

# Flume и Morphlines

## трансформация потоков данных без строчки кода

**epam**  
Low Level Programming Department  
Denis Pynkin

23 августа 2014 г.

## 1 Apache Flume

## 2 Cloudera Morphlines

## 3 Синтетический пример использования


# Apache Flume



## Flume

Это распределенная система для эффективного сбора, агрегирования и перемещения больших потоков данных из множества разных источников в централизованное хранилище данных.

# Apache Flume





## Достоинства Flume

- масштабируемость
- селективная и динамическая маршрутизация событий
- низкие задержки
- высокая пропускная способность
- декларативное описание

# Конкуренты?




VS




# Модель данных

## Flume Event

Определен, как элемент потока данных, состоящий из собственно данных и набора строковых атрибутов.




# Flume: Source




- AVRO
- Thrift
- JMS
- Exec
- NetCat
- Twitter
- Syslog
- HTTP
- **Custom**

# Flume: Channel




- Memory
- JDBS
- File
- Custom

# Flume: Sink




- AVRO
- Thrift
- Logger  
(stdout)
- File
- HDFS
- Null
- Solr
- Elastic Search
- **Custom**

# Flume: модификаторы




- Source Interceptor
- Channel Selector
- Sink Processor

## Flume: топологии: fan-in



## Flume: топологии: multiplexing/fan-out



1 Apache Flume


2 Cloudera Morphlines

3 Синтетический пример использования

# Morphlines

Morphlines – это pipe

Pipe – это Morphlines



## Morphlines

Конфигурационный файл, описывающий pipeline последовательных преобразований в парадигме ETL.

# Модель данных

## Концепция


Данные поступают в виде бесконечного (или хотя бы достаточно большого) потока записей

## Record

Набор именованных полей, причем каждое поле может содержать от одного и более значений.

В качестве значения для поля можно использовать любой объект Java.


# Morphlines



## Morphlines – это фреймворк

Основная цель создания Morphlines – быстрая разработка приложений для обработки потоков данных в Hadoop с последующей записью результатов в Apache Solr, HBase, HDFS и прочие системы.

# Morphlines




## Интеграция с Flume

- Source interceptor
- Solr Sink

## Интеграция

- любое Java приложение

# Morphlines: пример интеграции



# Описание преобразований

## Конфигурационный файл

Последовательный список команд для преобразования данных, описанный в формате HOCON (Human Optimized Config Object Notation).

Возможность бранчевания с помощью команд pipe, if и tryRules.

# Конфигурационный файл

```
morphlines: [ {  
    id: vsftpFileLog  
    importCommands: [ "org.kitesdk.**" ]  
  
    commands: [  
        { readLine { charset : UTF-8 } }  
  
        { addLocalHost {  
            field : server  
            useIP : false  
        } }  
  
        { generateUUID { field : id} }  
    ] } ]
```

- 1 Apache Flume
- 2 Cloudera Morphlines
- 3 Синтетический пример использования

## Т3


Разработать систему, собирающую статистику скачивания файлов со множества ftp-серверов и сохраняющую ее в файл в формате JSON, с указанием:

- ① времени скачивания (в unix-time);
- ② имени файла;
- ③ размера файла;
- ④ ip-адреса клиента;
- ⑤ имени сервера с которого скачали этот файл.


Формат строки в логе:

```
Tue Jul 22 19:15:23 2014 [pid 9388] [vsftpd] OK DOWNLOAD:  
Client "10.6.136.54",  
"/video/HighLoad master-class/out-1406031869.mkv",  
189505527 bytes, 3909.30Kbyte/sec
```


# Архитектура



# Архитектура: элементы



# Описание агента 'collector'



```
collector.sources = avro-in
collector.channels = mem-channel
collector.sinks = file-out

collector.channels.mem-channel.type = memory
```


# Описание агента 'collector': source

```
# get stream over avro channel
collector.sources.avro-in.type = avro
collector.sources.avro-in.channels = mem-channel
collector.sources.avro-in.bind = 0.0.0.0
collector.sources.avro-in.port = 5555
```

## Описание агента 'collector': sink

```
# write stream to file every 5 minutes or 1000 events
collector.sinks.file-out.type = file_roll
collector.sinks.file-out.sink.rollInterval = 300
collector.sinks.file-out.batchSize = 1000
collector.sinks.file-out.sink.directory = /tmp/flume/log/
collector.sinks.file-out.channel = mem-channel
```

# Описание агента 'vsftpd'



```
vsftpd.sources = logreader  
vsftpd.channels = mem-channel  
vsftpd.sinks = avro-out
```

```
vsftpd.channels.mem-channel.type = memory
```

# Описание агента 'vsftpd': sink

```
# sink stream over avro channel
vsftpd.sinks.avro-out.type = avro
vsftpd.sinks.avro-out.channel = mem-channel
vsftpd.sinks.avro-out.hostname = 127.0.0.1
vsftpd.sinks.avro-out.port = 5555
```


## Описание агента 'vsftpd': source

```
# Read from log file
vsftpd.sources.logreader.type = exec
vsftpd.sources.logreader.command = tail -F /var/log/vsftpd.log
vsftpd.sources.logreader.channels = mem-channel
# expecting veeeeery loooong string
vsftpd.sources.logreader.deserializer = LINE
vsftpd.sources.logreader.deserializer.maxLineLength = 32768
```

## Описание агента 'vsftpd': source: morphlines

```
# set interceptor for converting string to AVRO
vsftpd.sources.logreader.interceptors = morphline
# morphline interceptor config
vsftpd. . . .interceptors.morphline.type =
    org.apache.flume.sink.solr.morphline.MorphlineInterceptor?
vsftpd. . . .interceptors.morphline.morphlineFile =
    /tmp/flume/conf/morphlines.conf
vsftpd. . . .interceptors.morphline.morphlineId =
    vsftpFileLog
```

# Morphline pipe



# Morphline: разборка строк

```
{ grok {  
    dictionaryString : """  
    TS %{DAY} %{MONTH} %{MONTHDAY} %{TIME} %{YEAR}  
    PATH (?>/(?>[\w\s_!$@:.,-]+|\\\.)*)+  
    """  
    expressions : {  
        message : """  
            %{TS:timestamp}.*Client "%{IP:ip}",  
            "%{PATH:file}", %{INT:size}.*  
        """  
    }  
}
```

# Morphline: преобразуем в AVRO

```
# Convert Morphline Record to AVRO-event according schema
{
  toAvro {
    schemaString : """
    { "type": "record",
      "name": "ftpfile",
      "fields": [
        { "name": "timestamp", "type": "long", "default": -1 },
        { "name": "server", "type": "string", "default": "" },
        { "name": "ip", "type": "string", "default": "" },
        { "name": "file", "type": "string", "default": "" },
        { "name": "size", "type": "long", "default": -1 }
      ]
    }
    """
  }
}
```

That's All Folks!

Вопросы ?

denis\_pynkin@epam.com