

Ημιδομημένες ΒΔ - XML



- Εισαγωγή
- Η δομή των XML δεδομένων
- Οργάνωση / διαχείριση XML δεδομένων
- Ερωτήσεις σε XML δεδομένα
- Αποθήκευση XML δεδομένων σε Σχεσιακές ΒΔ

Βασική πηγή διαφανειών: Silberschatz et al., "Database System Concepts", 4/e
Εργαστήριο Πληροφοριακών Συστημάτων, Παν/μιο Πειραιώς (<http://infolab.cs.unipi.gr/>)
έκδοση: Δεκέμβριος 2007



- ➔
- Εισαγωγή
 - Η δομή των XML δεδομένων
 - Οργάνωση / διαχείριση XML δεδομένων
 - Ερωτήσεις σε XML δεδομένα
 - Αποθήκευση XML δεδομένων σε Σχεσιακές ΒΔ

Εισαγωγή



- XML: Extensible Markup Language
- Ορίστηκε από το WWW Consortium (W3C) ως συμπλήρωμα της HTML.
 - Δεν σχεδιάστηκε για βάσεις δεδομένων αλλά για διαχείριση εγγράφων
 - Ενώ η HTML (Hyper-Text Markup Language) περιγράφει την αναπαράσταση των δεδομένων, η XML περιγράφει το περιεχόμενο, π.χ. , tag: `<people> </people>`
 - Για τον ορισμό της αναπαράστασης μπορεί να χρησιμοποιηθεί ένα ξεχωριστό stylesheet σε μια ειδική γλώσσα την XSL.
 - Σε αντίθεση με την HTML, η XML είναι επεκτάσιμη
 - Οι χρήστες μπορούν να προσθέτουν νέα tags και να καθορίζουν πως πρέπει να αντιμετωπίζονται τα tags κατά την εμφάνισή τους.
 - Ο στόχος ήταν η XML να αντικαταστήσει την HTML ως γλώσσα για την δημοσίευση ιστοσελίδων στο Internet.

Εισαγωγή (συν.)



- **Markup:** οποιοδήποτε τμήμα ενός document το οποίο δεν αποτελεί τμήμα της εκτυπωμένης εξόδου.
- **Markup language:** μια αυστηρά τυπική περιγραφή σχετικά με το ποιο είναι το περιεχόμενο του κειμένου, ποιο το markup και τι σημαίνει.
- Σε σύγκριση με τις βάσεις δεδομένων η XML μπορεί να μην είναι τόσο αποδοτική αφού έχουμε επανάληψη των tags, ωστόσο η XML είναι ιδανική για την ανταλλαγή δεδομένων μεταξύ εφαρμογών
 - Η κυρίως χρήση της XML αφορά την ανταλλαγή δεδομένων μεταξύ εφαρμογών
 - Τα tags είναι αυτοπεριγραφικά.

Εισαγωγή (συν.)



- Παράδειγμα

```
<bank>
  <account>
    <account-number> A-101 </account-number>
    <branch-name>      Downtown </branch-name>
    <balance>          500      </balance>
  </account>
  <depositor>
    <account-number> A-101 </account-number>
    <customer-name> Johnson </customer-name>
  </depositor>
</bank>
```

Γιατί χρειάζεται η XML;



- Η ανταλλαγή δεδομένων είναι εξαιρετικά σημαντική σήμερα
 - Π.χ.: Τραπεζικά δεδομένα: μεταφορές κεφαλαίου ...
 - Η έντυπη διακίνηση πληροφορίας μεταξύ των εταιριών αντικαθίσταται από την ηλεκτρονική διακίνηση.
- Κάθε τομέας εφαρμογών έχει το δικό του σύνολο από standards για την αναπαράσταση της πληροφορίας.
- Η XML έχει γίνει η βάση όλων των νέας γενιάς standards για την ανταλλαγή των δεδομένων.
- Ένα μεγάλο σύνολο εργαλείων διατίθεται για την ανάλυση (parsing), την δυνατότητα πλοήγησης (browsing) και τον καθορισμό ερωτήσεων (querying) πάνω στα XML δεδομένα.

Θέματα σχετικά με τη χρήση της XML



- Οργάνωση των XML δεδομένων
- Διαχείριση των XML δεδομένων
- Ερωτήσεις πάνω στα XML δεδομένα

Η δομή των XML δεδομένων



- Το βασικό στοιχείο σε ένα XML document είναι το element
- **Element (στοιχείο)**: ένα τμήμα δεδομένων ανάμεσα σε δύο matching tags (`<tagname>` `</tagname>`).
- Τα Elements πρέπει να είναι κατάλληλα εμφωλευμένα.
 - Σωστή εμφώλευση
 - `<account> ... <balance> .... </balance> </account>`
 - Λανθασμένη εμφώλευση
 - `<account> ... <balance> .... </account> </balance>`
 - Τυπικά: κάθε tag αρχής πρέπει να έχει ένα μοναδικό και "ταιριαστό" tag τέλους.

Παράδειγμα εμφωλευμένων Elements



```
<bank-1>
  <customer>
    <customer-name> Hayes </customer-name>
    <customer-street> Main </customer-street>
    <customer-city> Harrison </customer-city>
    <account>
      <account-number> A-102 </account-number>
      <branch-name> Perryridge </branch-name>
      <balance> 400 </balance>
    </account>
    <account>
      ...
    </account>
  </customer>
  .
  .
</bank-1>
```

Γιατί χρειάζεται η εμφώλευση;

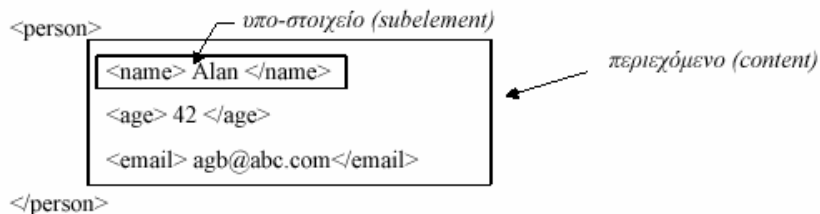


- Δεν υποστηρίζεται αλλά ούτε και απαγορεύεται η χρήση της στις σχεσιακές βάσεις δεδομένων
 - Η κανονικοποίηση αντικαθιστά τις εμφωλευμένες δομές σε κάθε σειρά με ένα ξένο κλειδί σε ένα πίνακα που περιέχει το customer name και πληροφορίες για την customer address.
 - Η εμφώλευση υποστηρίζεται στις αντικειμενοστραφείς – σχεσιακές βάσεις δεδομένων.
- Κατάλληλο για τη μεταφορά δεδομένων
 - Οι εξωτερικές εφαρμογές δεν έχουν άμεση πρόσβαση στα δεδομένα που αναφέρονται από κάποιο ξένο κλειδί.

Η δομή των XML δεδομένων (Συν.)



- Στην XML επιτρέπεται ο συνδυασμός κειμένου με υπο-στοιχεία (subelements).



Γνωρίσματα (*attributes*)



- Τα elements μπορούν να έχουν **γνωρίσματα**, τα οποία ορίζονται ως ζεύγη (όνομα, τιμή) μέσα στο tag αρχής του element.
 - `<account acct-type = "checking" >`
 `<account-number> A-102 </account-number>`
 `<branch-name> Perryridge </branch-name>`
 `<balance> 400 </balance>`
 `</account>`
- Τα γνωρίσματα είναι strings, και δεν περιέχουν markup πληροφορία
- Τα γνωρίσματα θα πρέπει να εμφανίζονται μία μόνο φορά σε ένα tag, σε αντίθεση με τα sub-elements που μπορούν να επαναλαμβάνονται.
 - `<account acct-type = "checking" monthly-fee="5">`



Γνωρίσματα vs. subelements

- Το όνομα ενός γνωρίσματος είναι μοναδικό σε κάθε tag, ενώ τα ονόματα των subelements δεν είναι.
 - Τα γνωρίσματα αποτελούν μέρος του markup (άρα δεν εμφανίζονται στο τελικό αποτέλεσμα), ενώ τα sub-elements αποτελούν μέρος των περιεχομένων του document.
 - Προσφέρουν εναλλακτικούς τρόπους αναπαράστασης δεδομένων.
 - `<person>`

```

              <name> Alan </name>
              <age>  42 </age>
              <email> agb@abc.com</email>
            </person>
          
```
 - `<person name="Alan" age="42" email="agb@abc.com" />`
 - Υπόδειξη: χρησιμοποιήστε τα γνωρίσματα για την αναγνώριση των elements (as identifiers), και χρησιμοποιήστε τα sub-elements για τα περιεχόμενα.



Namespaces

- Εφόσον η XML χρησιμοποιείται για την ανταλλαγή δεδομένων μεταξύ επιχειρήσεων θα πρέπει να υπάρχει ένας μηχανισμός για τον καθορισμό καθολικά μοναδικών ονομάτων για τα element tags των document.
 - Καθορίζοντας ένα μοναδικό string ως το όνομα κάποιου element αποφεύγεται η σύγχυση.
- Λύση: συσχέτισε κάθε tag ή element με ένα μοναδικό καθολικό identifier, π.χ. μια web σελίδα
 - **unique-name:element-name**
- Π.χ. Αν η First Bank ήθελε να εξασφαλίσει ότι τα XML documents της δεν θα είχαν ίδια tags με τα XML documents κάποιας άλλης επιχείρησης θα μπορούσε να χρησιμοποιήσει ένα url ως εξής:
 - ```

<bank xmlns:FB='http://www.FirstBank.com'>
...
 <FB:branch>
 <FB:branchname>Downtown</FB:branchname>
 <FB:branchcity> Brooklyn </FB:branchcity>
 </FB:branch> ... </bank>

```

## XML Document Schema



- Οι βάσεις δεδομένων έχουν σχήματα που καθορίζουν ποια δεδομένα μπορούν να αποθηκευτούν στη βάση και τους τύπους δεδομένων των αποθηκευμένων τιμών.
- Τα XML documents μπορούν να δημιουργηθούν χωρίς να σχετίζονται με κάποιο σχήμα.
  - ελευθερία (ένα element μπορεί να έχει οποιοδήποτε subelement ή γνώρισμα)
  - τι γίνεται στην περίπτωση που τα XML documents πρέπει να επεξεργαστούν αυτόματα ως τμήμα μιας εφαρμογής;
- Τα σχήματα είναι σημαντικά για την ανταλλαγή δεδομένων στην XML.
- Υπάρχουν δύο μηχανισμοί για τον καθορισμό ενός XML σχήματος
  - **Document Type Definition (DTD)**
    - Ήδη καθιερωμένο, χρησιμοποιείται ευρέως.
  - **XML Schema**

ΒΔ: Ημιδομημένες ΒΔ - XML Νεότερο, με αυξανόμενη χρήση.

ΠΑ.ΠΕΙ. – Γιάννης Θεοδωρίδης

## Document Type Definition (DTD)



- Περιγράφει μια κλάση από XML documents χρησιμοποιώντας μια γλώσσα που είναι ουσιαστικά μια γραμματική χωρίς συμφραζόμενα με αρκετούς περιορισμούς.
- Το DTD περιορίζει τη δομή των XML δεδομένων
  - Ποια elements μπορούν να υπάρχουν
  - Ποια γνώρισμα μπορεί/ πρέπει να έχει ένα element
  - Ποια subelements μπορεί/ πρέπει να υπάρχουν μέσα σε ένα element, και πόσες φορές.
- Το DTD δεν περιορίζει τους τύπους δεδομένων π.χ. integer
  - Όλες οι τιμές αναπαρίστανται ως strings.
- Το DTD είναι μια λίστα από κανόνες σχετικά με τα subelements και τα γνώρισμα που μπορούν να υπάρχουν μέσα σε ένα element.
- DTD syntax
  - `<!ELEMENT element (subelements-specification) >`
  - `<!ATTLIST element (attributes) >`

ΒΔ: Ημιδομημένες ΒΔ - XML

16

ΠΑ.ΠΕΙ. – Γιάννης Θεοδωρίδης

## Παράδειγμα: Bank DTD



```
<!DOCTYPE bank [
 <!ELEMENT bank ((account | customer | depositor)+)>
 <!ELEMENT account (account-number branch-name balance)>
 <! ELEMENT customer(customer-name customer-street
 customer-city)>
 <! ELEMENT depositor (customer-name account-number)>
 <! ELEMENT account-number (#PCDATA)>
 <! ELEMENT branch-name (#PCDATA)>
 <! ELEMENT balance(#PCDATA)>
 <! ELEMENT customer-name(#PCDATA)>
 <! ELEMENT customer-street(#PCDATA)>
 <! ELEMENT customer-city(#PCDATA)>
]>
```

## Καθορισμός elements στο DTD



- Τα subelements μπορούν να καθοριστούν ως
  - ονόματα elements, ή
  - #PCDATA, π.χ., character strings
    - PCDATA (parsed character data) υποδηλώνει κείμενο
  - EMPTY (το element δεν έχει περιεχόμενο)
  - ANY (δεν υπάρχει περιορισμός ως προς τα subelements που μπορεί να έχει το element)
    - Αν δεν υπάρχει δήλωση για κάποιο element υποδηλώνεται το any.

## Καθορισμός elements στο DTD (συν.)



- Παράδειγμα
  - `<! ELEMENT depositor (customer-name account-number)>`
  - `<! ELEMENT customer-name (#PCDATA)>`
  - `<! ELEMENT account-number (#PCDATA)>`
- Ένα subelement μπορεί να περιέχει κανονικές εκφράσεις (regular expressions)
  - `<!ELEMENT bank ( ( account | customer | depositor)+)>`
    - Σημειογραφία:
      - `"|"` - εναλλακτικές επιλογές
      - `"+"` -  $\geq 1$  εμφανίσεις
      - `"*"` -  $\geq 0$  εμφανίσεις

## IDs και IDREFs



- Το **ID** γνώρισμα αποτελεί μοναδικό identifier για ένα element (object identifier).
- Η τιμή του ID ενός element θα πρέπει να είναι μοναδική στο XML document.
- Σε ένα element το πολύ ένα γνώρισμα επιτρέπεται να είναι τύπου ID.
- Το **IDREF** γνώρισμα είναι μια αναφορά σε ένα element και πρέπει να περιέχει μια τιμή που εμφανίζεται σε κάποιο ID γνώρισμα των elements του document.
- Ένα IDREF γνώρισμα περιέχει ένα σύνολο από ( $\geq 0$ ) τιμές ID γνωρισμάτων.

## Bank DTD με γνωρίσματα



- Το DTD της τράπεζας με γνωρίσματα τύπου ID και IDREF.

```
<!DOCTYPE bank-2[
 <!ELEMENT account (branch, balance)>
 <!ATTLIST account
 account-number ID # REQUIRED
 owners IDREFS # REQUIRED>
 <!ELEMENT customer(customer-name, customer-street,
 customer-city)>
 <!ATTLIST customer
 customer-id ID # REQUIRED
 accounts IDREFS # REQUIRED>
 ... declarations for branch, balance, customer-name,
 customer-street and customer-city
]>
```

## XML δεδομένα με γνωρίσματα ID και IDREF



```
<bank-2>
 <account account-number="A-401" owners="C100 C102">
 <branch-name> Downtown </branch-name>
 <balance> 500 </balance>
 </account>
 <customer customer-id="C100" accounts="A-401">
 <customer-name>Joe </customer-name>
 <customer-street> Monroe </customer-street>
 <customer-city> Madison</customer-city>
 </customer>
 <customer customer-id="C102" accounts="A-401 A-402">
 <customer-name> Mary </customer-name>
 <customer-street> Erin </customer-street>
 <customer-city> Newark </customer-city>
 </customer>
</bank-2>
```

## Περιορισμοί των DTD's



- Δεν υπάρχουν τύποι στα elements κειμένου και τα γνωρίσματα
  - Όλες οι τιμές είναι strings, δεν υπάρχουν integers, reals, κ.α.
- Είναι δύσκολο να καθοριστούν μη ταξινομημένα σύνολα από subelements.
  - Η ταξινόμηση δεν υπάρχει συνήθως στις βάσεις δεδομένων
  - Η έκφραση (A | B)\* επιτρέπει τον καθορισμό ενός μη ταξινομημένου συνόλου, αλλά
    - Δεν εγγυάται ότι κάθε ένα από τα A και B εμφανίζεται μία μόνο φορά
- Τα IDs και IDREFs δεν έχουν τύπους
  - Στο παράδειγμα δεν υπάρχει τρόπος να καθοριστεί ο τύπος του element στο οποίο αναφέρεται ένα γνώρισμα τύπου ID ή IDREFS.
    - Το γνώρισμα *owners* θα πρέπει (ιδανικά) να αναφέρεται στα elements του customer.

## XML Schema



- Πρόκειται για μια σύνθετη **schema language** που αντιμετωπίζει τα μειονεκτήματα των DTDs. Υποστηρίζει
  - “Κλασσικούς” τύπους δεδομένων
    - Π.χ. integer, string, κλπ.
    - περιορισμούς στις min/max τιμές
  - Τύπους δεδομένων ορισμένους από το χρήστη
  - Καθορίζεται και η ίδια στην σύνταξη της XML, σε αντίθεση με τα DTDs
  - Είναι ενσωματωμένη με τα namespaces
  - Έχει πολλά ακόμη χαρακτηριστικά
    - List types, περιορισμούς μοναδικότητας και ξένου κλειδιού, κληρονομικότητα ...
- ΟΜΩΣ είναι σημαντικά πιο πολύπλοκη από τα DTDs, και δεν χρησιμοποιείται ακόμη ευρέως.

## XML Schema του Bank DTD



```
<xsd:schema xmlns:xsd=http://www.w3.org/2001/XMLSchema>
<xsd:element name="bank" type="BankType"/>
<xsd:element name="account">
 <xsd:complexType>
 <xsd:sequence>
 <xsd:element name="account-number" type="xsd:string"/>
 <xsd:element name="branch-name" type="xsd:string"/>
 <xsd:element name="balance" type="xsd:decimal"/>
 </xsd:sequence>
 </xsd:complexType>
</xsd:element>
..... definitions of customer and depositor
<xsd:complexType name="BankType">
 <xsd:sequence>
 <xsd:element ref="account" minOccurs="0" maxOccurs="unbounded"/>
 <xsd:element ref="customer" minOccurs="0" maxOccurs="unbounded"/>
 <xsd:element ref="depositor" minOccurs="0" maxOccurs="unbounded"/>
 </xsd:sequence>
</xsd:complexType>
</xsd:schema>
```

## Ερωτήσεις και μετατροπές σε XML δεδομένα



- Αναφερόμαστε σε:
  - Μετατροπή πληροφορίας από ένα XML schema σε ένα άλλο.
  - Ερωτήσεις πάνω σε XML δεδομένα
- Τα δύο παραπάνω σχετίζονται άμεσα, και αντιμετωπίζονται με τα ίδια εργαλεία
- Standard XML querying/ translation languages
  - **XPath** - Απλή γλώσσα που χρησιμοποιεί εκφράσεις μονοπατιού.
  - **XSLT** - Απλή γλώσσα που σχεδιάστηκε για μετάφραση από XML σε XML και από XML σε HTML
  - **XQuery** - Μια XML query language με πολλά χαρακτηριστικά που προτάθηκε ως standard για ερωτήσεις πάνω σε XML δεδομένα.

## Το δεντρικό μοντέλο των XML δεδομένων



- Οι γλώσσες ερωτήσεων και μετατροπών στηρίζονται σε ένα **δεντρικό μοντέλο** από XML δεδομένα.
- Ένα XML document μοντελοποιείται ως **δέντρο**, οι **κόμβοι** του οποίου αντιστοιχούν στα elements και τα γνωρίσματα.
  - Οι κόμβοι των elements έχουν παιδιά, τα οποία μπορεί να είναι γνωρίσματα ή subelements.
  - Το κείμενο ενός element μοντελοποιείται ως ένα κόμβος κειμένου που είναι παιδί του element.
  - Τα παιδιά ενός κόμβου διατάσσονται με βάση τη σειρά τους στο XML document
  - Οι κόμβοι των elements και των γνωρισμάτων (εκτός της ρίζας) έχουν ένα πατέρα, ο οποίος είναι element.
  - Η ρίζα έχει ένα παιδί, το οποίο είναι το βασικό element του document.
- Χρησιμοποιούνται όροι όπως: κόμβος, παιδί, πατέρας, αδερφός κόμβος, πρόγονος, απόγονος, κ.α., οι οποίοι θα πρέπει να διερμηνευτούν με βάση το παραπάνω δεντρικό μοντέλο των XML δεδομένων.

## XPath



- Χρησιμοποιείται για την επιλογή τμημάτων ενός XML document χρησιμοποιώντας **εκφράσεις μονοπατιού**.
- Μία έκφραση μονοπατιού (path expression) είναι μια ακολουθία βημάτων που διαχωρίζονται μέσω του "/"
  - Κάτι αντίστοιχο με τα όνομα αρχείου στην ιεραρχία του μονοπατιού
- Το αποτέλεσμα μιας έκφρασης μονοπατιού: ένα σύνολο τιμών.
- Π.χ. η έκφραση μονοπατιού (για το παράδειγμα [bank-2 data](#))
  - /bank-2/customer/customer-name
  - επιστρέφει τα εξής:
    - <customer-name>Joe</customer-name>
    - <customer-name>Mary</customer-name>
- Ενώ η έκφραση μονοπατιού
  - /bank-2/customer/customer-name/text()
- επιστρέφει τα ίδια ονόματα χωρίς όμως τα περιβάλλοντα tags.

## XPath (συν.)



- Το αρχικό "/" συμβολίζει τη ρίζα του document
- Οι εκφράσεις μονοπατιού **αποτιμούνται** από αριστερά προς τα δεξιά.
  - Κάθε βήμα ενεργεί στο σύνολο των στιγμιотύπων που παράχθηκε από το προηγούμενο βήμα.
- Οι συνθήκες του selection μπορούν να μπουν σε οποιοδήποτε βήμα σε ένα μονοπάτι, μέσα σε [ ].
  - Π.χ. `/bank-2/account[balance > 400]`
    - Επιστρέφει τα elements account με balance>400.
  - `/bank-2/account[balance]`
    - επιστρέφει τα elements account με που περιέχουν υπόλοιπο (balance) ως subelement.
- Οι τιμές των γνωρισμάτων προσπελούνται μέσω του "@".
  - Π.χ. `/bank-2/account[balance > 400]/@account-number`
    - Επιστρέφει τους αριθμούς λογαριασμού με balance>400.

## XPath συναρτήσεις



- Υποστηρίζει αρκετές συναρτήσεις
  - Η συνάρτηση **count()** στο τέλος του μονοπατιού μετράει το πλήθος των elements του συνόλου που παράχθηκε από το μονοπάτι.
    - Π.χ. `/bank-2/account[customer/count() > 2]`
      - Επιστρέφει τα accounts με > 2 πελάτες
  - Επίσης, υποστηρίζει συναρτήσεις που ελέγχουν τη θέση των κόμβων (1, 2, ..).
- Οι λογικές εκφράσεις **and** και **or** και η συνάρτηση **not()** μπορούν να χρησιμοποιηθούν στις συνθήκες.
- Τα IDREFs μπορούν να βρεθούν μέσω της συνάρτησης **id()**
  - Η **id()** μπορεί να εφαρμοστεί επίσης και σε σύνολα όπως τα IDREFS
  - Π.χ. `/bank-2/account/id(@owners)`
    - Επιστρέφει όλους τους πελάτες που αναφέρονται από το γνώρισμα owners του account element.

## XPath συναρτήσεις (συν.)



- Ο τελεστής “|” υλοποιεί την ένωση (*union*)
  - Π.χ. `/bank-2/account/id(@owners) | /bank-2/loan/id(@borrower)`
    - Επιστρέφει τους πελάτες που έχουν είτε accounts είτε loans.
    - Ωστόσο, το “|” δεν μπορεί να εμφωλευτεί μέσα σε άλλους τελεστές.
- Το “//” χρησιμοποιείται για να παρακάμψει τα πολλαπλά επίπεδα κόμβων
  - Π.χ. `/bank-2//customer-name`
    - Βρίσκει κάθε `customer-name` element *οπουδήποτε* κάτω από το `/bank-2` element, και ανεξάρτητα από το element στο οποίο περιέχεται.
- Σε ένα βήμα στο μονοπάτι μπορούμε να μεταβούμε στους: γονείς, αδέρφια, προγόνους και απογόνους των κόμβων που προκύπτουν από το προηγούμενο βήμα και όχι απλά στα παιδιά.
  - “//”: αντιστοιχεί στο “όλους τους απογόνους”
  - “..”: καθορίζει τον πατέρα.

## XSLT



- Ένα **stylesheet** αποθηκεύει τον τρόπο μορφοποίησης ενός document - συνήθως αποτελεί ξεχωριστό document.
  - Π.χ. Ένα HTML stylesheet μπορεί να καθορίσει τη γραμματοσειρά, τα χρώματα κ.α.
- Η **XML Stylesheet Language (XSL)** σχεδιάστηκε αρχικά για την αυτόματα παραγωγή HTML από XML.
- Η XML περιλαμβάνει ένα γενικού σκοπού μηχανισμό μετατροπής, που ονομάζεται XSL Transformations (XSLT).
  - Η XSLT μπορεί να μεταφράζει XML σε XML, και XML σε HTML.
- Οι μετατροπές της XSLT εκφράζονται μέσω κανόνων που ονομάζονται **templates**.
  - Τα templates συνδυάζουν τα selections μέσω των XPath με την “κατασκευή” των αποτελεσμάτων.

## XSLT Templates



- Π.χ. ενός XSLT template με **match** και **select**

```
<xsl:template match="/bank-2/customer">
 <xsl:value-of select="customer-name"/>
</xsl:template>
<xsl:template match="*" />
```
- Το γνώρισμα match του xsl:template καθορίζει ένα pattern στο XPath
- Τα elements του XML document που ταιριάζουν με το pattern επεξεργάζονται μέσω των ενεργειών που υπάρχουν μέσα στο xsl:template element.
  - xsl:value-of επιστρέφει καθορισμένες τιμές (εδώ, το customer-name)
- Για τα elements που δεν ταιριάζουν σε κανένα template
  - Τα γνωρίσματα και τα περιεχόμενα κειμένου εξαγονται ως έχουν
  - Τα templates εφαρμόζονται αναδρομικά στα subelements
- Το <xsl:template match="\*" /> template περιλαμβάνει όλα τα elements που δεν ταιριάζουν σε κανένα άλλο template

## XSLT Templates (συν.)



- Αν κάποιο element ταιριάζει σε παραπάνω από ένα templates, μόνο ένα από αυτά χρησιμοποιείται.
  - Το ποιο, εξαρτάται από σύνθετα σχήματα προτεραιότητας / προτεραιότητες του χρήστη.
  - Υποθέτουμε πως μόνο ένα template ταιριάζει σε κάθε element.

## XML έξοδος



- Οποιοδήποτε κείμενο ή tag του XSL stylesheet που δεν ανήκει στο xsl namespace εξάγεται ως έχει.

- Π.χ. για το παράδειγμα:

```
<xsl:template match="/bank-2/customer">
 <customer>
 <xsl:value-of select="customer-name"/>
 </customer>
</xsl:template>
<xsl:template match="*" />
```

- η έξοδος είναι:

```
<customer> Joe </customer>
<customer> Mary </customer>
```

## XSLT: ταξινόμηση



- Η χρήση μιας **xsl:sort** εντολής μέσα σε ένα template έχει ως αποτέλεσμα να ταξινομηθούν όλα τα elements που πληρούν τους κανόνες του template.

- Π.χ.

```
<xsl:template match="/bank">
 <xsl:apply-templates select="customer">
 <xsl:sort select="customer-name"/>
 </xsl:apply-templates>
</xsl:template>
<xsl:template match="customer">
 <customer>
 <xsl:value-of select="customer-name"/>
 <xsl:value-of select="customer-street"/>
 <xsl:value-of select="customer-city"/>
 </customer>
</xsl:template>
<xsl:template match="*" />
```

## XQuery



- Η XQuery είναι μια γενικού σκοπού γλώσσα ερωτήσεων για XML δεδομένα που αναπτύχθηκε από το W3C (World Wide Web Consortium).
- Η XQuery προέρχεται από τη γλώσσα ερωτήσεων Quilt, η οποία με τη σειρά της προέρχεται από τις SQL, XQL και XML-QL.
- Η XQuery χρησιμοποιεί ένα συντακτικό της μορφής FLWR ("flower"):

**for ... let ... where .. result ...**

όπου

**for** ⇔ SQL from

**where** ⇔ SQL where

**result** ⇔ SQL select

**let** επιτρέπει προσωρινές μεταβλητές, δεν υπάρχει κάτι αντίστοιχο στην SQL.

## Εκφράσεις FLWR στην XQuery



- Απλή FLWR έκφραση στην XQuery
  - Βρες όλους τους λογαριασμούς με balance>400, και κάθε αποτέλεσμα να περικλείεται από ένα <account-number> .. </account-number> tag.
- Η πρόταση Let δεν είναι απαραίτητη στο παραπάνω ερώτημα, η επιλογή μπορεί να γίνει στο XPath. Η ερώτηση μπορεί να γραφτεί ως:

```
for $x in /bank-2/account
let $acctno := $x/@account-number
where $x/balance > 400
return <account-number> $acctno </account-number>
```

```
for $x in /bank-2/account[balance>400]
return <account-number> $x/@account-number
</account-number>
```

## Joins



- Καθορίζονται με τρόπο παρόμοιο με αυτό της SQL

```
for $a in /bank/account,
 $c in /bank/customer,
 $d in /bank/depositor
where $a/account-number = $d/account-number
and $c/customer-name = $d/customer-name
return <cust-acct> $c $a </cust-acct>
```

- Εναλλακτικά με XPath selections:

```
for $a in /bank/account
 $c in /bank/customer
 $d in /bank/depositor[
 account-number = $a/account-number and
 customer-name = $c/customer-name]
return <cust-acct> $c $a</cust-acct>
```

## XQuery: εκφράσεις μονοπατιού



- \$c/text()**: επιστρέφει το κείμενο ενός element χωρίς subelements ή tags.
- Οι εκφράσεις μονοπατιού στην XQUERY υποστηρίζουν τον τελεστή: “->” για τα IDREFs
  - Ισοδύναμος με τη συνάρτηση id( ) της XPath, αλλά πιο εύχρηστος
  - Μπορεί να εφαρμοστεί σε ένα σύνολο από IDREFs και να επιστρέψει ένα σύνολο αποτελεσμάτων
  - Στην έκδοση June 2001 έγινε αλλαγή από “->” το “=>”

## Αποθήκευση XML Δεδομένων



- Τα XML δεδομένα μπορούν να αποθηκευτούν σε μη-σχεσιακές αποθήκες δεδομένων
  - Απλά αρχεία
    - απλά
    - Αλλά, έχουν όλα τα προβλήματα της αποθήκευσης σε αρχείο (no concurrency, no recovery, ...)
  - XML βάσεις δεδομένων
    - Σχεδιασμένες ειδικά για την αποθήκευση XML δεδομένων, να υποστηρίζουν το DOM μοντέλο και ερωτήσεις
    - Υπάρχουν περιορισμένα εμπορικά συστήματα προς το παρόν
- ...

## Αποθήκευση XML Δεδομένων (συν.)



- ... ή μπορούν να αποθηκευτούν σε σχεσιακές βάσεις δεδομένων
  - Τα δεδομένα πρέπει να μετατραπούν σε σχεσιακή μορφή
  - πλεονέκτημα: ώριμα συστήματα βάσεων δεδομένων
  - μειονέκτημα: επιπλέον κόστος για τη μετατροπή των δεδομένων και των queries
  - Εναλλακτικοί τρόποι αποθήκευσης:
    - Αναπαράσταση μέσω string
    - Αναπαράσταση μέσω δέντρων
    - Αντιστοιχία σε σχέσεις

## Αναπαράσταση μέσω strings




- Αποθήκευση κάθε element του υψηλότερου επιπέδου σαν ένα string πεδίο μιας πλειάδας της βάσης
  - Χρήση μιας απλής σχέσης για την αποθήκευση όλων των elements, ή
  - Χρήση μιας ξεχωριστής σχέσης για κάθε element type του υψηλότερου επιπέδου
- Πλεονεκτήματα
  - Μπορεί να αποθηκεύσει οποιαδήποτε XML δεδομένα ακόμη και χωρίς DTD.
  - Αν υπάρχουν πολλά elements στο υψηλότερο επίπεδο του document, τα strings είναι μικρά σε σχέση με το πλήρες document
    - Επιτρέπει γρήγορη πρόσβαση στα επιμέρους elements.
- Μειονέκτημα: χρειάζεται να αναλύσουμε συντακτικά (parse) strings για να προσπελάσουμε τις τιμές μέσα στα elements
  - Η ανάλυση αυτή είναι αργή

## Αναπαράσταση μέσω δέντρων



- Μοντελοποίηση XML δεδομένων ως δέντρο και αποθήκευσή τους χρησιμοποιώντας σχέσεις

nodes(id, type, label, value)  
child (child-id, parent-id)



- Σε κάθε element / γνώρισμα δίνεται ένα μοναδικό αναγνωριστικό.
- Η ετικέτα καθορίζει το όνομα του tag του element / το όνομα του γνωρίσματος.
- Η τιμή είναι το κείμενο του element / γνωρίσματος.
- Η σχέση child συμβολίζει τις σχέσεις parent-child στο δέντρο
  - Μπορούμε να προσθέσουμε ένα επιπλέον γνώρισμα στο child για να κρατάμε τη διάταξη των παιδιών.

## Αναπαράσταση μέσω δέντρων (συν.)



- Πλεονεκτήματα:
  - Μπορεί να αποθηκεύσει οποιαδήποτε XML δεδομένα ακόμη και χωρίς DTD.
- Μειονεκτήματα:
  - Τα δεδομένα σπάνε σε πάρα πολλά τμήματα, αυξάνοντας την πολυπλοκότητα χώρου.
  - Ακόμα και τα απλά queries απαιτούν ένα μεγάλο αριθμό joins, το οποίο μπορεί να απαιτεί πολύ χρόνο.

## Αντιστοιχία σε σχέσεις



- Αν το DTD του document είναι γνωστό, μπορεί να γίνει η αντιστοίχιση των δεδομένων σε σχέσεις.
- Μια σχέση δημιουργείται για κάθε τύπο element.
  - Τα elements (τύπου #PCDATA), και τα γνωρίσματα αντιστοιχίζονται στα γνωρίσματα των σχέσεων.
- Πλεονεκτήματα:
  - Αποδοτική αποθήκευση
  - Δυνατότητες: μετάφρασης XML queries σε SQL, αποδοτικής εκτέλεσης, μετάφρασης των SQL αποτελεσμάτων πίσω σε XML.
- Μειονεκτήματα:
  - Απαιτείται η γνώση του DTD
  - Υπάρχει κόστος μετάφρασης

## Αντιστοιχία σε σχέσεις (συν.)



- Η σχέση που δημιουργείται για κάθε τύπο element περιέχει
  - Ένα id γνώρισμα για την αποθήκευση ενός μοναδικού id για κάθε element.
  - Ένα γνώρισμα που αντιστοιχεί σε κάθε γνώρισμα element
  - Ένα parent-id γνώρισμα για την αποθήκευση του element πατέρα
    - Όπως στην αναπαράσταση μέσω δέντρων
    - Μπορεί επίσης να αποθηκευτεί και η θέση (ith child)
- Όλα τα subelements που εμφανίζονται μία μόνο φορά μπορούν να γίνουν γνωρίσματα της σχέσης
  - Για text-valued subelements, αποθήκευση του κειμένου ως τιμή του γνωρίσματος.
  - Για πολύπλοκα subelements, αποθήκευση του id του subelement.
- Τα subelements που εμφανίζονται πολλές φορές αναπαρίστανται σε ξεχωριστό πίνακα
  - Παρόμοια αντιμετώπιση με τη μετατροπή του ER σε σχεσιακό.