XML Path Language (XPath)

Erik Wilde
ETH Zürich
http://dret.net/netdret/

jax2004

Abstract

Die *XML Path Language (XPath)* ist nicht nur die Grundlage für viele aktuelle XML-Technologien (XSLT, XML Schema, XQuery), sondern auch ein unentbehrliches Tool für jeden XML-Profi, das in seiner Nützlichkeit am besten mit den bekannten *Regulären Ausdrücken* für textbasierte Technologien verglichen werden kann. In dieser Session wird XPath detailliert beschrieben und mit vielen Beispielen vorgestellt.

jax2004

Übersicht

- Motivation
- Analogie File System ↔ XML Dokumente
  - beides sind Baummodelle, aber mit Unterschieden
  - Navigieren in Bäumen
- XPath Übersicht
  - XPath Location Paths
  - XPath Funktionen
- XPath Anwendungen
- Zusammenfassung

Motivation XPath

- Entwicklung von XSLT
  - Transformationssprache für XML Dokumente
  - Kernpunkt ist Selektion von Teilen eines Dokuments
- XPath als Teil von XSLT
  1. zunächst integraler Bestandteil
  2. Potential für die Wiederverwendung wurde erkannt
     - Selektion von Dokumententeilen ist vielerorts praktisch
  3. XPath als eigener Standard, auf den XSLT verweist
- XPath ist somit allgemein verwendbar
  - grundlegende XML-Technologie

Bäume: Filesystem vs. XML

- Unterschiede zwischen der Navigation
  - Unix cd Kommando vs. XPath

1. Knotentypen (XPath *Node Types*)
2. Knotenanzahl (XPath *Node Sets*)
3. Richtungen (XPath *Axes*)
4. Filter (XPath *Predicates*)

5. XPath Datenmodell (mehr als nur Knoten)
6. XPath Funktionen

Baumsicht eines Filesystems

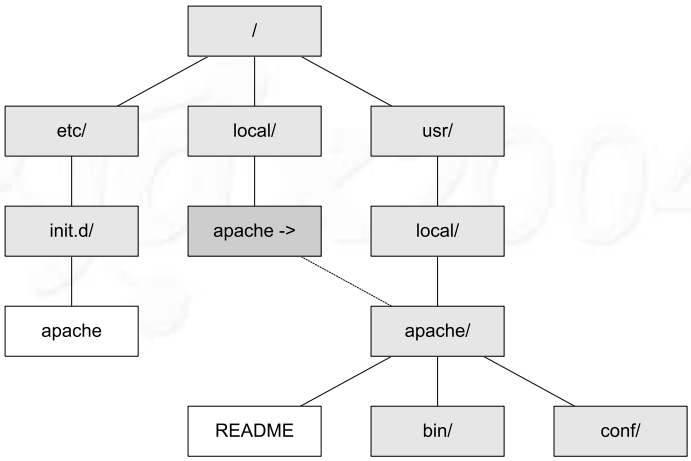

Eigenschaften eines Filesystems

- 3 verschiedene Arten von Knoten
  - Directories, Files, Symbolic Links
- durch das Filesystem garantierte Bedingungen
  - keine Directory-Einträge mit gleichem Namen
  - es gibt immer genau ein Root-Directory
  - Metainformationen werden im Directory gespeichert
    - Owner, Permissions, Creation Date, Modification Date
- verschiedene Sichten des Filesystems
  - *Raw Device* vs. *OS File System Support*
  - *OS File System* vs. *Network File System (NFS, SMB)*

XML Dokument

```
<?xml version="1.0"?>
<html xmlns="http://www.w3.org/1999/xhtml">
 ...
 <body>
  <table border="0">
   <thead> .... </thead>
   <!-- Tabelleninhalt beginnt hier -->
   <tbody> ... </tbody>
  </table>
</body>
</html>
```

Baumsicht eines XML Dokuments

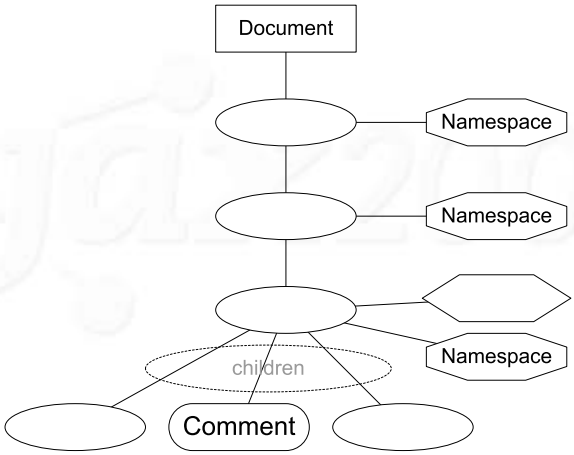

1. Knotentypen

- XPath definiert 7 Knotentypen
  - *Root* Node (repräsentiert das gesamte Dokument)
  - *Element* und *Attribute* Nodes
  - *Text* Nodes für Text innerhalb von Elementen
  - *Namespace* Nodes für gültige Namespaces
  - *Processing Instruction (PI)* und *Comment* Nodes
- Elemente haben nicht nur Kinder
  - Kinder sind Text, Elemente, PIs und Kommentare
  - Attribute und Namespaces sind keine Kinder
    - aber das Element ist das Elternteil dieser Knoten!

2. Knotenanzahl

- cd verlangt immer genau ein Directory
  - dieses wird danach zum *Current Working Directory*
- in vielen Fällen löst die Shell Wildcards auf
  - `ls -laF *.ppt`
  - das Kommando muss mehrere Parameter akzeptieren
- spezielle Kommandos erzeugen Listen
  - können per Pipe übermittelt werden
  - `find . -name README -ls | wc`
- Unix hat kein allgemeines Modell für *File Sets*

Abarbeitung Filesystem Pfad

- jeder Schritt selektiert genau ein Directory
  - Wildcards im Pfad sind nicht erlaubt
  - Directorynamen sind eindeutig

```
cd /usr/local/apache/bin/
   1 → 1 ——→ 1 ——————→ 1 ——→ 1
```

Abarbeitung XPath

- jeder Schritt selektiert eine Knotenmenge
  - der nächste Schritt operiert auf dieser Menge
  - pro Schritt kann die Menge wachsen oder schrumpfen

```
/html/body/table/thead/tr
```

1 → 1 → 1 → 3 → 2 → 4

3. Richtungen

- absolute und relative Pfade
  - Pfad beginnt mit Slash oder mit einem Namen
- Unix Pfade gehen immer einen Schritt abwärts
  - implizite Semantik des Slashes im Pfad
  - `.` und `..` sind keine Ausnahmen, sondern Hacks
    - auf spezielle Directories umgebogene Directory-Einträge
- XPath unterstützt verschiedene Richtungen
  - der Slash trennt die Schritte (keine implizite Richtung)
  - die Richtung wird durch die XPath Axis angegeben
    - wird sie weggelassen, so ist der Default `child`

child Axis

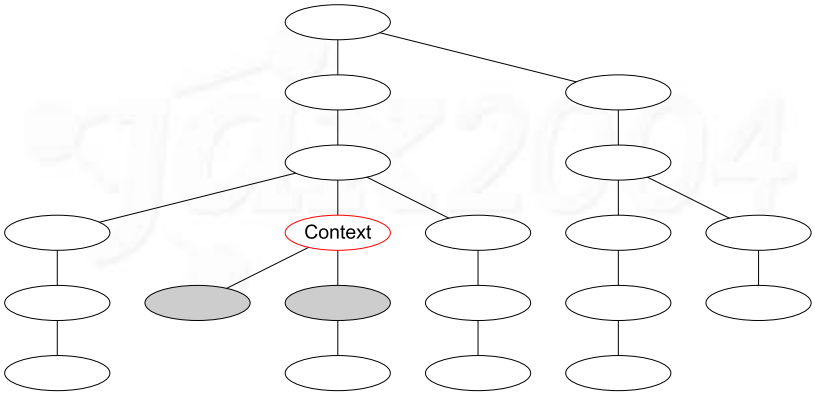

descendant Axis

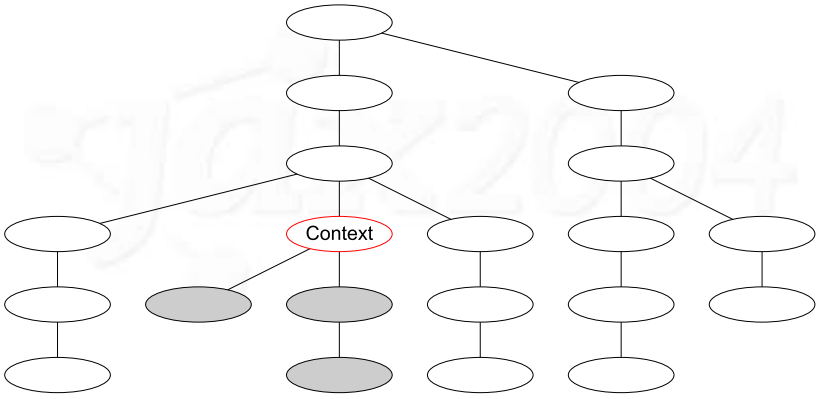

parent Axis

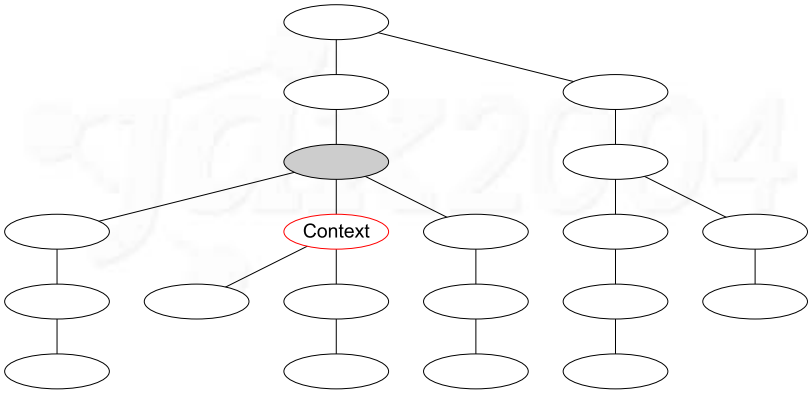

ancestor Axis

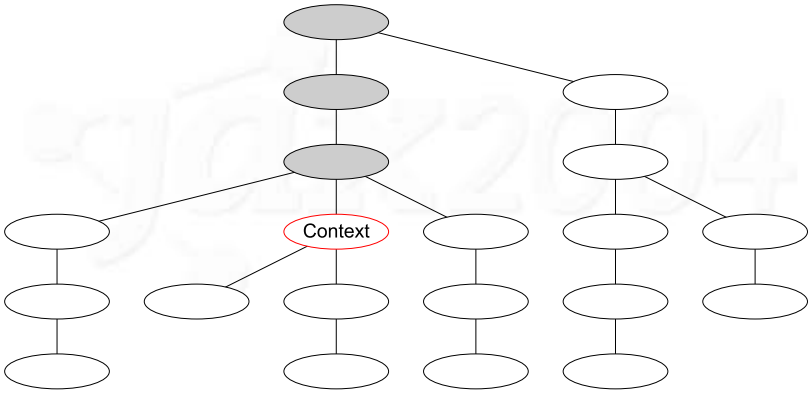

previous-sibling Axis

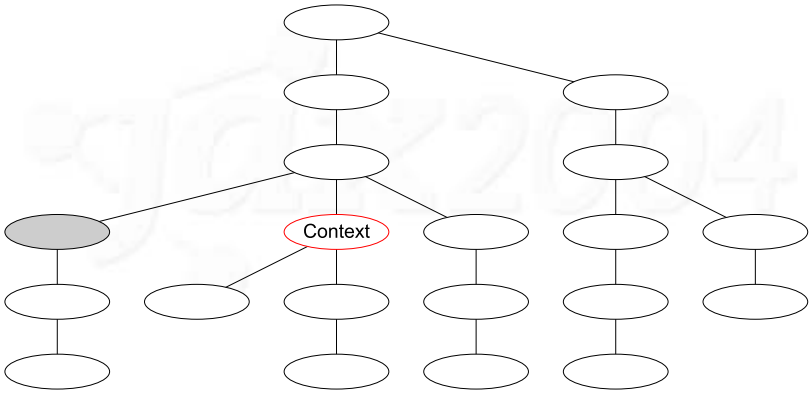

following-sibling Axis

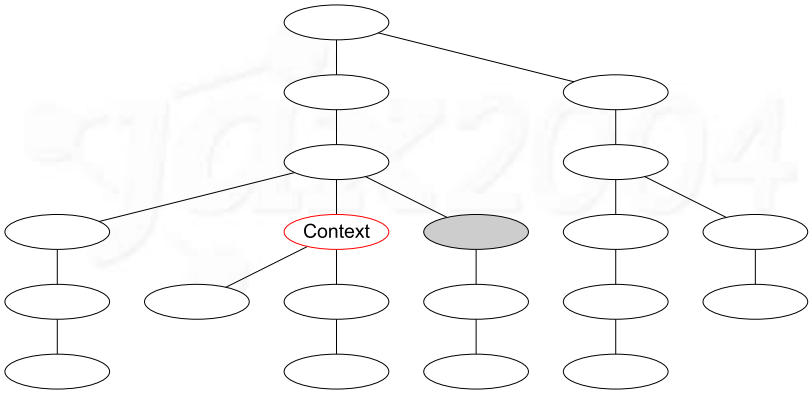

self Axis

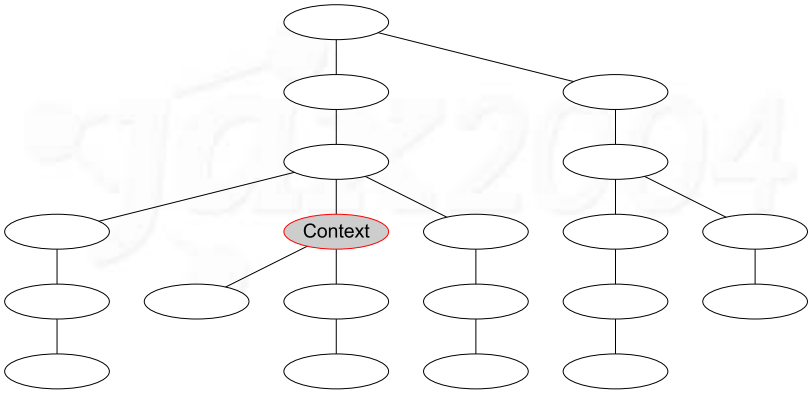

ancestor-or-self Axis

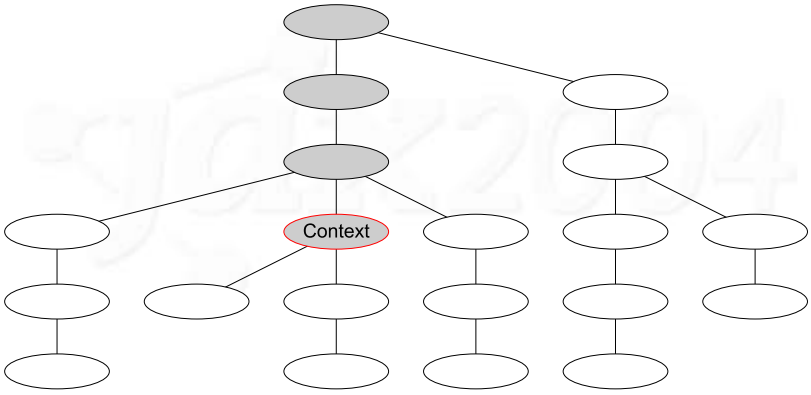

descendant-or-self Axis

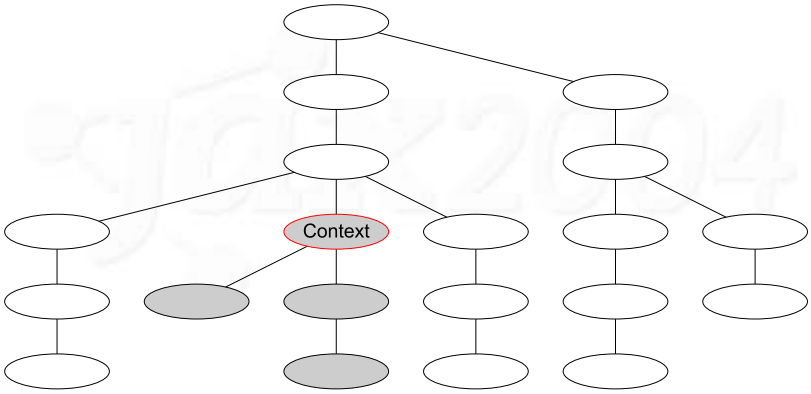

attribute Axis

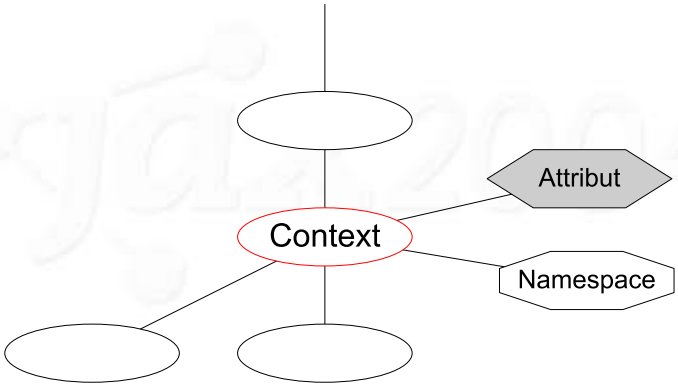

namespace Axis

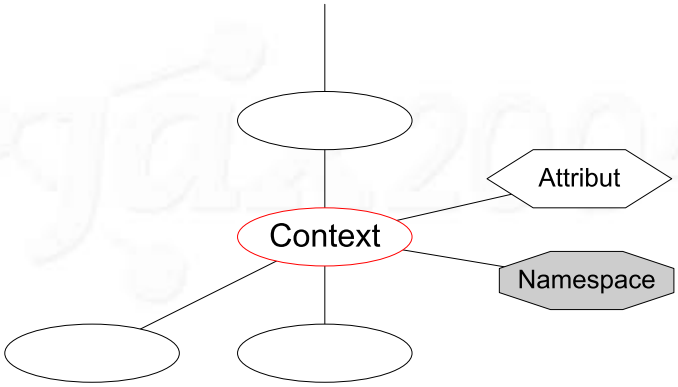

XPath Location Path Syntax

- Folge von *Location Steps*, getrennt mit `/`
  - erste Komponente: *Axis Specifier* (gefolgt von `::`)
  - zweite Komponente: *Node Test*
  - dritte Komponente: 0-n *Predicates* (in `[]`)
- Abkürzungen in Location Paths
  - `child::` ist die *Default Axis*
  - `attribute::` kann abgekürzt werden als `@`
  - `//` ist kurz für `/descendant-or-self::node()/`
  - `.` ist kurz für `self::node()`
  - `..` ist kurz für `parent::node()`

XPath Node Tests

- Namenstest (für Elemente und Attribute)
  - testet einen Node auf einen bestimmten Namen
    - `/html/head/table`
  - * kann verwendet werden als Wildcard Character
- Test auf den Nodetype
  - markiert mit nachfolgenden Klammern
  - Test auf `text()`, `comment()` oder `node()`
- Test auf Processing Instruction
  - anwendbar auf spezifische Processing Instruction
    - `processing-instruction("myapplication")`

4. Filter (Prädikate)

- jeder Schritt kann zusätzliche Filter enthalten
  - Auswertung jedes Filters für jeden selektierten Node
    - daraus resultiert eine logisches *and* der Filter
  - Filter sind XPath Expressions
    - Auswertung relativ zum selektierten Node
    - Interpretation als `boolean` (ausser für `number`)
- Reduktion der Resultatmenge eines Schrittes
  - `/descendant::table[not(thead)]`
  - können in einigen Fällen vermieden werden
    - `/descendant::table[thead]`
    - `/descendant::table/thead/..`

Filter in XML Bäumen

- Abarbeitung eines Location Paths
  1. Node Set ist die Basis jedes Schrittes
     - Context/Node: Node, Context Size, Context Position, ...
  2. Selektion der Nodes (Axis und Node Test)
  3. Auswertung aller Filter für alle selektierten Nodes
  4. die verbleibenden Nodes sind das neue Node Set
- Aufgabe: Finden Sie den 6. Link im HTML
  - Ansatz 1: `//a[position()=6]` ≡ `//a[6]`
    - Problem: `/descendant-or-self::node()/a[6]`
  - korrekter XPath: `/descendant::a[6]`

XPath Expressions

- Location Paths sind ein Sonderfall von XPath
- allgemein ist ein XPath eine *Expression*
  - Auswertung gemäss definierter Grammatik
    - XPath `(2+2)*10` ergibt die Zahl 40
  - Expressions treten oft in Filtern auf
    - `//table[count(tbody/tr) > 10]`
- wichtig für die Auswertung von Expressions
  - der Context (durch Umgebung oder Location Path)
  5. der Umgang mit Datentypen
  6. die Verfügbarkeit von Funktionen

5. XPath Datenmodell

- XPath unterscheidet 4 Datentypen
  1. `node-set` (Mengen von Knoten)
  2. `boolean` (true oder false)
  3. `number` (Floating Point Numbers)
  4. `string` (Unicode Character strings)
- Beispiele für XPaths dieser Datentypen
  1. `//table[thead]`: alle Tabellen mit einem `thead`
  2. `1=2`: ergibt den Boolean Wert `false`
  3. `27 div 16`: ergibt 1.6875
  4. `substring('abcd',2,2)`: ergibt den String `bc`

String-value eines Nodes

- wichtiges Konzept für XPath Resultate
  - jeder Node Type hat einen String-value
  - lokal oder rekursiv definiert
- Definition der String-values
  - *Root*: Konkatenation aller Text Node Descendants
  - *Element*: Konkatenation aller Text Node Descendants
  - *Attribute*: normalisierter Attributwert
  - *Namespace*: Namespace URI
  - *Processing Instruction*: Inhalt (nicht das Target!)
  - *Comment* und *Text*: Inhalt

XPath Umgang mit Datentypen

- XPath definiert viele implizite Konvertierungen
  - keine gute Grundlage für eine typensichere Sprache
  - Umformungsregel müssen bekannt sein
    - es gibt explizite Funktionen, die diese Regeln definieren
    - diese werden u.U. implizit angewandt
- viele XPaths sind "korrekt"
  - häufiger Effekt beim Lernen von XPath
    1. Typ-Probleme (oder anderes...) im XPath
    2. Resultat ist ein leeres Node Set
    3. kann als Boolean, String oder Number interpretiert werden

6. XPath Funktionen

- Funktionen mit dem Resultattyp `boolean`
  - `boolean, contains, false, lang, not, starts-with, true`
- Funktionen mit dem Resultattyp `number`
  - `ceiling, count, floor, last, number, position, round, string-length, sum`
- Funktionen mit dem Resultattyp `string`
  - `concat, local-name, name, namespace-uri, normalize-space, string, substring, substring-after, substring-before, translate`
- Funktionen mit dem Resultattyp `node-set`
  - `id`

Location Paths und Funktionen

- Location Paths können Funktionen benutzen
  - kommen dann immer in Prädikaten vor
  - `//a[substring(@href,string-length(@href)-2)='pdf']`
- Funktionen können Location Paths benutzen
  - falls die Funktion Node Sets akzeptiert
    - `count(//a)` zählt die Anzahl der Links auf einer Seite
    - andernfalls findet eine implizite Konvertierung statt
- dieses Prinzip kann geschachtelt werden
  - die Übersichtlichkeit kann leiden
    - `//*[@*]` oder `//*[count(@*) = count(*)]`
  - sehr komplexe Aufgabenstellungen lösbar

XPath ist keine Query-Sprache

- Query-Sprachen kennen zwei Aspekte:
  1. *Adressierung* von gesuchten Informationen
  2. *Rekombination* der gesuchten Informationen
  - XPath behandelt nur den ersten Aspekt!
- XQuery als neue Query-Sprache für XML
  - wird auf XPath aufbauen
  - verwendet jedoch eine erweiterte Version (XPath 2.0)
- XPath als Grundlage für viele Standards
  - XSLT, XML Schema, XPointer, XQuery
  - aber auch als Grundlage für Tools (z.B. Editoren)

XPath in XSLT

- XSLT verwendet XPath an vielen Stellen
  - *Match Patterns* für Templates
  - Konditionen in Bedingungen
  - Ausführen von Schleifen (Iterationen über Node Sets)
  - Ausgaben von Werten
- XPath ist die *Expression Language* von XSLT
- XSLT ist ohne XPath nicht denkbar
  - oftmals Design-Frage beim XSLT-Schreiben
    - komplexere XPaths oder mehr XSLT Code?
  - XPath wichtigste Grundlage für Umgang mit XSLT

XPath in XML Schema

- XML Schema als DTD++
  - viele neue Konzepte
- Verallgemeinerung des `ID/IDREF` Konstrukts
  - Identity Constraints
  - Uniqueness, Keys, Key References
- Selektion von Knoten für Constraints
  - Selektion der Knoten des Constraints
    - z.B. alle `person` Elemente eines Dokuments
  - Selektion der auszuwertenden Felder
    - z.B. müssen `name` & `vorname` eindeutig sein

XPath in XPointer

- XPointer definiert XML Fragment Identifier
  - `http://...xml#xpointer(id(x99))`
- erweitert XPath sehr massiv
  - führt neue Datentypen ein
  - führt neue Funktionen ein
- Unterstützung von Ranges
  - Idee der Selektion wie mit einer Maus
    - Anfangspunkt und Endpunkt
    - dafür braucht man ein Konzept für Punkte...
    - ...und die Bereiche zwischen ihnen

Ausblick auf XPath 2.0

- vollständig neues Datenmodell
  - Sequenzen als Grundlage
    - Sequenzen sind geordnet (und erlauben Duplikate)
    - Sequenzen können verschiedene Datentypen enthalten
    - über Sequenzen kann iteriert werden
  - Unterstützung der XML Schema Datentypen
- konditionale Ausdrücke
  - `if-then-else` innerhalb des XPath
- verbesserte Mengenoperationen
  - XPath 1.0 kennt nur die Vereinigung von Mengen

XPath in XQuery

- XQuery wird die Query-Sprache für XML
  - XPath 2.0 ist ein grosser Teil der Sprache
  - XQuery hat zusätzliche Konstruktoren

```
<bib>
  { for $b in doc("http://www.bn.com/bib.xml")/bib/book
    where $b/publisher = "Addison-Wesley" and $b/@year > 1991
    return
      <book year="{ $b/@year }">
      { $b/title }
      </book>
  }
</bib>
```


Zusammenfassung

- XPath als Selektion von XML Teilen
  - strukturell orientiert an XML
    - basiert (indirekt...) auf dem Infoset
  - spartanischer Support für Text-Handling
    - nicht das Ziel von XPath
- XPath als Grundlage für XML Standards
- XPath als Tool
  - Unterstützung in Editoren als *Find* Syntax