



# 運用抓抓龍製作個人化書籤搜尋引擎

Build Your Personal Bookmark Search Engine using Crawlzilla

**Jazz Wang**  
**Yao-Tsung Wang**  
**jazz@nchc.org.tw**



Powered by DRBL

# WHO AM I ? 這傢伙是誰啊? JAZZ ?

- 講者介紹：

- 國網中心 王耀聰 副研究員 / 交大電控碩士


- [jazz@nchc.org.tw](mailto:jazz@nchc.org.tw)

- 所有投影片、參考資料與操作步驟均在網路上

- 由於雲端資訊變動太快，愛護地球，請減少不必要之列印。



**FLOSS 使用者**  
Debian/Ubuntu  
Access Grid  
Motion/VLC  
Red5  
Debian Router  
DRBL/Clonezilla  
Hadoop




**行動力薄弱的開發者**

DRBL/Clonezilla  
Hadoop Ecosystem

**推廣者**

DRBL/Clonezilla  
Partclone/Tuxboot  
Hadoop Ecosystem

# Information Versus Available Storage




Source: IDC, 2007

# 2007 Data Explore


**Top 1 : Human Genomics - 7000 PB / Year**  
**Top 2 : Digital Photos - 1000 PB+ / Year**  
**Top 3 : E-mail (no Spam) - 300 PB+ / Year**



Source: IDC, 2007



Source: IDC, 2007



Particle Physics Large Hadron Collider (15PB)	Human Genomics (7000PB) 1GB / person 200PB+ captured 200% CAGR	World Wide Web (~1PB)	Wikipedia (10GB) 100% CAGR
Annual Email Traffic, no spam (300PB+)	Internet Archive (1PB+)	Estimated On-line RAM in Google (8PB)	Personal Digital Photos (1000PB+) 100% CAGR
200 of London's Traffic Cams (8TB/day)	2004 Walmart Transaction DB (500TB)	Typical Oil Company (350TB+)	Merck Bio Research DB (1.5TB/qtr)
UPMC Hospitals Imaging Data (500TB/yr)	MIT Babytalk Speech Experiment (1.4PB)	Terashake Earthquake Model of LA Basin (1PB)	One Day of Instant Messaging in 2002 (750GB)
Total digital data to be created this year <b>270,000PB</b> (IDC)			


Phillip B. Gibbons, Data-Intensive Computing Symposium

Source: <http://www.emc.com/collateral/analyst-reports/expanding-digital-idc-white-paper.pdf>

Source: [http://lib.stanford.edu/files/see\\_pasig\\_dic.pdf](http://lib.stanford.edu/files/see_pasig_dic.pdf)



# IT'S THE DATA, STUPID!



「笨蛋！重點在經濟」

( **"It's the economy, stupid"** )

卡維爾 ( **James Carville** ) 自創這句標語，  
促使柯林頓當上美國第 **42** 屆總統。

- **1992** 年

「笨蛋！重點還是在經濟」

( **"It's STILL the economy, stupid"** )

卻讓小布希嘲笑是幼稚的總統。

- **2002** 年

雲端時代，谷歌會說：「笨蛋！重點在資料」

( **"It's the data, stupid"** )

誰掌握了你的資料，就有機會掌握你的荷包  
想想看，電腦、手機掉了，您心疼的是甚麼呢？

- **2007** 年

# Search is everywhere in our daily life !!

## 「搜尋」已經成爲我們生活中的一部分

搜尋結果

### 檔案搜尋

網址(D) 搜尋結果


搜尋小幫手

您想要搜尋什麼?

- 圖片、音樂，或視訊(P)
- 文件(文字處理、試算表，等等)(O)
- 所有檔案和資料夾(L)
- 電腦或人員(C)
- 說明和支援中心裡的資訊(I)

您也可能想要...

- 搜尋網際網路(S)
- 變更喜好(G)



0 個物件

Gmail Calendar Documents Photos Sites Web More -

Search

All Mail

From

To

Subject

Has the words

Doesn't have

Has attachment

Date within 1 day of

Examples: f

Search

### 信件搜尋

發 的交談

larwin.nchc.org.tw 於 2011年12月02日 (週五) 10時53分46秒 的交談

(10時53分48秒) Shunfa 楊順發

(10時53分51秒) Jazz Yao-Tsun

(10時54分08秒) Shunfa 楊順發

(10時54分42秒) Jazz Yao-Tsun

(10時54分49秒) Jazz Yao-Tsun

(10時54分51秒) Jazz Yao-Tsun

(10時55分02秒) Shunfa 楊順發

(10時55分04秒) Shunfa 楊順發

(10時55分39秒) Jazz Yao-Tsun

尋找(F)

關閉(C)

### 即時通訊搜尋

IEEE Xplore DIGITAL LIBRARY

BROWSE

- Journals & Magazines
- Conference Proceedings
- Standards
- Books
- Educational Courses

SIGN IN

Search 3,076,887 documents

SEARCH

Advanced Search | Preferences | Search Tips

### 資料庫搜尋

## 今天要談的是「網頁搜尋」

設Yahoo!奇摩為首頁 資訊展PK線上搶先

# YAHOO! 奇摩

網頁 | 知識+ | 圖片 | 影片 | 部落格 | 字典 | 新聞 | 購物 BETA

網頁搜尋

熱門: 第一美腿 12歲父親 嫩模女神 幼稚病 51區 花心星座 解夢 知識: 傷口癢竟是 電鍋料理

2011 資訊月 ONLINE 3G特展搶先看!!

# To speed up search, We need “Index”

爲了加速搜尋的效率，我們需要「索引」

## Index

出現頁碼

關鍵字

### Symbols

! (exclamation mark) command prefix, 368

### A

ack queue in HDFS, 66

ACLs (access control lists)  
for Hadoop services, 283  
ZooKeeper, 446, 456

ActiveKeyValueStore class (example), 464

ad hoc analysis and product feedback  
(hypothetical use case), 511

adjacency list, 560

installation, 565

prerequisites, 565

TeraByte sort on, 553

Apache Hadoop project, 10, 12

Apache Lucene project, 9

Apache Nutch, 9

Apache Thrift services, 49

Apache ZooKeeper, 442

(see also ZooKeeper)

APIs in ZooKeeper, 453

archive files, copying to tasks, 253

archive tool, 72

archives, 72

# History of Hadoop ... 2001~2005

## Hadoop 這套軟體的歷史源起 ... 2001~2005



- Lucene

- <http://lucene.apache.org/>
- 用 Java 設計的高效能文件索引引擎 API
- a high-performance, full-featured **text search engine library** written entirely in **Java**.
- 索引文件中的每一字，讓搜尋的效率比傳統逐字比較還要高的多
- Lucene create an **inverse index** of every word in different documents. It enhance performance of text searching.

# History of Hadoop ... 2005~2006

## Hadoop 這套軟體的歷史源起 ... 2005~2006

- Nutch
  - <http://nutch.apache.org/>
  - Nutch 是基於開放原始碼所開發的網站搜尋引擎
  - Nutch is open source **web-search** software.
  - 利用 Lucene 函式庫開發
  - It builds on **Lucene and Solr**, adding web-specifics, such as a **crawler**, a **link-graph database**, parsers for HTML and other document formats, etc.






# History of Hadoop ... 2006 ~ Now

## *Hadoop* 這套軟體的歷史源起 ... 2006 ~ Now

- Nutch 後來遇到儲存大量網站資料的瓶頸，剛好看到 Google 在一些會議分享他們的三大關鍵技術 ...
- Added DFS & MapReduce implement to Nutch
- According to **user feedback** on the mail list of Nutch ....
- Hadoop became separated project **since Nutch 0.8**
- Nutch DFS → Hadoop Distributed File System (HDFS)
- **Yahoo** hire Dong Cutting to build a team of web search engine at **year 2006**.
  - Only **14 team members** (engineers, clusters, users, etc.)
- Dong Cutting joined Cloudera at year 2009.



**YAHOO!**

**cloudera**



# lock files don't work in JDK 1.1

Log In

Views

### Details

Type:	Bug	Status:	Closed
Priority:	Major	Resolution:	Fixed
Affects Version/s:	1.2	Fix Version/s:	None
Component/s:	core/store		
Labels:	None		
Environment:	Operating System: All		

### People

Assignee: [Lucene Developers](#)  
 Reporter: [Doug Cutting](#)  
 Vote (0) Watch (0)

### Dates

Created: 09/Oct/01 16:19



# test

Log In

Views

### Details

Type:	Bug	Status:	Closed
Priority:	Trivial	Resolution:	Fixed
Affects Version/s:	None	Fix Version/s:	None
Component/s:	None		
Labels:	None		

### People

Assignee: Unassigned  
 Reporter: [Doug Cutting](#)  
 Vote (0) Watch (0)

### Dates

Created: 11/Feb/05 04:23



# initial import of code from Nutch

Log In

Views

### Details

Type:	Task	Status:	Closed
Priority:	Major	Resolution:	Fixed
Affects Version/s:	None	Fix Version/s:	0.1.0
Component/s:	None		
Labels:	None		

### People

Assignee: [Doug Cutting](#)  
 Reporter: [Doug Cutting](#)  
 Vote (0) Watch (0)

### Dates

Created: 01/Feb/06 02:54

# Do you like to write notes?

## 你有寫筆記的習慣嘛？



想知道更多 | 升級至專業版 | 檔案下載 | 部落格 | 百寶箱

- 登入
- 立即註冊

### 什麼都記得住



#### 擷取每件事。

儲存點子、喜愛事物以及所見所聞。

#### 隨處存取。

Evernote 幾乎能在所有電腦、手機以及其他行動裝置上使用。

#### 快速尋找事物。

根據標題、標籤甚至是影像內的印刷與手寫文字進行搜尋。

取得 Evernote

立即下載

免費使用。

## 大腦記憶力有限，只好靠筆記啦！

# Tools that I used to write notes

## 我作筆記的工具 (1) 維基 **Oddmuse Wiki**

軟體下載：<http://www.oddmuse.org/>

[關於本站](#) [更新紀錄](#) [[年曆\(c\)](#)] [[登入\(l\)](#)] [[上一頁](#)] [[首頁\(h\)](#)] [[12-02\(9\)](#)] [[12-03\(0\)](#)] [[12-04\(1\)](#)] [[12-05\(2\)](#)] [[12-06\(3\)](#)]

December 2011						
Su	Mo	Tu	We	Th	Fr	Sa
				1	2	
4	5	6	7	8	9	1
11	12	13	14	15	16	1
18	19	20	21	22	23	2
25	26	27	28	29	30	3

## 關於本站

架站日期：2005/01/01

基本架構：<http://www.oddmuse.org/> Oddmuse Wiki

## 更新紀錄

2005-01-01		
chinese-utf8.pl	<b>Chinese Translations</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Chinese">http://www.oddmuse.org/cgi-bin/wiki/Chinese</a>
download.pl	<b>Download Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Download_Extension">http://www.oddmuse.org/cgi-bin/wiki/Download_Extension</a>
headers.pl	<b>Header Markup Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Header_Markup_Extension">http://www.oddmuse.org/cgi-bin/wiki/Header_Markup_Extension</a>
tables-long.pl	<b>Long Table Markup Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Long_Table_Markup_Extension">http://www.oddmuse.org/cgi-bin/wiki/Long_Table_Markup_Extension</a>
tables.pl	<b>Table Markup Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Table_Markup_Extension">http://www.oddmuse.org/cgi-bin/wiki/Table_Markup_Extension</a>
usemod.pl	<b>Usemod Markup Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Usemod_Markup_Extension">http://www.oddmuse.org/cgi-bin/wiki/Usemod_Markup_Extension</a>
2005-02-16		
calendar.pl	<b>Calendar Extension</b>	<a href="http://www.oddmuse.org/cgi-bin/wiki/Calendar_Extension">http://www.oddmuse.org/cgi-bin/wiki/Calendar_Extension</a>

2005~2008



# Tools that I used to write notes

## 我作筆記的工具 (2) 維基 PmWiki

軟體下載：<http://www.pmwiki.org/>

### 導覽列 (編輯)

首頁  
民視專訪  
福山參訪  
超級視訊  
阿聰的首頁  
穎燦的首頁  
測試沙箱  
近期更新

### PmWiki 官方網站

程式安裝  
常見問題  
外掛程式  
布景主題  
臭蟲管理

### PmWiki 使用手冊

頁面編輯入門  
頁面編輯技巧  
建立新的頁面

Main » [Home Page](#)

[本文](#) · [編輯](#) · [附檔](#) · [列印](#) · [歷史](#)

Search

縮小 正常 放大

### 歡迎使用 PmWiki:

以下是一些 [PmWiki](#) 安裝後的預設頁面，你可以從這些頁面開始瞭解 PmWiki:

- [Pm Wiki](#) 的 [相關文件目錄](#)。
- 什麼是 [WikiWikiWeb](#) ?
- [頁面編輯技巧](#) 和 [寫作語法](#) 這兩份完文件描述如何建立一個 Wiki 頁面。
- 你可以用 [測試沙箱](#) 來練習 Wiki 的語法。

請定期拜訪 [PmWiki 官方網站](#) 以便獲得最新的資訊。

« [October 2011 period](#) · [February 2012 period](#) »

### December 2011

Mon	Tue	Wed	Thu	Fri	Sat	Sun
			<a href="#">01</a>	<a href="#">02</a>	<a href="#">03</a>	<a href="#">04</a>
<a href="#">05</a>	<a href="#">06</a>	<a href="#">07</a>	<a href="#">08</a>	<a href="#">09</a>	<a href="#">10</a>	<a href="#">11</a>
<a href="#">12</a>	<a href="#">13</a>	<a href="#">14</a>	<a href="#">15</a>	<a href="#">16</a>	<a href="#">17</a>	<a href="#">18</a>
<a href="#">19</a>	<a href="#">20</a>	<a href="#">21</a>	<a href="#">22</a>	<a href="#">23</a>	<a href="#">24</a>	<a href="#">25</a>
<a href="#">26</a>	<a href="#">27</a>	<a href="#">28</a>	<a href="#">29</a>	<a href="#">30</a>	<a href="#">31</a>	

### January 2012

Mon	Tue	Wed	Thu	Fri	Sat	Sun
						<a href="#">01</a>
<a href="#">02</a>	<a href="#">03</a>	<a href="#">04</a>	<a href="#">05</a>	<a href="#">06</a>	<a href="#">07</a>	<a href="#">08</a>
<a href="#">09</a>	<a href="#">10</a>	<a href="#">11</a>	<a href="#">12</a>	<a href="#">13</a>	<a href="#">14</a>	<a href="#">15</a>
<a href="#">16</a>	<a href="#">17</a>	<a href="#">18</a>	<a href="#">19</a>	<a href="#">20</a>	<a href="#">21</a>	<a href="#">22</a>
<a href="#">23</a>	<a href="#">24</a>	<a href="#">25</a>	<a href="#">26</a>	<a href="#">27</a>	<a href="#">28</a>	<a href="#">29</a>
<a href="#">30</a>	<a href="#">31</a>					

# Tools that I used to write notes

## 我作筆記的工具 (3) 離線網頁 ScrapBook

安裝：<https://addons.mozilla.org/zh-TW/firefox/addon/scrapbook/>

The screenshot shows the Mozilla Add-ons website for the ScrapBook extension. The page features the Mozilla logo, a search bar, and a navigation menu. The main content area displays the ScrapBook 1.4.8 extension by Gomita, with a description: "協助您擷取網頁，方便整理擷取後的資料。" (Helps you capture web pages, making it easy to organize the data after capture). A green "精選" (Featured) banner is visible. The extension has a 4.5-star rating and 564 user reviews. A "新增至 Firefox" (Add to Firefox) button is prominent. Below the extension card, there is a "捐款" (Donate) button with a "建議 US\$2.99" (Suggested \$2.99) label. A yellow box on the right contains the text "2005~NOW".



# Tools that I used to write notes

## 我作筆記的工具 (4) 維基 + 版本控制 **Trac**

軟體下載：<http://trac.edgewall.org/>

[Login](#) | [Preferences](#) | [Help/Guide](#) | [About Trac](#)

	<a href="#">Wiki</a>	<a href="#">Timeline</a>	<a href="#">Roadmap</a>	<a href="#">Browse Source</a>	<a href="#">View Tickets</a>	<a href="#">Search</a>
--	----------------------	--------------------------	-------------------------	-------------------------------	------------------------------	------------------------

[Start Page](#) | [Index](#) | [History](#) | [Last Change](#)

~ Welcome to NCHC Grid Architecture Research Group ~

### 【Project News】

- 2011-01-28: [2011 Project Deliverable Results](#) had updated~
- 2010-07-01: [2010 Project Deliverable Results](#) had updated~
- 2009-03-18: [2009 Project Deliverable Results](#) had updated~
- 2008-10-08: [2008 Project Deliverable Results](#) had updated~
- [雲端平台維護日誌](#)
- [Paper Reading Schedule \(讀書會行程\)](#)
- [Submission Deadline List \(投稿截止日期列表\)](#)
- [2008 Related NEWS](#)

### 【Project News】

#### 【1: Distributed / Parallel Computing】

- 1.1: [Kerrighed](#)
- 1.2: [BOINC](#)
- 1.3: [WebOS](#)
- 1.4: [Parallel Computing](#)

#### 【2: File System & Data Grid】

- 2.1 [Distributed & Parallel File System](#)
- 2.2 [FS Realition](#)

#### 【3: Virtualization】

#### 【Projects】

#### 【Related Conference Paper / Poster / Demo Submission】

#### 【Possible Technical Whitepaper Submission】

#### 【Technical Tutorials】

[Visitor](#)

### 【1: Distributed / Parallel Computing】

#### 1.1: [Kerrighed](#)

#### 1.2: [BOINC](#)

- 2008-05-27: [How to Setup BOINC example project](#)
- 2008-02-13: [How to Build BONIC Server](#)

2006~NOW

# Tools that I used to write notes

## 我作筆記的工具 (5) 線上書籤 **ReadItLater**

安裝：<http://readitlaterlist.com/>

The image shows a screenshot of the Read It Later website. The top navigation bar includes links for Login, Sign Up, API, and Help. Below the main logo, there are links for Firefox, iPhone/iPad, Android, Mobile, and All Browsers. A yellow box highlights the text "2010~NOW". The main content area features the slogan "One reading list, everywhere you are." and two call-to-action buttons: "Add to Firefox" and "Add to iPhone/iPad". The "Add to Firefox" button lists supported browsers: Internet Explorer, Chrome, Safari, and others. The "Add to iPhone/iPad" button lists supported devices: Android, BlackBerry, WebOS, and others. Below the main content, there are three icons representing different usage scenarios: a computer and phone for "Save", an airplane and train for "Read on or offline", and a car for "Access Anywhere".

2010~NOW

One reading list, everywhere you are.

**Add to Firefox**

Internet Explorer  
Chrome  
Safari  
others

**Add to iPhone/iPad**

Android  
BlackBerry  
WebOS  
others

**Save**

Save pages from your computer or phone


**Read on or offline**

Read at home, work, on the plane, or during your commute; *even without an internet connection*

**Access Anywhere**

Read It Later is integrated into many popular applications and platforms you may already use.





從歷史筆記  
找東西還真  
痛苦～

It's  
painful to  
search all  
my notes!



既然我有許多筆記放在網頁上，  
何不試試自家研發的抓抓龍呢？

# Crawlzilla 系統功能

## Feature of Crawlzilla

- 支援**叢集運算**及顧全  
安全性
- 支援**中文分詞**功能
- 支援多工網頁爬取
- 支援**多重搜尋引擎**
- **即時瀏覽資料庫資訊**
- 解決中文亂碼及中文  
支援
- 支援多國語言
- 網頁管理

如果您還不認識抓抓龍，

不妨看一下 2010 年 Hadoop 使用者會議的錄影

[http://cloud.nchc.org.tw/20101202/slides/01\\_Crawlzilla.wmv](http://cloud.nchc.org.tw/20101202/slides/01_Crawlzilla.wmv)

# System Architecture of Crawlzilla

## 抓抓龍系統架構

Web UI ( Crawlzilla Website + Search Engine)

JSP + Servlet + JavaBean

Nutch

Lucene

Crawlzilla System Management

Tomcat

Hadoop

PC1

PC2

PC3



# Comparison with other projects

## 抓抓龍與其他搜尋引擎專案的比較

	<b>Spidr</b>	<b>Larbin</b>	<b>Jcrawl</b>	<b>Nutch</b>	<b>Crawlzilla</b>
Install	Rube Package Install	Gmake Compiler and Install	Java Compiler and Install	Deploy Configure Files	<b>Provide Auto Installation</b>
Crawl website pages	O	O	O	O	<b>O</b>
Parser Content	X	X	X	O	<b>O</b>
Cluster Computing	X	X	X	O	<b>O</b>
Interface	Command	Command	Command	Command	<b>Web-UI</b>
Support Chinese Segmentation	X	X	X	X	<b>O</b>

# New Feature of Crawlzilla 1.0

## 抓抓龍 1.0 的新功能

- 支援多重使用者
- 採用 jQuery Ui 打造的新網頁管理介面
- 支援重新爬取 ( Re-Crawl )
- 支援排程爬取 ( Schedule / Crontab )
- 支援雲端服務：
  - 懶得自己建？沒關係！這裡可以試用！
  - <http://demo.crawlzilla.info>

# Multi-user Web Search Cloud Service : Crawlzilla 1.0

## Crawlzilla 1.0 多人版雲端服務 (1)

首先連線到 <http://demo.crawlzilla.info>

(1)

Home Crawl 索引庫管理 系統排程 Slave安裝 系統設定 登入/註冊

使用者登入

使用者註冊

使用者帳號	demo
使用者密碼	.....
密碼確認	.....
電子信箱	jazz@nchc.org.tw

Submit Reset

運算節點

- 工作排
- 空間管

(2)

(3)

▲ Step 1 : 新使用者註冊頁面

# Multi-user Web Search Cloud Service : Crawlzilla 1.0

## Crawlzilla 1.0 多人版雲端服務 (2)

接著等待管理者幫您開啓帳號！

尚未啓用會員列表

使用者	e-mail	申請時間	確認使用者
demo	jazz@nchc.org.tw	2011-12-04 21:18:37	Accept User

系統概況

項目	
會員人數	
搜尋引擎總數	



**Your account has been accepted from Crawlzilla System**

crawlzilla@gmail.com <crawlzilla@gmail.com>  
To: jazz@nchc.org.tw

We are pleased to inform you that your account has been accepted.

Please visit <http://140.110.134.197:8080> to build your search engine!

Thank you for use crawlzilla.

–This mail sent by the system automatically, do not reply to this mail.–

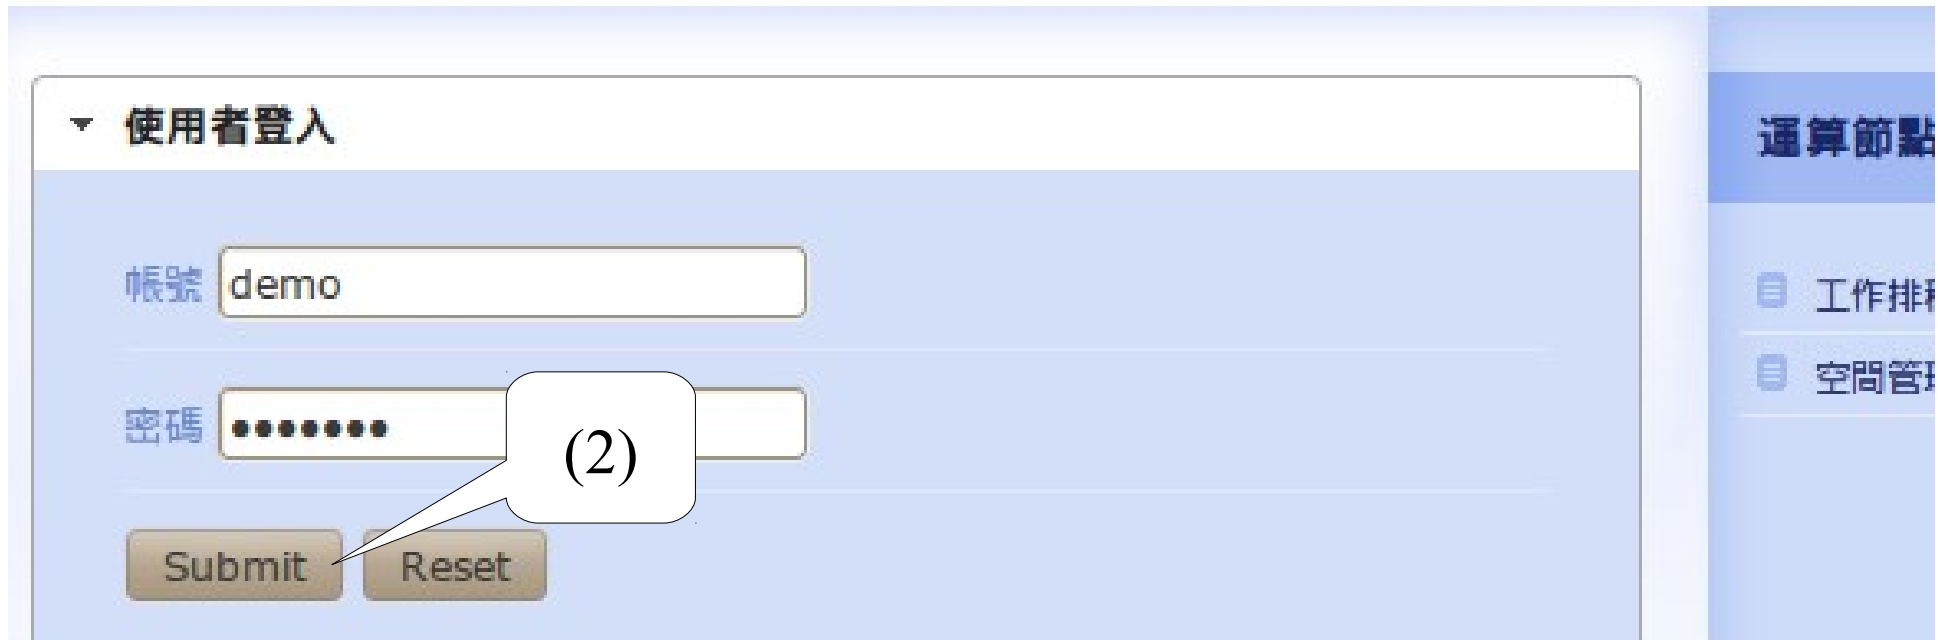
▲ Step 2 : 等待管理者啓用，您會收到啓用通知



## Crawlzilla 1.0 多人版雲端服務 (3)

重新連線到 <http://demo.crawlzilla.info>

(1)



▲ Step 3 : 登入您的個人化管理頁面

## Crawlzilla 1.0 多人版雲端服務 (4)

建立新的搜尋索引庫

(1)

Home

Crawl

索引庫管理

系統排程

### Crawl-建立搜尋引擎

#### ▼ Crawl Setup

索引庫名稱: all

(2)

(5)

#### ▼ Crawl Setup

索引庫名稱: all

輸入欲爬取的網址(可多行):

http://cloud.nchc.org.tw/~jazz/rii\_export.html  
http://cloud.nchc.org.tw/~jazz/firefox\_bookmarks.html  
http://trac.nchc.org.tw/grid/wiki/jazz/Work\_2011  
http://trac.nchc.org.tw/grid/wiki/jazz/Work\_2010  
http://trac.nchc.org.tw/grid/wiki/jazz/Work\_2009  
http://trac.nchc.org.tw/grid/wiki/jazz/Work\_2008

(3)

爬取深度設定: 2

(4)

註: 因系統負載有限, 此一體驗網站 能建立3個索引庫, 不便之處請見諒

▶ 排程設定 (Option)

Submit

Reset

▲ Step 4 : 輸入索引庫名稱、起始網址與搜尋深度

## Crawlzilla 1.0 多人版雲端服務 (5)

接著只能靜候抓抓龍幫您建立搜尋索引庫

HRER to check the status of your jobs!' is provided. At the bottom, a red warning states: 'The crawling time depends on your system performance, URLs number, and depth.' On the right side, there is a sidebar with a blue background and white text. It contains a '搜尋引擎列表' section and a '運算節點即時狀態' section. The '運算節點即時狀態' section has two items: '工作排程器狀態' and '空間管理員狀態'. A white speech bubble with the number '(1)' points to the '工作排程器狀態' item."/>

Crawlzilla Search Engine Hands-on Display

Home Crawl 索引庫管理 系統排程 Slave安裝 系統設定 系統登出

**Setup has been submit !!! But, it need time to crawl !!!**

ex. 4URLs with 1 depth -> 10~20 minute  
4URLs with 2 depth -> 40~80 minute  
100URLs with 10 depth -> very very long

click [HRER](#) to check the status of your jobs!

**The crawling time depends on your system performance, URLs number, and depth.**

搜尋引擎列表

運算節點即時狀態

- 工作排程器狀態
- 空間管理員狀態

(1)

▲ Step 5 : 等待抓抓龍幫您建立專屬的搜尋索引庫

## Crawlzilla 1.0 多人版雲端服務 (6)

### 索引庫管理

Home Crawl **索引庫管理** 系統排程 Slave安裝 系統設定

(1)

### 索引庫管理

系統爬取狀態

索引庫名稱	爬取狀態	爬取時間	刪除狀態
all	crawling	0h:3m:31s	

(2)

▲ 您可以在索引庫管理看到目前爬取已使用的時間

## Crawlzilla 1.0 多人版雲端服務 (7)

搜尋索引庫建立完成後，  
可以於「索引庫管理」處進行**手動**重新爬取（re-crawl）  
或刪除索引庫的動作

索引庫管理

系統爬取狀態

索引庫名稱	爬取狀態	爬取時間	刪除狀態
-------	------	------	------

索引庫列表

索引庫名稱	建立時間	爬取時間	爬取深度	索引庫操作	執行
ril	2011-12-04 16:15:24	0:18:13	2	Select Re-Crawl Delete IDB	Run

告訴您  
該索引庫  
花了多久  
時間爬取

▲ 您可以在索引庫管理進行手動重新爬取或刪除索引庫



## Crawlzilla 1.0 多人版雲端服務 (8)

可以於「系統排程」處進行**排程**重新爬取 ( schedule )

The screenshot shows the '系統排程' (System Scheduling) page in the Crawlzilla 1.0 interface. The page has a navigation bar at the top with links for Home, Crawl, 索引庫管理, 系統排程 (highlighted), Slave安裝, and 系統設定. The main content area is titled '索引庫爬取排程' (Index Library Crawl Scheduling) and is divided into two sections: '排程資訊' (Scheduling Information) and '新增排程' (Add Scheduling).

Callout (1) points to the '系統排程' menu item in the navigation bar. Callout (2) points to the '刪除排程' (Delete Scheduling) button in the table header. Callout (3) points to the '索引庫選擇' (Index Library Selection) dropdown menu. Callout (4) points to the 'Submit' button at the bottom of the form.

索引庫名稱	爬取排程時間	週期	刪除排程
-------	--------	----	------

新增排程

索引庫選擇

排程日期

排程時間  時  分

週期

▲ 您可以在索引庫管理看到目前爬取已使用的時間

## Crawlzilla 1.0 多人版雲端服務 (9)

可以於「索引庫管理」處進行即時讀取索引庫資訊

索引庫列表

索引庫名稱	建立時間	爬取時間	爬取深度	索引庫操作	執行
ril	2011-12-04 16:15:24	0:18:13	2	Select ▼	Run

(1)

(2)

### 關於搜尋引擎ril

▼ 基本資訊

索引庫名稱 ril

搜尋引擎連結位置 /home/crawler/crawlzilla/user/jazzwang/IDB/ril/index

搜尋引擎狀態 OK

爬取深度 2

建立時間 20111204-15:57:16

執行時間 0:18:13

起始連結 [http://cloud.nchc.org.tw/~jazz/ril\\_export.html](http://cloud.nchc.org.tw/~jazz/ril_export.html)

▶ 立即搜尋及網頁嵌入語法

▲ 您可以在索引庫管理取得即時搜尋索引庫的資訊

## Crawlzilla 1.0 多人版雲端服務 (10)

在搜尋索引庫資訊中，可以取得加入個人化搜尋引擎的語法



The screenshot displays a web page titled "關於搜尋引擎ril". It features a navigation menu with "基本資訊" and "立即搜尋及網頁嵌入語法". The "立即搜尋及網頁嵌入語法" section is expanded, showing a search engine logo for "CRAWLZILLA" and a search input field. Below this, the "語法" section displays the following HTML code:

```
  
  
<form name="search" action="http://demo.crawlzilla.info/jazzwang_ril/search.jsp" method="get">  
  
<input name="query" size=15></form>
```

Callout (1) points to the search engine logo and input field. Callout (2) points to the HTML code block.

▲ 您可以在索引庫管理取得嵌入網頁的語法

## Crawlzilla 1.0 多人版雲端服務 (11)

索引庫內容說明了共搜尋了多少個文件（網頁），  
並且會統計最常到訪的網址排行榜

索引庫內容 ril

資料總覽

總共文字數 213155

文件檔數量 3234

索引庫更新日期 Sun Dec 04 16:15:23 CST 2011

被搜尋分析到的網址

分析的文件型態

出現次數前五十分的字符

(1)

索引庫內容 ril

資料總覽

被搜尋分析到的網址

Order	Contents	Counts	Order	Contents
0	site:www.digitimes.com.tw	204	1	site:www.bnext.c
2	site:groups.google.com	74	3	site:highscalabilit
4	site:www.theregister.co.uk	49	5	site:www.ithome
6	site:www.cloudera.com	47	7	site:gigaom.com
8	site:en.wikipedia.org	39	9	site:www.networ
10	site:wiki.apache.org	37	11	site:www.zdnet.c
12	site:www.howtoforge.com	33	13	site:www.freegro
14	site:ajaxian.com	29	15	site:news.networ
16	site:www.linuxfordevices.com	25	17	site:ieeexplore.ie
18	site:www.linux-mag.com	24	19	site:insidehpc.cor
20	site:www.readwriteweb.com	22	21	site:only-percept
22	site:www.nosqldatabases.com	19	23	site:www.openfo
24	site:www.inside.com.tw	17	25	site:www.sys-cor

(2)

▲ 索引庫內容提供了許多統計資訊

## Crawlzilla 1.0 多人版雲端服務 (12)

此外，索引庫內容也說明了共搜尋了哪幾種文件，並且會統計最常出現的關鍵字排行榜

### 索引庫內容 ril

▶ 資料總覽

▶ 被搜尋分析到的網址

▼ 分析的文件型態

Order	Contents	Counts	Order	Contents	Counts
0	type:text	3232	1	type:text/html	3231
2	type:html	3231	3	type:xhtml+xml	2
4	type:application/xhtml+xml	2	5	type:application	2
6	type:text/plain	1	7	type:plain	1

(1)

▶ 出現次數前五十分的字符

### 索引庫內容 ril

▶ 資料總覽

▶ 被搜尋分析到的網址

▶ 分析的文件型態

▼ 出現次數前五十分的字符

Order	Contents	Counts	Order	Contents	Counts
0	content:a	2350	1	content:1	2346
2	content:2011	2240	3	content:2	2235
4	content:s	2218	5	content:3	2082
6	content:4	2030	7	content:all	1988
8	content:com	1903	9	content:about	1879
10	content:from	1861	11	content:you	1851
12	content:5	1804	13	content:10	1794
14	content:more	1786	15	content:can	1746
16	content:2010	1714	17	content:new	1653
18	content:your	1626	19	content:i	1620
20	content:use	1609	21	content:data	1602

(2)

▲ 索引庫內容提供了許多統計資訊

# 你也可以擁有自己的搜尋引擎 !!!

## Start from Here!

- **Crawlzilla** 示範多人自訂搜尋雲端服務
  - <http://demo.crawlzilla.info>
- **Crawlzilla @ Google Code Project Hosting ( 中文 )**
  - <http://code.google.com/p/crawlzilla/>
- **Crawlzilla @ Source Forge (Tutorial in English)**
  - <http://sourceforge.net/p/crawlzilla/home/>
- **Crawlzilla User Group @ Google**
  - <http://groups.google.com/group/crawlzilla-user>
- **NCHC Cloud Computing Research Group**
  - <http://trac.nchc.org.tw/cloud>



# Authors of Crawlzilla

## 抓抓龍作者群

陳威宇 (左)

***waue@nchc.org.tw***

***waue0920@gmail.com***

郭文傑 (中)

***rock@nchc.org.tw***

***goldjay1231@gmail.com***

楊順發 (右)

***shunfa@nchc.org.tw***

***shunfa@gmail.com***





## Questions?

Slides - <http://trac.nchc.org.tw/cloud>

**Jazz Wang**  
**Yao-Tsung Wang**  
**jazz@nchc.org.tw**



Powered by DRBL