Definiowanie typów dokumentów

Część 1. DTD, XML Schema

Jak wygląda XML?

```
<?xml version="1.0"?>
<zeznanie-sprawcy nr="1313/2001">
<autor>st. asp. Jan Łapówka</autor>
<miejsce>Dołowice Górne</miejsce>
<treść>Wypadek dnia
<data>13.10.2001r</data>
o godzinie <godzina>13:13</godzina>
(<dzien-tygodnia>piątek
</dzien-tygodnia>) miał  miejsce nie
z mojej winy. <poszkodowany>Alojzy
M.</poszkodowany> nie miał żadnego
pomysłu w którą stronę uciekać, więc
go przejechałem.</treść>
</zeznanie-sprawcy>
```

Deklaracja XML

Element główny

Atrybut

Element

Znacznik początkowy

Znacznik końcowy

Zawartość tekstowa

Struktura logiczna dokumentu XML

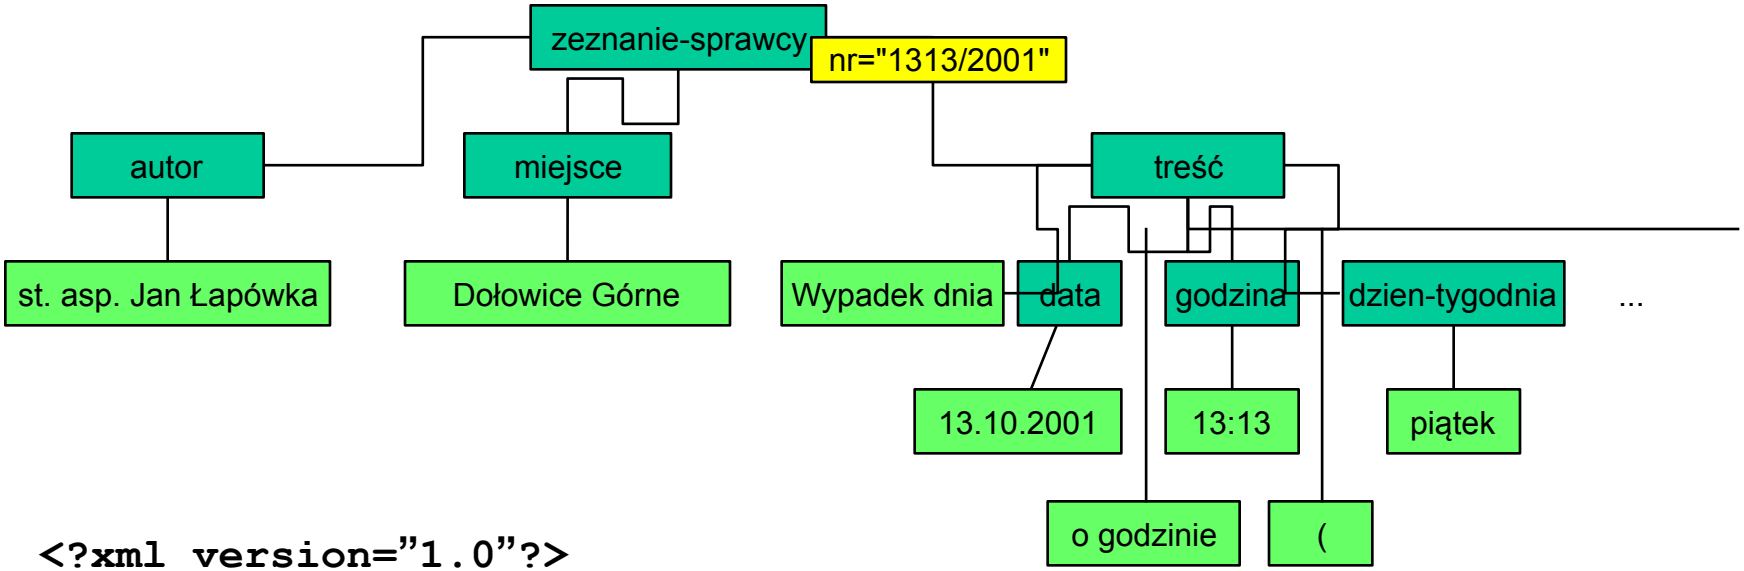


```
<?xml version="1.0"?>
<zeznanie-sprawcy nr="1313/2001">
<autor>st. asp. Jan Łapówka</autor>
<miejsce>Dołowice Górne</miejsce>
<treść>Wypadek dnia <data>13.10.2001r</data>
o godzinie <godzina>13:13</godzina>  (<dzien-tygodnia>piątek
</dzien-tygodnia>) miał  miejsce nie z mojej winy.
<poszkodowany>Alojzy M.</poszkodowany> nie miał żadnego
pomysłu w którą stronę uciekać, więc go przejechałem.</treść>
</zeznanie-sprawcy>
```

Składnia XML

- Deklaracja XML:
```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
```
- Znaczniki:
```
<tag attributename="attribute value">
</tag>
```
- Znaczniki elementu pustego:
```
<br></br>
<br/>
```
- Komentarz:
```
<!-- komentarz -->
```
- Instrukcja przetwarzania:
```
<?target processing-instruction-body?>
```
- Sekcja CDATA:
```
<![CDATA[dowolny <tekst " nieprzetwarzany & przez
   [ parser]]>
```

Encje predefiniowane

`&amp;`	`&`
`&lt;`	`<`
`&gt;`	`>`
`&apos;`	`&apos;`
`&quot;`	`&quot;`

Unicode

- Światowy standard kodowania znaków.
- Odmiany:
  - UTF-7 (korzysta tylko z 7-bitowego zestawu znaków ASCII),
  - UTF-8 (pierwsze 128 – ASCII, znak zajmuje od 1 do 6 bajtów),
  - UTF-16 (każdy znak to jedno lub dwa słowa 16-bitowe),
  - UTF-32 (każdy znak to jedno słowo 32-bitowe),
  - UCS-4 (znak zajmuje zawsze 4 bajty).
- Obowiązkowy standard dla dokumentów XML:
  - każde narzędzie XML-owe musi wspierać przynajmniej UTF-8.
- Sposób użycia w dokumentach XML:
  - jako odpowiedni ciąg bajtów,
  - `&#`*kod*`;` - kod dziesiętny znaku,
  - `&#x`*kod*`;` - kod szesnastkowy znaku.

Definiowanie języków

- XML, SGML – metajęzyki.
- Definiowanie języków (zastosowań, struktury dokumentów, typów dokumentów):
  - określanie zestawu dopuszczalnych elementów, atrybutów, ...,
  - definiowanie dopuszczalnej zawartości elementów (tekst, inne elementy),
  - przypisywanie atrybutów do elementów,
  - ...
- Metody definiowania struktury:
  - dokument XML bez formalnej definicji struktury,
  - DTD – Document Type Definition,
  - XML Schema (rekomendacja W3C z 2 maja 2001),
  - Relax NG.

Poprawność dokumentów

- Dokument XML poprawny składniowo (ang. *well-formed*):
  - każdy element musi być zamknięty,
  - nie ma nakładających się elementów,
  - wartości atrybutów w apostrofach lub cudzysłowach,
  - ...
- Dokument XML poprawny strukturalnie (ang. *valid*):
  - struktura dokumentu zgodna ze strukturą zdefiniowaną w definicji typu dokumentu,
  - obecne wszystkie wymagane atrybuty.

Modelowanie typów dokumentów

- Wieloetapowy proces analityczno-projektowy:
  - analiza struktury modelowanych bytów,
  - analiza przykładowych dokumentów,
  - analiza potencjalnych zastosowań dokumentów oraz przypadków użycia,
  - abstrakcyjny projekt struktury,
  - kodowanie projektu struktury np. przy pomocy DTD lub XML Schema,
  - testowanie,
  - pielęgnacja, zarządzanie zmianami.

Projektowanie struktury dokumentów

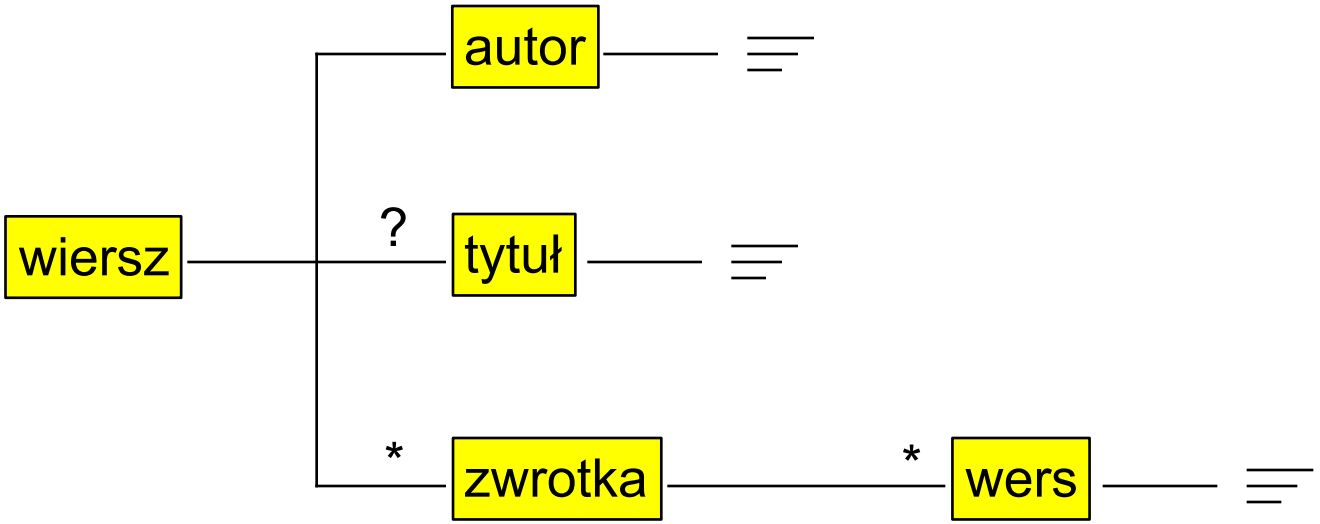

DTD – prosty przykład

```
<!DOCTYPE wiersz [
  <!ELEMENT wiersz  (autor, tytul?, zwrotka*)>
  <!ATTLIST wiersz bialy (tak|nie) "nie">
  <!ELEMENT autor   (#PCDATA)>
  <!ELEMENT tytul   (#PCDATA)>
  <!ELEMENT zwrotka (wers)*>
  <!ELEMENT wers    (#PCDATA)>
]>
```

element główny

zawartość elementów

wyrażenia regularne

atrybuty

Dlaczego DTD nie wystarcza?

- Zastosowania XML-a w integracji aplikacji – struktury danych:
  - przeniesienie zadania sprawdzania poprawności z tworzonej aplikacji na narzędzie walidujące daje spore oszczędności,
  - 60% tworzonego kodu dotyczy weryfikacji poprawności danych.
    Roger L. Costello, *XML Schema Tutorial*
- Cechy DTD:
  - niemal brak kontroli nad tekstową zawartością elementów i wartościami atrybutów,
  - bardzo ogólne metody definiowania częstości wystąpień,
  - mało „obiektowe”, nierozszerzalne modele struktury.

DTD – XML Schema

- Wywodzi się z SGML-a
- Specyficzna składnia
- 10 typów danych
- Brak kontroli tekstowej zawartości elementów
- Typowy mieszany model zawartości

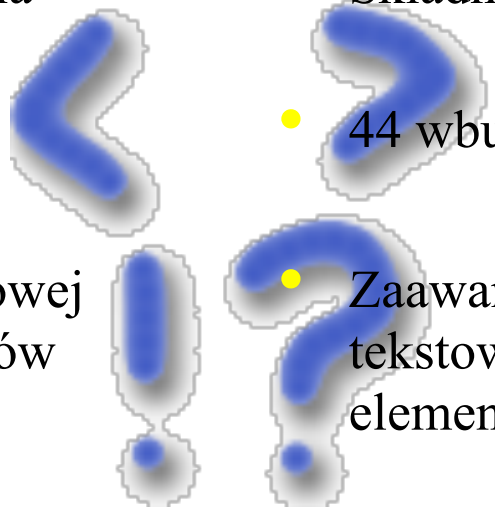

- Zaprojektowany na potrzeby XML-a
- Składnia XML
- 44 wbudowane typy proste
- Zaawansowana kontrola tekstowej zawartości elementów
- Możliwość definiowania własnych typów danych

Status XML Schema

- 15 lutego 1999: Dokument W3C opisujący wymagania stawiane przed nowym formatem:
  - mechanizmy tworzenia struktury,
  - typy proste,
  - reguły przetwarzania.
- 2 maja 2001: XML Schema staje się oficjalną rekomendacją W3C:
  - XML Schema Part 0: Primer,
  - XML Schema Part 1: Structures,
  - XML Schema Part 2: Datatypes.
- Obecnie trwają prace nad wersją 1.1 XML Schema (status: *working draft*).
- Przestrzeń nazw XML Schema: `http://www.w3.org/2001/XMLSchema`

Deklarowanie elementów i atrybutów

```
<xsd:element name="osoba">
  <xsd:complexType>
    <xsd:sequence>
      <xsd:element name="imie" type="xsd:string"/>
      <xsd:element name="nazwisko"
                   type="xsd:string"/>
      <xsd:element name="plec" type="xsd:string"/>
      <xsd:element name="wiek" type="xsd:string"/>
    </xsd:sequence>
    <xsd:attribute name="id" type="xsd:ID"/>
    <xsd:attribute name="NIP" type="NIPTyp"/>
  </xsd:complexType>
</xsd:element>
```

Kontrola użycia elementów i atrybutów

```
<xsd:element name="osoba">
  <xsd:complexType>
    <xsd:sequence>
      <xsd:element name="imie" type="xsd:string"
                   minOccurs="1" maxOccurs="2"/>
      <xsd:element name="nazwisko"
                   type="xsd:string"/>
      <xsd:element name="plec" type="xsd:string"/>
      <xsd:element name="wiek" type="xsd:string"/>
    </xsd:sequence>
    <xsd:attribute name="id" type="xsd:ID"
                   use="required"/>
    <xsd:attribute name="NIP" type="NIPTyp"/>
  </xsd:complexType>
</xsd:element>
```

Typy

- Typy wg zasięgu definicji:
  - typy nazwane,
  - typy anonimowe.
- Typy wg zawartości:
  - typy proste,
  - typy złożone o zawartości:
    - prostej,
    - elementowej,
    - mieszanej,
    - pustej.
- Typy wg pochodzenia:
  - typy wbudowane,
  - typy zdefiniowane w schemacie:
    - rozszerzenia innych typów,
    - ograniczenia innych typów,
    - listy i unie.

Typy nazwane i anonimowe

- Typy nazwane:

```
<xsd:complexType name="OsobaTyp">
  <xsd:sequence>
    <xsd:element name="imie" type="xsd:string"/>
    <xsd:element name="nazwisko" type="xsd:string"/>
  </xsd:sequence>
</xsd:complexType>
<xsd:element name="osoba" type="OsobaTyp"/>
```

- Typy anonimowe:

```
<xsd:element name="osoba">
  <xsd:complexType>
    <xsd:sequence>
      <xsd:element name="imie" type="xsd:string"/>
      <xsd:element name="nazwisko" type="xsd:string"/>
    </xsd:sequence>
  </xsd:complexType>
</xsd:element>
```

Typy proste i złożone

- Typy proste:

```
<xsd:simpleType name="NIPTyp">
  <xsd:restriction base="xsd:string">
    <xsd:pattern value="\d{3}-\d{3}-\d{2}-\d{2}"/>
  </xsd:restriction>
</xsd:simpleType>
```

- Typy złożone:

```
<xsd:complexType name="OsobaTyp">
  <xsd:sequence>
    <xsd:element name="imie" type="xsd:string"/>
    <xsd:element name="nazwisko" type="xsd:string"/>
  </xsd:sequence>
</xsd:complexType>
```

- Element może mieć typ prosty lub złożony.
- Atrybut może mieć wyłącznie typ prosty.

Typy złożone – typy zawartości

- Zawartość elementowa:

```
<osoba PESEL="12345678901">
  <imie>Jan</imie>
  <nazwisko>Kowalski</nazwisko>
</osoba>
```

- Zawartość prosta:

```
<masa jm="kg">10.55</masa>
```

- Zawartość mieszana:

```
<treść>Wypadek dnia <data>13.10.2001 r.</data>
o godzinie <godzina>13:13</godzina>
(<dzien-tygodnia>piątek</dzien-tygodnia>) miał
miejsce nie z mojej winy. <poszkodowany>Alojzy M.</
poszkodowany> nie miał żadnego pomysłu w którą stronę
uciekać, więc go przejechałem.</treść>
```

- Zawartość pusta:

```
<osoba PESEL="12345678901"/>
```

Definiowanie zawartości elementowej

- Grupy deklaracji elementów:
  - `sequence`,
  - `choice`,
  - `all`.
- Zagnieżdżanie grup:

```
<xsd:complexType name="OsobaTyp">
  <xsd:sequence>
    <xsd:element name="imie" type="xsd:string"/>
    <xsd:element ref="nazwisko"/>
    <xsd:choice>
      <xsd:element name="nr-dowodu" type="DowódTyp"/>
      <xsd:element name="nr-paszportu"
                   type="PaszportTyp"/>
    </xsd:choice>
  </xsd:sequence>
</xsd:complexType>
```

Grupa `all` – ograniczenia

- Nie może zawierać innych grup (tylko deklaracje elementów i odwołania do elementów).
- Każdy element może wystąpić co najwyżej raz.
- Grupa `all` nie może być zagnieżdżona w innej grupie.

- Zagnieżdżanie grup:

```
<xsd:complexType name="OsobaTyp">
  <xsd:all>
    <xsd:element name="imie" type="xsd:string"/>
    <xsd:element name="drugie-imie" type="xsd:string"
                 minOccurs="0"/>
    <xsd:element ref="nazwisko"/>
  </xsd:all>
</xsd:complexType>
```

Definiowanie zawartości prostej

```
<xsd:complexType name="MasaTyp">
  <xsd:simpleContent>
    <xsd:extension base="xsd:decimal">
      <xsd:attribute name="jm" type="xsd:string"/>
    </xsd:extension>
  </xsd:simpleContent>
</xsd:complexType>
```

Definiowanie zawartości mieszanej

```
<xsd:complexType name="ZeznanieTyp" mixed="true">
  <xsd:sequence>
    <xsd:element name="data" type="xsd:string"/>
    <xsd:element name="godzina" type="xsd:string"/>
    <xsd:element name="dzien-tygodnia"
                 type="xsd:string"/>
    <xsd:element name="poszkodowany"
                 type="xsd:string"/>
  </xsd:sequence>
</xsd:complexType>
```

Definiowanie zawartości pustej

```
<xsd:complexType name="OsobaTyp">
  <xsd:attribute name="PESEL" type="PESELTyp"/>
</xsd:complexType>
```

Gdzie szukać dalej

- *DTD Tutorial*
  - www.xmlfiles.com/dtd
- Megginson, D., *Structuring XML Documents*, Prentice Hall, 1998

- *W3C Architecture Domain: XML Schema*
  - www.w3.org/XML/Schema
- Costello, R., *XML Schema Tutorial*
  - www.xfront.com/xml-schema.html
- Costello, R., *XML Schemas: Best Practices*
  - www.xfront.com/BestPracticesHomepage.html
- Walmsley, P., *Definitive XML Schema*, Prentice Hall PTR, 2002