt, ahol az adatok forrása egy könyvtár (`spool dir`), ahonnan a fájlokat a Flume folyam HDFS-re tárolja! ★
2. Módosítsuk úgy a fenti konfigurációt, hogy az adatok a syslog-ból érkezzenek! ★
3. Készítsünk egy összetett Flume folyamatot, ami két ügynököt kapcsol össze: **A1:** `syslog -> http`, **A2:** `http -> hdfs`! ★ ★ ★

Referenciák

- [1] <https://data-flair.training/blogs/flume-source/>
- [2] <https://data-flair.training/blogs/flume-sink/>
- [3] <https://avro.apache.org/>
- [4] <https://flume.apache.org/releases/content/1.9.0/FlumeUserGuide.html#the-plugins-d-director-y>