

Gültige Dokumente = korrekte Dokumente?

Qualitätssicherung von XML-Dateien
mit Schematron

5/20/2011

Zur Person:

Manuel Montero Pineda

Dipl.-Wirtschaftsinformatiker (FH), M.A.

XML-Entwickler und Berater im Bereich XML-Schema, OOXML, XSLT, XSL-FO, uvm..

Hauptautor von „Professionelle XML-Verarbeitung mit Word“ und „XSL-FO in der Praxis“ beides erschienen beim dpunkt-Verlag.

Geschäftsführer der Firma data2type GmbH.

Validierung von XML-Dokumenten

Bei Publishing-Prozessen ist die Validierung von Dokumenten ein Freigabekriterium für die weiteren Abläufe.

Hierzu verwendete Schemasprachen sind:

- DTD (gerade bei Verlagen anzutreffen, wird aber nicht weiterentwickelt)
- XML-Schema (vom W3C herausgegebene Schema-Sprache)
- RelaxNG (ISO-zertifizierte Sprache)

Diese sogenannten grammatikbasierten Schemasprachen regeln beispielsweise das Auftreten und die Anordnung von Elementen, die Häufigkeit jedes Elementes sowie die Datentypen von Elementen und Attributen.

Beispielinstanz

```
1 <?xml version="1.0" encoding="UTF-8"?>
2
3 <arche xmlns="http://www.schematron.de/arche" xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
4   xsi:schemaLocation="http://www.schematron.de/arche arche.xsd">
5   <ladung>
6     <zimmer>
7       <tier geschlecht="weiblich" fleischfresser="nein">
8         <art>Zebra</art>
9         <gewicht einheit="kg">200</gewicht>
10        <alter>40</alter>
11      </tier>
12      <tier geschlecht="männlich" fleischfresser="nein">
13        <art>Zebra</art>
14        <gewicht einheit="kg">250</gewicht>
15        <alter>40</alter>
16      </tier>
17      <tier geschlecht="männlich" fleischfresser="nein">
18        <art>Zebra</art>
19        <gewicht einheit="kg">280</gewicht>
20        <alter>40</alter>
21      </tier>
22      <tier geschlecht="weiblich" fleischfresser="ja">
23        <art>Löwe</art>
24        <gewicht einheit="kg">200</gewicht>
25        <alter>16</alter>
26      </tier>
```

Grammatikbasierte Sprachen im Vergleich

DTD

```
1 <?xml encoding="UTF-8"?>
2
3 <!ELEMENT ns1:arche (ns1:ladung,ns1:maxReproduktionsalter,ns1:nutzlast)>
4 <!-->
5 <!-->
6 <!-->
7 <!-->
8 <!-->
9 <!-->
10 <!-->
11 <!-->
12 <!-->
13 <!-->
14 <!-->
15 <!-->
16 <!-->
17 <!-->
18 <!-->
19 <!-->
20 <!-->
21 <!-->
22 <!-->
```

XML-Schema

```
1 <?xml version="1.0" encoding="UTF-8" standalone="yes"?>
2 <!--W3C Schema generated by XMLSpy v2005 rel. 3 U (http://www.altova.com)-->
3 <xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema"
4   targetNamespace="http://www.schematron.de/arche" xmlns="http://www.schematron.de
5   elementFormDefault="qualified">
6   <xs:element name="alter">
7     <xs:simpleType>
8       <xs:restriction base="xs:positiveInteger">
9         <xs:maxInclusive value="200"/>
10      </xs:restriction>
11    </xs:simpleType>
12  </xs:element>
13  <xs:element name="arche">
14    <xs:complexType>
15      <xs:sequence>
16        <xs:element ref="ladung"/>
17        <xs:element ref="maxReproduktionsalter"/>
18        <xs:element ref="nutzlast"/>
19      </xs:sequence>
20    </xs:complexType>
21  </xs:element>
22  <xs:element name="art" type="xs:string"/>
23  <xs:element name="gewicht">
```

Relax NG (XML-Schreibweise)

```
1 <?xml version="1.0" encoding="UTF-8"?>␣
2 <grammar ns="http://www.schematron.de/arche" xmlns:xsi="http://www.w3.org/2001/XMLSchema"␣
3   xmlns="http://relaxng.org/ns/structure/1.0"␣
4   datatypeLibrary="http://www.w3.org/2001/XMLSchema-datatypes">␣
5   <start>␣
6     <element name="arche">␣
7       <attribute name="xsi:schemaLocation"/>␣
8       <element name="ladung">␣
9         <oneOrMore>␣
10          <element name="zimmer">␣
11            <oneOrMore>␣
12              <element name="tier">␣
13                <attribute name="fleischfresser">␣
14                  <data type="NCName"/>␣
15                </attribute>␣
16                <attribute name="geschlecht">␣
17                  <data type="NCName"/>␣
18                </attribute>␣
19                <element name="art">␣
20                  <data type="NCName"/>
```

Relax NG (Kompakt-Schreibweise)

```
1 default namespace = "http://www.schematron.de/arche"
2 namespace xsi = "http://www.w3.org/2001/XMLSchema-instance"
3
4 start =
5
6   element arche {
7     attribute xsi:schemaLocation { text },
8     element ladung {
9       element zimmer {
10         element tier {
11           attribute fleischfresser { xsd:NCName },
12           attribute geschlecht { xsd:NCName },
13           element art { xsd:NCName },
14           element gewicht {
15             attribute einheit { xsd:NCName },
16             xsd:integer
17           },
18           element alter { xsd:integer }
19         }+
20       },
21       element maxReproduktionsalter {
22         element tier_art {
23           element name { xsd:NCName },
24           element männlich { xsd:integer },
25           element weiblich { xsd:integer }
26         }+
27       },
28       element nutzlast {
29         attribute einheit { xsd:NCName },
30         xsd:integer
31       }
32     }
```

Vorteile von XML-Schema gegenüber DTDs

- Es ist einfacher den Elementinhalt und Dokumentaufbau zu beschreiben.
- Bessere Überprüfung der Dateninhalte.
- Einfacheres Zusammenspiel mit Datenbanken, da dort ähnliche Datentypen definiert werden können.
- Sehr genaue Definition von erlaubten individuellen Zeichenfolgen möglich.
- Konvertierung (casten) zwischen verschiedenen Datentypen ist möglich. Z.B. mache aus einem String einen Integer.
- Schemata unterstützen Namensräume. Dadurch ist eine Wiederverwendung in anderen Projekten einfacher.
- Schemata sind selbst in der XML-Syntax geschrieben.
- Dadurch können sie von XML-Parsern auf Validität überprüft werden.
- Schemata können prinzipiell mit XSLT verändert oder ausgewertet werden.

Weitere Vorteile von XML-Schema gegenüber DTDs

- Schemata können mit jedem XML-Editor erstellt werden.
- Integriertes Dokumentationsmodell.
- Sehr gute Modularisierungsmöglichkeiten.

Nachteile gegenüber DTDs

- Syntax von DTD ist zwar nicht XML-basiert aber dennoch relativ einfach.
- Große Schemata lassen sich ohne Entwicklungsumgebungen bzw. speziellen Editoren kaum pflegen bzw. entwickeln.

Vorteile von Relax NG gegenüber XML-Schema

- Bietet mehr Prüfmöglichkeiten
- Bessere Syntax.
- Intuitive Kompaktschreibweise

Nachteile von Relax NG gegenüber XML-Schema

- Wird von wenigen Editoren unterstützt.
- Scheint sich nicht durchzusetzen.

Zusammenfassung

	DTD	Schema	Relax NG
Verbreitung	++	+++	-
Mächtigkeit	-	++	+++
Zukunftsfähig	-	+++	+
Softwareunterstützung	+	++	-
Datentypen	-	++	++

Grammatikbasierte Sprachen bieten keine Möglichkeit Abhängigkeiten zu definieren. (Ausnahme ist XML-Schema 1.1)


Ablauf einer XML-Prüfung

1. **Prüfung der Syntax** (Wohlgeformtheit).
2. **Prüfung der Grammatik** (parsen gegen eine DTD, XML-Schema, etc.).
3. **Prüfung der Kohärenz** (Prüfung auf sogenannte Business-Rules) **NEU**.

Danach Freigabe für weitere Verarbeitungsprozesse wie z.B. XSLT-Stylesheets für Crossmediale Ausgaben.

XML

```
<arche>
  <zimmer>
    <tier
fleischfresser="nein">
      <art>Zebra</art>
    </tier>
    <tier fleischfresser="ja">
      <art>Gepard</art>
    </tier>
  </zimmer>
</arche>
```



XSD 1.0

```
<xs:element name="zimmer">
  <xs:complexType>
    <xs:sequence>
      <xs:element minOccurs="2"
maxOccurs="unbounded" ref="tier"/>
    </xs:sequence>
  </xs:complexType>
</xs:element>
```

Bedingung ist abbildbar durch XPATH!

Arche-Noah-Business-Rule:

Gibt es Fleischfresser und Vegetarier in einem Zimmer?

```
tier[@fleischfresser='ja'] and tier[@fleischfresser='nein']
```

Möglichkeiten von XPATH:

- Zugriff auf alle Knoten des XML-Dokuments
- Verschiedene Knotenoperationen
- Einsatz der XPATH-Funktionsbibliothek

XPATH in Schematron einbetten!

Was ist Schematron?

- Teil des DSDL (ISO 19757)
- Hosting Sprache in XML formuliert

```
<?xml version="1.0" encoding="UTF-8"?>
<schema xmlns="http://purl.oclc.org/dsdl/schematron"
queryBinding="[query language]
```

```
<?xml version="1.0" encoding="UTF-8"?>
<schema xmlns="http://purl.oclc.org/dsdl/schematron"
queryBinding="xslt2">
  <pattern>
    <rule context="zimmer">
      <assert test="not(tier[@fleischfresser='ja']
                        and tier[@fleischfresser='nein'])" />
    </pattern>
  </schema>
```

Was ist möglich bei der Kohärenz-Prüfung?

- Überprüfung von Kindstrukturen in Abhängigkeit von Attributwerten
- Überprüfung der Häufigkeit von Elementen in Abhängigkeit von Geschwisterelementen.
- Überprüfung komplexer Inhaltsregeln, wie z.B. die fehlerhafte Verwendung von Überspannungen bei CALS-Tabellen.
- Einschränkung bei der Verwendung von rekursiven Strukturen.
- Vermeidung von speziellen textuellen Inhalten, wie Folgen von Unterstrichen oder Punkten, die im dokumentenzentrierten Umfeld oft als Gestaltungselemente „missbraucht“ werden.
- Überprüfung von Summen, z.B. innerhalb von Rechnungsformularen.
- Überprüfung des Einsatzes von Processing-Instructions.


Lösungsansatz ist Schematron

- Schematron ist ein ISO-Standard seit Mai 2006.
- Die benötigten Programme sind kostenlos verfügbar.
- Unterstützung durch diverse XML-Editoren wie oXygen, XMLmind, etc.
- Einfache Programmierung mittels XPath.
- Individualisierte Fehlermeldungen.

Beispiel für ein Schematronschema:

```
<schema xmlns="http://purl.oclc.org/dsdl/schematron">
  <pattern id="Unterstriche">
    <rule context="a">
      <assert test="not(contains(., '___'))">
        Statt Unterstrichen sollte das Element
        "leerzeile verwendet werden!</assert>
      </rule>
    </pattern>
  </schema>
```

Schematron: Ein Ersatz für XML Schema?



-> Schematron als
Ergänzung zu
grammatikbasierten
Sprachen

Einsatzszenario

Ein Verlag lässt im Ausland Daten erfassen.

Nach einer Sichtung der Daten fallen einige Fehler auf, die nicht zu Validierungsproblemen führen, aber dennoch im Rahmen einer Qualitätssicherung behoben werden müssen.

Außerdem soll dokumentiert werden an welchen Stellen und wie häufig ein Eingriff notwendig war.

Beispiel für eine Anforderung die beim Sichten aufgefallen ist.

Silbentrennungen

Falsche Silbentrennungen kommen in unterschiedlichster Form vor:

- Feste Trennung: Schema-tron
- Feste Trennung mit Break: Schema-
tron
- Bedingte Trennung mit Leerschritt: Schema
tron
- Mehrfache bedingte Trennung: Schema

tron
- Korrekt ist: Schema
tron

In Schematron:

```
<schema xmlns="http://purl.oclc.org/dsdl/schematron">
  <pattern id="_6Silbentrennung">
    <rule context="*[normalize-space(./text())]">
      <assert test="not(contains(., '&#xAD; '))">
        Silbentrennung nur mit Hilfe der Entity
        "&#xAD;" Leerstellen danach sind nicht
        zulässig!</assert>
      <assert test="(not(contains(., '&#xAD;&#xAD;')))">
        Silbentrennung nur mit Hilfe einer Entity "&#xAD;".
        Entity darf nicht doppelt verwendet werden!</assert>
      ...
    </rule>
  </pattern>
</schema>
```

Wie nutzt man Schematron?


Szenario 1: Im Editor

**Editoren die Schematron unterstützen:
Oxygen, XMLMind,**

Szenario 2: Black-Box (Referenzimplementierung mit XSLT)

Szenario 3: Black-Box eingebettet in XProc

Schematron Einsatzszenario



Beispiele aus dem Publishing!

Fußnoten

```
<para>
```

In order to view this text in a browser, you have to start the browser.

```
<footnote>
```

```
  <para>browser: Tool to view (X)HTML.
```

```
    <footnote>
```

```
      <para>(X)HTML: XML Hypertext Markup Language</para>
```

```
    </footnote>
```

```
  </para>
```

```
</footnote>
```

```
</para>
```

SCH

```
<rule context="footnote">
  <assert test="not(../footnote)">
    ...
  </assert>
</rule>
```

PI's

SCH

```
<pattern id="PIs">  
  <rule context="processing-instruction()">  
    <assert test="starts-with(name(),'hdm')">  
      Diese PI stammt nicht aus der HdM.  
      Bitte dokumentieren Sie Ihre Funktion.  
      Name der PI: <value-of select="name()"/>  
    </assert>  
  </rule>  
</pattern>
```

Verschachtelte Listen

SCH

```
<pattern id="Listen">
  <rule context="listitem">
    report test="count(ancestor::listitem) > 2">
      Eine Liste darf nicht mehr als drei Ebenen haben.
      Wir sind in der
      <value-of select="count(ancestor::listitem)+1"/>
      . Ebene.
    </report>
  </rule>
</pattern>
```

Verwendung von Zeichen

Beispiel:

```
<para>Bitte tragen Sie hier ihren  
    Namen ein: _____</para>
```

```
<pattern id="Zeichen" role="warning">  
    <rule context="*[text()]">  
        <report test="contains(text(),'____')">  
            Mehr als drei Unterstriche hintereinander.  
        </report>  
    </rule>  
</pattern>
```

Schematron bei großen Grammatiken:


Wer benutzt Schematron?

- DocBook
- DITA
- TEI
- EPUB
- ...?

Schematron in DocBook



Schematron in Epub-check



The screenshot shows the SourceForge page for the 'epubcheck' project. The page title is 'ncx.sch - epubcheck - Project Hostin...'. The 'Source' tab is selected, showing the source path: `svn/ trunk/ com.adobe.epubcheck/ src/ com/ adobe/ epubcheck/ sch/ ncx.sch`. The source code for `ncx.sch` is displayed, starting with a comment: 'A Schematron schema for NCX version 2005-1'. The code includes a pattern for `ncx_pageTargUniqValTypeComb` and a pattern for `ncx_playOrderOrigin`. On the right, the 'Change log' section shows a change by markus.gylling on Feb 12, 2009, fixing a multiple `@playorder="1"` error. The 'Older revisions' section shows a revision by markus.gylling on Jan 22, 2008. The 'File info' section shows the file size as 3903 bytes and 81 lines.

epubcheck
ePUB Validation tool for EPUB

Project Home Downloads Wiki Issues Source

Checkout Browse Changes Search Trunk

Source path: [svn/](#) [trunk/](#) [com.adobe.epubcheck/](#) [src/](#) [com/](#) [adobe/](#) [epubcheck/](#) [sch/](#) ncx.sch [< r46 r145](#) [Hide details](#)

```
1 <sch:schema xmlns:sch="http://www.ascc.net/xml/schematron">
2   <!--
3     A Schematron schema for NCX version 2005-1
4
5     Adopted from Z3986 conformance validator ("ZedVal") schema
6     available in original at http://daisymfc.svn.sourceforge.net/viewvc/daisymfc/trunk/ncx-2005-1.rng?view=log
7
8     This schema uses Schematron 1.5 for integration with Jing, and
9     to get line/column locators in reported errors, as implemented
10    by James Clark. It may be upgraded to ISO Schematron in the future.
11
12    Latest edit: mgylling 20080116
13
14    -->
15
16    <sch:ns prefix="ncx" uri="http://www.daisy.org/z3986/2005/ncx/" />
17
18    <sch:pattern name="ncx_pageTargUniqValTypeComb" id="ncx_pageTargUniqValTypeComb">
19      <!-- pageTarget combination of value and type attributes is unique -->
20      <sch:rule context="ncx:pageList/ncx:pageTarget[@value]">
21        <sch:assert test="count(//ncx:pageTarget[@value=current()/@value and @type=current()/@type]=1)">
22          pageTarget combination of value and type is not unique
23        </sch:assert>
24      </sch:rule>
25    </sch:pattern>
26
27    <sch:pattern name="ncx_playOrderOrigin" id="ncx_playOrderOrigin">
```

Change log
[r106](#) by markus.gylling on Feb 12, 2009 [Diff](#)
Fix for multiple `@playorder="1"` being
flagged as error, as reported at http://groups.google.com/group/epubcheck/browse_thread/thread/b211c474964b1d90

Go to: [.../com/adobe/epubcheck/sch/ncx.sch](#) ▼
Project members, [sign in](#) to write a code review

Older revisions
[r46](#) by markus.gylling on Jan 22, 2008 [Diff](#)
[All revisions of this file](#)

File info
Size: 3903 bytes, 81 lines
[View raw file](#)

Fertig


Erweiterungen mit Java (nur mit Saxon)

```
<pattern>
  <rule context="bild">
    <let name="path" value="concat($myDir, '\', @src)"/>
    <let name="file" value="f:new($path)"/>
    <assert test="f:exists($file)">Bild
      <value-of select="tokenize($path, '\\')[last()]" />
      existiert nicht
    </assert>
  </rule>
</pattern>
```

```
1 <?xml version="1.0" encoding="UTF-8"?>
2 <?oxygen SCHSchema="schematron/bild.sch"?>
3
4 <collection>
5   <bild src="pics\bild.jpg"/>
6   <bild src="pics\bild2.jpg"/>
7   <bild src="pics\bild3.jpg"/>
8 </collection>
9
```

E [ISO Schematron (XSLT 2.0)]
Bild bild.jpg existiert nicht
(f:exists(\$file)) [assert]

Schematron validieren im Editor



data<2>type



Literaturhinweis in eigener Sache:

Unser Schematronbuch (Autoren sind Prof. Marko Hedler Hochschule der Medien Stuttgart und ich) erscheint im Sommer 2010 beim dpunkt Verlag.

Artikel zu Schematron:

Montero Pineda, Manuel, Hedler, Marko, Dünckel, Björn: Jedes Spiel hat seine Regeln, in: entwickler magazin, Heft 4 (2009).

<http://entwickler-magazin.de/zonen/magazine/psecom,id,8,online,2459.html>

Und natürlich die Seite zum Thema:

<http://www.schematron.com/>

Fragen?



Dammstr. 18

67059 Ludwigshafen

T: ++49-(0)621-68124792

F: ++49-(0)621-68124794

E: montero@data2type.de