



InformaticaUmanistica

Lezione 12

Funzionalità avanzate di Greenstone

Pasquale Savino

ISTI - CNR



UNIVERSITÀ DI PISA

Sommario

- ◆ **Processo di funzionamento di importazione e building di una collazione**
 - Import
 - Build

- ◆ **Il configuration file**

- ◆ **Uso di**
 1. Plug-in
 2. Classifiers
 3. Indici

- ◆ **Formattazione delle pagine web**

Digital Library Collections

- ◆ **Vi è una distinzione tra**
 - **COSTRUIRE** una collezione
 - **FORNIRE** informazioni agli utenti
- ◆ **È la stessa distinzione che esiste tra il ‘compile-time’ ed il ‘runtime’ nei linguaggi di programmazione**
- ◆ **La fase di costruzione è necessaria per preparare tutte le strutture dati che vengono poi utilizzate nella fase di delivery delle informazioni**

Costruzione manuale delle Collezioni

Costruzione di una collezione

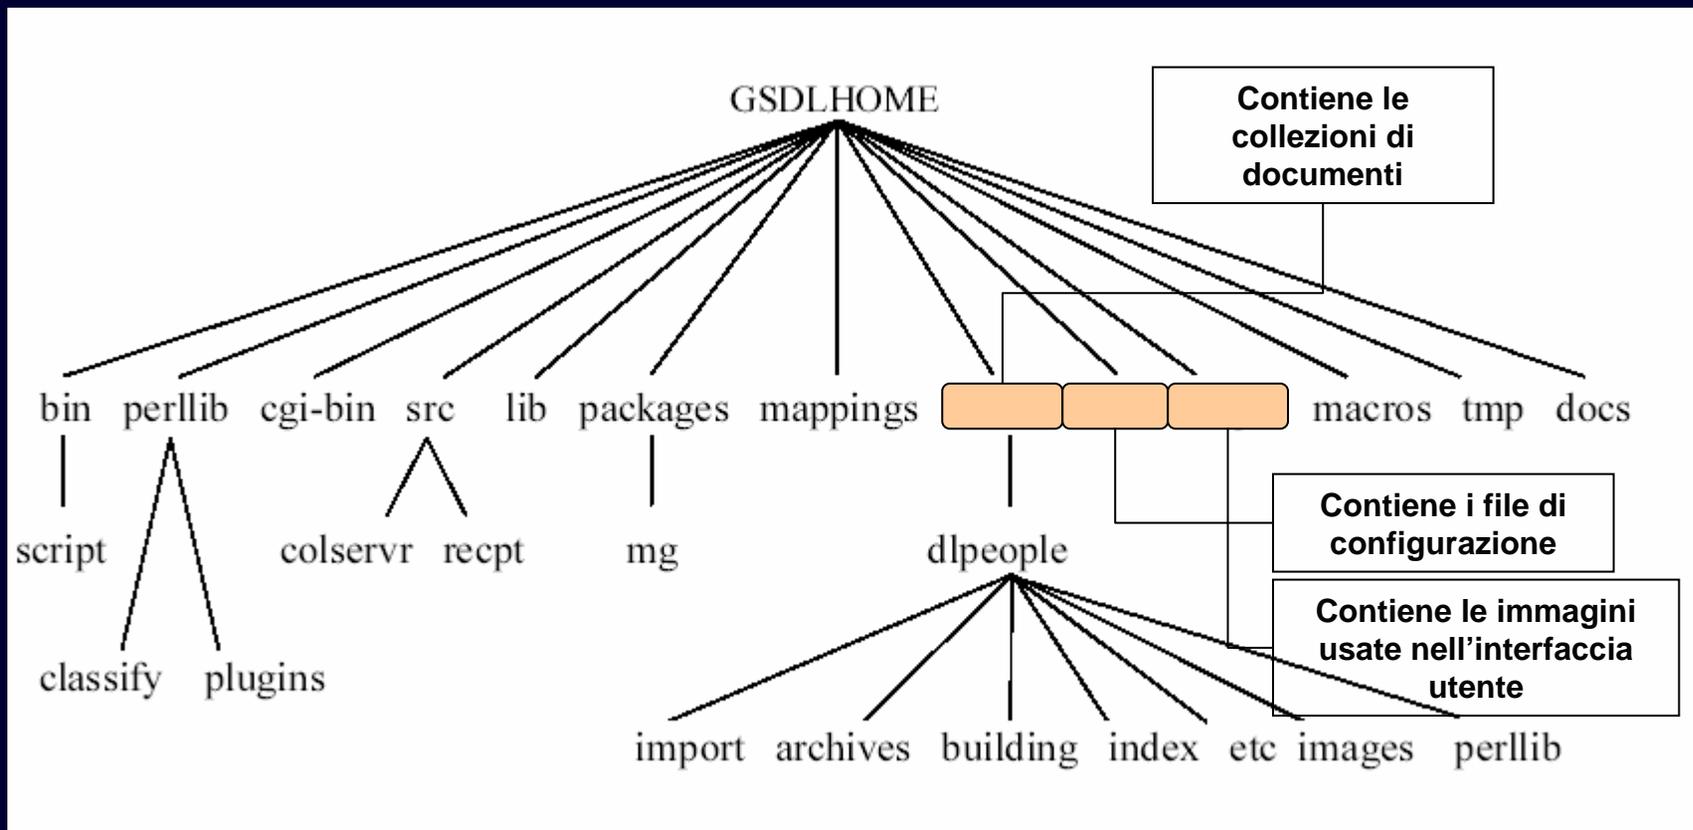
- ◆ **Il processo che consiste nel prendere un insieme di documenti ed i metadati che li descrivono e creare tutti gli indici e le strutture dati che ne supportano la ricerca (search), il browsing, e la visualizzazione**

Costruzione di una collezione

- ◆ **La costruzione di una collezione prevede quattro fasi**
 - **Make**
 - Creare uno scheletro di strutture e di file nel quale verranno inseriti i dati della collezione
 - **Import**
 - Importare i documenti ed i metadati e convertirli nel formato Greenstone
 - **Build**
 - Costruire gli indici e le strutture dati richieste
 - **Install**
 - Rendere operativa la collezione

Make

- ◆ Vengono create le seguenti cartelle (directories)

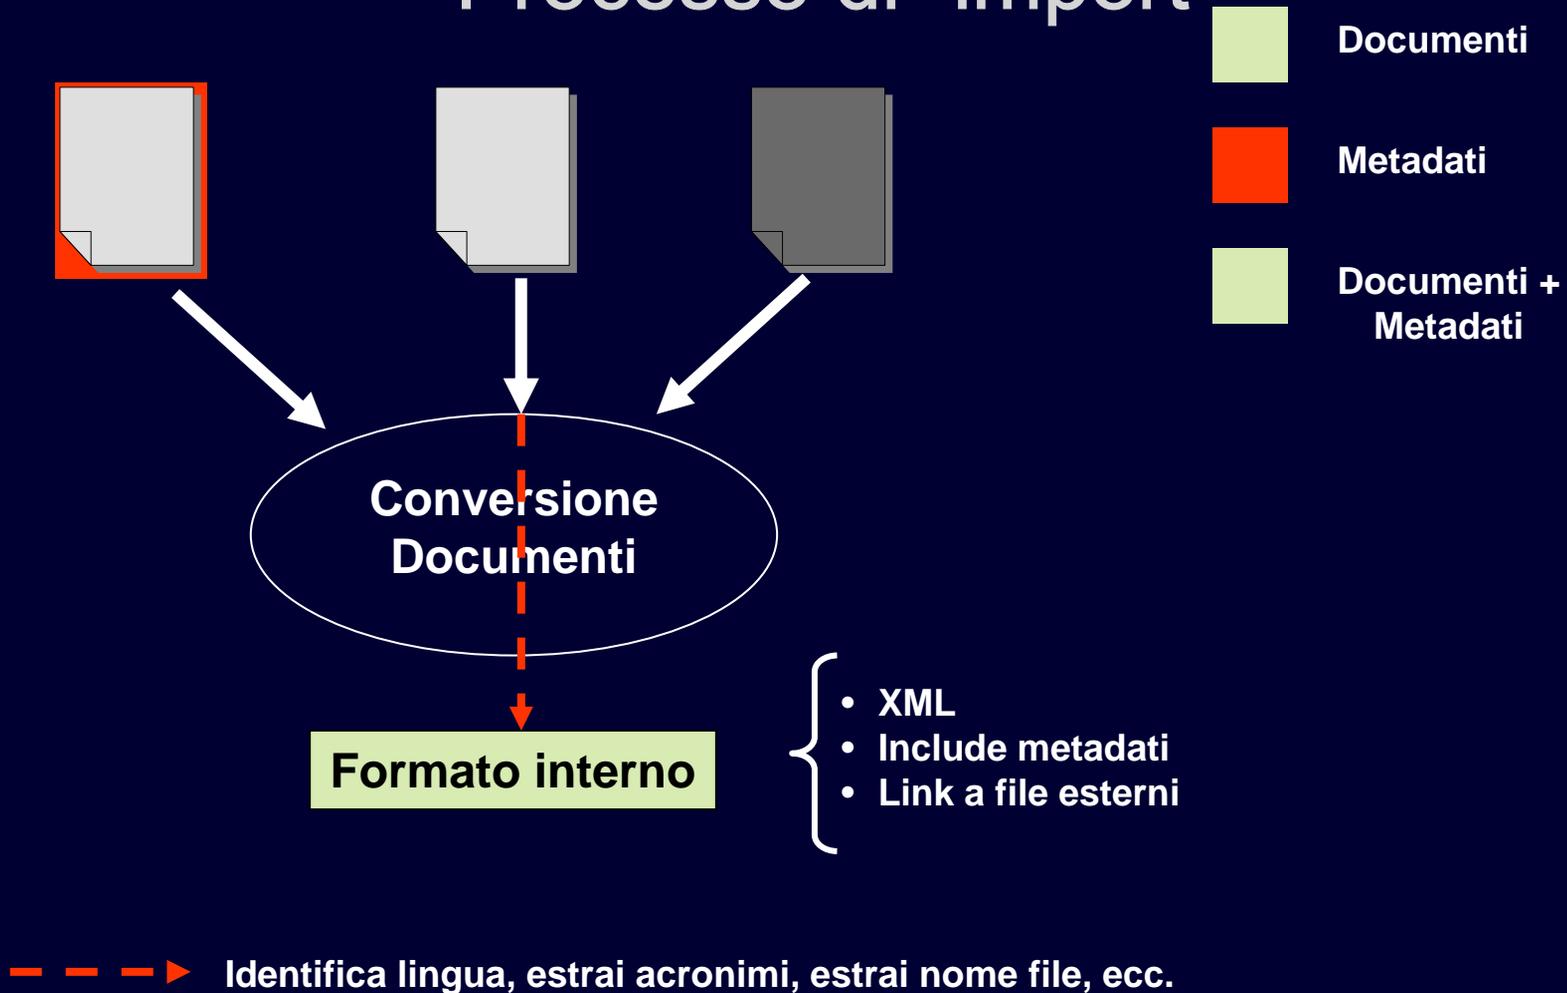


<i>bin</i>	Executable code, including binaries in the directory with your O/S name.
<i>bin/script</i>	Perl scripts used for creating and building collections (for example <i>import.pl</i> and <i>buildcol.pl</i>). To get a description of any of these programs, type their name at the command prompt.
<i>perllib</i>	Perl modules used at import and build time (plugins, for example).
<i>perllib/plugins</i>	Perl code for document processing plugins.
<i>perllib/classify</i>	Perl code for classifiers (for example the AZList code that makes a document list based on the alphabetical order of some attribute).
<i>cgi-bin</i>	All Greenstone CGI scripts, which are moved to the system cgi-bin directory.
<i>tmp</i>	Directory used by Greenstone for storing temporary files.
	
<i>src</i>	C++ code used for serving collections via a web server.
<i>src/colservr</i>	C++ code for serving collections—answering queries and the like.
<i>src/recpt</i>	C++ code for getting queries from the user interface and formatting query responses for the interface.
<i>packages</i>	Source code for non-Greenstone software packages that are used by Greenstone.
<i>packages/mg</i>	The source code for MG, the compression and indexing software used by Greenstone.
<i>mappings</i>	Unicode translation tables (for example for the GB Chinese character set).
<i>macros</i>	The macro files used for the user interface.
	
<i>lib</i>	C++ source code used by both the collection server and the receptionist.
	
<i>docs</i>	Documentation.

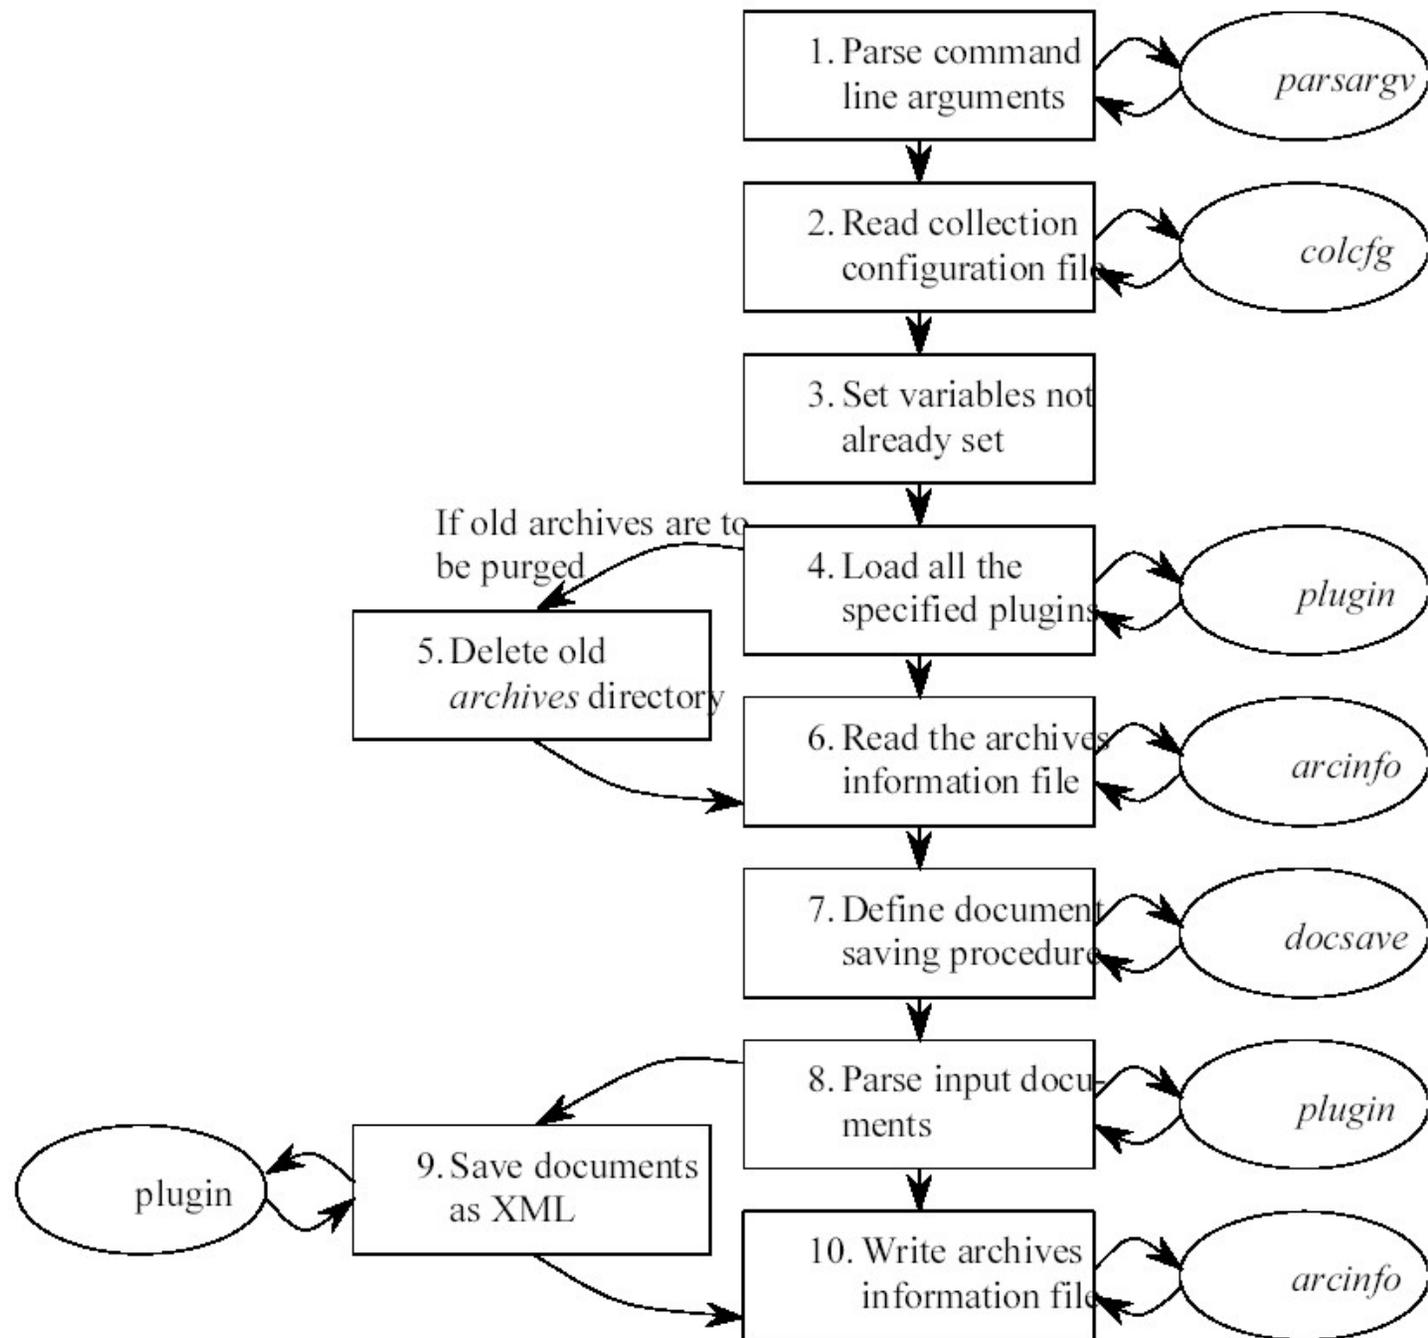
Processo di importazione

- ◆ Inserisce i documenti ed i metadati nel sistema in un formato XML standard.
- ◆ I documenti originali sono inseriti nella cartella *import*
- ◆ Il processo di “import” inserisce i file in formato XML standard nella cartella *archives*
- ◆ A questo punto i documenti originali possono essere cancellati
 - Nel caso la collezione debba essere rigenerata, questo può essere fatto a partire dai documenti archiviati
- ◆ Ogni nuovo documento da aggiungere alla collezione viene inserito nella cartella *import*. Il processo di importazione viene ripetuto
- ◆ Per conservare il formato originale dei documenti, non bisogna cancellare i file in archivio

Processo di "import"



II processo “import”



Opzioni per “import”

<i>-verbosity</i>	Number 0-3	Control how much information about the process is printed to standard error; 0 gives a little, 3 gives lots.
<i>-archivedir</i>	Directory name	Specify where the Greenstone archive files are stored—that is, where <i>import.pl</i> puts them and where <i>buildcol.pl</i> finds them. Defaults to <i>GSDLHOME/collect/col_name/archives</i>
<i>-maxdocs</i>	Number >0	Indicates the maximum number of documents to be imported or built. Useful when testing a new collection configuration file, or new plugins.
<i>-collectdir</i>	Directory name	Specify where the collection can be found. Defaults to <i>GSDLHOME/collect</i>
<i>-out</i>	Filename	Specify a file to which to write all output messages, which defaults to standard error (the screen). Useful when working with debugging statements.
<i>-keepold</i>	None	Do not remove the result of the previous import or build operation. In the case of import, do not remove the contents of the <i>archives</i> directory; when building, do not remove the content of the <i>building</i> directory.
<i>-debug</i>	None	Print plugin output to standard output.

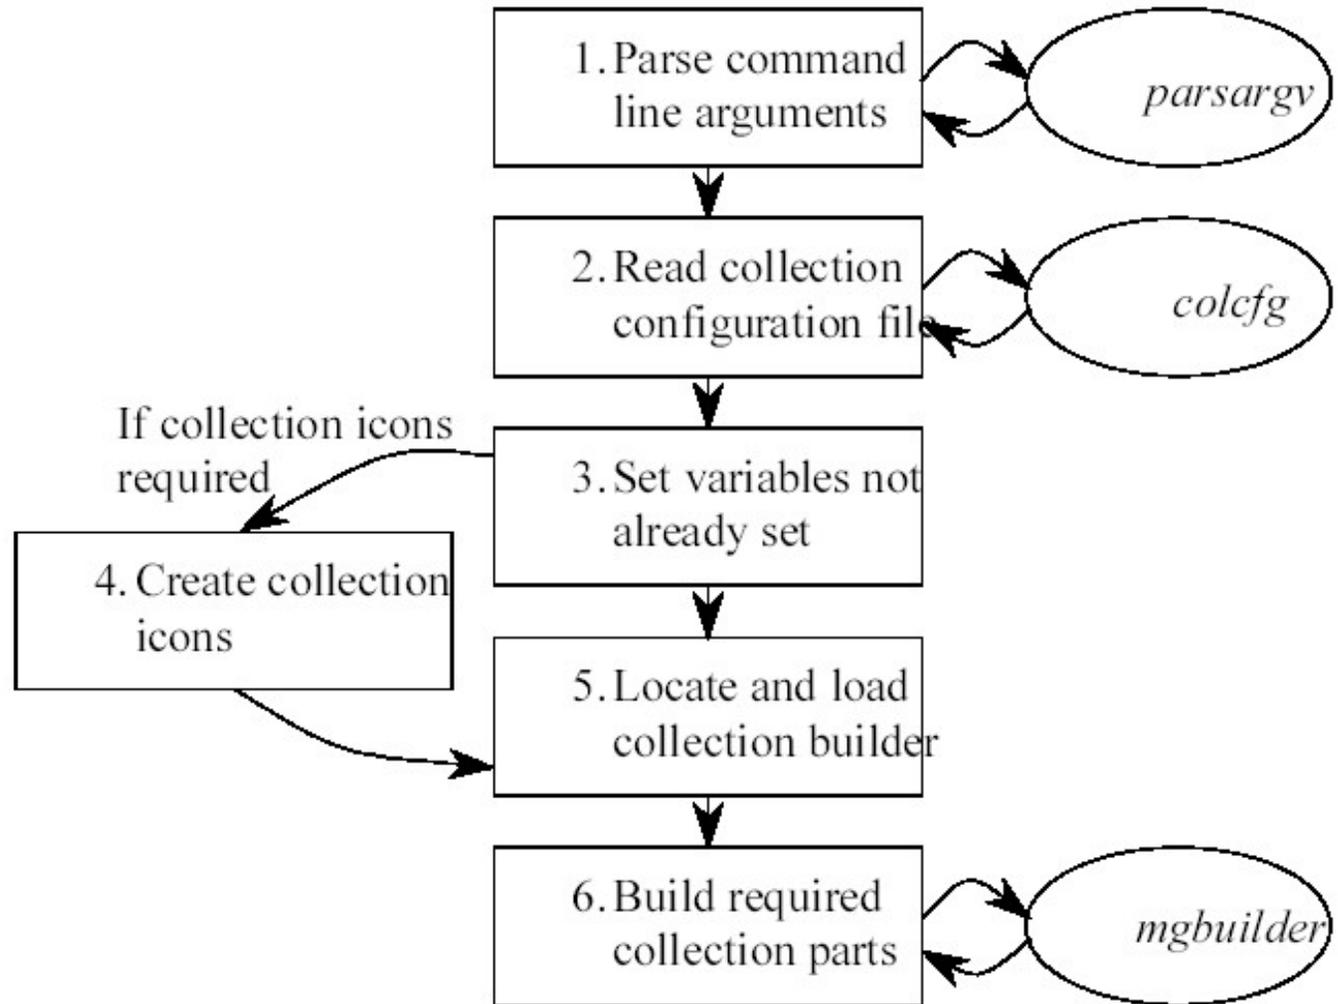
Opzioni aggiuntive per “import”

<i>-importdir</i>	Directory name	Where material to be imported is found. Defaults to <i>GSDLHOME/collect/col_name/import</i> .
<i>-removeold</i>	None	Remove the contents of the <i>archives</i> directory before importing.
<i>-gzip</i>	None	Zip up the Greenstone archive documents produced by <i>import</i> (ZIPPlug must be included in the plugin list, and <i>gzip</i> must be installed on your machine).
<i>-groupsize</i>	Number >0	Number of documents to group together into one Greenstone archive file, defaults 1 (that is, one document per file).
<i>-sortmeta</i>	Metadata tag name	Sort the documents alphabetically by the named metadata tag. However, if the collection has more than one group in the collection (i.e. <i>groupsize</i> >1), this functionality is disabled.
<i>-OIDtype</i>	<i>hash</i> or <i>incremental</i>	Method of creating OIDs for documents: <i>hash</i> hashes the content but is slow; <i>incremental</i> simply assigns document numbers sequentially, and is faster.

Il processo di “build”

- ◆ **Crea gli indici e le strutture dati che rendono operativa la collezione**
- ◆ **Gli indici per l'intera collezione vengono creati contemporaneamente**
 - Il processo di “build” non opera incrementalmente
 - Se si aggiunge nuovo material ad un archivio, bisogna ricreare l'intera collezione (ripetere il processo di “build”)

Il processo di "build"



Opzioni per “build”

<i>-verbosity</i>	Number 0-3	Control how much information about the process is printed to standard error; 0 gives a little, 3 gives lots.
<i>-archivedir</i>	Directory name	Specify where the Greenstone archive files are stored—that is, where <i>import.pl</i> puts them and where <i>buildcol.pl</i> finds them. Defaults to <i>GSDLHOME/collect/col_name/archives</i>
<i>-maxdocs</i>	Number >0	Indicates the maximum number of documents to be imported or built. Useful when testing a new collection configuration file, or new plugins.
<i>-collectedir</i>	Directory name	Specify where the collection can be found. Defaults to <i>GSDLHOME/collect</i>
<i>-out</i>	Filename	Specify a file to which to write all output messages, which defaults to standard error (the screen). Useful when working with debugging statements.
<i>-keepold</i>	None	Do not remove the result of the previous import or build operation. In the case of import, do not remove the contents of the <i>archives</i> directory; when building, do not remove the content of the <i>building</i> directory.
<i>-debug</i>	None	Print plugin output to standard output.

Opzioni aggiuntive per “build”

<i>-builddir</i>	Directory name	Specify where the result of building is to be stored (defaults to <i>GSDLHOME/collect/col_name/building</i>).
<i>-index</i>	Index name (e.g. <i>section:Title</i>)	Specify which indexes to build. This defaults to all the indexes indicated in the collection configuration file.
<i>-allclassifications</i>	None	Prevent the build process from removing classifications that include no documents (for example, the “X” classification in titles if there are no documents whose titles start with the letter <i>X</i>).
<i>-create_images</i>	None	Create collection icons automatically (to use this, GIMP, and the Gimp Perl module, must be installed).
<i>-mode</i>	<i>all</i> , <i>compress_text</i> , <i>infodb</i> , or <i>build_index</i>	Determine what the build process is to do (defaults to <i>all</i>). <i>All</i> does a full build, <i>compress_text</i> only compresses the document text, <i>infodb</i> creates a database of information pertaining to the collection—name, files, associated files, classification information and the like—and <i>build_index</i> builds the indexes specified in the collection configuration file or on the command line.
<i>-no_text</i>		Don’t store compressed text. This option is useful for minimizing the size of the built indexes if you intend always to display the original documents at run-time.

Collection Configuration File

Collection Configuration File

◆ Il Collection Configuration File

- Definisce la struttura della collezione
- Specifica come deve essere costruita la collezione
- Specifica come deve essere visualizzata la collezione

◆ Ogni linea del Collection Configuration File è una coppia “attributo”, “valore”

Collection Configuration File [1/4]

<i>creator</i>	E-mail address of the collection's creator
<i>maintainer</i>	E-mail address of the collection's maintainer
<i>public</i>	Whether collection is to be made public or not
<i>beta</i>	Whether collection is beta version or not
<i>indexes</i>	List of indexes to build
<i>defaultindex</i>	The default index
<i>subcollection</i>	Define a subcollection based on metadata
<i>indexsubcollections</i>	Specify which subcollections to index
<i>defaultsubcollection</i>	The default indexsubcollection
<i>languages</i>	List of languages to build indexes in
<i>defaultlanguage</i>	Default index language
<i>collectionmeta</i>	Defines collection-level metadata
<i>plugin</i>	Specify a plugin to use at build time
<i>format</i>	A format string (explained below)
<i>classify</i>	Specify a classifier to use at build time

Collection configuration file [2/4]

```
creator      username@email.com
maintainer   username@email.com
public       true
beta         false
```

Indici creati durante il build della collezione

Plugin da usare per convertire documenti nel formato Greenstone

Classificatore per creare una lista alfabetica di titoli

Collection configuration file [3/4]

Formato di presentazione dei metadati

Metadati della collezione

Collection configuration file [4/4]



Describe la collezione. Viene usato come testo nella sezione "About this collection"



Immagine che descrive la collezione. Viene usata nella home page della collezione

Subcollections [1/4]

- ◆ Greenstone permette di costruire sotto-collezioni, e di costruire indici per ognuna di esse.
- ◆ Consideriamo una collezione costituita documenti testuali, alcuni tratti dal “Journal of Digital Libraries” ed altri no
- ◆ Vogliamo creare due sotto-collezioni ed indici al livello di section

```
indexes      section:text
```

```
subcollection dl "Title/^Journal of Digital Libraries/i"
```

```
subcollection other "!Title/^Journal of Digital  
Libraries/i"
```

```
indexsubcollections dl other dl,other
```

Subcollections [2/4]

- ◆ **Lo stesso meccanismo può essere utilizzato per creare indici per collezioni che contengono documenti in diverse lingue**
- ◆ **La lingua del documento è un metadato (en per l'inglese, it per italiano, ecc.)**

```
indexes      section:text  section:Title  document:text  
Languages   it  en  fr
```

- ◆ **Vengono creati indici separati per section text, section title, e document text per le tre diverse lingue (9 indici in totale)**

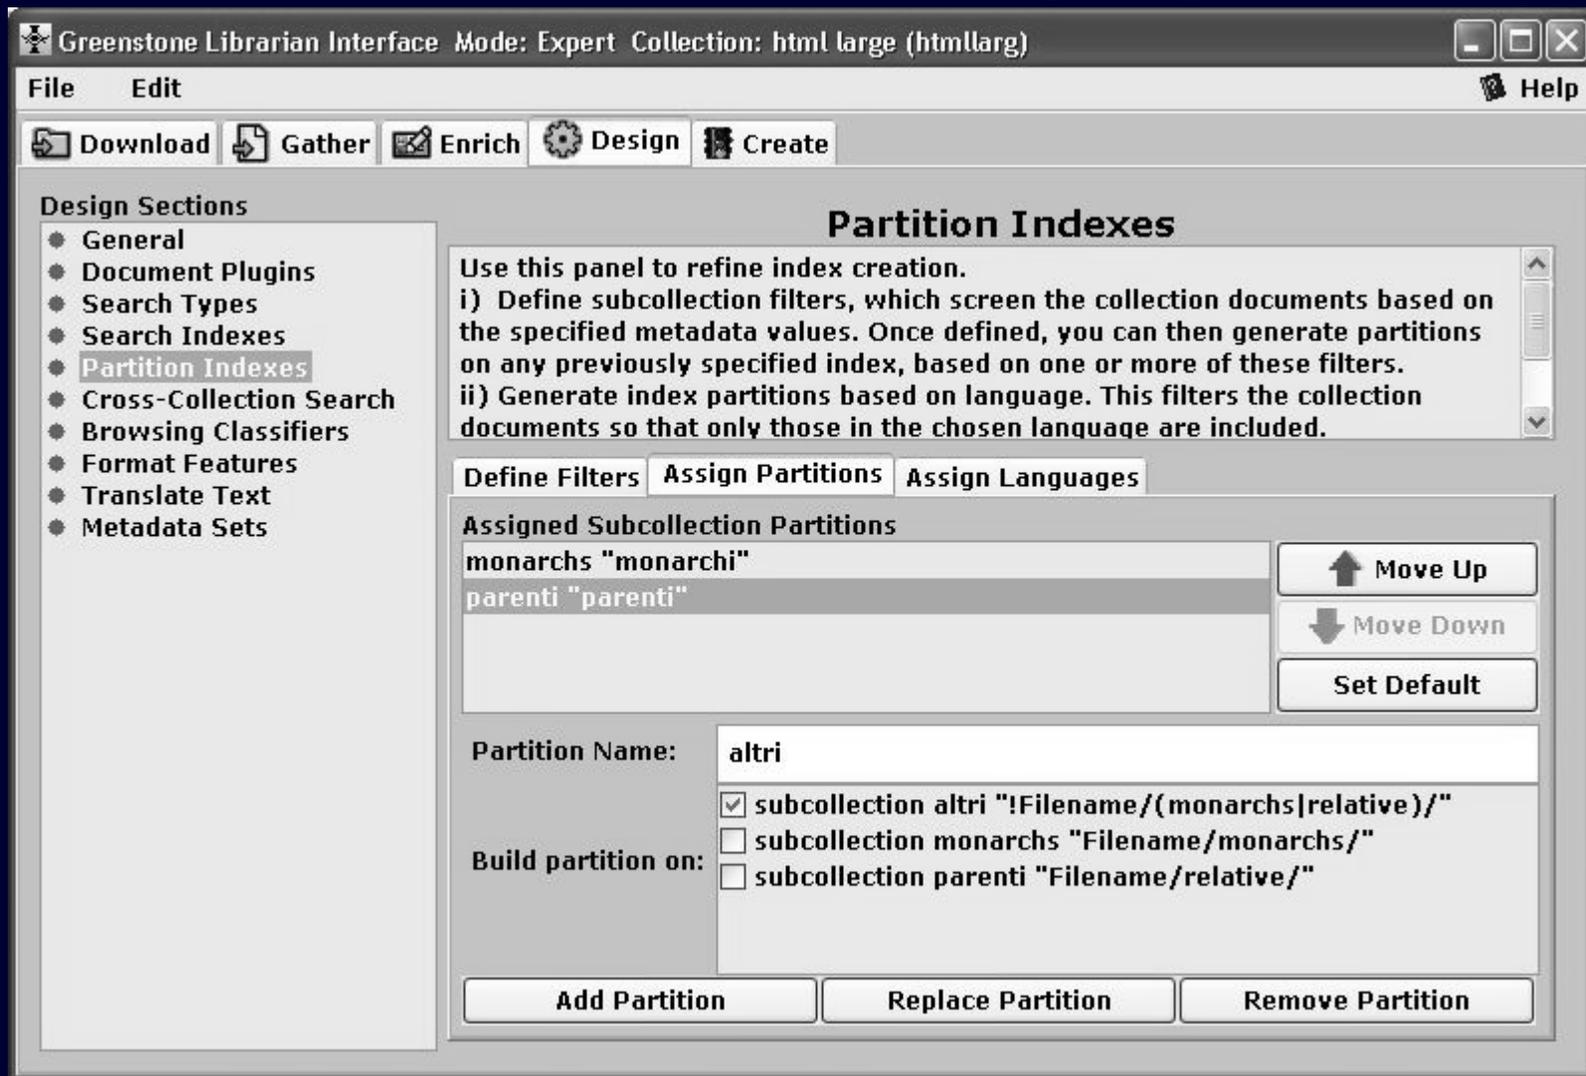
◆ Definizione dei filtri

Subcollections [3/4]

The screenshot shows the 'Partition Indexes' panel in the Greenstone Librarian Interface. The window title is 'Greenstone Librarian Interface Mode: Expert Collection: html large (html larg)'. The menu bar includes 'File', 'Edit', and 'Help'. The toolbar contains icons for 'Download', 'Gather', 'Enrich', 'Design', and 'Create'. On the left, a 'Design Sections' sidebar lists: General, Document Plugins, Search Types, Search Indexes, Partition Indexes (selected), Cross-Collection Search, Browsing Classifiers, Format Features, Translate Text, and Metadata Sets. The main panel is titled 'Partition Indexes' and contains the following text: 'Use this panel to refine index creation. i) Define subcollection filters, which screen the collection documents based on the specified metadata values. Once defined, you can then generate partitions on any previously specified index, based on one or more of these filters. ii) Generate index partitions based on language. This filters the collection documents so that only those in the chosen language are included.' Below this text are three tabs: 'Define Filters' (selected), 'Assign Partitions', and 'Assign Languages'. Under the 'Define Filters' tab, there is a list of 'Defined Subcollection Filters' with one entry: 'subcollection monarchs "Filename/monarchs/"'. Below the list are input fields for: 'Subcollection filter name:' (monarchs), 'Document attribute to match against:' (Filename), 'Regular expression to match with:' (monarchs), 'What do we do with files that match?' (radio buttons for Include and Exclude, with Include selected), and 'Flags to set when matching' (empty text box). At the bottom are three buttons: 'Add Filter', 'Replace Filter', and 'Remove Filter'.

◆ Creazione delle sottocollezioni

Subcollections [4/4]



Cross-collection searching

- ◆ In Greenstone è possibile effettuare ricerche su più collezioni, come se fossero costituite da una sola collezione
- ◆ Questa funzionalità viene abilitata inserendo nel Collection Configuration File

```
supercollection col_1 col_2 ...
```

- ◆ Nel caso che le collezioni siano denominate col_1, col_2, ecc.
- ◆ Questa indicazione deve essere presente nel file di configurazione di tutte le collezioni coinvolte.

Cross-collection searching

The screenshot shows the Greenstone Librarian Interface (GLI) in Expert Mode. The window title is "Greenstone Librarian Interface Mode: Expert Collection: html large (html larg)". The menu bar includes "File" and "Edit", and the toolbar contains "Download", "Gather", "Enrich", "Design", and "Create".

The "Design Sections" sidebar on the left lists various options, with "Cross-Collection Search" selected. The main content area is titled "Cross-Collection Search Configuration". It contains the following text:

Cross-collection searching is where a single search is performed over several collections, as if all the collections were one. Specify the collections to include in a search by clicking on the appropriate collection's name in the list below. The current collection will automatically be included.

WARNING: If the individual collections do not have the same indexes (including subcollection partitions and language partitions) as each other, cross-collection

Below the text is a list of collections with checkboxes:

- Beatles Bibliography (beatlesb)
- Greenstone demo (demo)
- html large (html larg)
- html1 (html)
- html2 (htmlv1)
- img (img)
- test (test)

Plug-ins

Plug-ins

- ◆ **I plug-in sono moduli software che gestiscono**
 - Conversioni di formato
 - Estrazione di metadati
- ◆ **I plug-in permettono di estendere le funzionalità di Greenstone**
 - È possibile sviluppare nuovi plug-in per estendere i tipi di documenti gestiti o i metadati che possono essere estratti
- ◆ **I plug-in sono scritti nel linguaggio Perl. Sono tutti derivati da un plug-in base: *BasPlug*.**
- ◆ ***BasPlug* crea un nuovo documento archivio di Greenstone ed assegna un identificatore al documento**
- ◆ **Maggiori informazioni su ogni plug-in si possono avere digitando “perl – S pluginfo.pl nome-plugin” alla linea comandi di windows**

Plug-Ins

- ◆ **I plug-in svolgono la maggior parte del processo di “import”**
- ◆ **I diversi plug-in vengono eseguiti nell’ordine in cui compaiono nel file *collect.cfg***
 - Il file in elaborazione viene passato ai diversi plug-in, finché non se ne trova una che può elaborarlo
- ◆ **Se nessun plug-in può elaborare il file, viene generato un warning**
- ◆ **Alcuni plug-in elaborano documenti di formati diversi, mentre altri sono utilizzati come supporto al processo di importazione:**
 - *RecPlug* – elabora le directories e permette la navigazione nella struttura a directory.
 - *GAPlug* – elabora i documenti nel Greenstone Archive Format
 - *ArcPlug* – viene utilizzato durante il processo di “build” per individuare gli OID dei documenti importati (la lista si trova nel file *archives.inf* file)

Plug-ins & Document Formats

- ◆ I plug-in sono specificati nel “collection configuration file”
- ◆ Il nome del file determina il formato del documento e conseguentemente il plug-in che viene utilizzato
- ◆ Esempi di alcuni plug-in:

TEXTPlug

HTMLPlug

WORDPlug

PDFPlug

PSPlug

EMAILPlug

BibTexPlug

ReferPlug

SRCPlug

ImagePlug

ZIPPlug

Plug per il testo

◆ TEXTPlug Plug-In

- *.txt
- *.text

◆ Gestisce Plain Text

◆ Crea automaticamente un metadato Title ottenuto dalla prima linea di testo del file

HTML Plug-in

◆ Opera su file del tipo

- *.htm, *.html, .shtml, .shm, .asp, .php, .cgi

◆ Funzionalità

- Importa file HTML
- Il metadato Title viene estratto dal tag HTML <title>
- Altri metadati possono essere estratti se è presente il tag HTML <meta>
- Riconosce ed analizza i link presenti nel file
- I link vengono sostituiti con riferimenti al documento

Plug in per Microsoft Word Files

- ◆ **Tipi di file gestiti dal WORDPlug Plug-In**
 - *.doc
- ◆ **Importa documenti Microsoft Word**
- ◆ **Il Plug in converte file Word in HTML**

Plug in per PDF Files

- ◆ **Tipi di file gestiti dal PDFPlug Plug-In**
 - *.pdf
- ◆ **Importa file PDF (Adobe's Portable Document Format)**
- ◆ **Greenstone usa programmi indipendenti per convertire file PDF in HTML**

PostScript Files

- ◆ **PSPlug Plug-In**
 - *.ps
- ◆ **Imports PostScript Files**
- ◆ **Works best when a standard conversion program is already installed on the computer**
- ◆ **Uses simple text extraction algorithm if no conversion program is present**

Email Files

- ◆ **EMAILPlug**
 - *.email
- ◆ **Imports files containing email**
 - Each source is checked for e-mail contents
- ◆ **Extracts metadata:**
 - Subject
 - To
 - From
 - Date
- ◆ **Deals with common formats**
 - Netscape, Eudora, Unix mail readers

Compressed & Archived Files

◆ ZIPPlug Plug-In

- *.zip
- *.tar
- .gz
- *.z
- *.tgz
- *.bz

◆ Relies on standard utility programs being present

Configurazione Plug-in con GLI

The screenshot displays the Greenstone Librarian Interface (GLI) in Expert Mode for a collection named 'test (test)'. The main window is titled 'Plugin Selection & Configuration'. On the left, a 'Design Sections' sidebar lists various options, with 'Document Plugins' selected. The main area contains instructions on how to add, configure, or remove plugins. Below the instructions is a list of 'Currently Assigned Plugins' including ZIPPlug, GAPlug, TEXTPlug, HTMLPlug -smart_block, EMAILPlug, PDFPlug, RTFPlug, WordPlug, PSPlug, and ImagePlug. To the right of this list are 'Move Up' and 'Move Down' buttons. At the bottom, there is an 'Editing Controls' section with a dropdown menu set to 'BNContentePlug' and three buttons: 'Add Plugin', 'Configure Plugin', and 'Remove Plugin'.

Greenstone Librarian Interface Mode: Expert Collection: test (test)

File Edit Help

Download Gather Enrich Design Create

Design Sections

- General
- **Document Plugins**
- Search Types
- Search Indexes
- Partition Indexes
- Cross-Collection Search
- Browsing Classifiers
- Format Features
- Translate Text
- Metadata Sets

Plugin Selection & Configuration

Use this view to add, configure or remove plugins from your collection. To add one choose it from the combobox and click 'Add Plugin'.
To configure or remove one, select it from the list of assigned plugins then:
i) Change its position in the plugin order by clicking on the arrow buttons.
(Note: The position of RecPlug and ArcPlug are fixed).
ii) Configure it by clicking 'Configure Plugin'.

Currently Assigned Plugins

- plugin ZIPPlug
- plugin GAPlug
- plugin TEXTPlug
- plugin HTMLPlug -smart_block
- plugin EMAILPlug
- plugin PDFPlug
- plugin RTFPlug
- plugin WordPlug
- plugin PSPlug
- plugin ImagePlug

Move Up

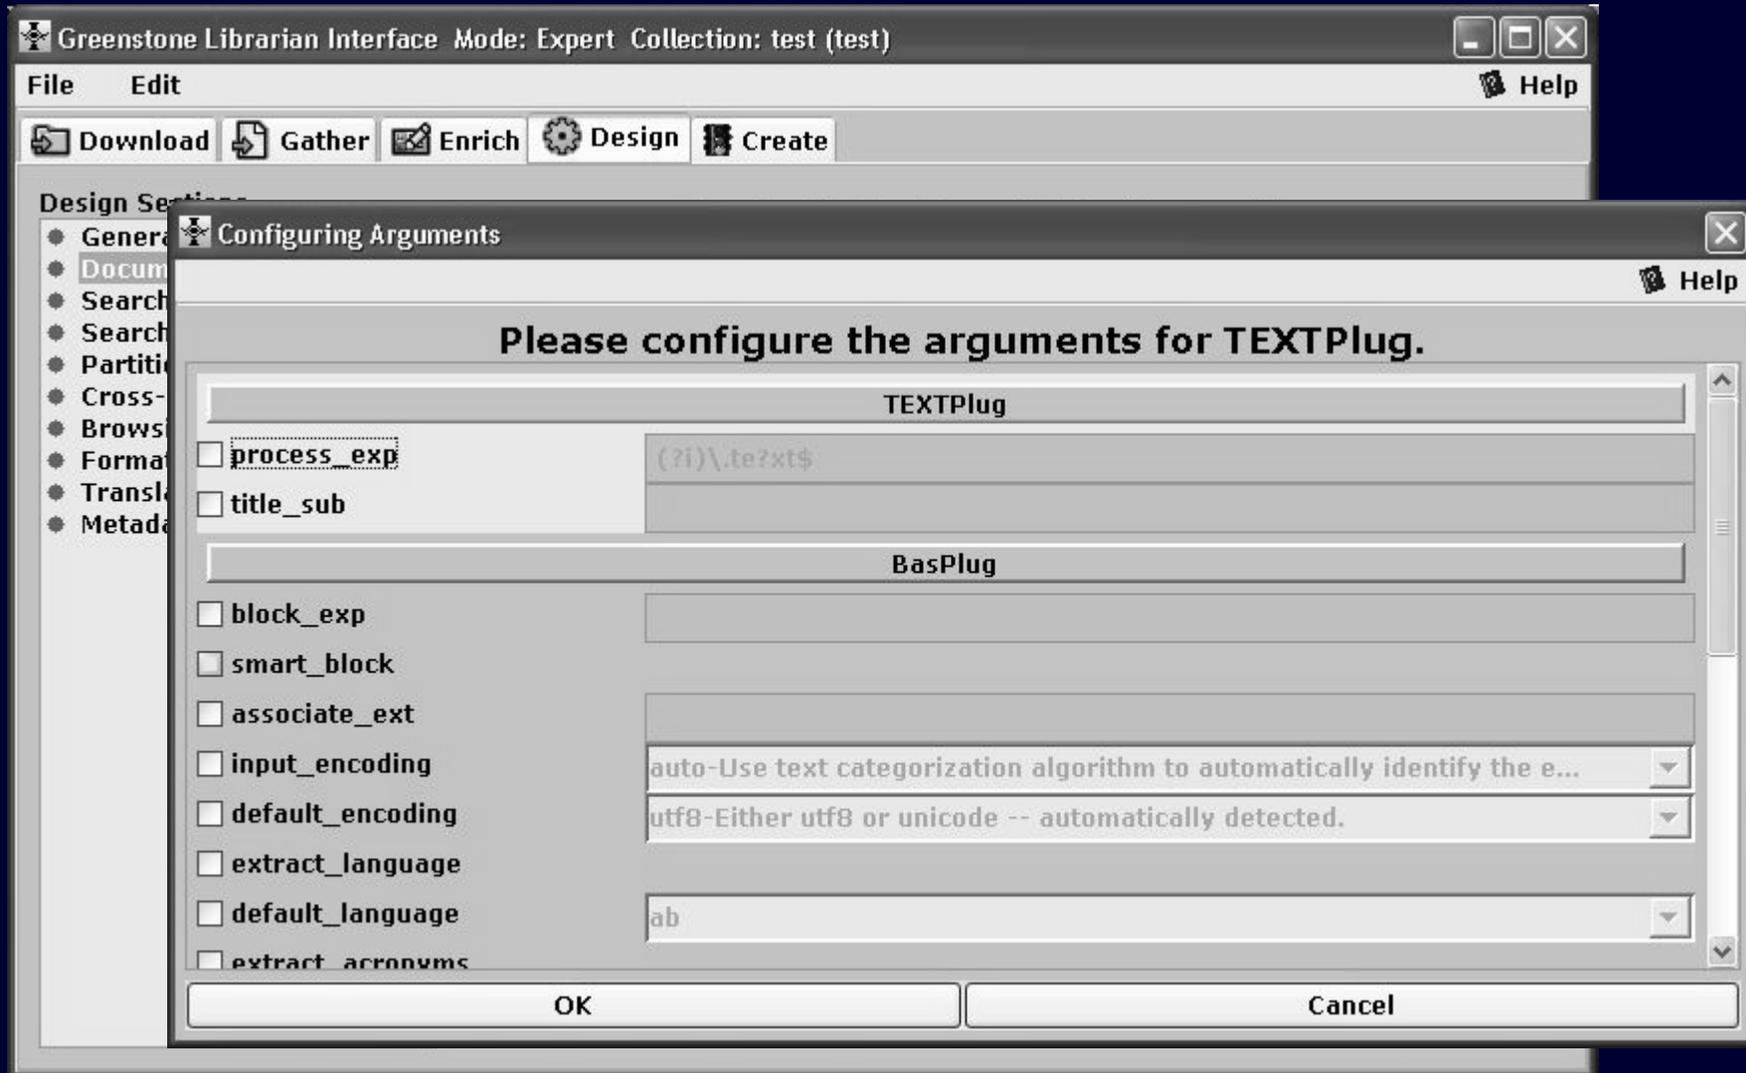
Move Down

Editing Controls

Select plugin to add: BNContentePlug

Add Plugin Configure Plugin Remove Plugin

Configurazione Plug-in con GLI



Classifiers

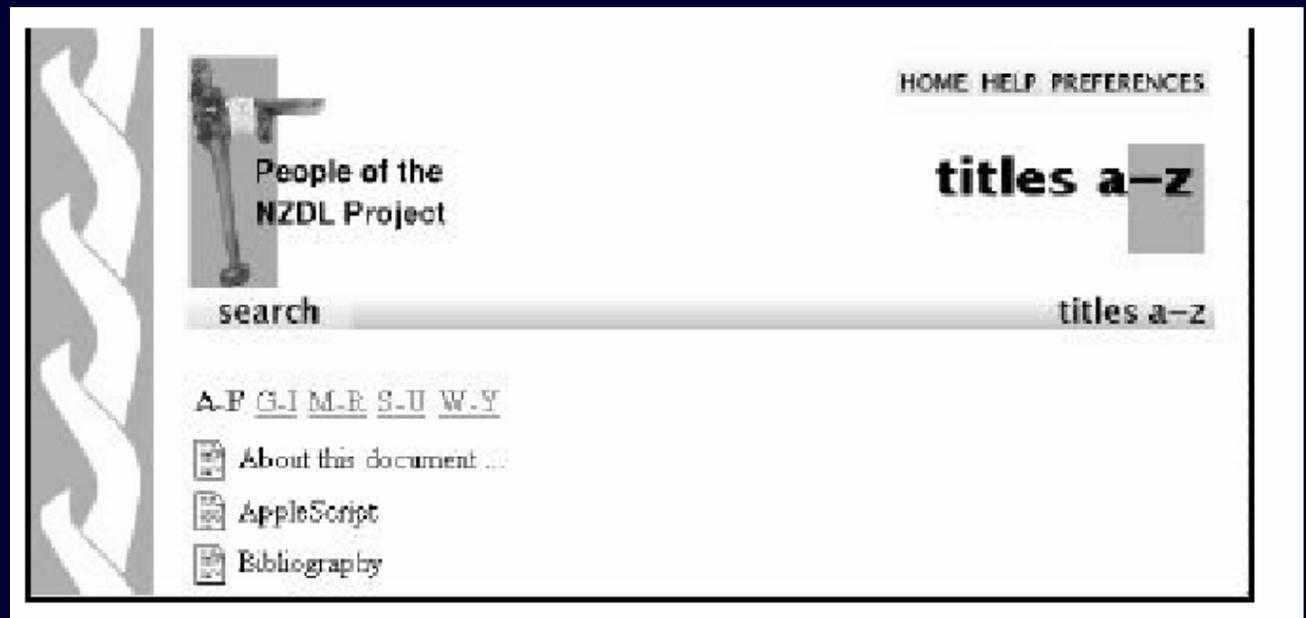
I Classifiers

- ◆ **Gestiscono strutture per il browsing della collezione**
- ◆ **Vengono specificati nel Collection Configuration File**
- ◆ **Per ogni classifier vi è una linea del tipo**
 - `classify nome_classifier opzioni`
- ◆ **I programmatori possono scrivere nuovi classifiers per creare nuove strutture di browsing**

Esempi di Classifier [1/4]

◆ AZList classifier

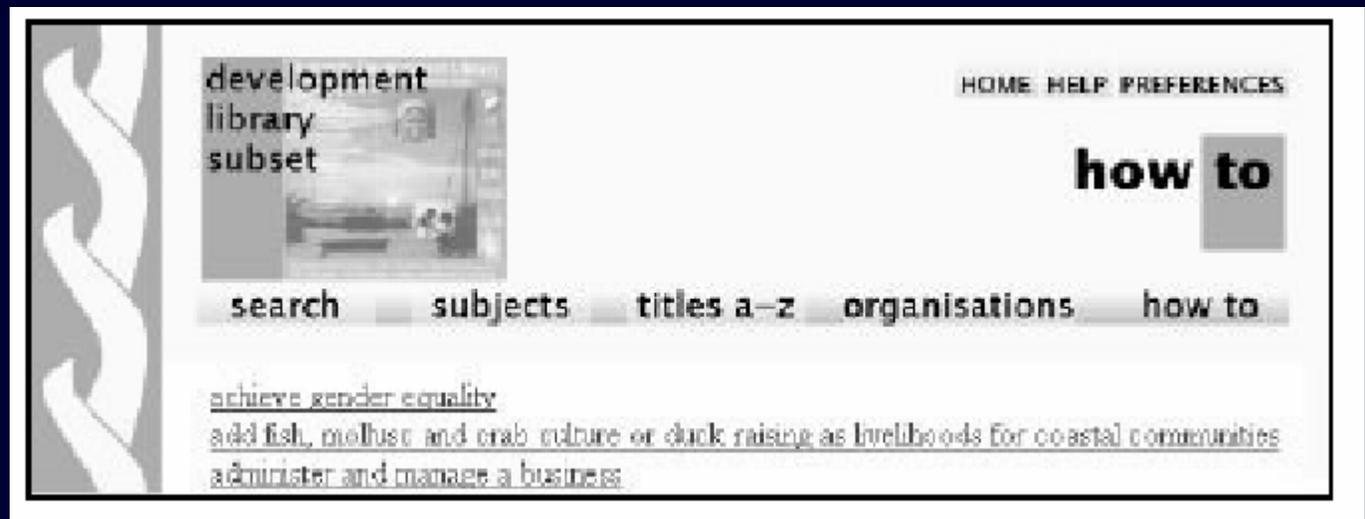
- Crea una lista ordinata alfabeticamente di elementi
- Ad es. `Classify AZList -metadata Title`



Esempi di Classifier [2/4]

◆ List classifier

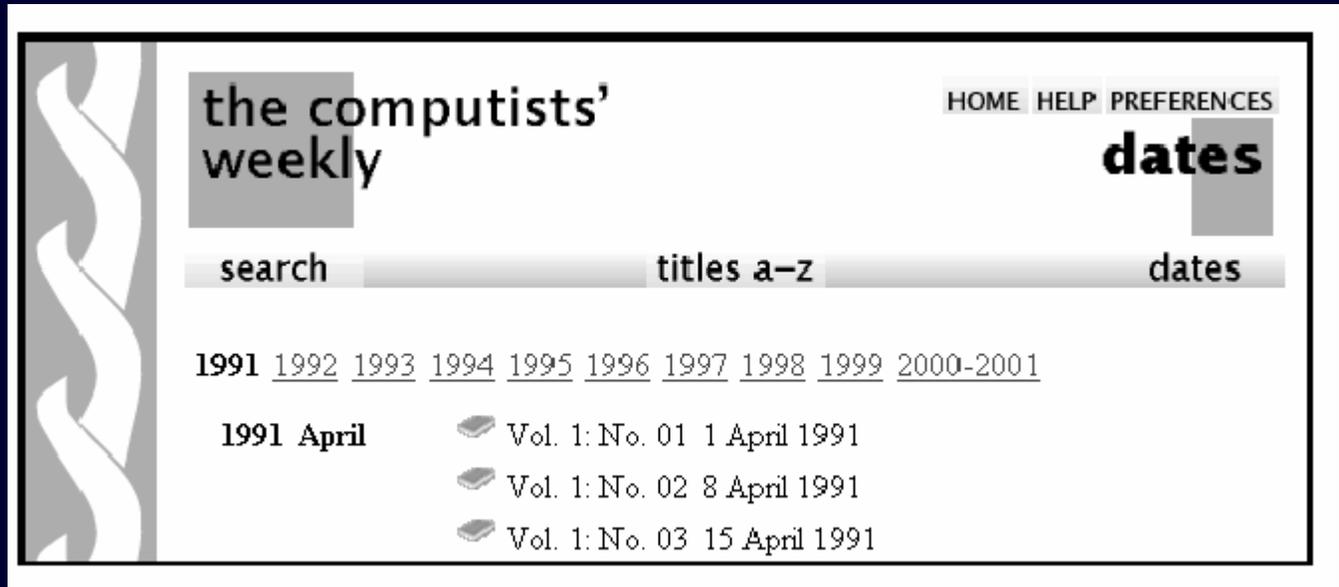
- Crea una lista ordinata di elementi e li visualizza senza alcun ordine specifico
- Ad es. `classify List -metadata Howto`



Esempi di Classifier [3/4]

◆ DateList classifier

- Crea una lista ordinata di elementi data
- Ad es. `classify DateList -metadata date`



The screenshot shows a web interface for 'the computists' weekly'. The page features a navigation bar with links for 'HOME', 'HELP', and 'PREFERENCES'. Below the navigation bar, there are three tabs: 'search', 'titles a-z', and 'dates', with 'dates' being the active tab. The main content area displays a list of years from 1991 to 2000-2001, with '1991' selected. Underneath, there are three entries for the year 1991, each with a small icon and a date: '1991 April', 'Vol. 1: No. 01 1 April 1991', 'Vol. 1: No. 02 8 April 1991', and 'Vol. 1: No. 03 15 April 1991'.

Esempi di Classifier [4/4]

◆ Classifier gerarchici

- Creano classificazioni gerarchiche e sono utili per la classificazione di soggetti ed organizzazioni
- Ad es. `classify Hierarchy -hfile sub.txt -metadata Subject -sort Title`



The screenshot shows a library website interface. At the top left, there is a logo for 'development library subset' with a small image of a book. To the right of the logo are links for 'HOME', 'HELP', and 'PREFERENCES'. Below the logo is a navigation bar with buttons for 'search', 'subjects', 'titles a-z', 'organisations', and 'how to'. The main content area displays a hierarchical classification of subjects. It starts with '03.00 Education, Training' and then 'Vocational Training and Education'. Under this category, there are two items listed with leaf icons:

- Carpentry for Vocational Schools. A Teachers Handbook
no. of pages: 252
source ref: gr0004 fibo
- Course: Manual Woodworking Techniques. Instruction Examples for Practical Vocational Training - Boring

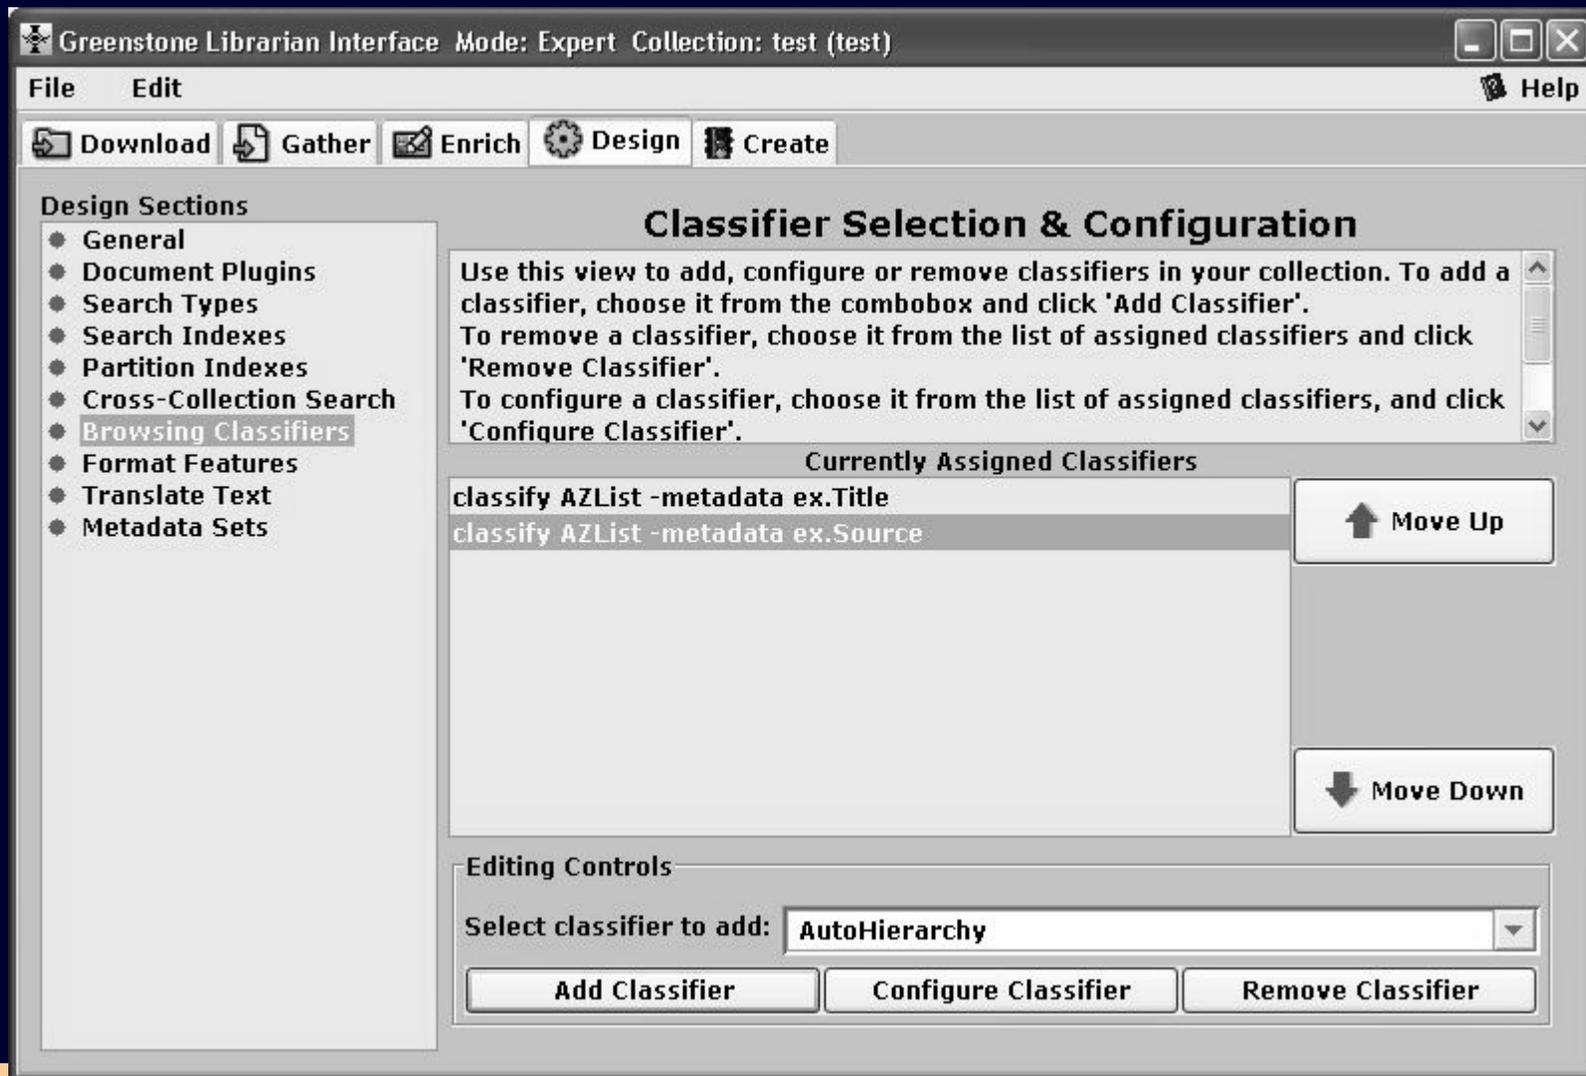
I classifiers

◆ Informazioni sui classifiers si possono avere digitando dalla linea comandi

- `perl -S classinfo.pl nome-classifier`

<i>Hierarchy</i>	Hierarchical classification
<i>hfile</i>	Classification file
<i>metadata</i>	Metadata element to test against <i>hfile</i> identifier
<i>sort</i>	Metadata element used to sort documents within leaves (defaults to <i>Title</i>)
<i>buttonname</i>	Name of the button used to access this classifier (defaults to value of metadata argument)
<i>List</i>	Alphabetic list of documents
<i>metadata</i>	Include documents containing this metadata element
<i>buttonname</i>	Name of button used to access this classifier (defaults to value of metadata argument)
<i>SectionList</i>	List of sections in documents
<i>AZList</i>	List of documents split into alphabetical ranges
<i>metadata</i>	Include all documents containing this metadata element
<i>buttonname</i>	Name of button used to access this classifier (defaults to value of metadata argument)
<i>AZSectionList</i>	Like <i>AZList</i> but includes every section of the document
<i>DateList</i>	Similar to <i>AZList</i> but sorted by date

Gestione del Classifiers con la GLI



Gestione del Classifiers con la GLI

The image shows a screenshot of the Greenstone Librarian Interface (GLI) in Expert Mode. The main window is titled "Greenstone Librarian Interface Mode: Expert Collection: test (test)". The menu bar includes "File" and "Edit", and the toolbar contains "Download", "Gather", "Enrich", "Design", and "Create". The "Design Sections" list on the left includes "General", "Document Plug", "Search Types", "Search Indexe", "Partition Index", "Cross-Collectio", "Browsing Clas", "Format Featur", "Translate Text", and "Metadata Sets". The main area is titled "Classifier Selection & Configuration".

A dialog box titled "Configuring Arguments" is open, displaying the message: "Please configure the arguments for AutoHierarchy." The dialog box has a title bar with a "Help" button and a close button. The main content area is titled "AutoHierarchy" and contains a list of metadata fields. The "dc.Title" field is selected. Other fields in the list include "dc.Rights Management", "dc.Source", "dc.Subject and Keywords", "ex.Encoding", "ex.Language", "ex.Source", and "ex.Title". There are also several checkboxes for configuration options: "firstvalueonly", "allvalues", "buttonname", "sort", "separator", "suppresslastlevel", "hlist_at_top", "builddir", and "outhandle". The "STDOUT" field is visible at the bottom of the list. The dialog box has "OK" and "Cancel" buttons at the bottom.

Indici

Uso di indici per la ricerca

- ◆ **La ricerca è resa possibile da indici costruiti sulle diverse componenti dei documenti**
 - Documenti intero
 - Paragrafi
 - Titoli
 - Sezioni
 - Titoli di sezione
 - Titoli delle figure
 - Ecc.

Indici

- ◆ **Gli indici possono essere creati automaticamente utilizzando**
 - I documenti
 - File di supporto che contengono i valori dei metadati

- ◆ **Gli indici devono essere ricostruiti automaticamente**
 - Quando un nuovo documento viene inserito nella collezione

Plug-ins per gli indici

- ◆ I documenti sono convertiti in formato XML standard da plug-in specifici. Queste rappresentazioni XML dei documenti vengono utilizzate per l'indicizzazione
- ◆ DTD del Metadata file

```
<!DOCTYPE GreenstoneDirectoryMetadata [  
<!ELEMENT DirectoryMetadata (FileSet*)>  
<!ELEMENT FileSet (FileName+,Description)>  
<!ELEMENT FileName (#PCDATA)>  
<!ELEMENT Description (Metadata*)>  
<!ELEMENT Metadata (#PCDATA)>  
<ATTLIST Metadata name CDATA #REQUIRED>  
<ATTLIST Metadata mode (accumulate|override) "override">  
>
```

Esempio di XML Metadata File

```
<?xml version="1.0" ?>
<!DOCTYPE GreenstoneDirectoryMetadata SYSTEM
"http://greenstone.org/dtd/GreenstoneDirectoryMetadata/1.0/GreenstoneDirectoryM
etadata.dtd">
<DirectoryMetadata>
<FileSet>
<FileName>nugget.*</FileName>
<Description>
<Metadata name="Title">Nugget Point Lighthouse</Metadata>
<Metadata name="Place" mode="accumulate">Nugget Point</Metadata>
</Description>
</FileSet>
<FileSet>
<FileName>nugget-point-1.jpg</FileName>
<Description>
<Metadata name="Title">Nugget Point Lighthouse</Metadata>
<Metadata name="Subject">Lighthouse</Metadata>
</Description>
</FileSet>
</DirectoryMetadata>
```

Tagging Document Files

- ◆ **Una diversa modalità per associare metadati sui quali creare gli indici, consiste nell'aggiungere dei metadati direttamente nei documenti**

```
<!--  
<Section>  
<Description>  
<Metadata name="Title"> Realizing human rights for poor  
people: Strategies for achieving the international  
development targets </Metadata>  
</Description>  
-->  
(text of section goes here)  
<!--  
</Section>  
-->
```

Gestione degli indici con la GLI

Greenstone Librarian Interface Mode: Expert Collection: test (test)

File Edit Help

Download Gather Enrich Design Create

Design Sections

- General
- Document Plugins
- Search Types
- Search Indexes
- Partition Indexes
- Cross-Collection Search
- Browsing Classifiers
- Format Features
- Translate Text
- Metadata Sets

Index Selection

Here you choose what searchable indexes the collection will have.
To add a new index, select what material is to be indexed, choose the level of the index, and click 'Add Index'.
To remove an index, select it from the assigned indexes list and click 'Remove Index'.
To set the default index, select it from the assigned indexes list and click 'Set'.

Assigned Indexes

document:text "text" [Default Index]
document:ex.Title "titles"
document:ex.Source "filenames"

Move Up
Move Down
Set Default Index

Index Name: filenames

Build index on:

- dc.Autore
- dc.Contributor
- dc.Coverage
- dc.Creator
- dc.Date
- dc.Description
- dc.Format
- dc.Language
- dc.Publisher
- dc.Relation
- dc.Resource Identifier

At the level: document

Add Index Replace Index Remove Index

Come formattare l'output

Introduzione

- ◆ **Le pagine web visualizzate da Greenstone non sono preesistenti ma vengono generate**
- ◆ **Le modalità di visualizzazione sono controllate dal comando “format” del Collection Configuration File**
- ◆ **Elementi della pagina controllabili**
 - Item della pagina che presentano i documenti
 - Liste prodotte dai classifiers e risultati delle ricerche

Visualizzazione degli item nella pagina

format DocumentImages true/false

If *true*, display a cover image at the top left of the document page (default *false*).

format DocumentHeading formatstring

If *DocumentImages* is *false*, the format string controls how the document header shown at the top left of the document page looks (default *[Title]*).

format DocumentContents true/false

Display table of contents (if document is hierarchical), or next/previous section arrows and “page k of n” text (if not).

format DocumentButtons string

Controls the buttons that are displayed on a document page (default *Detach|Highlight*).

format DocumentText formatstring

Format of the text to be displayed on a document page: default

```
<center><table width=537>  
<tr><td>[Text]</td></tr>  
</table></center>
```

format DocumentArrowsBottom true/false

Display next/previous section arrows at bottom of document page (default *true*).

format DocumentUseHTML true/false

If *true*, each document is displayed inside a separate frame. The Preferences page will also change slightly, adding options applicable to a collection of HTML documents, including the ability to go directly to the original source document (anywhere on the Web) rather than to the Greenstone copy.

Come formattare le liste

◆ **Format lista-parte comandi**

- La prima parte (`list`) è obbligatoria ed identifica le liste alle quali applicare i comandi di formattazione
- Search è la lista generata da una ricerca, mentre CL1, CL2, ... sono le liste generate dal primo, secondo, ... classificatore
- La seconda parte (`parte`) è opzionale e specifica a quale parte della lista i comandi vanno applicati (HList, VList, DateList)
 - Ad es. `format CL4Vlist` si applica a tutte le VList in CL4

Come formattare le liste

- ◆ **Comandi** è una stringa che specifica come formattare la lista
- ◆ **Può contenere codice HTML, metadati ed i seguenti elementi**

<code>[Text]</code>	The document's text
<code>[link] ... [/link]</code>	The HTML to link to the document itself
<code>[icon]</code>	An appropriate icon (e.g. the little text icon in a <i>Search Results</i> string)
<code>[num]</code>	The document number (useful for debugging).
<code>[metadata-name]</code>	The value of this metadata element for the document, e.g. <code>[Title]</code>

Esempio [1/8]

◆ Esempio di classifiers e format commands della demo collection

```
1 classify Hierarchy -hfile sub.txt -metadata Subject -sort Title
2 classify AZList -metadata Title
3 classify Hierarchy -hfile org.txt -metadata Organisation -sort Title
4 classify List -metadata Howto
5 format SearchVList "<td valign=top [link] [icon] [/link]</td><td>{ If}
6 { [parent(All':'):Title], [parent(All':'):Title]:}
7 [link] [Title] [/link]</td>"
8 format CL4Vlist "<br>[link] [Howto] [/link]"
9 format DocumentImages true
10 format DocumentText "<h3>[Title]</h3> \\n\\n<p>[Text]"
```

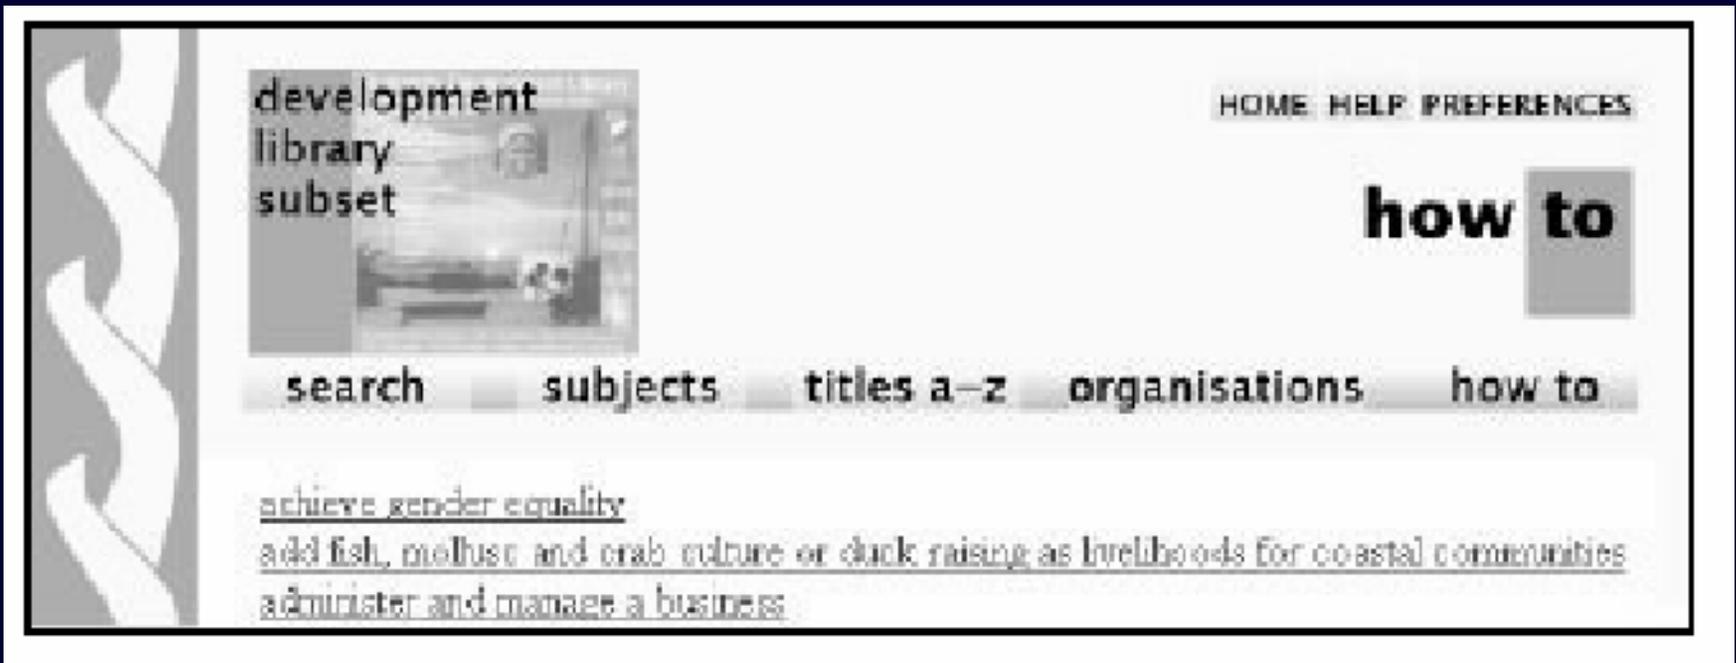
Esempio [2/8]

Howto classifier. È il quarto classifier (CL4)
È un List classifier che genera una lista di titoli di documenti

```
1 classify Hierarchy -hfile sub.txt -metadata Subject -sort Title
2 classify AZList -metadata Title
3 classify Hierarchy -hfile org.txt -metadata Organisation -sort Title
4
5 format SearchVList "<td valign=top [link] [icon] [/link]</td><td>{ If
6                       { [parent(All':'):Title], [parent(All':'):Title]: }
7                       [link] [Title] [/link]</td>"
8
9 format DocumentImages true
10 format DocumentText "<h3>[Title]</h3>\\n\\n<p>[Text]"
```

Comando di formattazione di CL4
Gli elementi figlio degli elementi top-level sono visualizzati come una VList
Ogni elemento si trova su una nuova linea e contiene il testo del campo Howto collegato al documento

Esempio [3/8]



The screenshot shows a web interface for a digital library. On the left, there is a vertical decorative element with a wavy, white pattern on a grey background. The main content area has a header with the text "development library subset" and a small image of a library interior. To the right of the header, there are navigation links: "HOME", "HELP", and "PREFERENCES". Below the header, there is a large, bold "how to" button. At the bottom of the interface, there is a horizontal menu with five items: "search", "subjects", "titles a-z", "organisations", and "how to". Below the menu, there are three lines of text, each underlined: "achieve gender equality", "add fish, mollusc and crab culture or duck raising as livelihoods for coastal communities", and "administer and manage a business".

development library subset

HOME HELP PREFERENCES

how to

search subjects titles a-z organisations how to

achieve gender equality
add fish, mollusc and crab culture or duck raising as livelihoods for coastal communities
administer and manage a business

Esempio [4/8]

```
format DocumentImages true
```



```
format DocumentText  
"<h3>[Title]</h3>\\n\\n<p>[Text]"
```

```
1 classify Hierarchy  
2 classify AZList  
3 classify Hierarchy  
4 classify List  
5 format SearchVList "<td valign=top [link] [icon] [/link]</td><td>{ If }  
  { [parent(All':'):Title], [parent(All':'):Title]: }  
  [link] [Title] [/link]</td>"  
6  
7 format CL4Vlist      "<br>[link] [Howto] [/link]"
```

Esempio [5/8]

[link] [icon] [/link]

[parent (All': ') :
Title]

[link] [Title] [/link]

```
1 classify Hie  
2 classify AZI [link] [Title] [/link]  
3 classify Hie  
4 classify List -metadata Howto
```

```
7 format CL4Vlist "<br>[link] [Howto] [/link] "  
8 format DocumentImages true  
9 format DocumentText "<h3>[Title]</h3> \\n\\n<p>[Text] "  
10
```



Esempio [6/8]

[link] [icon] [/link]

[parent (All': ') :
Title]

[link] [Title] [/link]

demo collection

HOME HELP FEED

sea

search subjects titles a-z organization hc

Search for chapters which contain terms of the words

swallow

results

Word count: swallow 394
42 documents matched the query.

Farming swale 1: Learning about swale; Building a pen; Food and shelter p
Learning about swale: How you must decide

Farming swale 2: Choosing swale; Care and harvesting; Further improve
Building the second pen; Fencing swale to water and pen

Farming swale 1: Learning about swale; Building a pen; Food and shelter p
Learning about swale: Where can you farm swale?

Farming swale 2: Choosing swale; Care and harvesting; Further improve
swale: Choose your swale

- ◆ Una versione semplice per il formato del classificatore Howto dovrebbe essere del tipo

```
<td valign=top>[link][icon][link]</td>  
<td>[link][Title][link]</td>
```

- ◆ In questo modo si ha un link al documento tramite la sua icona ed un link al documento tramite il titolo

- ◆ I documenti della collezione hanno una struttura gerarchica (book, section, subsection, ecc.)
- ◆ La search dà come risultato una specifica parte del documento, per cui con

```
<td>[link][Title][/link]</td>
```

visualizzo solo il titolo della componente trovata. Se voglio visualizzare tutta la struttura gerarchica di titoli devo utilizzare un elemento specifico (*parent*) che fornisce il 'parent' di un oggetto o, se si specifica 'All', fornisce tutta la struttura.

```
<td>{[parent('All' : `):Title]: }[link][Title][/link]</td>
```

Questa stringa genera tutti i titoli a partire da Book, separati da ':'. Rimane il problema di un documento che non ha struttura. In tal caso parent è una stringa vuota, per cui avrei come risultato

```
: Titolo del documento
```

- ◆ Per evitare questo inconveniente utilizzo uno statement *if*

```
{If} {[metadata], se-non-vuoto, se-vuoto}
```

verifica se il valore in [metadata] è vuoto o no, ed esegue le azioni corrispondenti

- ◆ Lo statement *or*

```
{Or} {azione-1, else azione-2, else azione-3, ecc.}
```

valuta tutte le azioni in sequenza, finché non ne trova una che non generi una stringa vuota.

- ◆ Quindi il format corretto risulta essere

```
<td valign=top>[link][icon][link]</td>  
<td> {If} {[parent(All' : `):Title],  
          [parent(All' : `):Title]:}  
      [link][Title][link]</td>
```

Greenstone Librarian Interface Mode: Expert Collection: test (test)

File Edit Help

Download Gather Enrich Design Create

Design Sections

- General
- Document Plugins
- Search Types
- Search Indexes
- Partition Indexes
- Cross-Collection Search
- Browsing Classifiers
- Format Features**
- Translate Text
- Metadata Sets

Format Commands

The web pages you see when using Greenstone are not pre-stored but are generated 'on the fly' as they are needed. Format commands are used to change the appearance of these generated pages. Some are switches that control the display of documents or parts of documents; others are more complex and require html code as an argument.

To add a format command, choose it from the 'feature' list. If a True/False option

Currently Assigned Format Commands

```
format DateList "<td>[link][icon][link]</td><td>[highlight]{ Or }{ [dls.Title],[dc.T
format HList "[link][highlight]{ Or }{ [dls.Title],[dc.Title],[ex.Title],Untitled}[/highlic
format VList "<td valign=top>[link][icon][link]</td><td valign=top>[ex.srclink]{
```

Editing Controls

Choose Feature

Affected Component

HTML Format Statement

```
<td valign=top>
<td valign=top>
>
<td valign=top>
{ Or }{ [dls.Title]
[/highlight]{ If}
```

AllowExtendedOptions
CL1: AZList -metadata ex.Title
CL2: AZList -metadata ex.Source
DocumentArrowsBottom
DocumentArrowsTop
DocumentButtons
DocumentContents

Variables [Text] Insert

Add Format Replace Format Remove Format

Format features

Riferimenti

- ◆ **Greenstone Developer Guide, cap. 2**

<http://prdownloads.sourceforge.net/greenstone/Developer-en.pdf>