


# Laboratorio Reti di Calcolatori

Laurea Triennale in Comunicazione Digitale

Anno Accademico 2013/2014




# XML

- XML = eXtensible Markup Language
  - Progettato per trasporto e memorizzazione dati, non per visualizzazione dato. Non esegue alcuna operazione ma creato per strutturare e memorizzare le informazioni all'interno di tag. Uno degli strumenti più usati per il trasporto dell'informazione.

```
<?xml version="1.0"?>
<note>
  <to>Tove</to>
  <from>Jani</from>
  <heading>Reminder</heading>
  <body>Don't forget me this weekend!</body>
</note>
```

- Linguaggio di markup con tag non predefiniti ma definibili dal programmatore. Autore del documento può inventare i propri tag. Solitamente nomi tag devono essere autoesplicativi del contenuto.
- Raccomandato da W3C
- Autodescrittivo e con regole sintattiche stringenti
- Indipendente da hardware e software (text-based)
- Non rimpiazza HTML perchè obiettivi diversi:
  - XML si focalizza sul dato
  - HTML progettato per visualizzare il dato



# Uso di XML

- Separa i dati da HTML
  - Se il dato cambia (pagina HTML dinamica) non devo cambiare il documento HTML ma il file di dati XML associato. HTML/CSS per visualizzazione e layout e XML per contenuto da visualizzare. Necessito di un linguaggio lato client per estrarre il dato da XML (Javascript).
- Semplifica condivisione di dati
  - Formato dei dati in database non sempre compatibili. Dati XML memorizzati come file di testo. Quasi totalmente indipendente da software.
- Semplifica trasporto dati e il cambio di piattaforma
- Rende il dato più disponibile
  - Applicazioni diverse possono accedere allo stesso dato, basta che io legga un file testuale.
- Utilizzato per definire linguaggi di markup specializzati



# Albero XML

```
<?xml version="1.0" encoding="ISO-8859-1"?>
<note>
  <to>Tove</to>
  <from>Jani</from>
  <heading>Reminder</heading>
  <body>Don't forget me this weekend!</body>
</note>
```

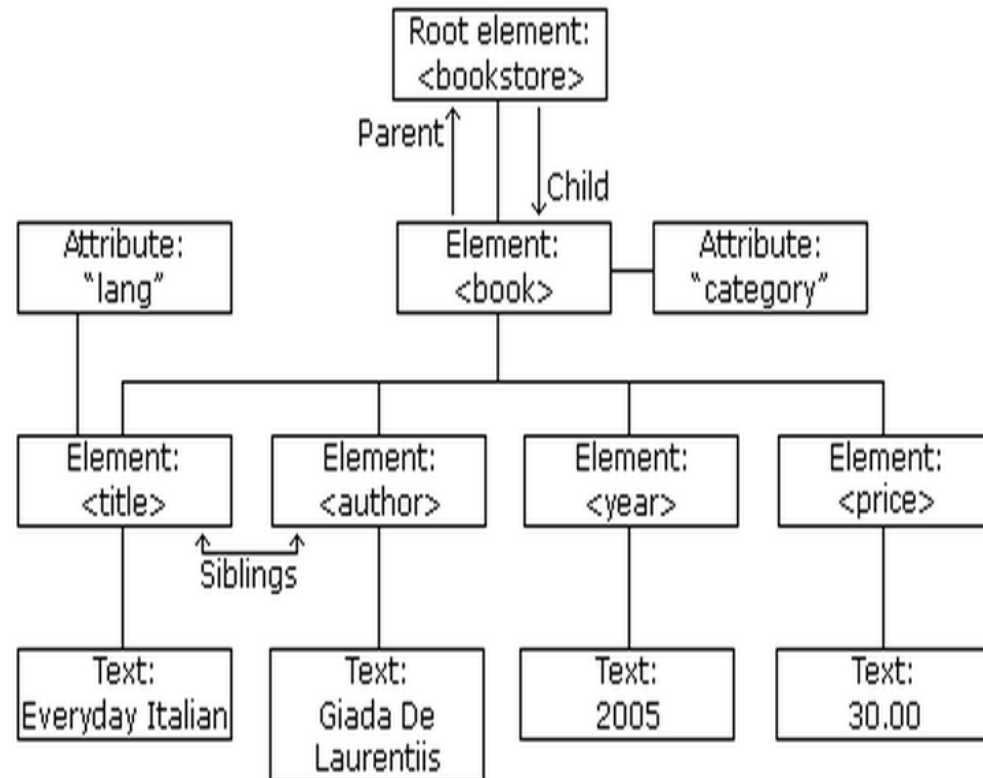
- Prima linea: dichiarazione XML con versione e codifica utilizzata.
- <note> è la radice
- <note> ha 4 figli
- </note> chiude la radice
- Elementi in un file XML formano un albero del documento. L'albero inizia dalla radice e si ramifica nei sottolivelli. Ogni elemento può avere dei sotto elementi


```
<root>
  <child>
    <subchild>.....</subchild>
  </child>
</root>
```

- Ogni elemento può avere degli attributi e del contenuto testuale

# Esempio


```
<bookstore>
  <book category="COOKING">
    <title lang="en">Everyday Italian</title>
    <author>Giada De Laurentiis</author>
    <year>2005</year>
    <price>30.00</price>
  </book>
  <book category="CHILDREN">
    <title lang="en">Harry Potter</title>
    <author>J K. Rowling</author>
    <year>2005</year>
    <price>29.99</price>
  </book>
  <book category="WEB">
    <title lang="en">Learning XML</title>
    <author>Erik T. Ray</author>
    <year>2003</year>
    <price>39.95</price>
  </book>
</bookstore>
```





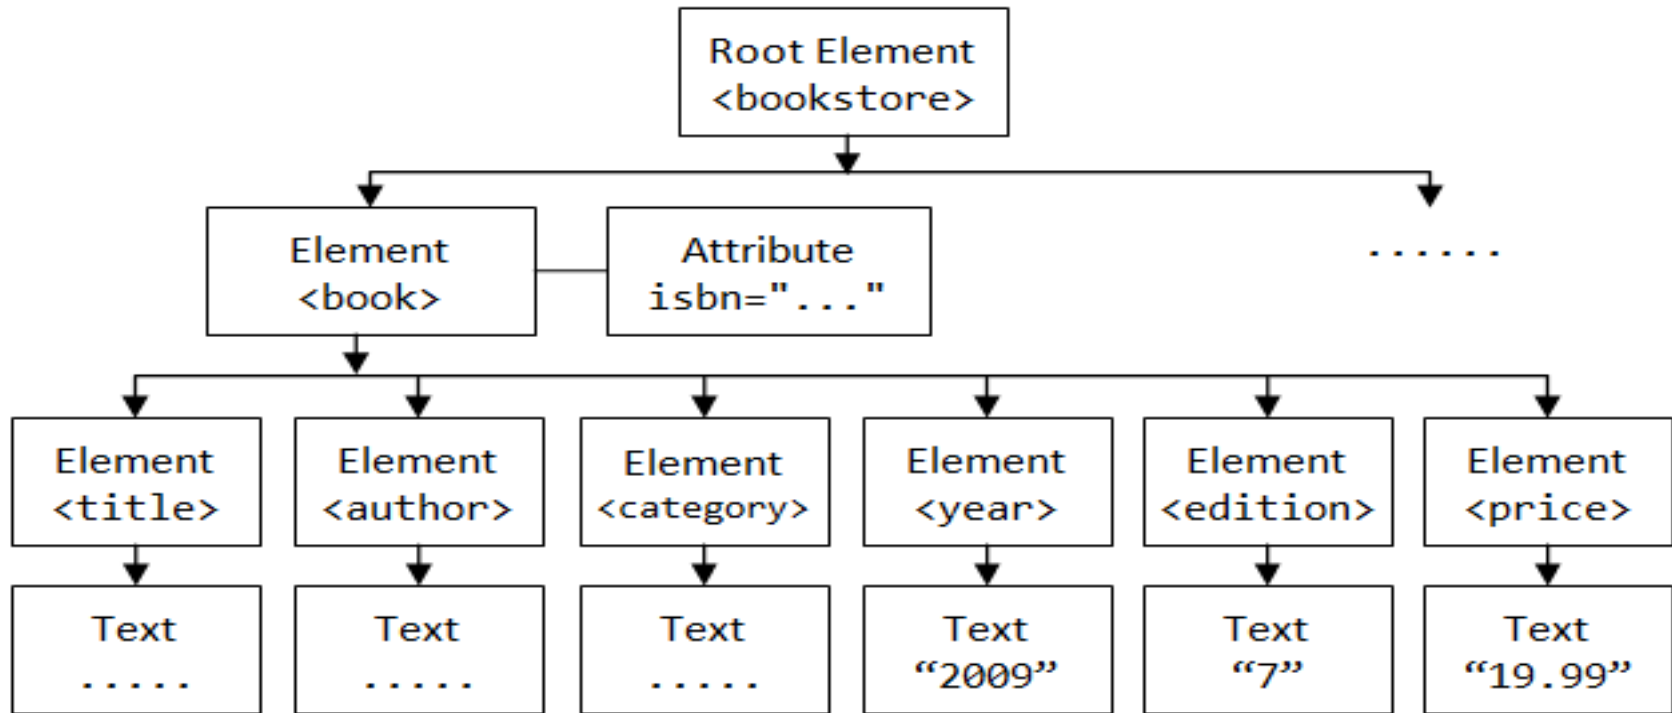
# Sintassi XML


1. Elementi devono avere una start tag ed un end tag
2. Un elemento è costituito da start ed end tag + i caratteri inclusi tra i tag (dati e figli)
3. Il nome di un elemento può contenere qualsiasi carattere Unicode ma non spazi vuoti. Deve iniziare con una lettera o ‘\_’ o ‘:’. Non può iniziare con alcune parole riservate come ‘xml’
4. Ogni documento XML deve avere una sola radice
5. Gli elementi devono essere propriamente innestati
6. XML è case sensitive. Start e end tags devono essere uguali
7. Uno start tag può contenere attributi nella forma nome-attributo=“valore-attributo”. Attributi forniscono ulteriori informazioni sull’elemento. Valori devono essere quotati(‘ o “)
8. I caratteri < e > devono essere rimpiazzati da entity reference nella forma &nome. Ci sono 5 entity reference predefinite: &lt; (<), &gt; (>), &amp; (&), &quot; (“), and &apos; (‘)
9. Commenti nella forma <!-- commento -->, come HTML
10. Gli spazi sono considerati e il carattere di nuova linea è \n



# XML ben formato

- Un documento XML è ben formato se la sua struttura rispetta le specifiche XML (sintatticamente corretto).





# Elemento XML

- Documento XML contiene elementi. Un elemento può contenere:

- Altri elementi
- Testo
- Attributi

```
<bookstore>
  <book category="CHILDREN">
    <title>Harry Potter</title>
    <author>J K. Rowling</author>
    <year>2005</year>
    <price>29.99</price>
  </book>
  <book category="WEB">
    <title>Learning XML</title>
    <author>Erik T. Ray</author>
    <year>2003</year>
    <price>39.95</price>
  </book>
</bookstore>
```

- Elementi devono seguire le regole di naming:
  - Nomi possono contenere lettere, numeri e altri caratteri
  - Non possono iniziare con un punto o con una cifra
  - Non possono iniziare con xml
  - Non possono contenere spazi
  - Devono essere descrittivi, corti e semplici
  - Evitare '-', ':', ':' nel nome
- Elemento può essere esteso per raggruppare più informazioni





# Attributo XML

- Attributo aggiungono ulteriori informazioni all'elemento che non sono parte del dato stesso ma possono aiutare il software che utilizza il documento XML

```
<file type="gif">computer.gif</file>
```


- I valori dell'attributo devono essere racchiusi tra doppi apici (come le stringhe in Java)
- Nessuna regola circa l'uso degli elementi o degli attributi

```
<person sex="female">  
  <firstname>Anna</firstname>  
  <lastname>Smith</lastname>  
</person>
```

```
<person>  
  <sex>female</sex>  
  <firstname>Anna</firstname>  
  <lastname>Smith</lastname>  
</person>
```

- Attributi non possono contenere valori multipli, strutture ad albero e non sono facilmente espandibili.
- Metadata memorizzati come attributo

```
<messages>  
  <note id="501">  
    <to>Tove</to>  
    <from>Jani</from>  
    <heading>Reminder</heading>  
    <body>Don't forget me this weekend!</body>  
  </note>
```



# DTD e Schema


- *DTD* e *Schema* sono tecniche per definire la struttura di un documento XML. Descrivono gli oggetti e le relazioni tra loro. Specificano un insieme di vincoli che stabiliscono se un albero XML (ben formato) è VALIDO.

## DTD

- Dichiarabile all'interno (inline) di un file XML o in un file esterno

Un *inline DTD* è racchiuso all'interno di una dichiarazione DOCTYPE

```
<!DOCTYPE root-element [  
    dichiarazione  
>
```




```
<!DOCTYPE bookstore [  
  <!ELEMENT bookstore (book+)>  
  <!ELEMENT book (title, author+, category*, language?, year?, edition?, price)>  
    <!ATTLIST book ISBN CDATA #REQUIRED>  
  <!ELEMENT title (#PCDATA)>  
  <!ELEMENT author (#PCDATA)>  
  <!ELEMENT category (#PCDATA)>  
  <!ELEMENT language (#PCDATA)>  
  <!ELEMENT year (#PCDATA)>  
  <!ELEMENT edition (#PCDATA)>  
  <!ELEMENT price (#PCDATA)>  
>
```

Faccio riferimento ad una definizione esterna con

```
<!DOCTYPE root-element SYSTEM "DTD-filename">
```

```
<!ELEMENT bookstore (book+)>  
<!ELEMENT book (title, author+, category*, language?, year?, edition?, price)>  
  <!ATTLIST book ISBN CDATA #REQUIRED>  
<!ELEMENT title (#PCDATA)>  
<!ELEMENT author (#PCDATA)>  
<!ELEMENT category (#PCDATA)>  
<!ELEMENT language (#PCDATA)>  
<!ELEMENT year (#PCDATA)>  
<!ELEMENT edition (#PCDATA)>  
<!ELEMENT price (#PCDATA)>
```



# Sintassi DTD

- **Dichiarazione di un elemento**

`<!ELEMENT nome-elemento (contenuto-elemento)>`

`<!ELEMENT nome-elemento categoria>`

## **Categoria o contenuto:**

- #PCDATA
- EMPTY
- ANY


## **Indicatori di occorrenza**

- +: 1 o più occorrenze
- \*: 0 o più occorrenze
- ?: 0 o solo 1 occorrenza
- Nessun indicatore: esattamente 1

## **Connettori**

- , : sequenza degli elementi figli
- | : scelta tra 1 degli elementi

```
<!ELEMENT title (#PCDATA)>
<!ELEMENT name (first_name,
last_name)>
<!ELEMENT person (name, address?,
email+, hobby*)>
<!ELEMENT message
(#PCDATA|(head, body))>
<!ELEMENT out_of_print EMPTY
<!ELEMENT message ANY>
```



- **Dichiarazione di una lista di attributi**

*<!ATTLIST nome-elemento*

*attribute-1-name attribute-1-type default*

*>*

*default-value|#REQUIRED|#IMPLIED|#FIXED value*

**Tipi di attributo:**

- CDATA
- ID: identificatore univoco
- IDREF, IDREFS: riferimento all'ID di altro elemento
- ENTITY, ENTITIES: entity esterna
- NMTOKEN, NMTOKENS: parole che non contengono spazi
- Lista di NMTOKEN separati da |


**Default:**

- #REQUIRED
- #IMPLIED: usa default dell'applicazione
- #FIXED valore : deve usare valore specificato
- Valore di default

```
<!ATTLIST payment mode CDATA  
"cash">
```

```
<!ATTLIST trade action (buy|sell)  
#REQUIRED>
```

```
<!ATTLIST person  
email CDATA #REQUIRED  
handphone CDATA #REQUIRED >
```




- **Dichiarazione entity**

*Entity* è una variabile per definire della sostituzioni testuali o caratteri speciali. Una volta definita posso invocarla usando *&nome-entity*

*<!ENTITY entity-name "entity-value">*


*<!ENTITY entity-name SYSTEM "url">*



# XML Namespace

- *Namespace* nasce da necessità di evitare conflitti tra nomi degli elementi.
- Associa un prefisso ad un URL univoco  
***xmlns:abc="http://www.abc.com/XSL/1.0"***  
Il prefisso usato come abbreviazione per l'URL e assicura unicità dei nomi (evita naming conflict)
- Valido all'interno dell'elemento in cui è stato dichiarato


```
<?xml version="1.0"?>
<book_review
  xmlns:abc="http://abc.com/rating/v10"
  xmlns:xyz="http://xyz.com/book/rating"
  xmlns="http://mydotcom.com/rating/book"> //default ns
  <book title="XML for dummies">
    <abc:rating>5</abc:rating>
    <xyz:rating>Excellent</xyz:rating>
    <rating>0.7</rating>
  </book> ...
</book_review>
```



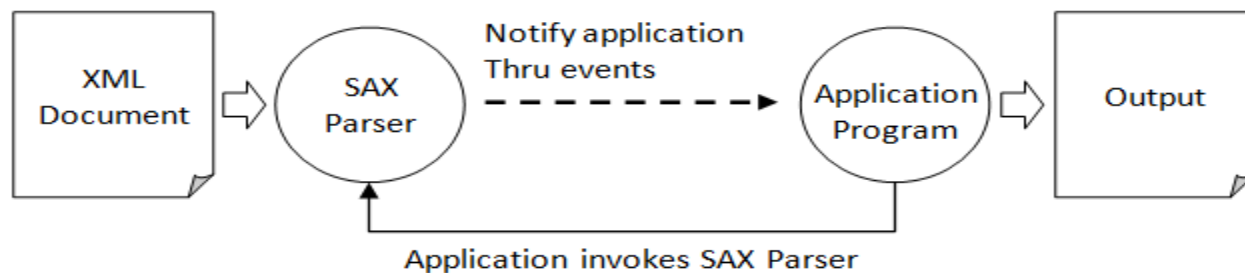
# JAXP

- Per processare i dati contenuti in un file XML di deve utilizzare un parser che tokenizza e reperisce gli oggetti di un documento XML. Il parser si pone tra XML e applicazione assicurandosi che documento sia ben formato
- *Java API for XML Processing*: insieme di interfacce standard per la gestione dei file XML
  - Metodo standard di accesso e manipolazione XML indipendente da librerie utilizzate
  - Diverse librerie già implementate
- Si compongono di
  1. *SAX* (Simple API for XML parsing): libreria di basso livello per parsing. Metodi vengono invocati quando ho un evento di apertura/chiusura tag
  2. *DOM* (Document Object Model): libreria di alto livello che trasforma XML in un albero di oggetti con la stessa struttura del documento.
  3. *XSLT* ( XML Style Sheet Transformation ): applico foglio di stile a XML






- **SAX** è un *event-driven* API. SAX API definisce una serie di metodi di callback che vengono invocati quando occorre un evento durante il parsing. Eventi per inizio/fine documento, inizio/fine tag, attributi, entity, commenti..




- **DOM** è un *object-oriented* API. Il parser DOM costruisce esplicitamente l'interno albero del documento XML. Manipolo i nodi dell'albero. Meccanismi di query, traversal e manipolazione del modello



# SAX


- Si legge XML e ad ogni elemento interessante viene invocato un metodo (metodi di callback) per gestire evento sollevato.
- Molto veloce e non richiede tutto il documento in memoria



**SAXParserFactory:** crea un'istanza del parser SAX  
**SAXParser** è l'istanza fondamentale, contiene oggetto XMLReader che legge XML e implementa il metodo parse(). Scansiona il documento e invoca i metodi di callback implementati  
Interfacce per metodi di callback:

- *Content Handler*
- *ErrorHandler*
- *DTDHandler*
- *EntityResolver*

Basta estendere la classe **DefaultHandler**

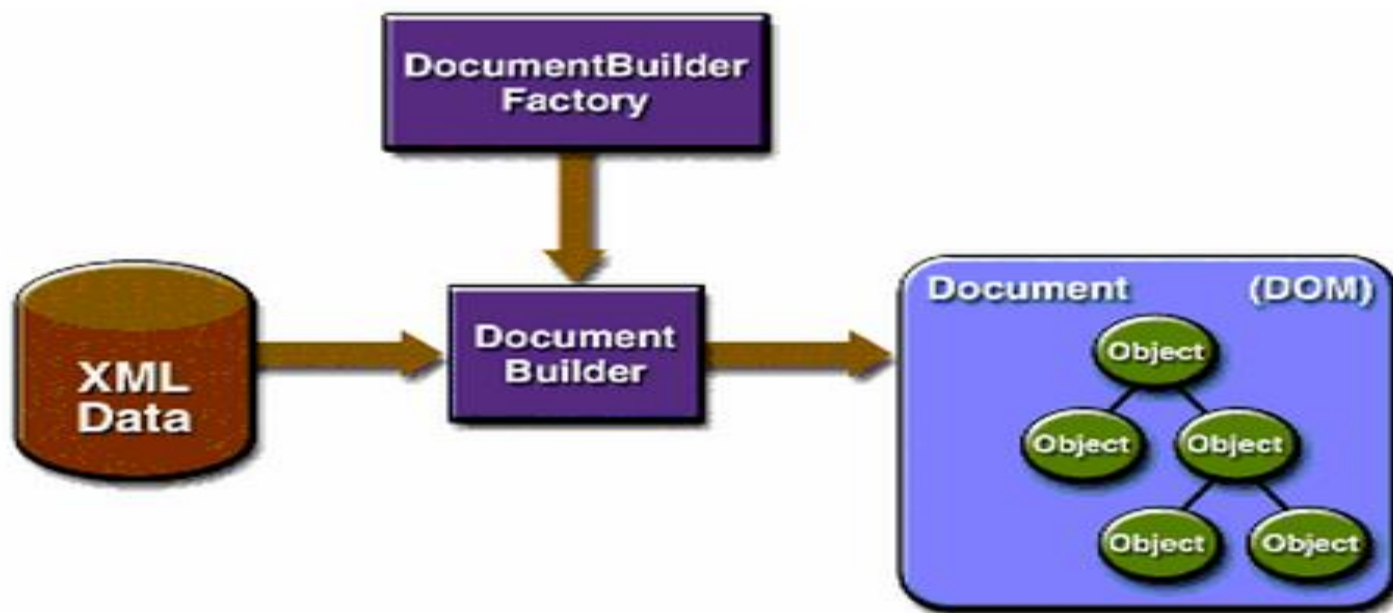


Metodi di callback più comuni:

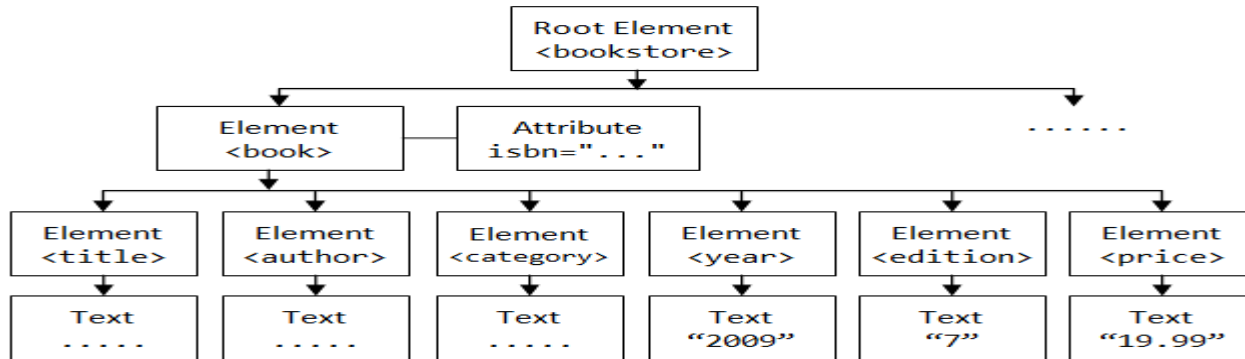

- Inizio e fine documento
  - ***void startDocument() void endDocument()***
- Inizio e fine tag
  - ***void startElement(String uri, String localName, String qName, Attributes attributes)***
  - ***void endElement(String uri, String localName, String qName)***
- Gestione dati all'interno del documento
  - ***void characters(char[] chars, int start, int length)***
- In startElement accedo agli attributi attraverso l'argomento Attributes che dispone dei metodi:
  - ***int getLength()***
  - ***String getValue(int qName)***
  - ***String getValue(int index)***
  - ***String getQName(int index)***

# DOM

- Documento XML viene convertito in albero di oggetti a cui posso accedere



- **DocumentBuilderFactory** è la factory usata per creare degli oggetti **DocumentBuilder**. Tramite questi ultimi un documento XML viene trasformato nell'albero DOM corrispettivo.



Per accedere alla root:

```
Element root = doc.getDocumentElement();
```


Ricerca di elementi per nome del tag

```
NodeList bookNodes = doc.getElementsByTagName("book");
```

```
NodeList allNodes = doc.getElementsByTagName("*");
```

- ***org.w3c.dom.Node*** definisce delle costanti per i tipi di nodo:

```
Node.ELEMENT_NODE, Node.ATTRIBUTE_NODE, Node.COMMENT_NODE  
,Node.ENTITY_NODE, Node.ENTITY_REFERENCE_NODE,Node.PROCESSING_INSTRUCTION_NODE, Node.TEXT_NODE, ..
```




# JSON


- *JSON* (JavaScript Object Notation) è un formato per lo scambio di dati. Si basa su un sottoinsieme di JavaScript
- JSON è un formato di testo completamente indipendente dal linguaggio di programmazione, ma utilizza convenzioni conosciute dai programmatori di linguaggi della famiglia del C.
- JSON è basato su due strutture:
  - Un insieme di coppie nome/valore.
  - Un elenco ordinato di valori.
- Queste sono strutture di dati universali. Virtualmente tutti i linguaggi di programmazione moderni li supportano in entrambe le forme

# Sintassi


**object**



**array**



**value**





# Esempio

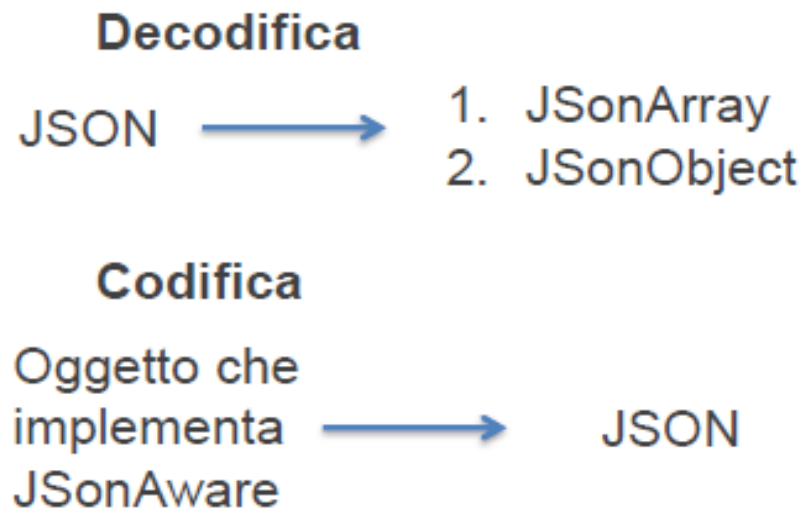
```
{
  "completed_in": 0.018,
  "page": 1,
  "query": "moratti",
  "results": [
    {
      "created_at": "Tue, 20 Nov 2012 11:30:38 +0000",
      "from_user_id": 366233317,
      "text": "RT @IlariaTriplete: #Moratti: \"Ho detto a Cellino che ha una squadra bellissima e gli ho augurato di tenersi i due tecnici che mi sembrano molto in gamba\"",
    },
    {
      "created_at": "Tue, 20 Nov 2012 11:30:11 +0000",
      "from_user_id": 72009402,
      "text": "Il \"signore\" #Moratti #vandermejde #cinqantamila #inter http://t.co/pVRozpqv",
    },
    {
      "created_at": "Tue, 20 Nov 2012 11:30:01 +0000",
      "from_user_id": 2800649,
      "text": "RT @IlariaTriplete: #Moratti: \"Il rigore? Sono cose che nel calcio capitano. Il brutto è che capitano tutte le domeniche\""
    }
  ],
  "results_per_page": 3,
}
```




# JSON-Simple

- *JSON-simple*: una delle tante librerie Java per trattare il formato JSON
  - Semplice e di facile utilizzo (Map e List)
  - Piena compatibilità con la RFC di JSON
  - Codifica e decodifica
  - Dove: <http://code.google.com/p/json-simple/downloads/list>
- Mapping

JSON	Java
String	java.lang.String
Number	java.lang.Number
True/false	java.lang.Boolean
null	null
Array	java.util.List
Object	java.util.Map






# Codifica

## Codifica solo con JSONObject

```
JSONObject obj=new JSONObject();  
obj.put("name","foo");  
obj.put("num",new Integer(100));  
obj.put("balance",new Double(1000.21));  
obj.put("is_vip",new Boolean(true));  
obj.put("nickname",null);  
System.out.print(obj);
```

## Codifica con Map

```
Map obj=new LinkedHashMap();  
obj.put("name","foo");  
obj.put("num",new Integer(100));  
obj.put("balance",new Double(1000.21));  
obj.put("is_vip",new Boolean(true));  
obj.put("nickname",null);  
String jsonText =  
JSONValue.toJSONString(obj);  
System.out.print(jsonText);
```



# Codifica

## Codifica solo con JSONArray

```
JSONArray list = new JSONArray();  
list.add("foo");  
list.add(new Integer(100));  
list.add(new Double(1000.21));  
list.add(new Boolean(true));  
list.add(null);  
System.out.print(list);
```

## Codifica con List

```
LinkedList list = new LinkedList();  
list.add("foo");  
list.add(new Integer(100));  
list.add(new Double(1000.21));  
list.add(new Boolean(true));  
list.add(null);  
String jsonText =  
JSONValue.toJSONString(list);  
System.out.print(jsonText);
```



# Codifica

## Combinazione JSONArray/JSONObject

```
JSONArray list1 = new JSONArray();
list1.add("foo");
list1.add(new Integer(100));
list1.add(new Double(1000.21));

JSONArray list2 = new JSONArray();
list2.add(new Boolean(true));
list2.add(null);

JSONObject obj = new JSONObject();
obj.put("name", "foo");
obj.put("num", new Integer(100));
obj.put("balance", new Double(1000.21));
obj.put("is_vip", new Boolean(true));
obj.put("nickname", null);

obj.put("list1", list1);
obj.put("list2", list2);

System.out.println(obj);
```


## Combinazione Map e List

```
Map m1 = new LinkedHashMap();
Map m2 = new HashMap();
List l1 = new LinkedList();

m1.put("k11", "v11");
m1.put("k12", "v12");
m1.put("k13", "v13");
m2.put("k21", "v21");
m2.put("k22", "v22");
m2.put("k23", "v23");
l1.add(m1);
l1.add(m2);

String jsonString =
JSONValue.toJSONString(l1);

System.out.println(jsonString);
```




# Decodifica

## JSONValue

```
String
s="[0,{\"1\":{\"2\":{\"3\":{\"4\":[5,{\"6\":7}]}}}]}]";
Object obj=JSONValue.parse(s);
JSONArray array=(JSONArray)obj;
JSONObject obj2=(JSONObject)array.get(1);
s="{ }";
obj=JSONValue.parse(s);
System.out.println(obj);
s="[5,]";
obj=JSONValue.parse(s);
System.out.println(obj);
s="[5,,2]";
obj=JSONValue.parse(s);
System.out.println(obj);
```

## JSONParser

```
JSONParser parser=new JSONParser();
String
s="[0,{\"1\":{\"2\":{\"3\":{\"4\":[5,{\"6\":7}]}}}]}]";
Object obj=parser.parse(s);
JSONArray array=(JSONArray)obj;
JSONObject obj2=(JSONObject)array.get(1);
s="{ }";
obj=parser.parse(s);
System.out.println(obj);
s="[5,]";
obj=parser.parse(s);
System.out.println(obj);
s="[5,,2]";
obj=parser.parse(s);
System.out.println(obj);
```



# Esercizi

1. Si codifichi una stringa in formato JSON utilizzando tutti i metodi presentati a lezione e infine si memorizzi la stringa sul file 'encode.txt'. Il contenuto della stringa è quello presentato come esempio nelle slide.
2. Si legga il file precedentemente salvato e lo si decodifichi utilizzando i tutti i metodi visti a lezione
3. Partendo dal un file bookstore.xml definito come nelle slide, si popoli una libreria (da creare) con oggetti libro costruiti a partire dall' XML. In una versione di utilizzi un parser SAX mentre nella seconda si utilizzi un parser DOM