

---

# 大数据技术之标题

## 一、Flume 简介

- 1) Flume 提供一个分布式的，可靠的，对大数据量的日志进行高效收集、聚集、移动的服务，Flume 只能在 Unix 环境下运行。
- 2) Flume 基于流式架构，容错性强，也很灵活简单。
- 3) Flume、Kafka 用来实时进行数据收集，Spark、Storm 用来实时处理数据，impala 用来实时查询。

## 二、Flume 角色

### 2.1、Source

用于采集数据，Source 是产生数据流的地方，同时 Source 会将产生的数据流传输到 Channel，这个有点类似于 Java IO 部分的 Channel。

### 2.2、Channel

用于桥接 Sources 和 Sinks，类似于一个队列。

### 2.3、Sink

从 Channel 收集数据，将数据写到目标源（可以是下一个 Source，也可以是 HDFS 或者 HBase）。

### 2.4、Event

传输单元，Flume 数据传输的基本单元，以事件的形式将数据从源头送至目的地。

## 三、Flume 传输过程

source 监控某个文件或数据流，数据源产生新的数据，拿到该数据后，将数据封装在一个 Event 中，并 put 到 channel 后 commit 提交，channel 队列先进先出，sink 去 channel 队列中拉取数据，然后写入到 hdfs 或者 HBase 中。

---

## 四、Flume 部署及使用

### 4.1、文件配置

**flume-env.sh** 涉及修改项：

```
JAVA_HOME=/home/admin/modules/jdk1.8.0_121
```

### 4.2、案例

#### 4.2.1、案例一

目标：Flume 监控一端 Console，另一端 Console 发送消息，使被监控端实时显示。

分步实现：

##### 1) 创建 Flume Agent 配置文件 **flume-telnet.conf**

```
# 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
```

## 2) 安装 telnet 工具

```
$ sudo rpm -ivh telnet-server-0.17-59.el7.x86_64.rpm
```

```
$ sudo rpm -ivh telnet-0.17-59.el7.x86_64.rpm
```

## 3) 判断 44444 端口是否被占用

```
$ netstat -an | grep 44444
```

## 4) 先开启 flume 先听端口

```
$ bin/flume-ng agent --conf conf/ --name a1 --conf-file conf/flume-telnet.conf
```

```
-Dflume.root.logger==INFO,console
```

## 5) 使用 telnet 工具向本机的 44444 端口发送内容

```
$ telnet localhost 44444
```

## 4.2.2 案例二

目标：实时监控 hive 日志，并上传到 HDFS 中

分步实现：

### 1) 拷贝 Hadoop 相关 jar 到 Flume 的 lib 目录下(要学会根据自己的目录和版本查找 jar 包)

```
$ cp share/hadoop/common/lib/hadoop-auth-2.5.0-cdh5.3.6.jar ./lib/
```

```
$ cp share/hadoop/common/lib/commons-configuration-1.6.jar ./lib/
```

```
$ cp share/hadoop/mapreduce1/lib/hadoop-hdfs-2.5.0-cdh5.3.6.jar ./lib/
```

```
$ cp share/hadoop/common/hadoop-common-2.5.0-cdh5.3.6.jar ./lib/
```

```
$ cp ./share/hadoop/hdfs/lib/htrace-core-3.1.0-incubating.jar ./lib/
```

```
$ cp ./share/hadoop/hdfs/lib/commons-io-2.4.jar ./lib/
```

尖叫提示：标红的 jar 为 1.99 版本 flume 必须引用的 jar

### 2) 创建 flume-hdfs.conf 文件

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

---

```
a2.sources = r2

a2.sinks = k2

a2.channels = c2

# Describe/configure the source

a2.sources.r2.type = exec

a2.sources.r2.command = tail -F

/home/admin/modules/apache-flume-1.7.0-bin/my_custom_logs.txt

a2.sources.r2.shell = /bin/bash -c

# Describe the sink

a2.sinks.k2.type = hdfs

a2.sinks.k2.hdfs.path = hdfs://linux01:8020/flume/%Y%m%d/%H

#上传文件的前缀

a2.sinks.k2.hdfs.filePrefix = logs-

#是否按照时间滚动文件夹

a2.sinks.k2.hdfs.round = true

#多少时间单位创建一个新的文件夹

a2.sinks.k2.hdfs.roundValue = 1

#重新定义时间单位

a2.sinks.k2.hdfs.roundUnit = hour

#是否使用本地时间戳

a2.sinks.k2.hdfs.useLocalTimeStamp = true

#积攒多少个 Event 才 flush 到 HDFS 一次

a2.sinks.k2.hdfs.batchSize = 1000

#设置文件类型，可支持压缩

a2.sinks.k2.hdfs.fileType = DataStream

#多久生成一个新的文件
```

```
a2.sinks.k2.hdfs.rollInterval = 600

#设置每个文件的滚动大小

a2.sinks.k2.hdfs.rollSize = 134217700

#文件的滚动与 Event 数量无关

a2.sinks.k2.hdfs.rollCount = 0

#最小冗余数

a2.sinks.k2.hdfs.minBlockReplicas = 1

# Use a channel which buffers events in memory

a2.channels.c2.type = memory

a2.channels.c2.capacity = 1000

a2.channels.c2.transactionCapacity = 100

# Bind the source and sink to the channel

a2.sources.r2.channels = c2

a2.sinks.k2.channel = c2
```

### 3) 执行监控配置

```
$ bin/flume-ng agent --conf conf/ --name a2 --conf-file conf/flume-hdfs.conf
```

## 4.2.3 案例三

目标：使用 flume 监听整个目录的文件

分步实现：

1) 创建配置文件 flume-dir.conf

```
a3.sources = r3

a3.sinks = k3

a3.channels = c3

# Describe/configure the source
```

---

```
a3.sources.r3.type = spooldir

a3.sources.r3.spoolDir = /home/admin/modules/apache-flume-1.7.0-bin/upload

a3.sources.r3.fileHeader = true

#忽略所有以 .tmp 结尾的文件，不上传
a3.sources.r3.ignorePattern = ([^ ]*\tmp)

# Describe the sink

a3.sinks.k3.type = hdfs

a3.sinks.k3.hdfs.path = hdfs://linux01:8020/flume/upload/%Y%m%d/%H

#上传文件的前缀
a3.sinks.k3.hdfs.filePrefix = upload-

#是否按照时间滚动文件夹
a3.sinks.k3.hdfs.round = true

#多少时间单位创建一个新的文件夹
a3.sinks.k3.hdfs.roundValue = 1

#重新定义时间单位
a3.sinks.k3.hdfs.roundUnit = hour

#是否使用本地时间戳
a3.sinks.k3.hdfs.useLocalTimeStamp = true

#积攒多少个 Event 才 flush 到 HDFS 一次
a3.sinks.k3.hdfs.batchSize = 1000

#设置文件类型，可支持压缩
a3.sinks.k3.hdfs.fileType = DataStream

#多久生成一个新的文件
a3.sinks.k3.hdfs.rollInterval = 600

#设置每个文件的滚动大小
a3.sinks.k3.hdfs.rollSize = 134217700

#文件的滚动与 Event 数量无关
```

---

```
a3.sinks.k3.hdfs.rollCount = 0

#最小冗余数

a3.sinks.k3.hdfs.minBlockReplicas = 1

# Use a channel which buffers events in memory

a3.channels.c3.type = memory

a3.channels.c3.capacity = 1000

a3.channels.c3.transactionCapacity = 100

# Bind the source and sink to the channel

a3.sources.r3.channels = c3

a3.sinks.k3.channel = c3
```

## 2) 执行测试

```
$ bin/flume-ng agent --conf conf/ --name a3 --conf-file conf/flume-dir.conf &
```

尖叫提示：

在使用 Spooling Directory Source 时

- 1) 不要在监控目录中创建并持续修改文件
- 2) 上传完成的文件会以 .COMPLETED 结尾
- 3) 被监控文件夹每 600 毫秒扫描一次文件变动

## 4.2.4 案例四（待完善）

目标：使用 Java API 实现 Flume 开发