

Document Object Model 1.0

Απόδοση στα
Ελληνικά της παρουσίασης του Alan Robinson
από τον Γιάννη Παπαδάκη
Νοέμβριος 2007

Ενα XML DTD

```
<?xml version='1.0' encoding="US-ASCII"?>

<!DOCTYPE biosequence [
  <!ELEMENT seq (dbxref*, residues?) >
  <!ATTLIST seq      id      ID      #REQUIRED
                name    CDATA   #IMPLIED
                length  CDATA   #IMPLIED >

  <!ELEMENT residues (#PCDATA)>
  <!ATTLIST residues type   (dna | rna | aa) #REQUIRED>
]>
```

Ενα τμήμα XML

```
<seq id="my_seq" name="NUCLEAR RIBONUCLEOPROTEIN">
  <dbxref>
    <database>SWISS-PROT</database>
    <unique_id>P09651</unique_id>
  </dbxref>
  <residues type="aa">
    SKSESPKEPEQLRKLFICGLSFETTDLSRSHFEQWGTLTDCVVMRDPTKRS
    RGFGFVTYATVEEVDAAMNARPHKVDGRVVEPKRAVSREDSQRPGAHLTVKKI
    FVGGIKEDTEEEHHLRDYFEQYGKIEVIEIMTDRGSGKKRGFAFVTFDDHDSDV
    KIVIQKYHTVNGHNCEVRKALSKQEMASASSQRGRSGSGNFGGGRRGGFFGN
    DNFGRRGGNFSGRGGFFGSRGGGGYGGSGDGYNGFGNDGGYGGGGPGYSGGSRG
    YGSGCGYGNQGSGYGGSGSYDSYNNNGGRGFGGSGSNFGGGGSYNDFGNYN
    NQSSNFGPMKGGNFGGRSSGPYGGGGQYFAKPRNQGGYGGSSSSSYGSGRRF
  </residues>
</seq>
```

Χρησιμοποιώντας έναν XML Parser

- Τρία βασικά βήματα:
 - Δημιουργία του parser object
 - Ανάθεση του XML εγγράφου στον parser
 - Επεξεργασία των αποτελεσμάτων
- Γενικά, το «γράψιμο» XML – XML serialization δεν υποστηρίζεται από τους parsers (αν και ορισμένοι υλοποιούν proprietary μηχανισμούς)

Τύποι Parser

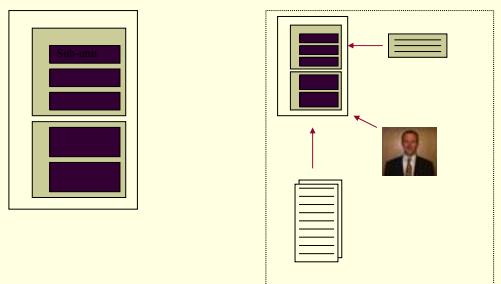
- Υπάρχουν πολλοί τρόποι κατηγοριοποίησης των parsers:
 - Validating και non-validating parsers
 - Parsers που υποστηρίζουν το Document Object Model (DOM)
 - Parsers που υποστηρίζουν το Simple API για XML (SAX)
 - Parsers γραμμένοι σε ορισμένη γλώσσα (Java, C++, Perl, κλπ.)

Non-validating Parsers

- Γρήγοροι και αποδοτικοί
 - Είναι κοπιαστικό για έναν XML parser να αναλύσει ένα DTD και να πιστοποιήσει ότι κάθε συστατικό στο XML έγγραφο ακολουθεί τους κανόνες του DTD
- Αν το μόνο που απαιτείται είναι ο εντοπισμός συστατικών και η εξόρυξη πληροφορίας συνίσταται η χρήση non-validating

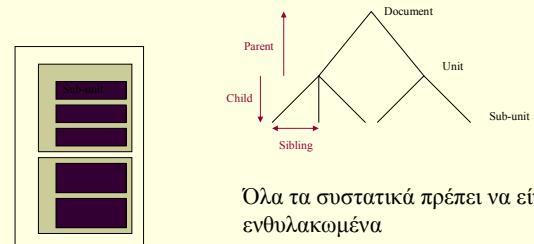
Δομή ενός XML

- Λογική δομή
 - Elements
- Φυσική δομή
 - Entities



Ιεραρχία XML

Η XML μπορεί να περιγράφει μια δενδρική ιεραρχία



Όλα τα συστατικά πρέπει να είναι ενθυλακωμένα

Parsing XML

- Δυο καθιερωμένα API
 - SAX (Simple API για XML)
 - Ορισμός handlers που περιέχουν μεθόδους κατά τη διάρκεια διάσχισης (parsed) της XML
 - DOM (Document Object Model)
 - Ορίζει ένα λογικό δέντρο που αναπαριστά την parsed XML δομή
- Εφαρμογές που δε χρειάζονται πολύπλοκη διαχείριση μπορούν να χρησιμοποιούν SAX
- Εφαρμογές που χρειάζονται δομική διαχείριση πολλών XML «πραγμάτων» (tokens) να χρησιμοποιούν DOM

DOM

- Document Object Model
- Σύνολο από interfaces για εφαρμογές που αποθηκεύουν ένα αρχείο XML στη μνήμη ως μια δευτερική δομή
- Το αφαιρετικό API επιπρέπει κατασκευή, πρόσβαση διαχείριση και επαναδόμηση της δομής και του περιεχομένου XML και HTML εγγράφων

Πλεονεκτήματα του DOM

- Διασχίζοντας ένα έγγραφο XML με έναν DOM parser, επιστρέφεται μια δομή που περιέχει όλα τα συστατικά του εγγράφου
- Το DOM παρέχει μια ποικιλία συναρτήσεων για την εξέταση της δομής και των περιεχομένων του εγγράφου

DOM αντί SAX

- Αν το έγγραφο είναι πολύ μεγάλο και χρειάζονται μόνο μερικά elements - επέλεξε SAX
- Αν πρέπει να επεξεργαστούν πολλά συστατικά και να εκτελεστούν διαδικασίες πάνω στο XML - επέλεξε DOM
- Αν πρέπει να ανοίξεις το έγγραφο XML πολλές φορές - επέλεξε DOM

DOM Standard

- DOM 1.0 standard από τη www.w3.org
- Αντικειμενοστραφής προσέγγιση
- Αποτελείται από έναν μεγάλο αριθμό διεπαφών
 - `org.w3c.dom.*`*
- Η κεντρική κλάση είναι: 'Document' (DOM tree)
- To Standard δεν περιλαμβάνει
 - Παραγωγή στην έξοδο XML format

Δημιουργώντας ένα DOM δέντρο

- Μια υλοποίηση DOM έχει μια μέθοδο ανάθεσης ενός XML αρχείου σε ένα factory object το οποίο θα επιστρέψει ένα Document object που αναπαριστά το συστατικό-ρίζα όλου του εγγράφου
- Το επόμενο βήμα είναι η χρήση του DOM standard interface για αλληλεπίδραση με την XML δομή



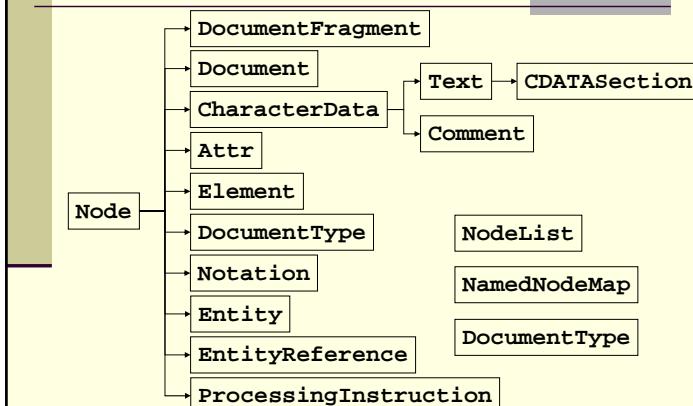
Δημιουργώντας ένα DOM δέντρο (2)

```
import org.w3c.dom.*;           //DOM interfaces
import com.sun.xml.tree.*;       //Using Sun classes
import org.xml.sax.*;            //Need SAX classes

public class myClass {
...
Document myDoc; //Document object
try {
    //if 'true' -> validate
    myDoc =
        XmlDocument.createXmlDocument("file:/doc.xml", true);
} catch (IOException err) {...}
catch (SAXException err) {...}
catch (DOMException err) {...}

//If no exceptions, should have a 'Document' object
```

DOM Interfaces και Classes



DOM Interfaces

- To DOM ορίζει πολλά interfaces
 - **Node** Ο βασικός τύπος δεδομένων για το DOM
 - **Element** Αντιστοιχεί στο συστατικό
 - **Attr** Αντιστοιχεί στο attribute του συστατικού
 - **Text** Το περιεχόμενο ενός συστατικού ή attribute
 - **Document** Αντιστοιχεί στο XML έγγραφο.
Συχνά, το αντικείμενο Document αναφέρεται ως DOM δέντρο

Node Interface

- Βασικό αντικείμενο του DOM (κόμβος-ρίζα στο δέντρο)
- Ένας κόμβος-Node μπορεί να είναι:

Elements	Entity declarations
Attributes	Entity references
Text	Notation declarations
Comments	Entire documents
CDATA sections	Processing instructions

- Node συλλογές-collections

- `NodeList`, `NamedNodeMap`, `DocumentFragment`

Node μέθοδοι

- Τρεις κατηγορίες μεθόδων
 - Χαρακτηριστικά Node
 - name, type, value
 - Τοποθεσία και πρόσβαση σε συγγενείς
 - parents, siblings, children, ancestors, descendants
 - Τροποποίηση Node
 - Edit, delete, re-arrange child nodes

Node μέθοδοι (2)

```
short      getNodeType();
String     getNodeName();
String     getNodeValue()          throws DOMException;
void       setNodeValue(String value) throws DOMException;
boolean    hasChildNodes();
NamedNodeMap getAttributes();
Document   getOwnerDocument();
```

Node Types - getNodeType()

```
ELEMENT_NODE      = 1  PROCESSING_INSTRUCTION_NODE = 7  
ATTRIBUTE_NODE    = 2  COMMENT_NODE             = 8  
TEXT_NODE         = 3  DOCUMENT_NODE            = 9  
CDATA_SECTION_NODE = 4  DOCUMENT_TYPE_NODE       = 10  
ENTITY_REFERENCE_NODE = 5 DOCUMENT_FRAGMENT_NODE = 11  
ENTITY_NODE        = 6  NOTATION_NODE            = 12  
  
if (myNode.getNodeType() == Node.ELEMENT_NODE) {  
    //process node  
    ...  
}
```

Ονόματα κόμβων και τιμές

- Κάθε κόμβος-node έχει όνομα και πιθανώς τιμή
- Το όνομα δεν είναι unique identifier (μόνο τοποθεσία)

Type	Interface Name	Name	Value
ATTRIBUTE_NODE	Attr	Attribute name	Attribute value
DOCUMENT_NODE	Document	#document	NULL
DOCUMENT_FRAGMENT_NODE	DocumentFragment	#document-fragment	NULL
DOCUMENT_TYPE_NODE	DocumentType	DOCTYPE name	NULL
CDATA_SECTION_NODE	CDATASection	#cdata-section	CDATA content
COMMENT_NODE	Comment	Entity name	Content string
ELEMENT_NODE	Element	Tag name	NULL
ENTITY_NODE	Entity	Entity name	NULL
ENTITY_REFERENCE_NODE	EntityReference	Entity name	NULL
NOTATION_NODE	Notation	Notation name	NULL
PROCESSING_INSTRUCTION_NODE	ProcessingInstruction	Target string	Content string
TEXT_NODE	Text	#text	Text string

Table as from "The XML Companion" - Neil Bradley

Child Nodes

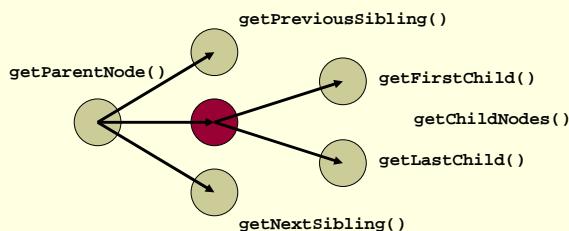
- Οι περισσότεροι κόμβοι δεν μπορούν να έχουν παιδιά, εκτός
 - Document, DocumentFragment, Element
- Ελεγχος της παρουσίας παιδιών
 - if (myNode.hasChildNodes()) {
 //process children of myNode
 ...
}

Node πλοιόγηση

- Κάθε κόμβος έχει συγκεκριμένη θέση στο δέντρο
- Το Node interface ορίζει μεθόδους για να βρει γειτονικούς κόμβους
 - Node getFirstChild();
 - Node getLastChild();
 - Node getNextSibling();
 - Node getPreviousSibling();
 - Node getParentNode();
 - NodeList getChildNodes();

Figure as from "The XML Companion" - Neil Bradley

Node πλούγηση (2)



```
Node parent = myNode.getParentNode();
if (myNode.hasChildren()) {
    NodeList children = myNode.getChildNodes();}
```

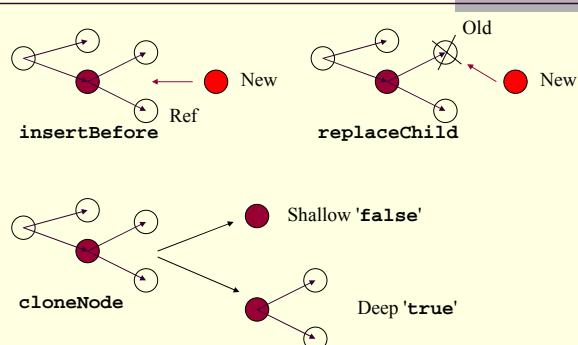
Διαχείριση Node

- Τα παιδιά ενός κόμβου στο δέντρο DOM μπορούν να υποστούν επεξεργασία- added, edited, deleted, moved, copied, κλπ.

```
Node removeChild(Node old) throws DOMException;
Node insertBefore(Node new, Node ref) throws DOMException;
Node appendChild(Node new) throws DOMException;
Node replaceChild(Node new, Node old) throws DOMException;
Node cloneNode(boolean deep);
```

Figure as from "The XML Companion" - Neil Bradley

Διαχείριση Node (2)



Document::Node Interface

- Αναφέρεται σε όλο το έγγραφο XML (ρίζα δέντρου)
- Μέθοδοι

```
//Information from DOCTYPE - See 'DocumentType'
DocumentType getDocumentType();

//Information about capabilities of DOM implementation
DOMImplementation getImplementation();

//Returns reference to root node element
Element getDocumentElement();

//Searches for all occurrences of 'tagName' in nodes
NodeList getElementsByTagName(String tagName);
```

Document::Node Interface (2)

- Μέθοδοι για δημιουργία κόμβων

```
Element createElement(String tagName) throws DOMException;  
  
DocumentFragment createDocumentFragment();  
  
Text createTextNode(String data);  
  
Comment createComment(String data);  
  
CDATASection createCDATASection(String data) throws  
                                         DOMException;  
ProcessingInstruction createProcessingInstruction(  
                                         String target, String data) throws DOMException;  
Attr createAttribute(String name) throws DOMException;  
  
EntityReference createEntityReference(String name)  
                           throws DOMException;
```

DocumentType::Node Interface

- Πληροφορίες για το ενθυλακωμένο έγγραφο DTD

- Το DOM 1.0 δεν επιτρέπει επεξεργασία του κόμβου

```
//Returns name of document  
String getName();  
  
//Returns general entities declared in DTD  
NamedNodeList getEntities();  
  
//Returns notations declared in DTD  
NamedNodeList getNotations();
```

Element::Node Interface

- Δυο κατηγορίες μεθόδων

- Γενικές μέθοδοι element

```
String getTagName();  
NodeList getElementsByTagName();  
void normalize();
```

- Διαχείριση Attributes

```
String getAttribute(String name);  
void setAttribute(String name, String value)  
                           throws DOMException;  
void removeAttribute(String name)  
                           throws DOMException;  
Attr getAttributeNode (String name);  
void setAttributeNode(Attr new)  
                           throws DOMException;  
void removeAttributeNode(Attr old)  
                           throws DOMException;
```

Element::Node Interface (2)

- Προφανώς, μόνο αντικείμενα Element έχουν attributes αλλά οι μέθοδοι για attribute του Element είναι απλοίκες

- Πρέπει να ξέρεις το όνομα του attribute
 - Δεν μπορείς να ξεχωρίσεις μεταξύ της default τιμής που υπάρχει στο DTD και σε αυτή που υπάρχει στο αρχείο XML

- Χρησιμοποιήσε τη μέθοδο getAttributes() του Node

- Επιστρέφει αντικείμενα Attr σε μορφή NamedNodeMap

Attr::Node Interface

- Interface σε αντικείμενα που έχουν δεδομένα attribute

```
//Get name of attribute  
String getName();  
  
//Get value of attribute  
String getValue();  
  
//Change value of attribute  
void setValue(String value);  
  
//if 'true' - attribute defined in element, else in DTD  
boolean getSpecified();
```

Attr::Node Interface (2)

- parentNode, previousSibling και nextSibling έχουν null τιμή για το Attr αντικείμενο

```
//Create the empty Attribute node  
Attr newAttr = myDoc.createAttribute("status");  
  
//Set the value of the attribute  
newAttr.setValue("secret");  
  
//Attach the attribute to an element  
myElement.setAttributeNode(newAttr);
```

CharacterData::Node Interface

- Χρήσιμες γενικές μέθοδοι για επεξεργασία κειμένου
- Δε χρησιμοποιείται άμεσα

- sub-classed σε Text και Comment Node types

```
String getData() throws DOMException;  
void setData(String data) throws DOMException;  
int getLength();  
void appendData(String data) throws DOMException;  
String substringData(int offset, int length) throws DOMException;  
void insertData(int offset, String data) throws DOMException;  
void deleteData(int offset, int length) throws DOMException;  
void replaceData(int offset, int length, String data) throws DOMException;
```

Text:: CharacterData Interface

- Αναφέρεται σε περιεχόμενο τύπου «κείμενο» σε Element ή Attr

- Συνήθως παιδί αυτών των κόμβων

- Μια μόνο μέθοδος προστίθεται στο CharacterData interface

- Text splitText(int offset) throws DOMException

- Εκτελώντας normalize() σε ένα Element συγχωνεύονται τα αντικείμενα Text tou

CDATASection::Text Interface

- Αναφέρεται σε κείμενο (CDATA) που δε θέλουμε να αναγνωριστεί ως σημείωση (το μόνο που αναγνωρίζεται είναι το "]]>" που τερματίζει την περιοχή CDATA)
- Το **DOMString** attribute του κόμβου **Text** έχει το κείμενο του CDATA
- Δεν προστίθενται μέθοδοι στο **CharacterData**
- Μέθοδος κατασκευής (Factory method) στο **Document**

```
CDATASection newCDATA =
    myDoc.createCDATASection("press <<<ENTER>>>");
```

Comment::Text Interface

- Αναφέρεται στα σχόλια
- όλοι οι χαρακτήρες μεταξύ '<!--' και '-->'
- Δεν προστίθενται μέθοδοι στο **CharacterData**
- Factory method in **Document** for creation

```
Comment newComment =
    myDoc.createComment(" my comment "); //Note spaces
```

ProcessingInstruction::Node Interface

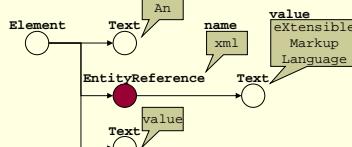
- Αναφέρεται σε δηλώσεις processing instruction
 - Το όνομα του κόμβου είναι η **ri**
 - Η τιμή του κόμβου είναι το κείμενο μεταξύ του ονόματος της **ri** και του **'?'**
- ```
//Get the content of the processing instruction
String getData()
//Set the content of the processing instruction
void setData(String data)
//The target of this processing instruction
String getTarget();
```
- Μέθοδος κατασκευής (Factory method) στο **Document**
- ```
ProcessingInstruction newPI =
    myDoc.createProcessingInstruction("ACME",
        "page-break");
```

Figure as from "The XML Companion" - Neil Bradley

EntityReference::Node Interface

- To DOM περιέχει interfaces για διαχείριση entities και entity references

```
<!ENTITY xml "eXtensible Markup Language">
<para>An &xml; value</para>
```



NodeList Interface

- Εχει τη συλλογή ταξινομημένων **Node** αντικειμένων
- 2 μέθοδοι

```
//Find number of Nodes in NodeList  
int getLength();  
  
//Return the i-th Node  
Node item(int index);  
-----  
Node child;  
NodeList children = element.getChildNodes();  
for (int i = 0; i < children.getLength(); i++) {  
    child = children.item(i);  
    if (child.getNodeType() == Node.ELEMENT_NODE) {  
        System.out.println(child.getNodeName());  
    }  
}
```

NamedNodeMap Interface

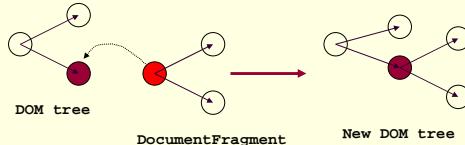
- Εχει τη συλλογή μη ταξινομημένων **Node** αντικειμένων
Π.χ. **Attribute**, **Entity**

- Τα μοναδικά ονόματα είναι απαραίτητα καθώς οι κόμβοι προσπελαύνονται με το όνομά τους

```
NamedNodeMap myAttributes = myElement.getAttributes();  
NamedNodeMap myEntities = myDocument.getEntities();  
-----  
int getLength();  
Node item(int index);  
Node getNamedItem(String name);  
Node setNamedItem(Node node) throws DOMException; //Node!  
Node removeNamedItem(String name) throws DOMException;
```

DocumentFragment::Node Interface

- Ενα τμήμα ενός κειμένου μπορεί να αποθηκευτεί προσωρινά σε κόμβο **DocumentFragment**
 - Π.χ. Για 'cut-n-paste'
- Οταν προστίθεται σε άλλο κόμβο, αυτοκαταστρέφεται



DOMImplementation Interface

- Interface για τον καθορισμό βαθμού υποστήριξης από τον DOM parser

```
hasFeature(String feature, String version);  
  
if (theParser.hasFeature("XML", "1.0")) {  
    //XML is supported  
    ...  
}
```

DOM αντί XSL

- Αν απαιτείται πολύπλοκη ταξινόμηση ή αναδόμηση, προτιμάται το DOM
- Η XSL είναι πιο lightweight