Esempi di SGML ∩ XML

Fabio Vitali

28 gennaio 2000

Introduzione

Qui esaminiamo in breve degli esempi delle varie caratteristiche di SGML e XML.

- Elementi
- Attributi
- Entità generali
- Entità parametriche
- Marked sections

Esempi di sviluppo del DTD

Ricapitolando, ci sono quattro caratteristiche di SGML che vale la pena considerare a fondo:

- Elementi ***<A> … </A>***
- Attributi <A ***HREF="http://…"***> … </A>
- Entità: <P>In HTML, si scrive entità</P>
- Marked sections

Elementi

Il content model di un elemento definisce quali e quanti elementi possono essere contenuti in un elemento.

Ci sono cinque famiglie di content model:

- **Qualunque**: un elemento può contenere qualunque elemento definito nel DTD
- **Vuoto**: un elemento non ha contenuto, e spesso ha solo il tag iniziale.
- **Testo**: un elemento può contenere solo testo (#PCDATA)
- **Strutturato**: un elemento può contenere solo altri elementi
- **Misto**: un elemento può contenere sia testo che altri elementi. XML ha solo UNA forma ammessa di content model misto.

Content model qualunque

```
<!ELEMENT X - - ANY>
```

- L'elemento X può contenere qualunque altro elemento specificato nel DTD, o anche testo

```
<X>adj<Y>dsb</Y>bdvb<Z>akbc</Z>bdkb</X>
```

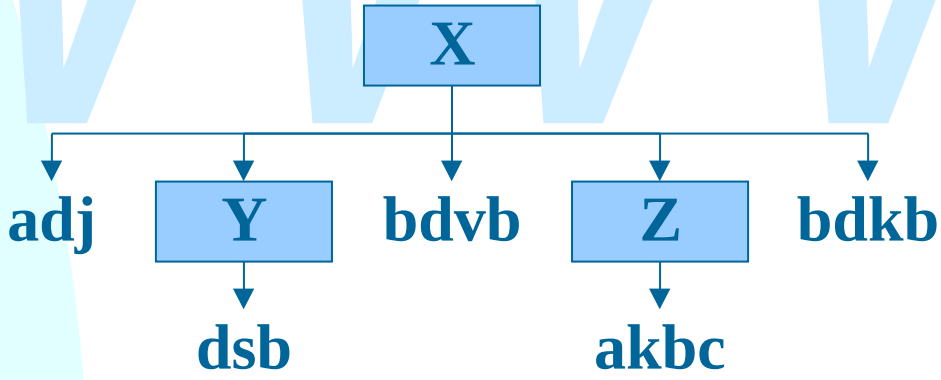

Content model vuoto

<!ELEMENT X - o EMPTY>

- L'elemento X non può contenere niente. E' equivalente scrivere il solo tag iniziale, o tag iniziale e finale (per questo se il content model è EMPTY, il secondo tag deve essere segnato come omissibile.

<X></X> **<X>**

- N.B. In XML il tag vuoto ha una sintassi diversa:

<X></X> **<X/>**

Content model testo

```
<!ELEMENT X - - #PCDATA>
```

- L'elemento X può solo contenere testo. E' proibito mettere altri elementi al suo interno

```
<X>adjbdkb</X>
```

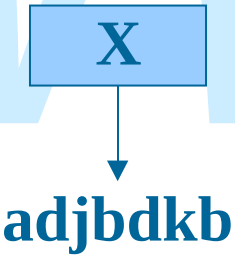

Content model strutturato

```
<!ELEMENT X - - (Y, (W | Z)+ , K*)>
```

- L'elemento X può contenere solo elementi secondo la specifica data, usando i separatori e gli operatori di ripetizione specificati.

```
<X><Y>dsb</Y><Z>bdvb<Z><Z>akbc</Z><W>bdkb</W><K>
eyiy</K></X>
```

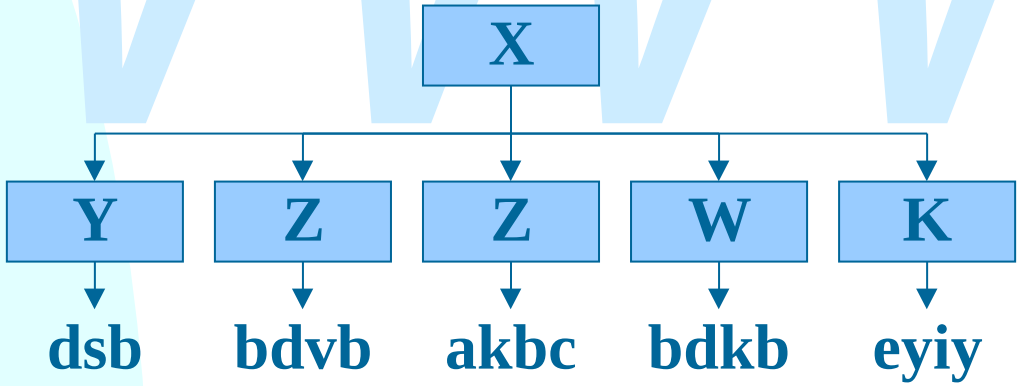

Content model misto

```
<!ELEMENT X - - (#PCDATA | Y | W | Z)*>
```

- L'elemento X può contenere sia testo sia altri elementi in maniera ed ordine specificati.
- L'unica forma accettabile di content model misto in XML è composta da una ripetizione di elementi alternativi, in cui il primo è #PCDATA. Cioè solo content model della forma qui sopra.

```
<X>adj<Z>dsb</Z>bdvb<Y>akbc</Y>bdkb</X>
```

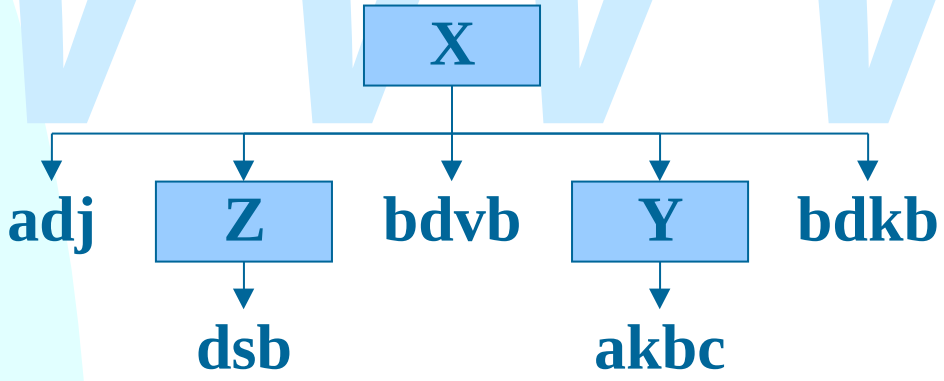

Separatori e ripetizioni

I separatori in SGML e XML sono due:

- La virgola indica elementi obbligatori e nel loro ordine.
- La barra verticale indica elementi alternativi

Gli operatori di ripetizione sono quattro

- Niente: elemento obbligatorio e non ripetibile
- ?: elemento facoltativo e non ripetibile
- +: elemento obbligatorio e ripetibile
- *: elemento facoltativo e ripetibile

Un esempio semplice

Una lettera commerciale è composta da un destinatario, un corpo e dei saluti. Il destinatario è composto di nome e ufficio interno. Il corpo è composto di paragrafi. I saluti sono testo semplice.

```
<!DOCTYPE lettera SYSTEM “lettera.dtd”>
<lettera>
   <destinatario>
      <nome>Mario Rossi</nome>
      <ufficio>Ufficio Acquisti</ufficio>
   </destinatario>
   <corpo>
      <para> Comprate tutto! </para>
   </corpo>
   <saluti> Arrivederci </saluti>
</lettera>
```


Il DTD relativo

```
<!ELEMENT lettera - - (destinatario, corpo, saluti)>
<!ELEMENTI destinatario - - (nome, ufficio) >
<!ELEMENT corpo - - (para)+>
<!ELEMENT saluti - - #PCDATA>
<!ELEMENT para - - #PCDATA>
```


Complichiamo l’esempio: alternative

Se il destinatario è interno, è composto da nome e ufficio interno. Altrimenti è composto da nome, ditta, indirizzo e città.

```
<!DOCTYPE lettera2 SYSTEM “lettera2.dtd”>
<lettera2>
   <destinatario>
      <nome>Mario Rossi</nome>
      <ditta>ACME, Inc.</ditta>
      <indirizzo>Via Garibaldi 1</indirizzo>
      <citta>Bologna</citta>
   </destinatario>
   …
</lettera2>
```


Il DTD relativo a lettera2

```
<!ELEMENT lettera2 - - (destinatario, corpo, saluti)>
<!ELEMENTI destinatario - -
      (nome, (ufficio | (ditta, indirizzo, citta)))>
<!ELEMENT corpo - - (para)+>
<!ELEMENT saluti - - #PCDATA>
<!ELEMENT para - - #PCDATA>
<!ELEMENT ditta - - #PCDATA>
<!ELEMENT indirizzo - - #PCDATA>
<!ELEMENT citta - - #PCDATA>
```

N.B.: le parentesi servono per evitare ambiguità. Allo stesso motivo “nome”, esistente in entrambe le possibilità, è stato estratto per evitare ambiguità di parsing.

Complichiamo l’esempio: ripetizioni

L’indirizzo è composto da una o più righe.

```
<!DOCTYPE lettera3 SYSTEM “lettera3.dtd”>
<lettera2>
   <destinatario>
      <nome>Mario Rossi</nome>
      <ditta>ACME, Inc.</ditta>
      <indirizzo>
         <riga>c/o Associated Producers</riga>
         <riga>Via Rossi 1</riga>
         <riga>Casteldebole</riga>
      </indirizzo>
      <citta>Bologna</citta>
   </destinatario>
   …
</lettera3>
```


Il DTD relativo a lettera3

```
<!ELEMENT lettera3 - - (destinatario, corpo, saluti)>
<!ELEMENTI destinatario - -
      (nome, (ufficio | (ditta, indirizzo, citta)))>
<!ELEMENT corpo - - (para)+>
<!ELEMENT saluti - - #PCDATA>
<!ELEMENT para - - #PCDATA>
<!ELEMENT ditta - - #PCDATA>
<!ELEMENT indirizzo - - (riga)+>
<!ELEMENT citta - - #PCDATA>
<!ELEMENT riga  - - #PCDATA>
```


Complichiamo l'esempio: content model misto

I paragrafi possono contenere anche corsivi e grassetti.

```
<!DOCTYPE lettera4 SYSTEM "lettera4.dtd">
<lettera4>
   <destinatario>
      …
   </destinatario>
   <corpo>
      <para> Comprate <bold>tutto!</bold> </para>
   </corpo>
   <saluti> Arrivederci </saluti>
</lettera4>
```


Il DTD relativo a lettera4

```
<!ELEMENT lettera4 - - (destinatario, corpo, saluti)>
<!ELEMENTI destinatario - -
      (nome, (ufficio | (ditta, indirizzo, citta)))>
<!ELEMENT corpo - - (para)+>
<!ELEMENT saluti - - #PCDATA>
<!ELEMENT para   - - (#PCDATA | bold | italic)*>
<!ELEMENT bold   - - (#PCDATA | italic)*>
<!ELEMENT italic - - (#PCDATA | bold)*>
<!ELEMENT ditta - - #PCDATA>
<!ELEMENT indirizzo - - (riga)+>
<!ELEMENT citta - - #PCDATA>
<!ELEMENT riga  - - #PCDATA>
```


Attributi

Gli attributi sono informazioni aggiuntive poste insieme all'elemento. Tecnicamente non fa parte del contenuto del documento, ma descrive e specifica l'elemento.

Ci sono tre famiglie di attributi importanti:

- **Qualunque stringa è lecita**
- **E' possibile scegliere solo uno dei valori proposti (lista)**
- **Il valore deve essere unico su tutto il documento (ID)**
- **Il valore deve essere uguale a quello di un ID esistente**

Attributi stringa

```
<!ATTLIST X
      a      CDATA    “pippo”
>
```

- Il tag iniziale di X può contenere un attributo chiamato “a”. Qualunque stringa è lecita. Se non viene specificata una stringa, il valore definito per default è “pippo”

- `<X a=“pluto”>adj</X>`
- `<X>bfg</X>` `<!-- a vale “pippo” -->`

Attributi lista

```
<!ATTLIST X
      a (pippo|pluto|paperino)  “pippo”
>
```

- Il tag iniziale di X può contenere un attributo chiamato “a”. Sono leciti solo i valori descritti. Se non viene specificata una stringa, il valore definito per default è “pippo”

- `<X a=“pluto”>adj</X>`
- `<X>bfg</X>  <!-- a vale “pippo” -->`
- `<X a=“paperino”>ljdn</X>`
- `<X a=“topolino”>kdjbk</X>  <!-- errore  -->`

Attributi ID

```
<!ATTLIST X
      a          ID                    #REQUIRED
>
```

- Il tag iniziale di X può contenere un attributo chiamato “a”. Sono leciti solo valori unici su tutto il documento. L’elemento X assume un’identificabilità assoluta all’interno del documento: è un “luogo notevole” Poiché il valore deve essere sempre diverso, non è possibile specificare un valore di default.

- `<X a=“pluto”>adj</X><X a=“pippo”>bfg</X>`
- `<X a=“pluto”>adj</X><X a=“pluto”>bfg</X>`
  `<!-- errore  -->`

Attributi IDREF

```
<!ATTLIST X
        a          ID                  #REQUIRED
        b          IDREF               #IMPLIED
>
```

- Il tag iniziale di X può contenere un attributo chiamato “a” ed uno chiamato “b”. I valori di “a” debbono essere unici.I valori di “b” debbono essere uguali ad un valore di “a” esistente da qualche parte nel documento.

- `<X a=“pluto”>adj</X><X b=“pluto”>bfg</X>`
- `<X a=“pluto”>adj</X><X b=“pippo”>bfg</X>`
  `<!-- errore  -->`

Valori di default negli attributi

I valori di default importanti in SGML e XML sono di quattro tipi:

- **Valore esplicito**: un stringa tra virgolette
- **Valore necessario**: la keyword #REQUIRED.
- **Valore facoltativo**: la keyword #IMPLIED.
- **Valore esplicito e non modificabile**: la keyword #FIXED e una stringa tra virgolette. Usata per scopi particolari. La vedremo per XLink.

Complichiamo l'esempio: attributi testo e lista

Ogni lettera deve avere una data di creazione e può avere un autore, che non fanno parte del contenuto della lettera. Inoltre è necessario specificare se il destinatario è interno o esterno.

```
<!DOCTYPE lettera5 SYSTEM "lettera5.dtd">
<lettera5 data="28/01/2000" autore="FV">
   <destinatario tipo="esterno">
      …
   </destinatario>
   <corpo>
      …
   </corpo>
   <saluti> … </saluti>
</lettera5>
```


Il DTD relativo a lettera5

```
<!ELEMENT lettera5 - - (destinatario, corpo, saluti)>
<!ATTLIST lettera5
      data        CDATA       #REQUIRED
      autore      CDATA       #IMPLIED
>
<!ELEMENTI destinatario - -
      (nome, (ufficio | (ditta, indirizzo, citta)))>
<!ATTLIST destinatario
      tipo  (interno | esterno)     “interno”
>
<!ELEMENT corpo - - (para)+>
<!ELEMENT saluti - - #PCDATA>
…
```


Complichiamo l'esempio: attributi ID e IDREF

Ogni paragrafo deve avere un identificativo univoco. L'elemento "link", che può essere contenuto nei paragrafi, può creare un link ad un paragrafo precedente.

```
<!DOCTYPE lettera6 SYSTEM "lettera6.dtd">
<lettera6 data="28/01/2000" autore="FV">
   …
   <corpo>
      <para id="P1"> Comprate tutto! </para>
      <para> Imparate il
         <link v="P1">paragrafo precedente</link>
      </para>
   </corpo>
   <saluti> … </saluti>
</lettera6>
```


Il DTD relativo a lettera6

```
<!ELEMENT lettera6 - - (destinatario, corpo, saluti)>
<!ELEMENT corpo - - (para)+>
<!ELEMENT para  - - (#PCDATA | bold | italic | link)*>
<!ATTLIST para
      id          ID          #IMPLIED
>
<!ELEMENT link  - - (#PCDATA | bold | italic)*>
<!ATTLIST link
      v           IDREF       #REQUIRED
>
…
```


Entità

Le entità sono macro testuali a sostituire dei riferimenti brevi, univocamente associati al loro significato esteso.

Ci sono due tipi di entità:

- **Generali**: definite in un DTD, possono essere usate nell'istanza di documento.
- Parametriche: definite in un DTD, possono essere usate nello stesso DTD, subito dopo.

Entità generali

```
<!ENTITY Z “pippo”>
```

- Ogni volta che scrivo il nome dell’entità, “&Z;” il processore sostituisce la stringa corrispondente, “pippo”.
- Un’entità della forma “&#NNN;”, dove NNN sono cifre decimali, viene sostituita con il carattere corrispondente nella tabella caratteri di default.

```
<X>Oggi ho visto &Z; </X>
<X>Che bella entit&#224; </X>
```


Entità parametriche

```
<!ENTITY % Z “#CDATA | Z”>
```

- Ogni volta che scrivo il nome dell’entità, “%Z;” il processore sostituisce la stringa corrispondente, “#CDATA | Y”.
- Posso usare questa notazione solo all’interno di un DTD

```
<!ELEMENT X (%Z;)*>
<!ELEMENT Y (%Z; | W)* >
```


Complichiamo l'esempio: entità generali

Forniamo supporto per le lettere accentate e forniamo due o tre forme standard di saluto

```
<!DOCTYPE lettera7 SYSTEM "lettera7.dtd">
<lettera7 data="28/01/2000" autore="FV">
   …
   <corpo>
      <para> Ol&agrave;! Comprate tutto! </para>
      …
   </corpo>
   <saluti> &CS; </saluti>
</lettera7>
```

In fase di elaborazione, "agrave" diventerà "à" e "CS" diventerà "Cordiali saluti".

Il DTD relativo a lettera7

```
<!ELEMENT lettera7 - - (destinatario, corpo, saluti)>
<!ELEMENT corpo - - (para)+>
<!ELEMENT para  - - (#PCDATA | bold | italic | link)*>
…
<!ENTITY agrave “&#224;” >
<!ENTITY CS     “Cordiali saluti”>
<!ENTITY AP     “A presto”>
…
```


Complichiamo l'esempio: entità parametriche (I)

Centralizziamo il content model misto, in modo da poterlo cambiare in un colpo solo. Perdiamo qualcosa, però.

```
<!DOCTYPE lettera8 SYSTEM "lettera8.dtd">
<lettera8 data="28/01/2000" autore="FV">
   …
   <corpo>
      <para> Ol&agrave;! Comprate tutto! </para>
      …
      </corpo>
   <saluti> &CS; </saluti>
</lettera8>
```

(il documento è identico!!!)

Il DTD relativo a lettera8

```
<!ELEMENT lettera8 - - (destinatario, corpo, saluti)>
<!ELEMENT corpo - - (para)+>
…
<!ENTITY % inline  “(#PCDATA | bold | italic | link)*”>
<!ELEMENT para   - - %inline;>
<!ELEMENT link   - - %inline;>
<!ELEMENT bold   - - %inline;>
<!ELEMENT italic - - %inline;>
…
```

- Cosa abbiamo perso?

Complichiamo l'esempio: entità parametriche (II)

- Raccogliamo e separiamo tutte le entità per le lettere strane, perché sono troppe e confondono le idee.
- Inoltre rendiamo il frammento di DTD compatibile sia con SGML che con XML (XML non ha le specifiche di minimizzazione!!!)

```
<!DOCTYPE lettera9 SYSTEM "lettera9sgml.dtd">
<lettera9 data="28/01/2000" autore="FV">
  …
  <corpo>
     <para> Ol&agrave;! Comprate tutto! </para>
   …
     </corpo>
   <saluti> &CS; </saluti>
</lettera9>
```


Il DTD relativo a lettera9

- File “entities.dtd”:

```
<!ENTITY agrave “&#224;” >
<!ENTITY egrave “&#232;” >
```

- File “lettera9.dtd”:

```
<!ENTITY % entities SYSTEM “entities.dtd”>
%entities;
<!ELEMENT lettera9 %min; (destinatario, corpo, saluti)>
<!ELEMENT corpo %min; (para)+>
```

- File “lettera9sgml.dtd”

```
<!ENTITY % min “- -”>
<!ENTITY % dtd SYSTEM
            “lettera9.dtd”>
%lettera9.dtd
```

- File “lettera9xml.dtd”

```
<!ENTITY % min “”>
<!ENTITY % dtd SYSTEM
            “lettera9.dtd”>
%lettera9.dtd
```


Marked sections

```
<![INCLUDE[
      Roba da includere
]]>
<![EXCLUDE[
      Roba da escludere
]]>
```

- Permette di specificare parti del DTD che vengono considerate ed escluse in alternativa.
- Per esempio permettono di specificare due content model per lo stesso elemento, da attivare in alternativa.

Complichiamo l'esempio: Marked Section

Creiamo due DTD, uno in cui certi elementi sono leciti, e l'altro in cui non lo sono. Questo deve essere fatto con un unico file, per gestire insieme tutte le evoluzioni successive.

```
<!DOCTYPE lettera10 SYSTEM "lettera10.dtd">
<lettera10 data="28/01/2000" autore="FV">
   …
   <corpo>
      <para> Comprate <bum>tutto!</bum></para>
      <para> Imparate il
         <link v="P1">paragrafo precedente</link>
      </para>
   </corpo>
   <saluti> &CS; </saluti>
</lettera10>
```


Il DTD relativo a lettera10

- File “lettera10.dtd”:

```
<!ELEMENT lettera10 - - (destinatario, corpo, saluti)>
<!ELEMENT corpo - - (para)+>
<![%BUM;[
  <!ENTITY % inline  “(#PCDATA | italic | link | bum)*”>
]]> <![%NoBUM; [
     <!ENTITY % inline  “(#PCDATA | italic | link )*”>
]]>
<!ELEMENT para   - - %inline;>
```

- File “lettera10-bum.dtd”

```
<!ENTITY % BUM “EXCLUDE”>
<!ENTITY % NoBUM “INCLUDE”>
<!ENTITY % dtd SYSTEM
           “lettera10.dtd”>
%lettera10.dtd
```

- File “lettera10+bum.dtd”

```
<!ENTITY % BUM “INCLUDE”>
<!ENTITY % NoBUM “EXCLUDE”>
<!ENTITY % dtd SYSTEM
           “lettera10.dtd”>
%lettera10.dtd
```


Conclusioni

Qui abbiamo fatto degli esempi di DTD XML e SGML.

- Elementi ***<A> … </A>***
- Attributi <A ***HREF="http://…"***> … </A>
- Entità: <P>In HTML, si scrive entità</P>
- Marked sections

Riferimenti

Wilde's WWW, capitolo 4

Altri testi:

- E. Maler, J. Al Andaloussi, ***Developing SGML DTDs, from text to model to markup***, Prentice Hall, 1997