Elaborazione di documenti XML

Corso di ***Applicazioni Telematiche***

A.A. 2005-06 – Lezione n.9

Prof. Roberto Canonico

Università degli Studi di Napoli Federico II

Facoltà di Ingegneria

XML e i linguaggi di programmazione

- XML non è altro che un formato passivo utilizzato per codificare dati
- I programmatori devono incorporare nelle proprie applicazioni le tecnologie necessarie per generare e interpretare documenti XML

I punti di forza

- Sintassi semplice
- Supporto per le strutture ricorsive
- Semplicità di debugging
- Indipendenza dal linguaggio e dalla piattaforma

API for XML

- La struttura grammaticale semplice di XML ha dato luogo alla creazione di diverse librerie per generare e interpretare documenti XML
- Esistono due diversi approcci alla elaborazione di documenti XML:
  - SAX (Simple API for XML)
  - DOM (Document Object Model)

DOM

- Il *Document Object Model* definisce una gerarchia di oggetti in grado di descrivere un documento XML
- Il parser integrato in DOM analizza il documento XML e genera in memoria la struttura DOM
- Il programmatore deve quindi solo creare il codice per cercare le informazioni nella struttura DOM

Utilizzo di DOM in un'applicazione

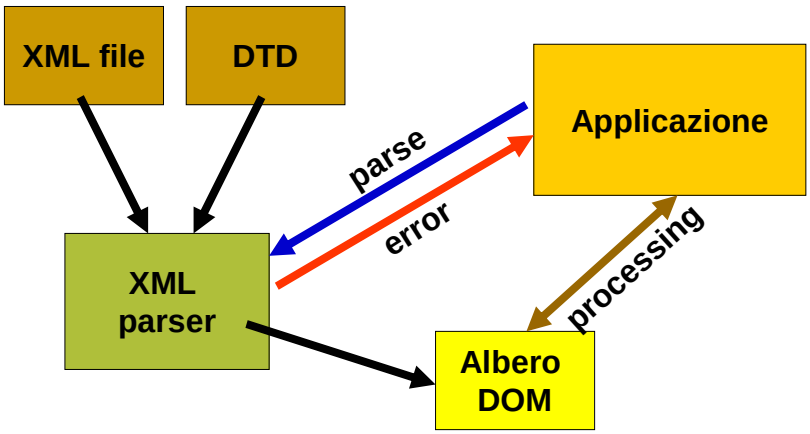

Utilizzo di SAX in un'applicazione

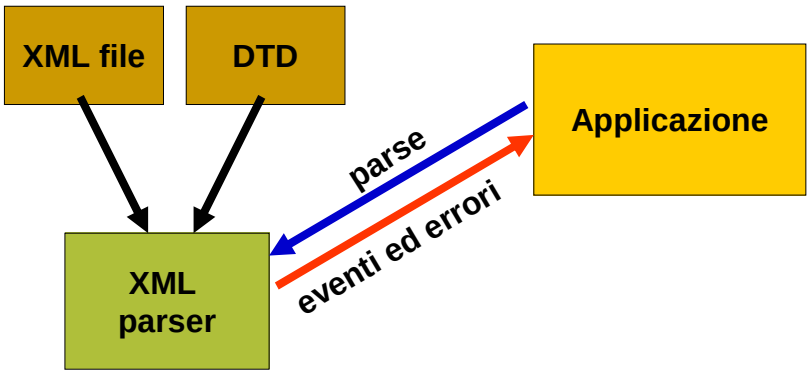

Elaborazione del documento

- Dopo il parsing
  - Se si usa un parser DOM
  - Il parser ritorna un oggetto di tipo *Document*
  - Il metodo *GetDocumentElement* restituisce l'elemento root
- Durante il parsing
  - Se si usa un parser SAX
  - Il parser genera eventi durante il parsing
  - L'applicazione elabora i dati mediante appositi metodi *handler*

SAX

- Le *Simple API for XML* definiscono un modello di interpretazione guidato dagli eventi
- Un parser SAX utilizza un meccanismo di callback per inviare delle notifiche durante l'interpretazione dei vari elementi XML
- Il parser quindi non mantiene uno stato, e non crea nessuna struttura in memoria; questa caratteristica lo rende particolarmente adatto per l'utilizzo con documenti molto grandi

Invocazione del parser DOM

```
DOMParser parser = new DOMParser() ;
parser.setErrorHandler( new MyErrorHandler() ) ;

try
{
    parser.parse( fn ) ;
}
catch( Exception e )
{
    System.out.println( "Exception invoking parser") ;
}
Document doc = parser.getDocument() ;

if ( doc != null )
{
    processTheDocument( doc ) ;
}
```

Invocazione del parser SAX

```
SAXParser parser = new SAXParser() ;
parser.setDocumentHandler( this );
parser.setErrorHandler( new MyErrorHandler() );

try
{
    parser.parse( fn ) ;
}
catch( Exception e )
{
    System.out.println( "Exception invoking parser", 0 ) ;
}
```

Gestione degli eventi SAX

```
public void startDocument()
{
}
public void endDocument()
{
}
public void startElement( String name, AttributeList attrs )
{
}
public void endElement( String name )
{
}
```

SAX e DOM

- La W3C ha definito soltanto l'interfaccia delle due librerie SAX e COM
- Questo ha permesso l'implementazione per moltissimi linguaggi di programmazione:
  - Java
  - C / C++
  - Perl
  - Python
  - Tcl
  - …

DOM vs. SAX

- DOM
  - Document Object Model (tree structure)
  - Good if you intend to edit the document
  - Good if you plan to process multiple times.
  - Avoids re-parsing each time.
  - Avoids building your own internal tree.
- SAX
  - Event based model.
  - Good if you don't need to edit in memory.
  - Good if memory is limited.
  - Good if only parts of document are required.

Domande?