

# Hadoop整合應用-Crawlzilla

@Taiwan Hadoop Ecosystem Workshop 2013

楊順發

<https://github.com/shunfa>

國家高速網路與計算中心

# 關於我-楊順發(shunfa)

- **現職：**

- 國家高速網路與計算中心-助理研究員
- 業餘Android App開發者

- **領域：**

- 巨量資料分析

- **專案：**

- Crawlzilla-建立私有搜尋引擎工具

- **GitHub & Contact**

- <https://github.com/shunfa>
- [shunfa@gmail.com](mailto:shunfa@gmail.com)

**先別管Crawlzilla了**



**你聽過**

**"Search Engine" 嗎？**

# Outline

- 初探搜尋引擎運作原理
- 搜尋引擎整合專案介紹-Nutch與Hadoop
- What is Crawlzilla?(using v1.5)
- What is Crawlzilla?(using v2.1)
- Demo

# Search Engine

- 三個主要階段

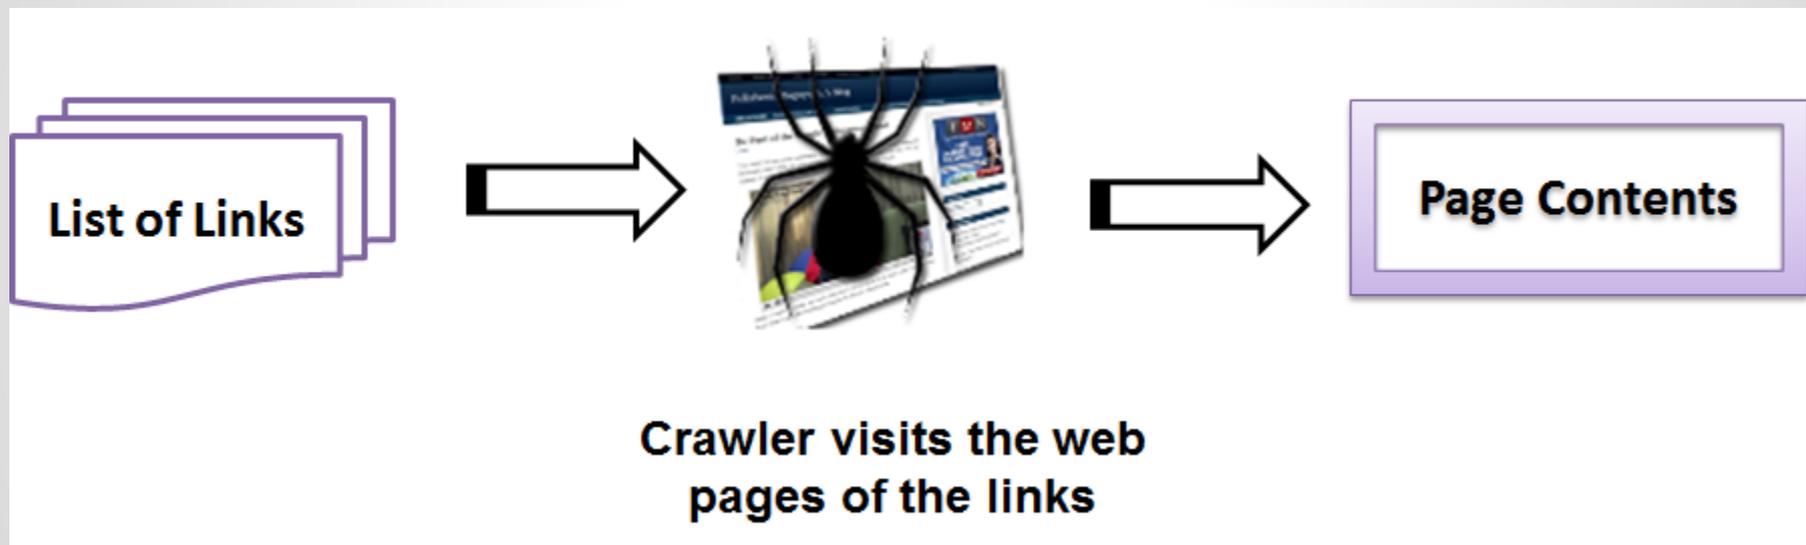
- 列出爬取清單

- 網路爬蟲針對清單進行爬取、並建立索引庫  
(Index Pool)

- 搜尋:使用者下搜尋指令時,系統從索引庫  
回傳搜尋結果

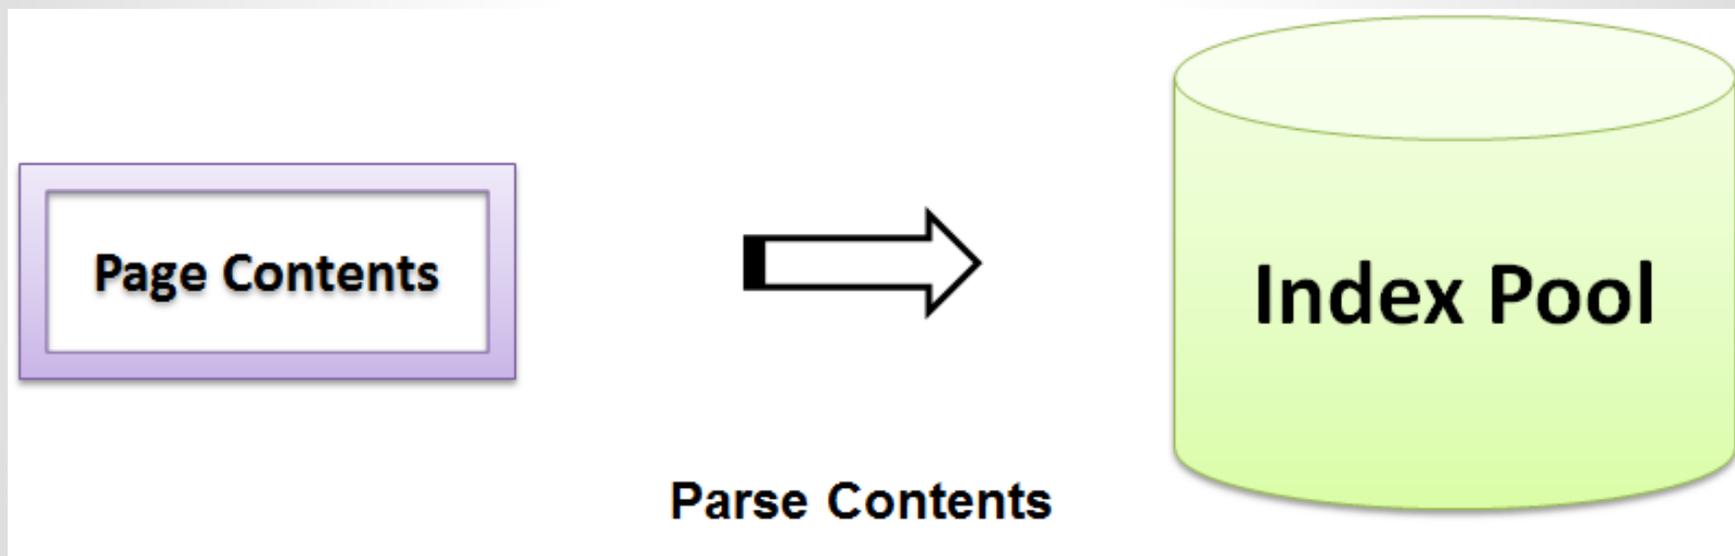
# 圖解搜尋引擎原理

- Crawling the Web



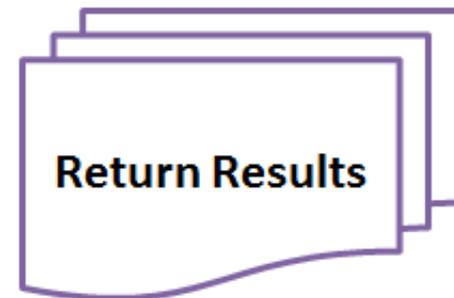
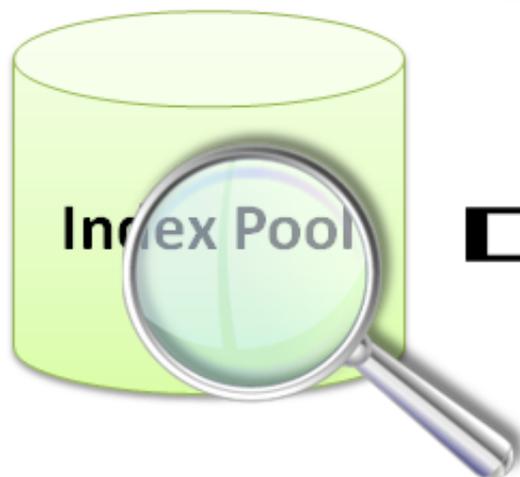
# 圖解搜尋引擎原理

- Building the Index Pool



# 圖解搜尋引擎原理

- Serving Queries



**User Sent a Query**

**Search from Index Pool**

# Google Search Engine的關鍵技術

- SOSP 2003 : “The Google File System”
- OSDI 2004 : “MapReduce : Simplified Data Processing on Large Cluster”
- OSDI 2006 : “Bigtable: A Distributed Storage System for Structured Data”

# Nutch

- Open Source Search Engine Project
- 始於2002



A screenshot of a Twitter post from Doug Cutting (@cutting). The post is a retweet of a tweet from @StefanGroschupf celebrating the 10th birthday of Nutch. The text of the tweet reads: "RT @StefanGroschupf: Happy 10th birthday #Nutch! Registered at sourceforce august 2002. Turned out to be quite a game changer. #Hadoop". The tweet includes interaction icons for reply, retweet, favorite, and more options. Below the tweet, there are statistics for 17 retweets and 4 favorites, along with a row of profile pictures of users who interacted with the tweet. The timestamp is "12年8月8日下午9:11".

 **Doug Cutting**  
@cutting 關注

RT @StefanGroschupf: Happy 10th birthday #Nutch! Registered at sourceforce august 2002. Turned out to be quite a game changer. #Hadoop

回覆 轉推 收藏 更多

17 則轉推 4 收藏

12年8月8日下午9:11

# Nutch

- In June, 2003, a successful 100-million-page demonstration system was developed.
- Nutch project has also implemented a MapReduce facility and a distributed file system.
- The two facilities have been spun out into their own subproject, called Hadoop.

# Nutch 與 Hadoop

- inject url
- crawldb **JOBNAME** /crawldb
- generate: select from **JOBNAME** /crawldb
- generate: partition **JOBNAME**  
/segments/20101126161446
- fetch **JOBNAME** /segments/20101126161446
- crawldb **JOBNAME** /crawldb
- linkdb **JOBNAME** /linkdb
- index-lucene **JOBNAME** /indexes
- dedup 1: urls by time
- dedup 2: content by hash
- dedup 3: delete from index(es)

# Using Nutch



簡介

常見問題



搜索

[幫](#)

[助](#)

[ca](#) | [de](#) | [en](#) | [es](#) | [fi](#) | [fr](#) | [hu](#) | [it](#) | [jp](#) | [ms](#) | [nl](#) | [pl](#) | [pt](#) | [sh](#) | [sr](#) | [sv](#) | [th](#) | [zh](#)

# Nutch 安裝步驟 - Step1. Hadoop單機安裝

- 安裝Hadoop

```
~$ cd /opt
/opt$ sudo wget http://ftp.twaren.
net/Unix/Web/apache/hadoop/core/hadoop-x.x.x/hadoop-x.x.x.
tar.gz
/opt$ sudo tar zxvf hadoop-x.x.x.tar.gz
/opt$ sudo mv hadoop-x.x.x/ hadoop
/opt$ sudo chown -R hadoop:hadoop hadoop
/opt$ cd hadoop/
/opt/hadoop$ gedit conf/hadoop-env.sh
```

# Nutch 安裝步驟 - Step1. Hadoop單機安裝

- 修改 `conf/hadoop-env.sh`

```
export JAVA_HOME=/usr/lib/jvm/java-6-sun
export HADOOP_HOME=/opt/hadoop
export HADOOP_CONF_DIR=/opt/hadoop/conf
export HADOOP_LOG_DIR=/tmp/hadoop/logs
export HADOOP_PID_DIR=/tmp/hadoop/pid
```

# Nutch 安裝步驟 - Step1. Hadoop單機安裝

## • 修改 conf/hadoop-site.xml

```
<configuration>
  <property>
    <name>fs.default.name</name>
    <value>hdfs://localhost:9000/</value>
    <description> </description>
  </property>
  <property>
    <name>mapred.job.tracker</name>
    <value>localhost:9001</value>
    <description> </description>
  </property>
  <property>
    <name>hadoop.tmp.dir</name>
    <value>/tmp/hadoop/hadoop-${user.name}</value>
    <description> </description>
  </property>
</configuration>
```

# Nutch 安裝步驟 - Step1. Hadoop單機安裝

- HDFS格式化並啟動Hadoop

```
/opt/hadoop$ bin/hadoop namenode -format
```

```
/opt/hadoop$ bin/start-all.sh
```

# Nutch 安裝步驟 - Step2. 安裝Nutch

- 下載 nutch 並解壓縮
- 配置hadoop,nutch目錄結構
- 複製函式庫檔
- 編輯設定檔
  - hadoop-env.sh
  - nutch-site.xml
  - crawl-urlfilter.txt

# Nutch 執行-爬取網站

- 編輯url清單
- 上傳清單到HDFS
- 執行nutch crawl
  - \$ bin/nutch crawl urls -dir search -threads 2 -depth 3  
-topN 100000

# Nutch 執行-設定Query UI(Tomcat)

- 下載tomcat
- 解壓縮
- tomcat server設定
  - 修改 /opt/tomcat/conf/server.xml 以修正中文亂碼問題
- 下載crawl結果
  - `$ cd /opt/nutch`
  - `$ bin/hadoop dfs -get search /opt/search`
- 設定nutch的搜尋引擎頁面到tomcat
- 設定搜尋引擎內容的來源路徑
  - `$ gedit /opt/tomcat/webapps/ROOT/WEB-INF/classes/nutch-site.xml`
- 啟動tomcat

# 叢集版使用方式

# Nutch 安裝步驟 - Step1. Hadoop叢集安裝

## 前言

清除所有在實做一作過的環境

step 0. 設定機器的ip & hostname 資訊

step 1. 設定兩台機器登入免密碼

step 2. 安裝java

step 3. 下載安裝Hadoop到"主機一"

step 4. 設定 hadoop-env.sh

step 5. 設定 hadoop-site.xml

step 6. 設定masters及slaves

step 7. Hadoop\_Home內的資料複製到其他主機上

step 8. 格式化HDFS

step 9. 啟動Hadoop

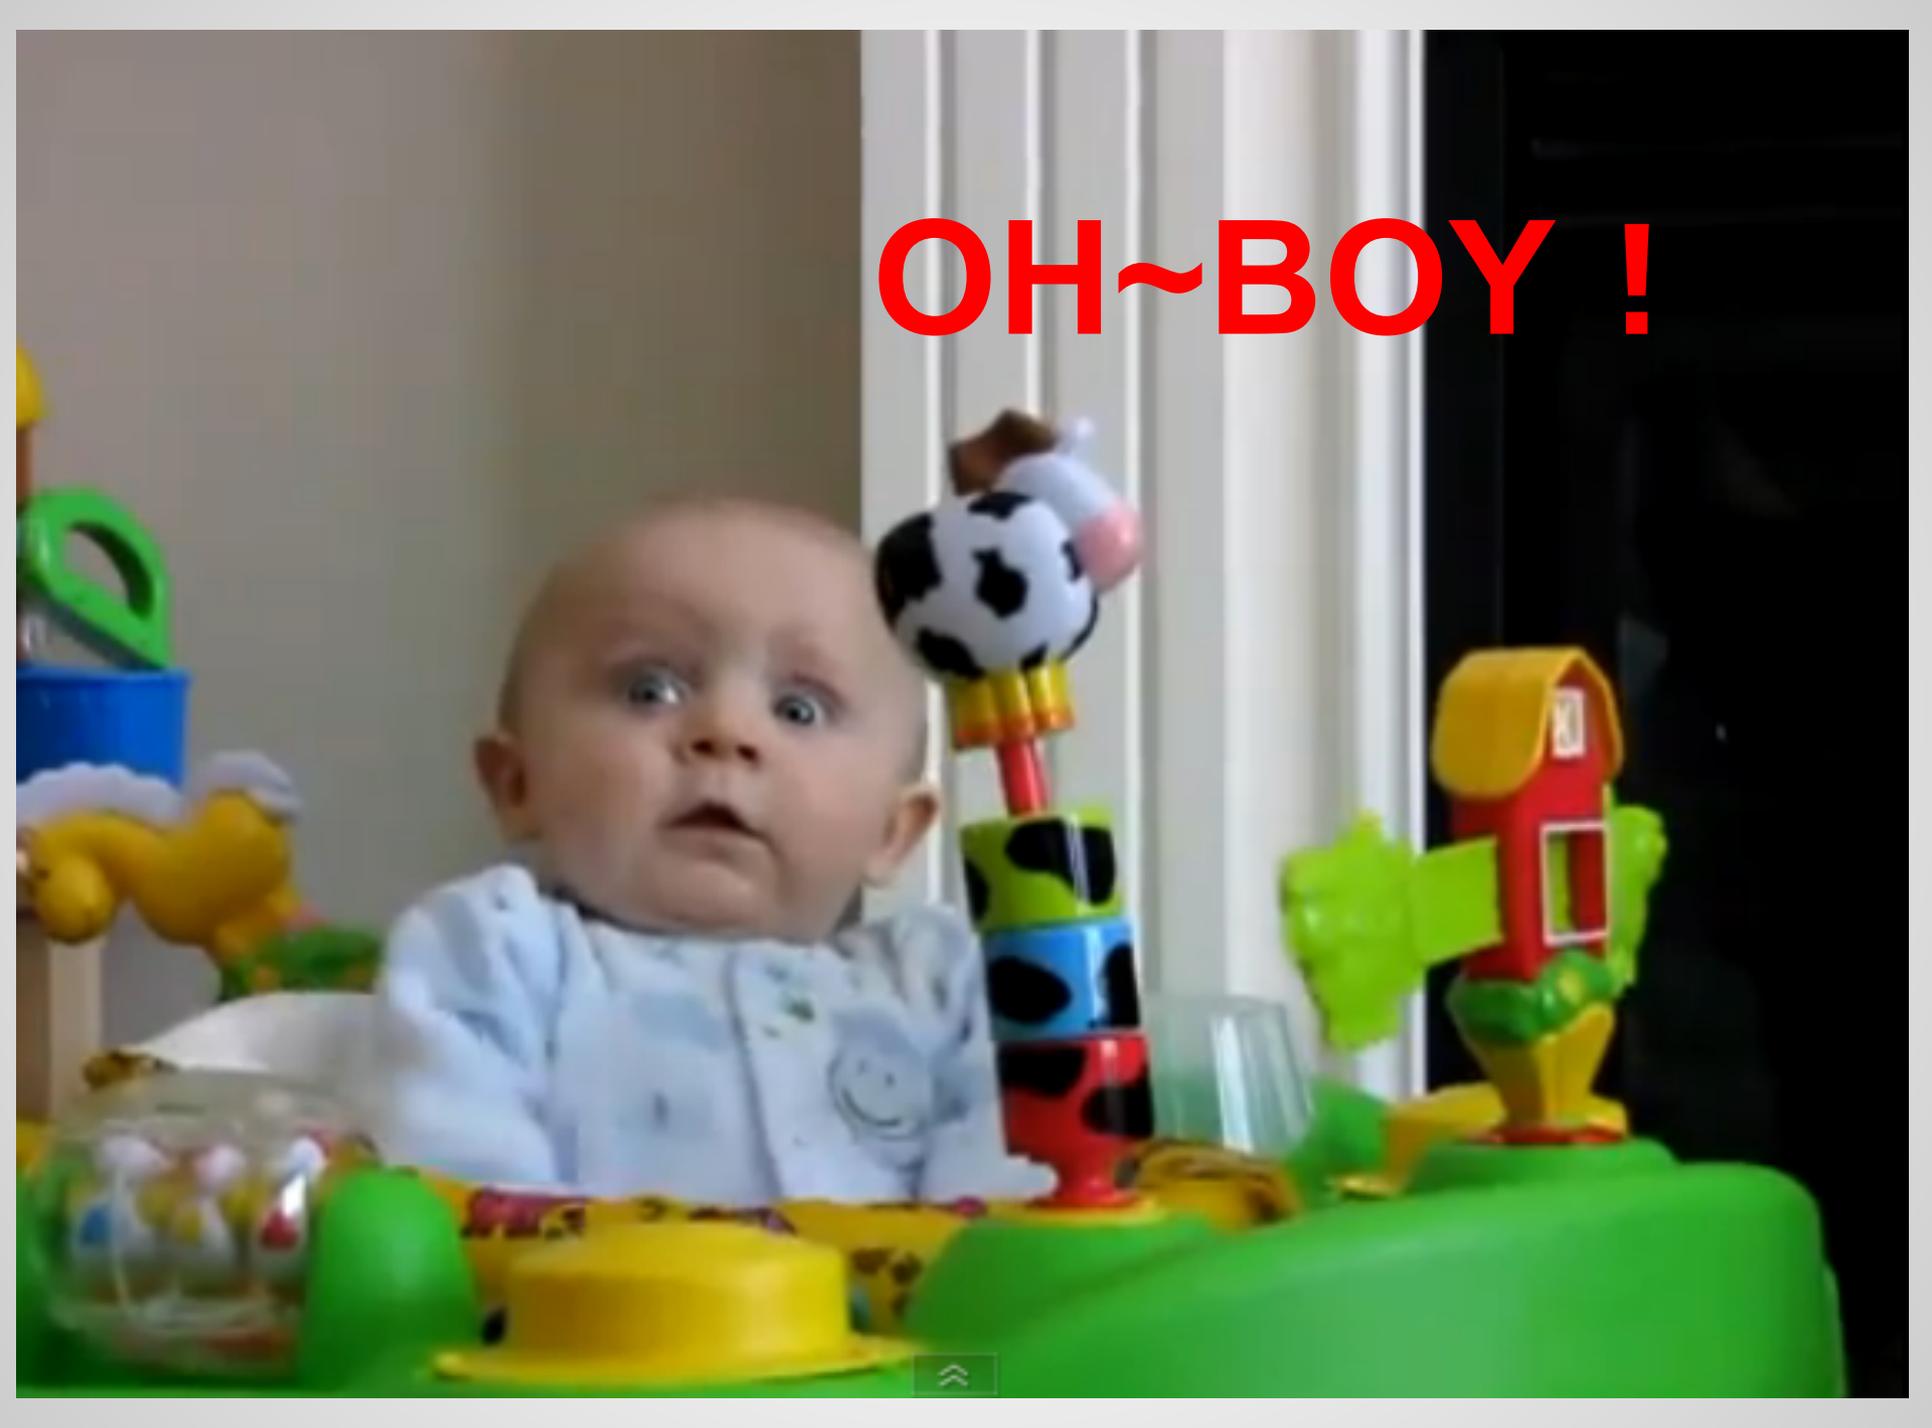
step 10. 停止hadoop

## 練習

# And then...

- 開始安裝 Nutch
- 啟動服務
- 開始建立索引庫
- 建立連結
- 上線服務

OH~BOY !



# 於是有了 NutchEZ

Developed By NCHC

## NutchEz 雛型版

你好，歡迎使用NutchEz！  
這套軟體是用來打造專屬於你的搜尋引擎  
你有網頁不希望被公開的搜尋引擎找到，  
卻又希望能有個搜尋介面的困擾嗎？  
用NutchEz就對了！因為他操作簡單，  
除了基本的網頁以外，還支援多種格式 (ppt,doc,txt...)  
並且是開源碼軟體，完全免費，安全無虞  
趕快來使用看看吧！

選擇你要的模式：

- 1 開始建構搜尋內容
- 2 開啟或關閉NutchEz的網頁伺服器

< 確定 >

< 取消 >

透過NutchEz來建構專屬於你自己所需的內容的搜尋引擎



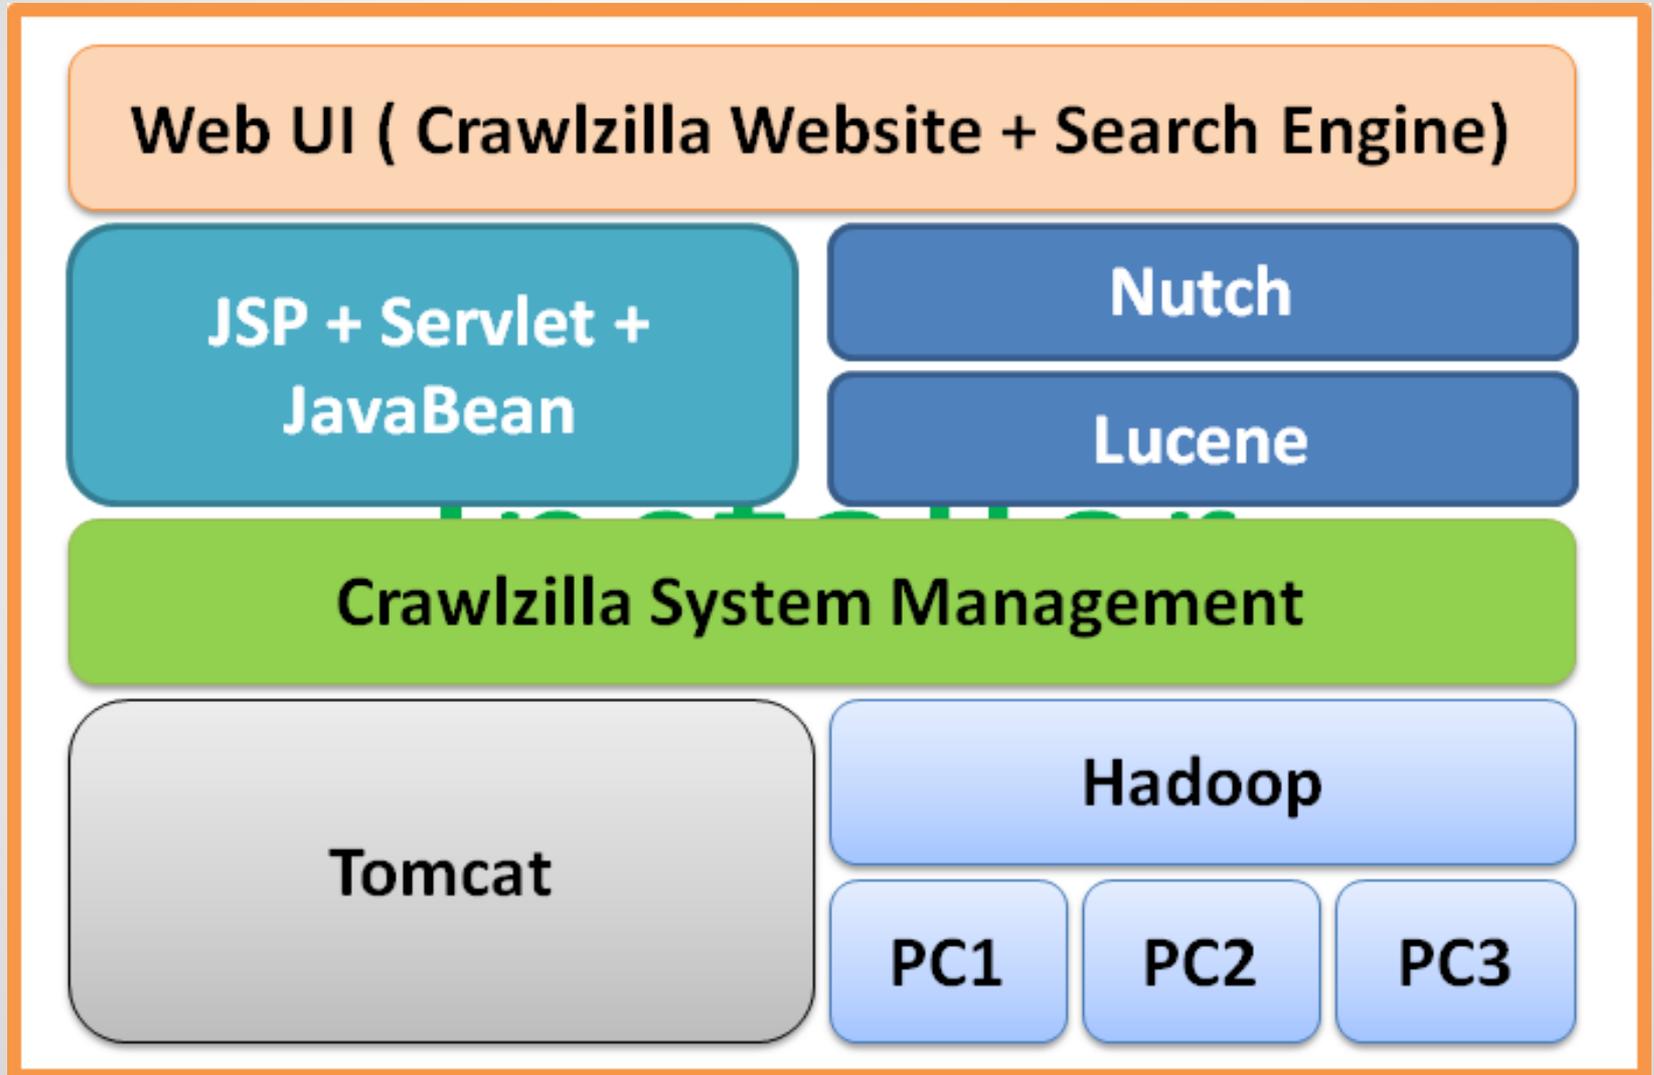
# NutchEZ 功能

- 快速安裝Nutch
- 文字模式輸入url list
- 單一搜尋引擎
- 很簡單好用的**單機版**Nutch

# NutchEZ 更名為 Crawlzilla

- 快速整合Hadoop, 包括架設叢集
- 友善的管理介面
- 大家都會用的瀏覽器使用模式
- 可以知道搜尋引擎的內容
- 多搜尋引擎
- 中文分詞
- .....

# How Crawlzilla Works(V1.5)?



# 中文分詞

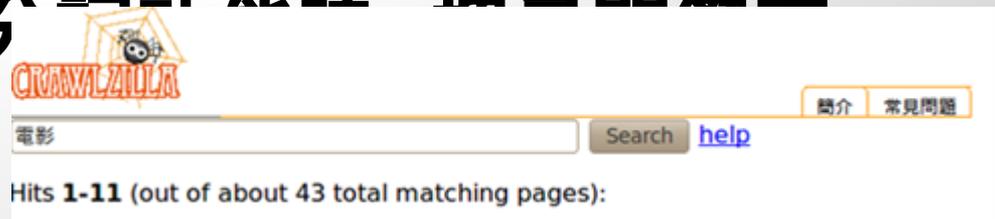
- 索引資料庫會以中文字詞為基本單位建立索引

- 搜尋引擎無中文分詞功能時，搜尋關鍵字 - 電影



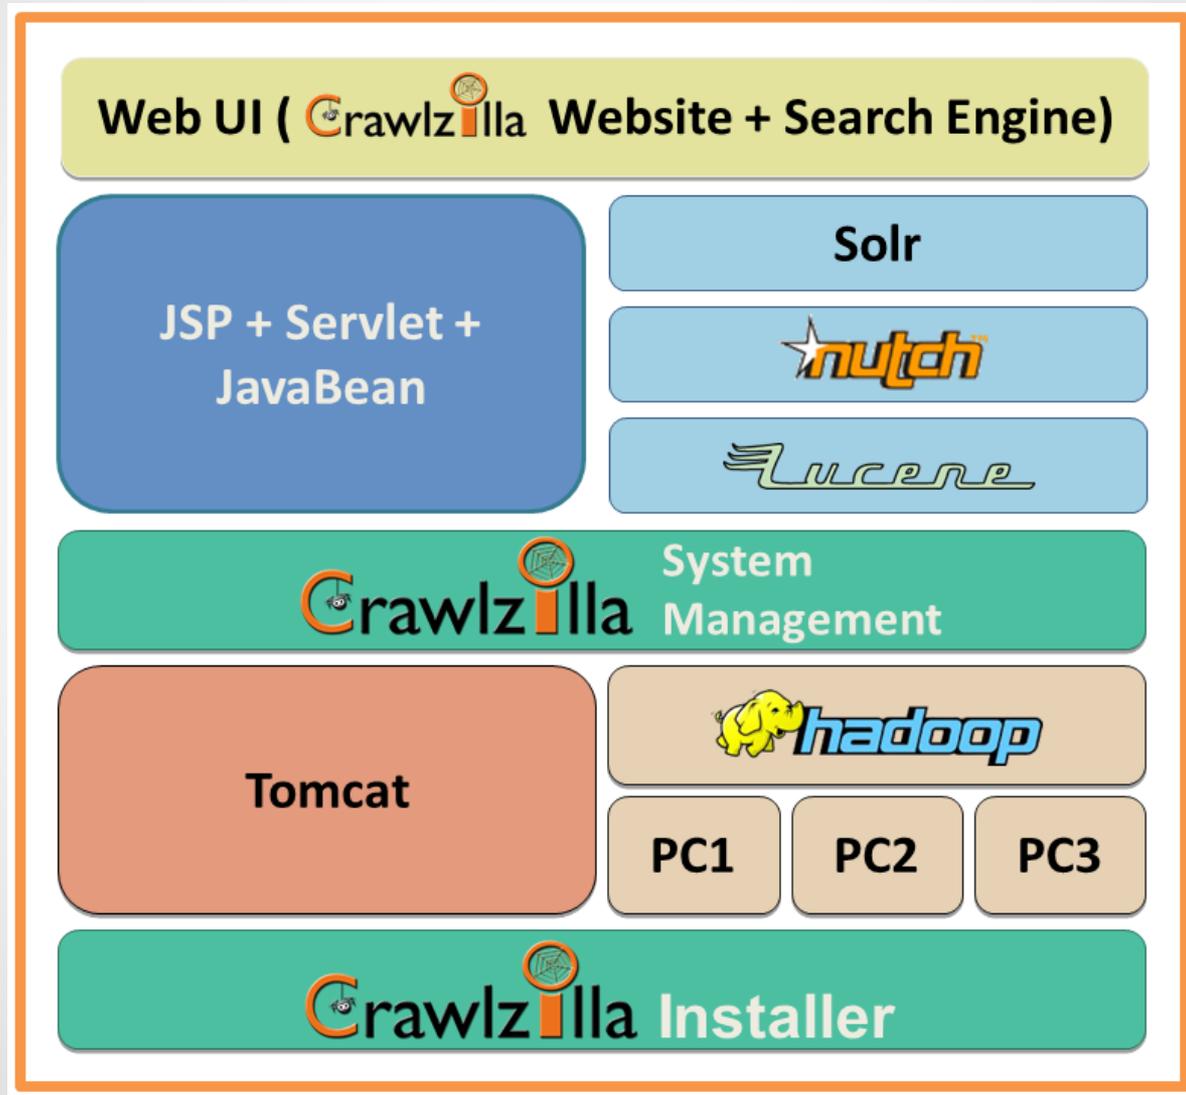
- 760 筆搜尋結果

- 搜尋引擎加入中文分詞功能時，搜尋關鍵字 - 電影



**Demo**  
**(<http://demo.crawlzilla.info/>)**

# How Crawlzilla Works(V2.1)?



# Crawlzilla 三版本比較表

	<b>0.3</b>	<b>1.x</b>	<b>2.1</b>
<b>Nutch版本</b>	v1.0	v1.2	v1.6
<b>多人版本</b>	X	O	X
<b>檢索工具</b>	Lucene	Lucene	Lucene&Solr
<b>多索引庫</b>	O	O	O
<b>叢集架設</b>	O	O	X(需手動)

# Crawlzilla V2.1 與 Solr的整合

- 特色

- Nutch v1.6
- 輕量
- Solr有提供相當完整的索引庫工具

- 缺點

- 資料量太大時無法爬取成功，需搭配叢集
- 官方已無提供Query UI，可搭配ajax-solr服用

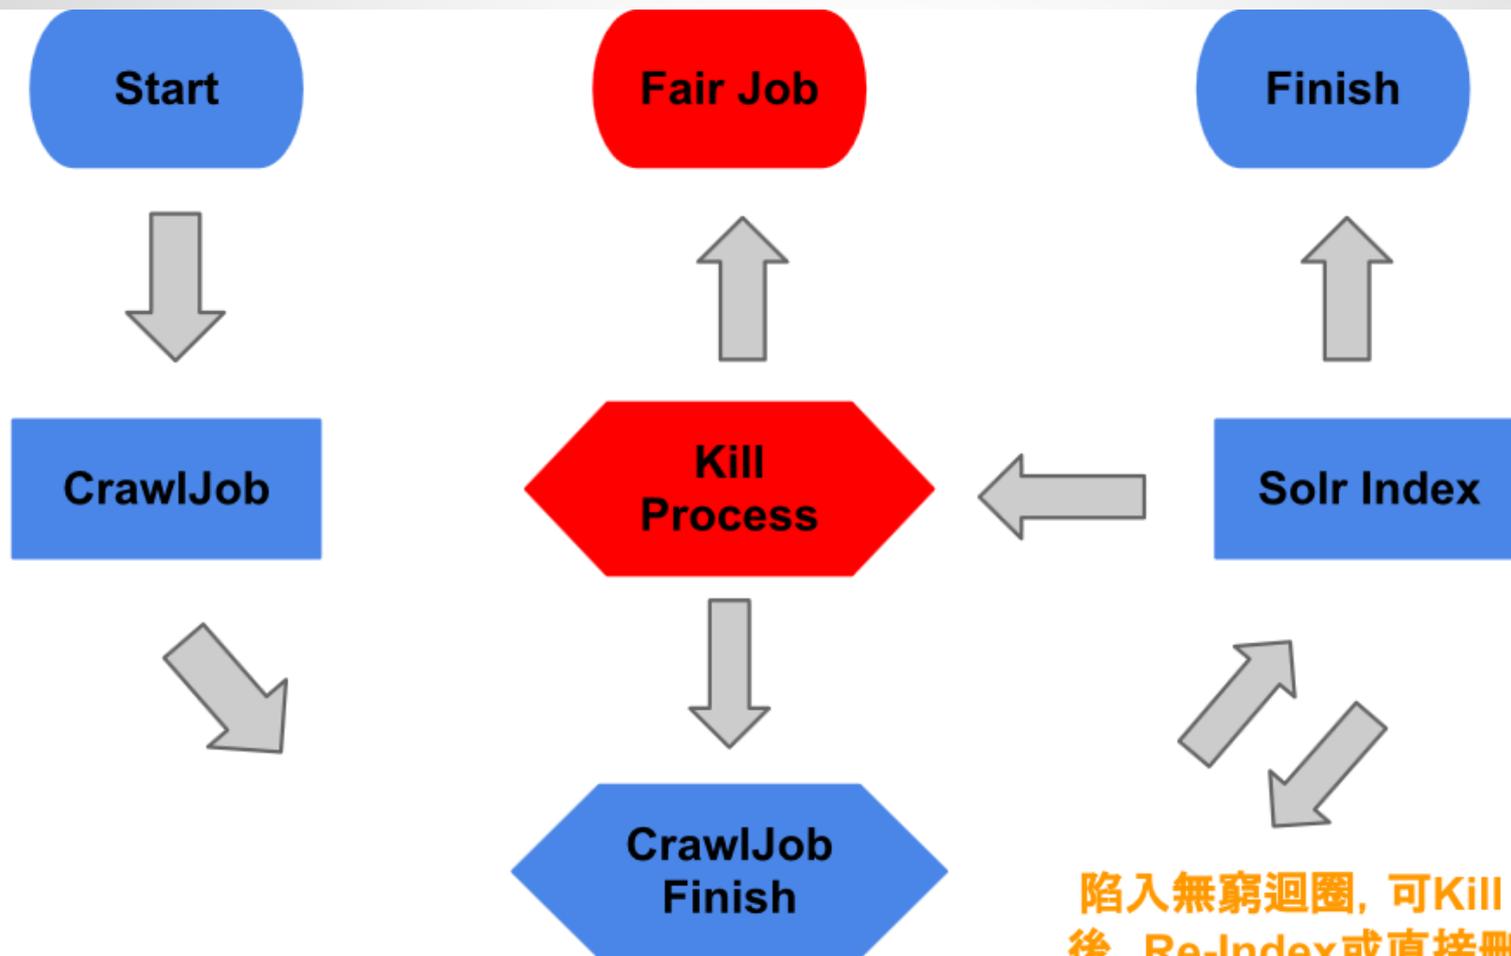
# Nutch 1.6 Local (Standalone) Mode

- 不必安裝Hadoop
- 設定以下
  - nutch-site.xml
  - regex-urlfilter.txt
- 執行
  - `bin/nutch crawl urls -dir crawl -depth 3 -topN 5`
  -

# Nutch 1.6 Local (Standalone) Mode

- 配置Solr
  - 將Nutch的配置複製到Solr中
  - 啟動Solr
  - 將Nutch 的 index 匯入至 Solr
  - 修改Solr設定
  - ...[more](#)

# 問題: Crawl Status



陷入無窮迴圈, 可Kill Process  
後, Re-Index或直接刪除此次爬  
取任務

# 判斷Job是否可以修復

- Step1 : 檢查crawlDB資料夾是否存在DB Name
- Step2 : 檢查solr.xml及solr資料夾是否存在DB Name, 均存在則可執行
  - Step3.a, 若不存在則必須執行
  - Step3.b, 砍掉從練
- Step3.a: 執行reindex程序
- Step3.b: 若存在以下資料, 則刪除
  - crawlDB/DB\_Name
  - solr.xml
  - solr folder

# 多重索引庫

- Solr設定

- 新增solr設定檔, 直接複製預設即可(collection1)

- 設定solr.xml

- 新增

- `<core schema="schema.xml" instanceDir="NCHC_EN_SP_0517/" name="NCHC_EN_SP_0517" config="solrconfig.xml" dataDir="data"/>`

# Stop Words

- 很多文字可以使文章更流暢，但對搜尋引擎來說試沒有意義的
  - Ex: and, but, then ...
- 建立SolrIndex前可先設定stopword
  - 路徑: `$SOLR_HOME/example/solr/IDBName/conf/stopword.txt`
  - 格式: 一行一個字

# Stop Words

- 效果
  - 未設定

10	/7618 Top-Terms: ?
227	中
203	768
	1024
200	3
183	2013
181	7
179	5776085
177	for
175	4
174	文

# Stop Words

- 效果
  - 加入stopword

10	/8726 Top-Terms: ?
266	中
233	2013
209	文
206	computing tel
204	3
202	886
201	fax national
199	center

# **Crawlzilla V2.1-Beta Demo**

# Feature works

- 中文詞庫
- 更多的通訊協定(ftp, smb...etc)
- Search UI Design
- 結合搜尋引擎的應用

# Questions?

- **特別感謝**

- **技術顧問**

- **王耀聰**

- **Crawlzilla原創群**

- **陳威宇**

- **郭文傑**

- **楊順發**

