

Sviluppo di un ambiente software per la consultazione offline di Wikipedia

Relatori: Prof. Marco Mezzalama
Prof. Juan Carlos De Martin
Ing. Alessandro Ugo
Candidato: Emanuele Richiardone




Novembre 2007

Laurea Magistrale in Ingegneria Informatica
III Facoltà di Ingegneria - Politecnico di Torino

Wikipedia

- Vasta enciclopedia collaborativa (*web2.0*)
 - Multilingue, buona qualità, molti argomenti
 - Fonte libera di sapere (*open content*)
 - Crescita più che lineare
- *wiki* – *wikitext* – MediaWiki
 - PHP e MySQL, estensioni
 - Voci: normali/redirect/categorie/template
 - Non solo testo
 - Licenze d'uso libere



Progetto WaNDA

- Accesso offline ai contenuti:
 - Digital divide
 - Educational
 - Enciclopedia tascabile
 - Open content
- Wikipedia è strutturata per l'accesso online
- Progetto WaNDA (linux@studenti)
- Studio di meccanismi e implementazioni

Caratteristiche

- Definizione di un processo di costruzione:
 - Mantenibile nel tempo
 - Utilizzo di software opensource
- Definizione di un formato:
 - Contenente testi enciclopedici e immagini
 - Per supporto eterogeneo “hot plug” (DVD, schede di memoria, pendrive, microdrive, ...) e non
 - Accessibile da generica postazione (multiplatforma)
 - Consultazione intuitiva senza richiedere installazione di software apposito



Formato del supporto

- Gerarchia di directory, detto *albero*:
 - *Ossatura* comune alle diverse versioni:
 - componenti statiche (HTML, CSS, ...)
 - componenti dinamiche (JavaScript, GET HTTP)
 - Voci normali, categorie e redirect costruite dal processo sotto forma di pagine HTML
 - Immagini immesse dagli utenti e generate
- Impacchettamento per la distribuzione:
 - Immagine ISO-9660:1999
 - Archivio per FAT32


Componenti dinamiche

- Impiego di tecnologie standard e diffuse:
 - JavaScript (*ECMAScript v3*)
 - *Percent-encoding, GET HTTP*
- Redirezione delle pagine
- Motore di ricerca offline
 - Basato su vettore associativo frammentato
 - Ricerca *esatta*, ricerca *estesa*
 - Ricerca completa
 - Estrazione casuale



Ricerca completa

Ricerca esatta




Ricerca estesa

Processo di conversione

- Software opensource e multiplatforma
- Piattaforma x86 con UNIX derivato (massima compatibilità con Wikipedia)
- DBMS MySQL, PHP-CLI, JVM, mawk
- Due gruppi di operazioni:
 - Download dei contenuti e importazione nel DBMS
 - Esportazione del *wikitext* e costruzione dell'*albero*

Processo di conversione



Prima fase

- Contenuti enciclopedici testuali disponibili sotto forma di dump XML compressi, aggiornati ogni 1-2 mesi
 - Download dei dump
 - Decompressione e filtro AWK, per ridurre la mole di dati da gestire di un fattore 1:20 (~20 ore)
 - Traduzione dell'XML in comandi SQL ed importazione nel DBMS locale



Seconda fase




- Utilizza un'installazione di MediaWiki con estensioni e il DBMS
- Totalmente gestita da un codice PHP:
 - Filtri SQL sui contenuti (voci segnate, pagine non enciclopediche, case-insensitive)
 - Creazione di una tabella di servizio
 - Estrazione delle voci (normali, categorie, redirect) e traduzione del *wikitext* utilizzando MediaWiki, con conseguente scrittura dei file HTML nell'albero (~40 ore)

Seconda fase

- Lista delle pagine e vettori per la ricerca
- Integrazione delle immagini utente secondo licenza e di quelle generate dal wikitext
- Impacchettamento nei due formati
- Le due fasi in totale durano alcuni giorni
- Le due operazioni più lente sono state ottimizzate
- Banda di accesso alla memoria secondaria, cache del processore

Controllo del formato

- Verifica automatica in PHP di indici, collegamenti e immagini
- Comunità di testing
 - Più proficua data la natura degli eventuali problemi
- Modifiche ai contenuti vanno eseguite sul DBMS prima della seconda fase
- Inesattezze implicite del sistema



Stato del progetto

- Obiettivi tecnologici raggiunti:
 - Buona qualità del formato
 - Soluzione mantenibile
 - Supporto testato su diverse piattaforme
- Applicabile ad altri contenuti:
 - Wikimedia (altre lingue, Wiktionary, ...)
 - Qualsiasi installazione di MediaWiki per ottenere versioni offline di un *wiki*
- Software rilasciato sotto GNU GPLv2



Ostacoli legali

- Diffusione online dei pacchetti
 - Coperta da limitazione di responsabilità se il soggetto è Wikimedia Foundation, altri?
 - D.Lgs 70/2003 (commercio elettronico)
- Distribuzione fisica di supporti
 - Editoria? (legge 47/1948)
- Ambito del progetto non proprio contemplato: licenze d'uso libere con nuove tecnologie

Conclusioni

- Ottimo progetto di diffusione dell'open content e dell'opensource
- Innovative soluzioni multiplatforma
- Pesanti ostacoli giuridici sulle licenze e alla diffusione open content
- Futuro del progetto:
 - Miglioramenti?
 - Scalabilità del supporto

