XBase, XPath e XPointer

Fabio Vitali

Introduzione

Qui esaminiamo:

- XBase, XPath e XPointer

XML Base, XPath, XPointer e XLink

XBase, XPath, XPointer e XLink sono quattro documenti di W3C per la specifica di link ipertestuali sui documenti XML.

Erano un'unica proposta chiamata XLL (da cui la terna XML, XLL e XSL), poi divisa in quattro per semplicità.

- **XML Base** specifica un meccanismo per esprimere URI di base per parti di documenti XML. E' simile all'elemento BASE di HTML.
- **XPath** specifica i meccanismi per indicare percorsi all'interno di un documento XML. E' usato anche da XSLT. E' una raccomandazione W3Cdel 16/11/99
- **XPointer** specifica i meccanismi per riferirsi a parti del documento XML (SGML permette di riferirsi solo ad elementi con l'attributo "ID", HTML solo ad elementi con l'attributo "NAME"). E' una candidate recommendation
- **XLink** usa i meccanismi di indirizzamento di XPointer per descrivere link anche sofisticati tra documenti XML. E' una Recommendation

XML Base

In molti casi è interessante specificare URI relativi all'interno di documenti. Alcune rirose XML hanno naturalmente un URI associato, che possa fare da base per gli URI relativi posti al suo interno.

Altre volte non li hanno (es.: documenti generati programmaticamente),a volte li hanno indesiderabili (documenti soggetti a trasformazioni intermedie).

In tutti i casi,può essere necessario suggerire una base esplicita per gli URI relativi presenti. XML Base è una raccomandazione W3C (27 giugno 2001) a questo scopo.

Sostanzialmente prevede di specificare la base usando da qualche parte (prima dell'uso) l'attributo riservato xml:base e come valore l'URI assoluto di base

```
<doc xml:base="http://www.site.com/dir/"> … </doc>
```


XPath

Gli XPath sono una sintassi comune per XSL e XPointer per esprimere locazioni all'interno di documenti XML.

XPath opera sulla struttura logica del documento, non su quella sintattica, usando una sintassi non XML accettabile all'interno di URI e attributi.

Un XPath è un espressione che restituisce un oggetto di uno di questi quattro tipi:

- Un booleano
- Una stringa
- Un numero
- Un insieme di nodi (nodi elemento, nodi attributi, nodi testo)

XPointer

Gli XPointer sono indirizzi di locazioni interne a documenti XML. Possono essere usati per indicare link da o a specifiche parti di documenti XML.

Gli XPointer sono una elaborazione dell'identificativo di frammento in un URL:

```
http://www.site.com/dir/file.html#nome
```

Gli XPointer sono dunque usati in un locatore, tipicamente un URI o URL, per indicare un frammento di quella risorsa.

Gli XPointer sono un'estensione degli XPath, di cui estendono leggermente la sintassi.

Location Path

Il tipo più importante di XPath è il Location Path. Questo può essere o assoluto o relativo. Un Location Path assoluto inizia con '/'.

Un Location Path è composto di una sequenza di passi di locazione (Location Steps) separati da '/', e letti da sinistra a destra. Ogni termine individua più precisamente un frammento della risorsa individuata in precedenza.

Es.: `/child::doc/child::chapter/descendant::para` identifica gli elementi "para" che discenda da un elemento "chapter" che sia figlio diretto della radice "doc" del documento XML.

Location Step

Un location step ha tre parti:

- Un **asse**, che individua la direzione di specifica del location step nell'albero e rispetto al contesto.
- Un **test di nodo**, che individua il tipo e il nome completo del nodo identificato dal location step
- Zero o più **predicati** che raffinano ulteriormente l'insieme di nodi selezionati dal location step

La sintassi è:

```
axis::test[pred1][pred2]…[pred N]
```


Assi

Gli assi identificano la direzione rispetto alla struttura del documento in cui andare a cercare l'oggetto da restituire rispetto al nodo contesto (NC). Tra gli assi possibili troviamo:

- **`child`**, **`descendant`**: figlio diretto e a quelaunque livello del NC
- **`parent`**, **`ancestor`**: il genitore immediato / qualunque livello del NC
- **`self`**, **`namespace`**: il NC; il nodo namespace del NC
- **`attribute`**: gli attributi del NC
- **`preceding-sibling`**, **`following-sibling`**: i nodi allo stesso livello ma precedenti o seguenti il NC.
- **`preceding`**, **`following`**: i nodi a qualunque livello (ma fuori al NC) che precedono o seguono il NC.
- **`descendant-or-self`**, **`ancestor-or-self`**: come `descendant` e `ancestor`, ma considerando anche il NC.

Un esempio di alcuni assi

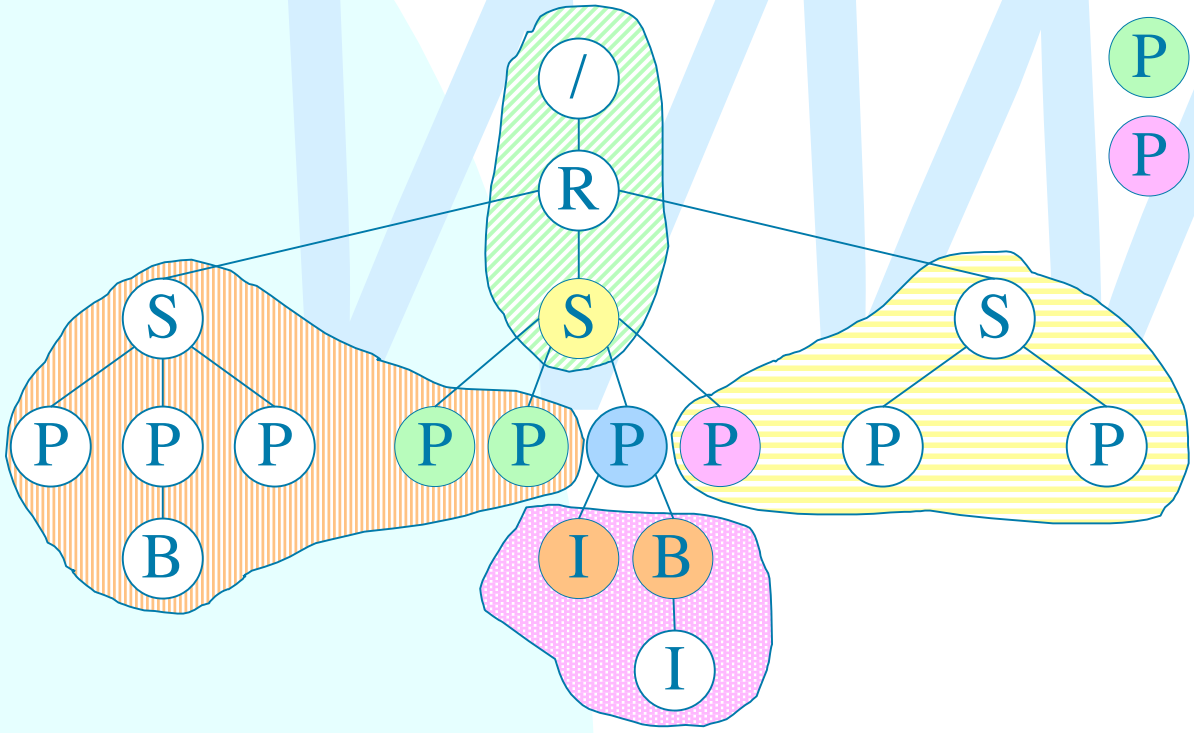

P Asse **self::**

S Asse **parent::**

I Asse **child::**

P Asse **preceding-sibling::**

P Asse **following-sibling::**

Asse **ancestor::**

Asse **descendant::**

Asse **preceding::**

Asse **following::**

Test di nodo (node test)

Il test di un nodo identifica attraverso il nome o il tipo l'oggetto da restituire. Se un asse contiene un nodo, questo può essere verificato attraverso un test sul nome (se è un elemento) o attraverso altri meccanismi:

- Se l'asse è `attribute`, il nodo è un attributo
- Se l'asse è `namespace`, il nodo è il namespace
- Altrimenti, il nodo è un elemento.

Il test può essere:

- Un nome: vero se il nodo (elemento o attributo) ha quel nome
- `text()`, `processing-instruction()`, `comment()`: vero se il nodo è di tipo testo, processing instruction o commento.
- `node()`: vero sempre
- * : vero per tutti i nodi del tipo definito dall'asse

Predicati

Un predicato filtra l'insieme dei nodi rispetto alla direzione indicata dall'asse per produrre un nuovo insieme di nodi.

Il filtro può essere attuato sulla posizione, o valutando un'espressione booleana. In questo secondo caso il risultato è quel sottoinsieme di nodi, tra quelli individuati finora, per cui l'espressione booleana è vera.

L'espressione booleana può essere (ovviamente complicata da operatori booleani come or, and e not), un'espressione relazionale (a=b, a!=b, a<b, ecc.), e/o un Location Path, e/o una funzione pre-definita.

- **Predicato: [a] con a EspressioneBooleana**
- **EspressioneBooleana: a or b, a and b, c, con a e b espressioni booleane e c espressione relazionale**
- **EspressioneRelazionale: a = b, a != b, a<b, a>b, a<=b, a>= b, c, dove c espressione aritmetica**
- **EspressioniAritmetiche: a + b, a - b, a * b, a div b, a mod b, c, -c, con c espressione di disgiunzione**
- **EspressioniDisgiunzione: a | b, c, con c espressione di path**
- **Espressione di Path: LocationPath o Espressione primaria**
- **Espressione Primaria: numero, lettera o chiamata funzione**

Funzioni predefinite

XPath non definisce un elenco completo di funzioni, ma un elenco fondamentale.

- Funzioni sull'insieme di nodi: `last()`, `position()`, `count()`, `id()`, `local-name()`, `namespace-uri()`, `name()`
  - **`child::para[position()=3]` individua il terzo nodo di nome "para" dentro al NC.**
  - **`child::para[last()]` individua l'ultimo nodo "para" nel NC.**
  - **N.B.: `child::para[3]` è equivalente a `child::para[position()=3]`**
- Funzioni stringa: `string()`, `concat()`, `starts-with()`, `contains()`, `substring-before()`, `substring-after()`, `substring()`, `string-length()`, `normalize-space()`, `translate()`,
- Funzioni booleane e numeriche

Sintassi abbreviata

In alcuni casi esistono delle forme abbreviate usabili invece della sintassi completa:

- Child::x si può abbreviare con x
- Attribute::x si può abbreviare con @x
- Descendant si può abbreviare con '//', self con '.', parent con '..'

Esempi:

- **`/doc/chapter[5]/section[2]`**: la seconda sezione del quinto capitolo dell documento.
- **`chapter//para`**: tutti i para discendenti a qualunque livello del nodo chapter figlio del NC
- **`//para`**: tutti i para discendenti a qualunque livello della radice del documento.

Altri esempi di XPath

- **`para[@type="warning"]`**: tutti i para figli del NC che abbiano l'attributo "warning".
- **`para[@type="warning"][5]`**: il quinto para figlio di NC ad avere l'attributo typeuguale a "warning".
- **`para[5][@type="warning"]`**: il quinto para figlio di NC, ma solo se ha l'attributo type uguale a "warning".
- **`chapter[title]`**: il "chapter" figlio del NC che contenga uno o più elementi "title"

Punti sottili (1)

Root node e document node

- Gli XPath assoluti iniziano sempre con /root (dove root è il nome dell'elemento radice), a parte /.
- Sono la stessa cosa? NO! Il nodo radice è più generale, e contiene l'elemento radice (corrispondente al tag radice), ma non coincide con lui.
- Il nodo radice contiene la dichiarazione XML, la dichiarazione di tipo di documento, eventuali altre processing instruction (es. per indicare il foglio di stile XSLT), **oltre al** nodo dell'elemento radice, chiamato, per evitare confusioni, *document element*.

Assi in ordine rovesciato

- La maggior parte degli assi idntifica la posizione seguendo l'ordine degli elementi nel documento. Gli assi che indicano elementi precedenti al nodo (e.g., ancestor, preceding e preceding-sibling) vanno in ordine rovesciato, dunque
  - preceding[1] viene **dopo** di preceding[2]
  - ancestor[1] è il padre, non la radice

Punti sottili (2)

Caratteri proibiti

- XPath viene usato in contesti con sintassi particolari (es. attributi XML o URI). In questi casi i caratteri leciti in XPath ma proibiti nel contesto vanno adeguatamente *escapati*.
  - Es. <xsl:template match="doc[position() < 3]">…
- Da notare che - è sia un carattere lecito nei nomi XML sia un operatore matematico in XPath. Quindi è necessario precedere l'operatore matematico con uno spazio
  - /doc/para[@foo-bar] è diverso da /doc/para[@foo - bar]

ID in XPath

- La funzione id(foobar) richiede di identificare quell'elemento che abbia un attributo di **tipo** ID il cui valore sia foobar.
- E' necessario avere il DTD per riconoscere che un attributo è di tipo ID. Poiché i DTD non sono necessari nei documenti XML, questa funzione può essere verificata solo da un parser validante, e quindi non è universale.

XPath e Explorer 5.0

Microsoft ha messo a disposizione tre versioni (ad oggi) di librerie XML, leggermente diverse le une dalle altre:

- MSXML 2.0: supporto pieno di XML, parziale di Namespace, versione draft, non definitiva, di XSL e XPath, niente Schema. Internet Explorer 5.0
- MSXML 3.0: supporto pieno di XML, pieno di Namespace, versione definitiva di XSL e XPath, versione draft, non definitiva, di Schema. Internet Explorer 5.5
- MSXML 4.0: supporto pieno di XML, Namespace, XSLT, XPath, versione **quasi** definitiva di Schema. Internet Explorer 6.0

In particolare, MSXML 2.0, per quel che riguarda XPath:

- Solo sintassi abbreviata, pochi assi
- Mancano completamente gli operatori aritmetici, e molti altri sono carenti
- Alcune funzioni hanno nomi diversi: end() invece di last(), index() invece di position(). Altre funzioni non esistono.

XPointer

XPointer è una delle attività più intricate e disgraziate del W3C (anche se HTTP-NG lo supera)

Dopo lunghe e intricate vicissitudini, una versione limitata e parziale è diventata Recommendation W3C nel marzo 2003. Il documento iniziale è stato frammentato in 4, tre dei quali sono stati approvati, ed il quarto ancora no.

Gli XPointer sono meccanismi per indicare all'interno di un URI la parte fragment, ovvero la specifica sezione del documento a cui faccio riferimento.

Questa parte può essere specificata o sulla base di un attributo id esistente (analogo a NAME di HTML), oppure indicando il nodo sulla base di un percorso di qualche tipo.

XPointer (2)

- **XPointer framework** (W3C recommendation) stabilisce l'organizzazione generale degli XPointer e la forma degli schemi da usare per indicare i frammenti interessanti.
- **XPointer xmlns()** (W3C recommendation) stabilisce come specificare nomi qualificati all'interno degli schemi XPointer
- **XPointer element()** (W3C recommendation) identifica due specifici schemi di indicazione di elementi all'interno di un XPointer: bare names (attributi di tipo id) e child sequences (sequenze di elementi figlio in un albero).
- **XPointer xpointer()** (W3C working draft) individua uno schema di XPointer che permette l'uso di XPath, e introduce due nuovi concetti, il punto ed il range, per indicare frammenti che non sono sottoalberi di un documento XML.

XPointer (3)

XPointer element()

- un *bare name* identifica l'elemento il cui ID è il nome dato
  - **`http://www.sito.com/file.xml#intro`** diventa **`http://www.sito.com/file.xml #element(intro)`**
- Una child sequence è una sequenza di attraversamento di un albero nei suoi figli
  - **`http://www.sito.com/file.xml#element(1/2)`**
- Le cose possono mescolarsi: una sequenza di attraversamento può partire da un bare name
  - **`http://www.sito.com/file.xml#xpointer(intro/1/2)`**

XPointer xpointer()

- Uno o più forme generali di frammento (General Fragment part). Può essere o un XPath, o un XPath con punti e range.
  - **`http://www.sito.com/file.xml#xpointer(a/b)`**

Estensioni a XPath (1)

XPointer xpointer() estende il concetto di node in quello di locazione. Una locazione è un nodo, o un punto, o un range di un documento XML. Quindi XPointer definisce due nuovi location types:

- Point: è definito da un nodo ed un indice, e rappresenta una posizione descritto dall'indice al'interno del nodo. Se il nodo non ha nodi figli, allora l'indice si riferisce alla stringa contenuta nel nodo.
- Range: è definito come due punti, il primo precedente al secondo.

Estensioni a XPath (2)

Inoltre XPointer definisce alcune funzioni aggiuntive, tra cui:

- range-to(nodo): dall'inizio di NC al nodo parametro
  - `xpointer(id("chap1")/range-to(id("chap2")))`
- string-range(): una sottostringa del NC
  - `string-range(//title,"Thomas Pynchon")[17]`
- range(node-set): tutti i range espressi dai parametri
- start-point(), end-point(): l'inizio e la fine del NC
- here(), origin(): il punto contesto, e l'origine del link.

Conclusioni

Qui abbiamo parlato di

- Xbase, XPath e XPointer

Riferimenti

- J. Clark, S. DeRose, XML Path Language (XPath), Version 1.0, W3C Recommendation 16 November 1999, http://www.w3.org/TR/xpath
- Paul Grosso, Eve Maler, Jonathan Marsh, and Norman Walsh, eds.. XPointer Framework, W3C Recommendation 25 march 2003, http://www.w3.org/TR/xptr-framework/
- Paul Grosso, Eve Maler, Jonathan Marsh, and Norman Walsh, eds.. XPointer element() Scheme, W3C Recommendation 25 march 2003, http://www.w3.org/TR/xptr-element/
- P. Grosso, E. Maler, J. Marsh, and N. Walsh, editors. XPointer xmlns() Scheme. World Wide Web Consortium, W3C Recommendation 25 march 2003, http://www.w3.org/TR/xptr-xmlns/.
- S. DeRose, E. Maler, and R. Daniel Jr., editors. XPointer xpointer() Scheme. World Wide Web Consortium, W3C Working Draft 19 December 2002, http://www.w3.org/TR/xptr-xpointer/