



XML e Java

1

Elaborazione di documenti XML

- Un elemento importante che ha consentito la diffusione dei linguaggi e delle tecnologie XML è il supporto fornito da strumenti per il parsing (analisi sintattica)
- Ogni applicazione che vuole fruire di XML deve includere un supporto per il parsing
- I parser XML sono diventati strumenti standard nello sviluppo delle applicazioni
- Per esempio JDK1.4 integra un supporto al parsing (specifiche JAXP), e come default fornisce un parser (Apache Crimson)

2

Compiti del parser

- Decomporre i documenti XML (istanza) nei loro elementi costitutivi
 - elementi, attributi, testo, processing instructions, entità, ...
- Eseguire controlli sul documento
 - Controllare che il documento sia ben formato
 - Controllare **eventualmente** che il documento sia valido (DTD, XML Schema)
- Non tutti i parser consentono la validazione dei documenti: si parla quindi di **parser validanti** e **non validanti**
- La validazione è una operazione computazionalmente costosa e quindi è opportuno potere scegliere se attivarla o meno

3

Modelli di parsing per XML

- Dal punto di vista dell'interfacciamento tra applicazioni e parser esistono due grandi categorie di API
- **Interfacce basate su eventi**
 - **Interfacce ESIS** (Element Structure Information Set): interfacce dei parser per documenti SGML
 - **Interfacce SAX** (Simple API for XML): sfruttano un modello a call-back
- **Interfacce Object Model**
 - W3C DOM Recommendation

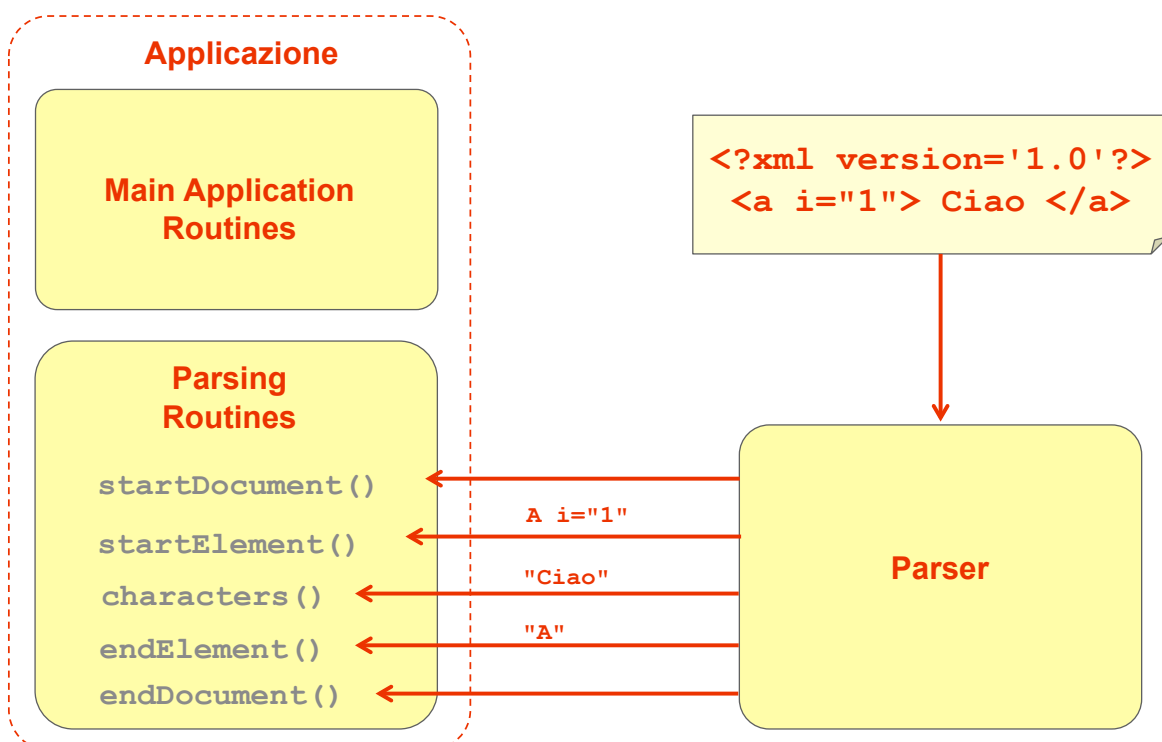
4

Interfacce ad eventi

- L'applicazione implementa un insieme di metodi di callback che vengono invocati dal parser mentre elabora il documento
 - Le callback sono invocate al verificarsi di specifici eventi es. start-tag, end-tag,...
- I parametri passati al metodo di callback forniscono ulteriori informazioni sull'evento
 - Nome dell'elemento
 - Nome e valore assunto dagli attributi
 - Valore delle stringhe contenute ...
- E' una modalità semplice ed efficiente
- E il modello adottato da SAX (Simple API for XML)
 - è uno standard de facto per il parsing di documenti XML

5

Schema di parsing ad eventi




6

Interfacce Object Model

- L'applicazione interagisce con una rappresentazione object-oriented del documento
- Il documento è rappresentato da un albero (parse tree) costituito da vari oggetti quali document, element, attribute, text, ...
- Il livello di astrazione che le interfacce Object Model forniscono al programmatore è maggiore rispetto a quello fornito dalle interfacce basate su modelli basati su eventi
 - Facile accedere ai figli di un elemento, ai fratelli, ...
 - Problema: Richiede la disponibilità di maggiori risorse computazionali (particolare memoria perché l'intero documento viene caricato in memoria)

7

Schema di parsing object model



8

Ricapitolando

- I parser XML rendono disponibile alle applicazioni la struttura ed il contenuto dei documenti XML e si interfacciano mediante due tipologie di API
 - **Event-based API (Es. API SAX)**
 - Notificano alle applicazioni eventi generati nel parsing dei documenti
 - Usano poche risorse ma non sono sempre comodissime da usare
 - **Object-model based APIs (es. DOM)**
 - Forniscono accesso al parse tree che rappresenta il documento XML Molto comode ed eleganti r
 - Richiedono però maggiori risorse, soprattutto in termini di memoria
 - I parser più diffusi supportano sia SAX sia DOM: spesso i parser DOM sono sviluppati su parser SAX
-

9

Parser in Java: JAXP

- JAXP è un framework che ci consente di istanziare ed utilizzare parser XML (sia SAX che DOM) nelle applicazioni Java
 - JAXP 1.1 è Inclusa nella JDK a partire dalla vers. 1.4
 - Fornisce vari package:
 - `org.xml.sax`: interfacce SAX 2.0
 - `org.w3c.dom`: interfacce DOM Level 2
 - `javax.xml.parsers`: inizializzazione ed uso dei parser
 - JAXP permette di operare indipendentemente dall'effettiva implementazione del parser utilizzata
 - Utilizza un parser presente all'interno del sistema
 - Usa il pattern **factory method** per ottenere questa indipendenza
-

10

JAXP: factory e parser

- `javax.xml.parsers` espone due classi factory, una per SAX e una per DOM:

`SAXParserFactory`

`DocumentBuilderFactory`

- Sono classi astratte ed espongono il metodo statico **`newInstance()`** che consente di ottenere un'istanza di una classe discendente concreta:

```
SAXParserFactory spf =  
    SAXParserFactory.newInstance();  
DocumentBuilderFactory dbf =  
    DocumentBuilderFactory.newInstance();
```

- Una volta ottenuta una factory possiamo invocarla per creare un parser con interfaccia SAX o DOM:

```
SAXParser saxParser = spf.newSAXParser();  
DocumentBuilder builder = dbf.newDocumentBuilder();
```

11

SAX Event Callback API

- SAX stabilisce un insieme di API molto diffuso
- È uno standard de-facto
 - SAX 1.0 Maggio 1998,
 - SAX 2.0 Maggio 2000
- **SAX non è un parser, ma è una interfaccia**
- L'interfaccia SAX è supportata da molti parser:
 - Sun JAXP
 - IBM XML4J,
 - Oracle XML Parser for Java
 - Apache Xerces
 - Microsoft MSXML (in IE 5)
 - ...

12

Interfacce SAX

- Le applicazioni interagiscono con parser conformi a SAX utilizzando interfacce stabilite
- Le interfacce di SAX possono essere divise in 3 categorie:
 - **Interfacce Parser-to-Application (call-back):** consentono di definire funzioni di call-back e di associarle agli eventi generati dal parser mentre questi processa un documento XML
 - **Interfacce Application-to-Parser:** consentono di gestire il parser
 - **Interfacce Ausiliarie:** facilitano la manipolazione delle informazioni fornite dal parser

13

Interfacce Parser to Application (call-back)

- Vengono implementate dall'applicazione per imporre un preciso comportamento a seguito del verificarsi di un evento:
- Sono quattro:
 - **ContentHandler:** metodi per elaborare gli eventi generati dal parser
 - **DTDHandler:** metodi per ricevere notifiche su entità esterne al documento e loro notazione dichiarata in DTD
 - **ErrorHandler:** metodi per gestire gli errori ed i warning nell'elaborazione di un documento
 - **EntityResolver:** metodi per personalizzare l'elaborazione di riferimenti ad entità esterne
- Se un'interfaccia non viene implementata il comportamento di default è ignorare l'evento.

14

Interfacce Application-to-Parser

- Sono implementate dal parser
 - **XMLReader**: interfaccia che consente all'applicazione di invocare il parser e di registrare gli oggetti che implementano le interfacce di callback
 - **XMLFilter**: interfaccia che consente di porre in sequenza vari XMLReaders come una serie di filtri

15

Interfacce Ausiliarie

- **Attributes**: Metodi per accedere ad una lista di attributi
- **Locator**: metodi per individuare l'origine degli eventi nel parsing dei documenti (es. systemID, numeri di linea e di colonna...)

16


ContentHandler

- Metodi per ricevere informazioni sugli eventi generali che si manifestano nel parsing di un documento XML.
 - `setDocumentLocator(Locator locator)`:
Riceve un oggetto che determina l'origine di un evento SAX. Per esempio potremmo usare il metodo per fornire informazioni agli utenti.
- Inizio e fine documento:
 - `startDocument(); endDocument()`
- Inizio e fine di un elemento:
 - `startElement(String namespaceURI, String localname, String qName, Attributes atts);`
 - `endElement(String namespaceURI, String localname, String qName);`
- Si noti che i due ultimi metodi supportano i namespaces

17


Altri metodi di ContentHandler

- `characters(char ch[], int start, int length)`
 - Notifica la presenza di character data.
- `ignorableWhitespace(char ch[], int start, int length)`
 - Notifica della presenza di whitespace ignorabili nell'element content.




18

Schema sintetico di un parser SAX



19

Schema di funzionamento di SAX in UML




20

Attivazione di un parser SAX

- Si crea prima una factory, poi il parser e infine il reader

```
SAXParserFactory spf =
    SAXParserFactory.newInstance();
try
{
    SAXParser saxParser =
        spf.newSAXParser();
    XMLReader xmlReader =
        saxParser.getXMLReader();
}
catch (Exception e)
{
    System.err.println(e.getMessage());
    System.exit(1);
};
```



21

SAX e i namespace: esempio 1

```
<xsl:stylesheet version="1.0"
  xmlns:xsl="http://www.w3.org/1999/XSL/Transform"
  xmlns="http://www.w3.org/TR/xhtml1/strict">
<xsl:template match="/">
  <html>
    <xsl:value-of select="//total"/>
  </html>
</xsl:template>
</xsl:stylesheet>
```

- Una invocazione del metodo di SAX `startElement` per l'elemento `xsl:template` passerebbe i seguenti parametri:

```
namespaceURI="http://www.w3.org/1999/XSL/Transform"
localname=template
qName=xsl:template
```

22

SAX e i namespace: esempio 2

```
<xsl:stylesheet version="1.0" ...  
  xmlns="http://www.w3.org/TR/xhtml1/strict">  
  <xsl:template match="/">  
    <html> ... </html>  
  </xsl:template>  
</xsl:stylesheet>
```

- Una invocazione del metodo di SAX `startElement` per l'elemento `html` passerebbe i seguenti parametri:
 namespaceURI= `http://www.w3.org/TR/xhtml1/strict`
 localname = `html`,
 qName = `html`
- Infatti `html` è senza prefisso e quindi appartiene al namespace di default

23

Esempio SAX - 1

- Consideriamo il seguente file XML:

```
<?xml version="1.0" encoding="ISO-8859-1"?>  
<db>  
  <person idnum="1234">  
    <last>Rossi</last><first>Mario</first>  
  </person>  
  <person idnum="5678">  
    <last>Bianchi</last><first>Elena</first>  
  </person>  
  <person idnum="9012">  
    <last>Verdi</last><first>Giuseppe</first>  
  </person>  
  <person idnum="3456">  
    <last>Rossi</last><first>Anna</first>  
  </person>  
</db>
```

24

Esempio SAX - 2

- Stampare a video nome, cognome e identificativo di ogni persona:
Mario Rossi (1234)
Elena Bianchi (5678)
Giuseppe Verdi (9012)
Anna Rossi (3456)
- Strategia di soluzione con un approccio event-based:
 - All'inizio di **person**, si registra **idnum** (p.es. 1234)
 - Si tiene traccia dell'inizio degli elementi **last** e **first**, per capire quando registrare nome e cognome (e.g., "Rossi" and "Mario")
 - Alla fine di **person**, si stampano i dati memorizzati

25

Esempio SAX - 3

- Incominciamo importando le classi che ci servono:

```
import org.xml.sax.XMLReader;  
import org.xml.sax.Attributes;  
import org.xml.sax.ContentHandler;  
  
// Implementazione di default di ContentHandler:  
import org.xml.sax.helpers.DefaultHandler;  
  
// Classi JAXP usate per accedere al parser SAX:  
import javax.xml.parsers.*;
```

26

Esempio SAX - 4

- Definiamo una classe che discende da **DefaultHandler** e ridefinisce solo i metodi di callback che sono rilevanti nella nostra applicazione:

```
public class SAXDBApp extends DefaultHandler
{
    // Flag per ricordare dove siamo:
    private boolean InFirst = false;
    private boolean InLast = false;
    // Attributi per i valori da visualizzare
    private String FirstName, LastName, IdNum;
```

27

Esempio SAX - 5

- Implementiamo i metodi di callback che ci servono
- Start element registra l'inizio degli elementi **first** e **last**, ed il valore dell'attributo **idnum** dell'elemento **person**:

```
public void startElement (String namespaceURI,
String localName, String rawName, Attributes atts)
{
    if (localName.equals("first"))
        InFirst = true;
    if (localName.equals("last"))
        InLast = true;
    if (localName.equals("person"))
        IdNum = atts.getValue("idnum");
}
```

28

Esempio SAX - 6

- Il metodo di callback **characters** intercetta il contenuto testuale
- Registriamo in modo opportuno il valore del testo a seconda che siamo dentro **first** o **last**:

```
public void characters (char ch[], int start,
    int length)
{
    if (InFirst) FirstName =
        new String(ch, start, length);
    if (InLast) LastName =
        new String(ch, start, length);
}
```

29

Esempio SAX - 7

- Quanto abbiamo trovato la fine dell'elemento **person**, scriviamo i dati. Quando troviamo la fine dell'elemento **first** o dell'elemento **last** aggiorniamo i flag in modo opportuno

```
public void endElement(String namespaceURI, String
    localName, String qName)
{
    if (localName.equals("person"))
        System.out.println(FirstName + " " +
            LastName + " (" + IdNum + ")" );
    //Aggiorna i flag di contesto
    if (localName.equals("first"))
        InFirst = false;
    if (localName.equals("last"))
        InFirst = false;
}
```

30

Esempio SAX – Il main

```
public static void main (String args[]) throws Exception
{
    // Usa SAXParserFactory per istanziare un XMLReader
    SAXParserFactory spf = SAXParserFactory.newInstance();
    try
    {
        SAXParser saxParser = spf.newSAXParser();
        XMLReader xmlReader = saxParser.getXMLReader();
        ContentHandler handler = new SAXDBApp();
        xmlReader.setContentHandler(handler);
        for (int i=0; i<args.length; i++)
            xmlReader.parse(args[i]);
    }
    catch (Exception e)
    {
        System.err.println(e.getMessage());
        System.exit(1);
    };
}
```

31

DOM

- **DOM** (**D**ocument **O**bject **M**odel) è una API per accedere e manipolare documenti XML (e HTML)
- Consente alle applicazioni di costruire documenti, navigare la loro struttura, aggiungere, modificare o cancellare elementi e contenuto
- DOM è object-based
- DOM è uno standard W3C supportato da numerosi linguaggi che utilizzano le stesse API
- Mentre SAX fornisce un meccanismo sequenziale per il parsing dei documenti DOM permette un accesso diretto senza imporre una particolare sequenza

32



Modello di DOM

- DOM è basato sui concetti tradizionali della programmazione ad oggetti:
 - Metodi: regolano l'accesso e consentono di alterare lo stato degli oggetti
 - Interfacce: consentono di dichiarare un insieme di metodi
 - Oggetti: incapsulano dati e metodi
- Il modello rappresenta i documenti XML come alberi (parse tree)
- La struttura ad albero è determinata dalle interfacce stabilite dalla specifica di DOM.
- Tipicamente la struttura ad albero viene mantenuta nell'implementazione dei parser DOM.

33

Esempio

```
<invoice>
  <invoicepage form="00"
    type="estimatedbill">
    <addressee>
      <addressdata>
        <name>Leila Laskuprintti</name>
        <address>
          <streetaddress>Pyynpolku 1
          </streetaddress>
          <postoffice>70460 KUOPIO
          </postoffice>
        </address>
      </addressdata>
    </addressee> ...
```



34

DOM Level 1

- DOM Level 1 fornisce il modello ed i meccanismi di base per rappresentare e manipolare la struttura e il contenuto di un documento
 - Non fornisce però accesso ai contenuti del DTD
- **DOM Core Interface**
 - Fornisce le interfacce di base per accedere ai documenti strutturati
 - Fornisce inoltre le **extended interfaces**, specifiche di XML, per gestire CDATASection, DocumentType, Notation, Entity, EntityReference, ProcessingInstruction
- **DOM HTML Interfaces**
 - Forniscono supporto per accedere ai documenti HTML

35

DOM Level 2

- DOM Level 2 aggiunge
 - Supporto per i **namespaces**
 - Accesso agli elementi tramite il valore degli attributi ID
- Funzionalità opzionali:
 - Interfacce per **document views** e **style sheets**
 - **Modello ad eventi** (per gestire ad esempio le azioni degli utenti sugli elementi)
 - Metodi per attraversare il documento e per manipolarne intere regioni (es. regioni selezionate dall'utente tramite un editor)
- Il caricamento e la scrittura dei documenti, benché spesso supportati, non sono specificati in DOM Level 2
 - Saranno inseriti in DOM Level 3


36

DOM Language Bindings

- DOM non dipende da un linguaggio specifico (language-independence):
- Le interfacce DOM sono definite sulla base della Interface Definition Language (OMG IDL; definito nelle specifiche di Corba)
- Language bindings (implementazioni delle interfacce di DOM) per tutti i principali linguaggi
 - Java
 - C++
 - JavaScript
- Nelle specifiche di DOM sono definiti i language bindings per
 - Java
 - JavaScript

37

Core interface: la tassonomia di Node



 Extended interfaces

38

Interfaccia Node: metodi

- `getNodeTypes()`
- `getNodeValue()`
- `getOwnerDocument()`
- `getParentNode()`
- `hasChildNodes()`
- `getChildNodes()`
- `getFirstChild()`
- `getLastChild()`
- `getPreviousSibling()`
- `getNextSibling()`
- `hasAttributes()`
- `getAttributes()`
- `appendChild(newChild)`
- `insertBefore(newChild, refChild)`
- `replaceChild(newChild, oldChild)`
- `removeChild(oldChild)`

39

Object Creation in DOM

- DOM specifica diverse classi
- L'oggetto X di DOM è inserito nel contesto di un Document:
`X.getOwnerDocument()`
- Gli oggetti che implementano l'interfaccia X sono creati da una factory
`D.createX(...)` ,
dove D è l'oggetto `Document`.
- Esempi:
`createElement("A")` ,
`createAttribute("href")` ,
`createTextNode("Hello!")`
- Creazione e salvataggio di `Document` sono demandati alle specifiche implementazioni

40

Interfacce Document ed Element

▪ Document

- `getDocumentElement()`
- `createAttribute(name)`
- `createElement(tagName)`
- `createTextNode(data)`
- `getDocType()`
- `getElementById(IdVal)`

▪ Element

- `getTagName()`
 - `getAttributeNode(name)`
 - `setAttributeNode(attr)`
 - `removeAttribute(name)`
 - `getElementsByTagName(name)`
 - `hasAttribute(name)`
-

41

Proprietà di Node

▪ `Node.nodeName()`

- Se applicato ad `Element` equivale a `getTagName()`
- Se applicato ad `Attr` restituisce il nome dell'attributo

▪ `Node.getNodeValue()`

- Restituisce il contenuto di un text node, il valore di un attributo...;
- Se applicato ad `Element` restituisce null

▪ `Node.nodeType()` :

- Restituisce un valore numerico costante (es. 1, 2, 3, ..., 12) che corrisponde a `ELEMENT_NODE`, `ATTRIBUTE_NODE`, `TEXT_NODE`, ..., `NOTATION_NODE`
-

42

Manipolazione di Content ed Element

- **Manipolazione di `CharacterData`:**
 - `substringData(offset, count)`
 - `appendData(string)`
 - `insertData(offset, string)`
 - `deleteData(offset, count)`
 - `replaceData(offset, count, string)`
(= delete + insert)
- **Accesso e manipolazione degli attributi di un `Element`:**
 - `getAttribute(name)`
 - `setAttribute(name, value)`
 - `removeAttribute(name)`

43

Interfacce `NodeList` e `NamedNodeMap`

- **`NodeList`** rappresenta liste ordinate di nodi:
 - Per esempio tutti i nodi figli di un nodo:
`Node.getChildNodes()`
 - Oppure tutti i discendenti di tipo "name" nell'ordine in cui appaiono nel documento.
`Element.getElementsByTagName("name")`
 - Si può usare la wild-card "*" per ottenere tutti gli elementi
- **Esempio: iteriamo su tutti i nodi figli di un nodo:**

```
for (i=0;i<node.getChildNodes().getLength();i++)  
    process(node.getChildNodes().item(i));
```
- **`NamedNodeMap`** permette di accedere a insiemi non ordinati di nodi individuati per nome:
 - Per esempio tutti gli attributi di un nodo:
`Node.getAttributes()`


44

Implementazioni di DOM

- **Parser Java**
 - IBM XML4J
 - Apache Xerces
 - Apache Crimson
 - SUN JAXP
 - ...
- **MS IE5 browser:**
 - interfacce per la programmazione COM per C/C++ e Visual Basic
 - oggetti ActiveX per i linguaggi di script
- **XML::DOM:** implementazione Perl di DOM Level 1

45

JAXP: Usare un Parser DOM



46

Attivazione e uso di un parser DOM in JAXP


- Si crea prima una factory, poi il document builder
- Si crea un oggetto di tipo File passando il nome del file che contiene il documento
- Si invoca il metodo parse del parser per ottenere un istanza di Document che può essere navigata

```
DocumentBuilderFactory dbf =  
    DocumentBuilderFactory.newInstance();  
  
DocumentBuilder builder =  
    dbf.newDocumentBuilder();  
  
File file = new File ("prova.xml");  
  
Document doc = dbf.parse(file)
```

47

DOM e SAX

- DOM è implementato usando SAX
- Il parser DOM implementa l'interfaccia ContentHandler
- Ad ogni evento costruisce un pezzo del modello DOM



48

Gestione del Parsing



- JAXP Consente la gestione degli errori nel parsing di documenti DOM
- Si crea una classe che implementa l'interfaccia ErrorHandler di SAX (metodi error, fatalError e warning).
- Un'istanza di questa classe viene passata al parser DOM usando il metodo setErrorHandler esposto da DocumentBuilder
- La Validazione ed i namespace vengono gestiti sia per **SAXParserFactories** e per **DocumentBuilderFactorys** con
 - **setValidating(boolean)**
 - **setNamespaceAware(boolean)**

49

Esempio DOM – Il documento XML

- Consideriamo un semplice documento XML:

```
<?xml version="1.0"?>
<student>
  <firstname>Paolo</firstname>
  <lastname>Rossi</lastname>
  <address>via Verdi 15</address>
  <city>Genova</city>
</student>
```



50

Esempio DOM – Caricamento del documento

```
import java.io.*;
import javax.xml.parsers.*;
import org.w3c.dom.*;

public class AccessingXmlFile
{
    public static Document loadDocument(String fileName)
    {
        try
        {
            File file = new File(fileName);
            DocumentBuilderFactory dbf =
                DocumentBuilderFactory.newInstance();
            DocumentBuilder db = dbf.newDocumentBuilder();
            return db.parse(file);
        }
        catch (Exception e)
        {
            e.printStackTrace();
        }
        ...
    }
}
```

51

Esempio DOM – Navigazione nel documento

```
...
public static void main(String argv[])
{
    Document document = loadDocument();
    Element root = document.getDocumentElement();
    root.normalize();
    System.out.println("Root " + root.getNodeName());
    System.out.println("Informazioni sugli studenti");
    NodeList nodes = root.getChildNodes();
    for (int i = 0; i < nodes.getLength(); i++)
    {
        Node el = nodes.items(i);
        String elName= el.getName()
        Node tx = el.getFirstChild();
        String elText=tx.getNodeValue();
        System.out.println(elname+"="+elText);
    }
}
```

52

JAXP: processor plugin

- Metodo per selezionare l'implementazione del parser XML che preferiamo a tempo di esecuzione
- Tipicamente sfrutta le system properties per individuare nel sistema il parser da utilizzare
- Interfacce:

```
javax.xml.parsers.SAXParserFactory  
javax.xml.parsers.DocumentBuilderFactory  
javax.xml.transform.TransformerFactory
```
- Esempio:

```
System.setProperty(  
    "javax.xml.parsers.DocumentBuilderFactory",  
    "com.icl.saxon.om.DocumentBuilderFactoryImpl");
```
- A default, l'implementazione di riferimento sfrutta
- Apache Crimson/Xerces per il parsing dei documenti XML
- Apache Xalan per la trasformazione di documenti

53

Altre API Java per il Parsing di XML

- JDOM
 - variante di DOM; maggiormente allineato alla programmazione orientata agli oggetti
 - <http://www.jdom.org/>
- DOM4J
 - Simile a JDOM ma con maggiori funzionalità
 - <http://www.dom4j.org/>
- JAXB (Java Architecture for XML Binding)
 - Compila i DTD in classi Java DTD-specific che consentono di leggere, scrivere e manipolare documenti XML validi
 - <http://java.sun.com/xml/jaxb/>

54