# XPath i XQuery

Patryk Czarnik

Instytut Informatyki UW

XML i nowoczesne technologie zarządzania treścią – 2011/12

## XPath i XQuery

- Języki „zapytań” nad dokumentami XML
  - wygodny wybór określonych węzłów dokumentu,
  - intuicyjna składnia („ścieżki” jak w drzewie katalogów),
  - arytmetyka, porównania,
  - bogaty zestaw funkcji.
- XPath stosowany w ramach innych standardów
  - XSLT,
  - XML Schema,
  - XPointer,
  - Document Object Model (moduł XPath).
- XQuery – samodzielny język
  - przetwarzanie/wyciąganie danych z dokumentów XML,
  - XML-owe bazy danych,
  - tradycyjne bazy danych ze wsparciem dla XML,
  - …

## XPath – status

- XPath 1.0 (rekomendacja, listopad 1999)
  - używany m.in. w XSLT 1.0, XML Schema, XPointer.
- XPath 2.0 (kilka rekomendacji, styczeń 2007):
  - *XML Path Language (XPath) 2.0*,
  - *XQuery 1.0 and XPath 2.0 Data Model*,
  - *XQuery 1.0 and XPath 2.0 Functions and Operators*,
  - *XQuery 1.0 and XPath 2.0 Formal Semantics*,
  - używany w XSLT 2.0,
  - związany z XQuery 1.0.

## Model danych XPath i XQuery

- Teoretyczna podstawa standardów XPath, XSLT i XQuery.
- Abstrakcyjna („po wczytaniu”) postać dokumentu XML.
- Typy danych oraz rzutowania między nimi.
- Różny w różnych wersjach XPath:
  - 1.0 – 4 typy danych, zbiory węzłów,
  - 2.0 (oraz XQuery 1.0) – typy proste XML Schema, sekwencje węzłów i wartości prostych.

## Dokument XML w modelu XPath

- Dokument jako drzewo.
- Uwzględnianie przestrzeni nazw.
- Możliwość uwzględniania schematu (w wersji 2.0).
- Rozwinięte sekcje CDATA oraz referencje do encji i znaków.
- Brak sąsiadujących węzłów tekstowych.
- Atrybut nie jest dzieckiem elementu.
- Korzeń, zwany także „węzłem dokumentu”, jest osobnym węzłem, różnym od elementu głównego.

# Rodzaje węzłów w XPath

- Rodzaje węzłów:
  - węzeł dokumentu (korzeń),
  - element,
  - atrybut,
  - węzeł tekstowy,
  - instrukcja przetwarzania,
  - komentarz,
  - węzeł przestrzeni nazw.
- Brak m.in.:
  - sekcji CDATA,
  - encji i referencji do encji.

# Drzewo dokumentu – przykład

```
<?xml version="1.0"?>
<?xml-stylesheet type="text/css" href="st.css"?>
<doc>
  <p id="P01" pierwszy="tak">Ala ma <![CDATA[kota]]></p>
  <p id="P02">Ola <em>miała</em> psa</p>
</doc>
<!-- Data modyfikacji: 2011-11-21 -->
```

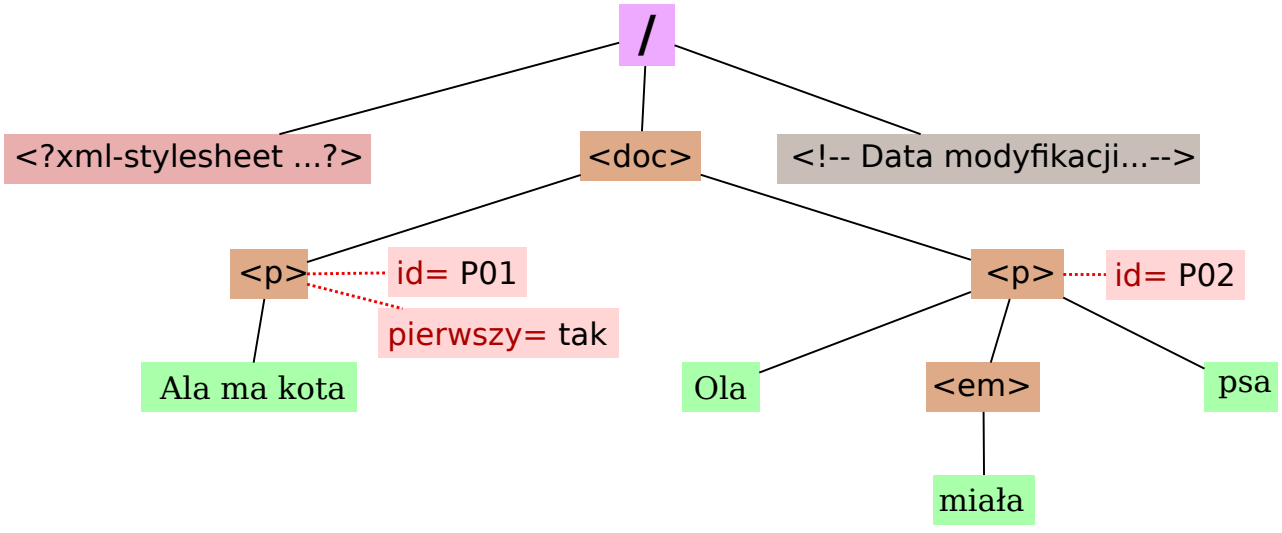

## Sekwencje

- Wartości w XPath 2.0 – sekwencje.
- Elementy (*items*) sekwencji:
  - węzły (z drzew dokumentów),
  - wartości atomowe.
- Równoważność elementu i jednoelementowej sekwencji:
  `3.14 = (3.14)`
- Spłaszczanie zagnieżdżonych sekwencji:
  `(3.14, (1, 2, 3), 'Ala') = (3.14, 1, 2, 3, 'Ala')`

## System typów

- Typy predefiniowane XML Schema.
- Typy dla węzłów poszczególnych rodzajów.
- Dodatkowo:
  - `xs:untyped`
  - `xs:untypedAtomic`
  - `xs:anyAtomicType`
  - `xs:dayTimeDuration`
  - `xs:yearMonthDuration`
- Możliwość używania zdefiniowanych w schemacie (prostych i złożonych), a także innych typów wyprowadzonych
  - o ile przetwarzanie *schema aware*,
  - nie zawsze dostępne.

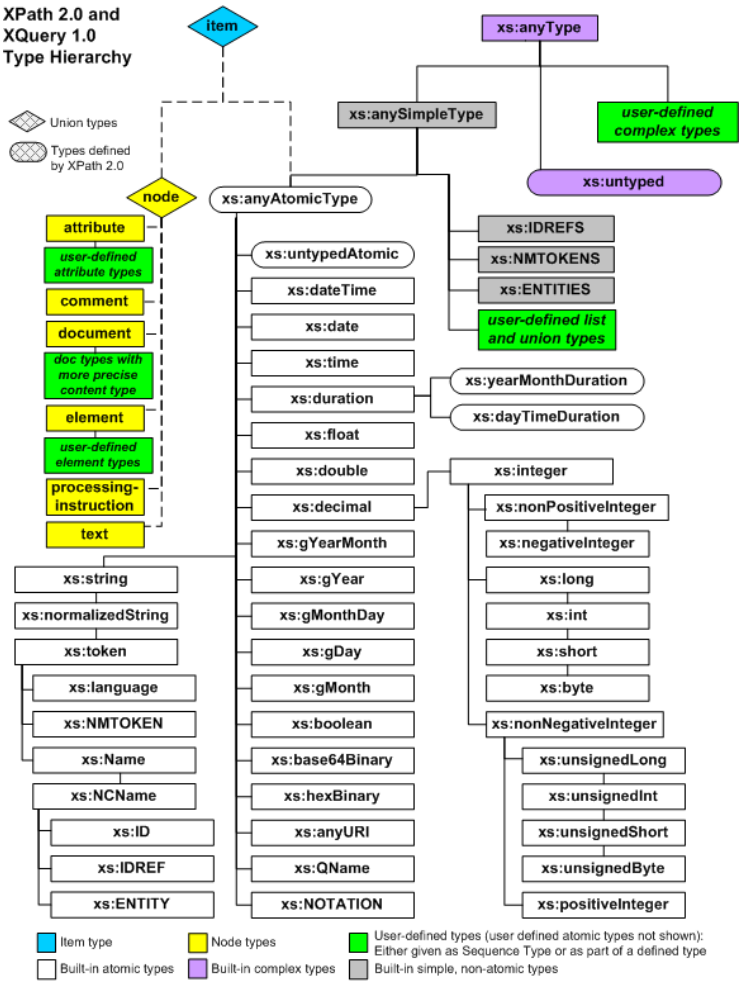


# XPath 1.0 – różnice w modelu danych

- Typy proste:
  - `boolean`,
  - `string`,
  - `number`.
- Jeden typ dla węzłów:
  - `node set`,
  - w XSLT 1.0 dodatkowo `result tree fragment` – ta sama natura, ale ograniczenia w użyciu.
- Brak zbiorów wartości prostych.
- Zbiory (a nie sekwencje) węzłów.

# Operacje związane z modelem danych XPath

- Rzutowania pomiędzy typami.
- *Effective Boolean Value* – zamiana dowolnej wartości (w tym węzłów) na wartość logiczną
  - tu podana definicja dla XPath 2.0,
  - analogiczna, ale prostsza, także dla XPath 1.0.
- Atomizacja – zamiana dowolnej sekwencji (w tym węzłów) na sekwencję wartości prostych
  - specyficzna dla XPath 2.0.

# *Effective Boolean Value*

- Częsta potrzeba traktowania dowolnej wartości jako wartości logicznej.
- Zasady zamiany:

| | | |
|---|---|---|
| pusta sekwencja | → | **fałsz** |
| sekwencja z węzłem na pierwszej pozycji | → | **prawda** |
| pojedyncza wartość logiczna | → | ta sama wartość |
| pojedynczy pusty napis | → | **fałsz** |
| pojedynczy niepusty napis | → | **prawda** |
| pojedyncza liczba równa 0 lub NaN | → | **fałsz** |
| inna pojedyncza liczba | → | **prawda** |
| inna wartość | → | błąd typu |

# Atomizacja

- Operacja służąca traktowaniu dowolnej sekwencji jako sekwencji wartości prostych.
- Nie zawsze wykonalna (możliwy błąd typów).
- Dla każdego elementu sekwencji:

| | | |
|---|---|---|
| wartość atomowa | → | ta wartość |
| węzeł o (znanym) typie atomowym | → | wartość węzła |
| węzeł typu lista | → | sekwencja elementów listy |
| węzeł nieznanego typu prostego, z mieszaną zawartością lub typu `xs:untypedAtomic` lub `xs:anySimpleType` | → | zawartość tekstowa jako jeden atom |
| element o zawartości elementowej | → | błąd typu |

# Literały i zmienne

## Literały

- napisy: `'12.5'`, `"He said, ""I don't like it."""`
- liczby: `12`, `12.5`, `1.13e-8`

## Zmienne

- `$x` – referencja do zmiennej o nazwie `x`,
- zmienne wprowadzane konstrukcjami:
  - XPath 2.0 (`for`, `some`, `every`)
  - XQuery (FLWOR, `some`, `every`, parametry funkcji)
  - XSLT 1.0 i 2.0 (`variable`, `param`)

# Rzutowanie typów

## Konstruktory typów

- `xs:date("2001-08-25")`
- `xs:float("NaN")`
- `adresy:kod-pocztowy("48-200")` (o ile schemat dostępny)
- `string(//obiekt[4])` (także w XPath 1.0)

## Operator `cast as`

- `"2001-08-25" cast as xs:date`
- ...

# Funkcje

- Wywołania funkcji:
  - `fn:concat('Pani ', imię, ' ', nazwisko)`
  - `count(//obiekt/@parzysty)`
  - `moje:silnia(12)`
- 150 standardowych funkcji XPath 2.0:
  - w przestrzeni nazw *http://www.w3.org/2005/xpath-functions*,
  - domyślna przestrzeń nazw dla funkcji.
- Definiowanie własnych funkcji
  (zalecane w osobnej przestrzeni nazw):
  - w XQuery,
  - w XSLT (2.0),
  - w środowisku wykonania,
- EXSLT (`http://www.exslt.org/`)
  - rozszerzenie dostępne w wielu implementachach XSLT/XPath 1.0, m.in. Xalan,
  - zestaw dodatkowych funkcji,
  - sposób definiowania własnych funkcji.

# Wybrane funkcje XPath

## Napisy

concat(s1, s2, ...) substring(s, pos, len)
starts-with(s1, s2) contains(s1, s2)
string-length(s) translate(s, t1, t2)

## Liczby

floor(x) ceiling(x)
round(x) abs(x)

## Węzły

name(n?) local-name(n?) namespace-uri(n?)
id(s) nilled(n?) document-uri(doc)

## Kontekst

current() position()
last() current-time()

## Sekwencje

count(S) sum(S) min(S) max(S) avg(S)
empty(S) reverse(S) distinct-values(S)

## Data i czas

month-from-date(t)
adjust-date-to-timezone(t, tz)

# Operatory

- 68 operatorów XPath 2.0 (mniej symboli, ale przeciążona notacja).
- Arytmetyka:
  - `+ - * div idiv mod`
  - na datach i *duration*: + i − zgodnie z typami.
- Sekwencje węzłów (w 1.0 „zbiory węzłów”):
  - `| union intersect except`
  - nie-węzły w sekwencjach – błąd typu,
  - wynik: sekwencja bez powtórzeń, porządek dokumentu.
- Wartości logiczne:
  - operatory `and or`
  - `true()`, `false()`, `not(_)` to funkcje.

# Operatory porównania

## Porównania atomowe (tylko XPath 2.0)

- `eq  ne  lt  le  gt  ge`
- na wstępie argumenty poddane atomizacji
- jeden z argumentów sekwencją pustą → wynik sekwencją pustą
- jeden z argumentów sekwencją wieloelementową → błąd typów,
- typy atomowe – intuicyjnie „normalne” porównanie, o ile typy pozwalają.

## Porównania ogólne (XPath 1.0 i 2.0)

- `=  !=  <  <=  >  >=`
- Stosowane do sekwencji.
- *Istnieje para elementów z lewej i prawej sekwencji, dla której zachodzi odpowiednia relacja na atomach.*

# Porównania ogólne – ciekawostki

- (Nie)Równość nie jest (nie)równością sekwencji.
- Równość nie jest przechodnia.
- $x$ `!=` $y$ nie jest równoważne `not(`$x$ `=` $y$`)`.

## Przykładowe porównania

```
<osoby> <osoba>Ala</osoba> <osoba>Ola</osoba> </osoby>
```

- `osoby/osoba = 'Ala'`
  jest prawdą, bo jeden z elementów jest równy Ala
- `osoby/osoba = 'Ola'`
  także jest prawdą, bo jeden z elementów jest równy Ola
- `osoby/osoba != 'Ola'`
  jest prawdą, bo jeden z elementów jest różny od Ola
- `not(osoby/osoba = 'Ewa')`
  jest prawdą, bo że żaden element nie jest równy Ewa

# Wyrażenie warunkowe (XPath 2.0)

```
if WARUNEK
  then WYNIK1
  else WYNIK2
```

- Liczy się *Effective Boolean Value*.
- Obliczana tylko jedna gałąź.

## Przykład

```
if informacje/cena
then
  if informacje/cena >= 1000
  then 'Przesyłka wartościowa'
  else 'Przesyłka zwykła'
else 'Brak danych'
```

# Pętla po sekwencji (XPath 2.0)

```
for $ZMIENNA in SEKWENCJA
return WYNIK
```

- *ZMIENNEJ* przypisywane kolejne wartości z *SEKWENCJI*,
- *WYNIK* obliczany z wybraną wartością *ZMIENNEJ*,
- wynik całości – sekwencja wyników częściowych.

## Przykłady

```
for $i in (1 to 10)
  return $i * $i

for $o in //obiekt
  return concat('Nazwa obiektu:', $o/@nazwa)
```

# Kwantyfikatory (XPath 2.0)

```
some $ZMIENNA in SEKWENCJA
satisfies WARUNEK

every $ZMIENNA in SEKWENCJA
satisfies WARUNEK
```

- Liczy się *Effective Boolean Value*.
- Możliwa leniwa ewaluacja.
- Dowolna kolejność przechodzenia po sekwencji.

## Przykłady

```
some $i in (1 to 10)  satisfies $i > 7

every $o in //obiekt  satisfies $o/@nazwa
```

# Ścieżki w XPath

## Ścieżka bezwzględna

`/krok/krok ...`

## Ścieżka względna

`krok/krok ...`

## Krok – składnia w pełni rozwinięta

`oś::test-węzłów [predykat1] [predykat2] ...`

- *oś* – kierunek w drzewie dokumentu,
- *test-węzłów* – wybór węzłów po rodzaju, typie, nazwie,
- *predykat* – opcjonalny, dodatkowo filtrujący węzły.

## Przykład

```
/descendant::oddział[attribute::id = 'ksi']/child::pracownik[1]
                                  /child::nazwisko/child::text()
```

# Osie

- child
- descendant
- parent
- ancestor
- following-sibling
- preceding-sibling
- following
- preceding
- attribute
- namespace
- self
- descendand-or-self
- ancestor-or-self

# Osie

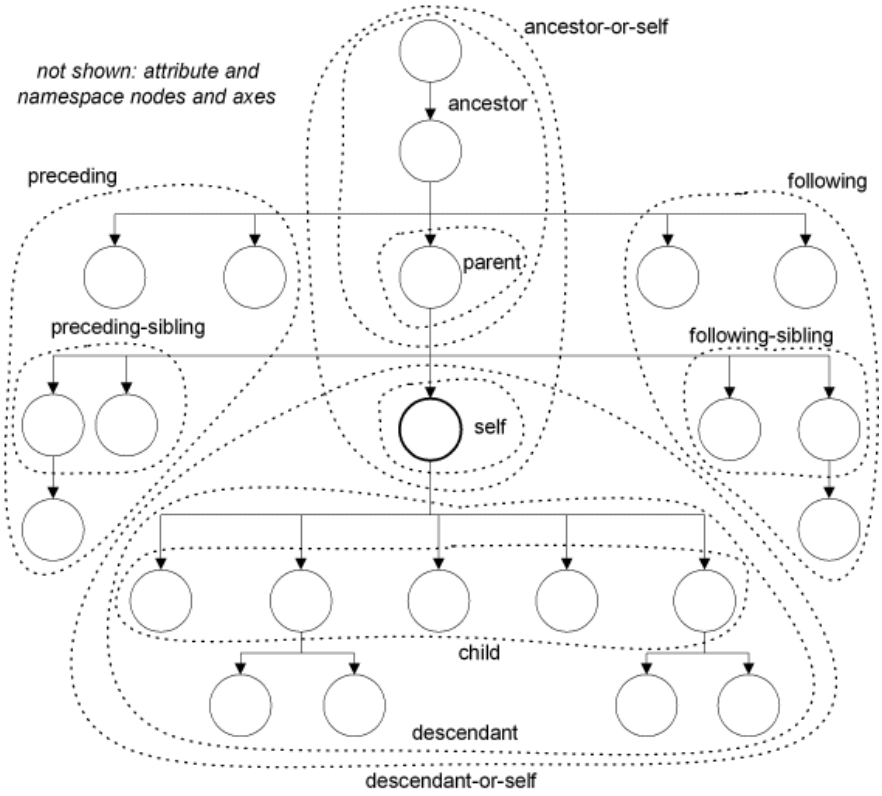

# Testy węzłów w XPath 1.0

## Rodzaj węzła

- `node()`
- `text()`
- `comment()`
- `processing-instruction()`
- `processing-instruction(xml-stylesheet)`

## Nazwa węzła (elementu bądź atrybutu, zależnie od osi)

- `pracownik`
- `*`
- `pre:pracownik`
- `pre:*`
- `*:pracownik` (tylko XPath 2.0)

# Dodatkowe testy węzłów w XPath 2.0

## W XPath 2.0 dodatkowo

- `document-node()`
- `element()`
- `element(pracownik)`
- `element(*, osobaTyp)`
- `element(pracownik, osobaTyp)`
- `attribute()`
- `attribute(id)`
- `attribute(*, xs:integer)`
- `attribute(id, xs:integer)`

# Predykaty

- Obliczane dla każdego węzła
  (węzeł na chwilę staje się węzłem kontekstowym).
- Każdy predykat „przesiewa” sekwencję.
- W zależności od typu wyniku predykatu:
  - liczba – porównywana z pozycją węzła w sekwencji (od 1),
  - nie liczba – decyduje *Effective Boolean Value*.
- Możliwe użycie poza ścieżkami (tzw. *filter expressions*).

## Przykłady

```
/child::oddział/child::pracownik[child::imię = 'Patryk']

child::pracownik[child::imię = 'Patryk']/child::nazwisko

//*[attribute::xlink:href][3]

(1 to 10)[. mod 2 = 0]
```

# Skróty składniowe

- Oś `child` można pominąć.
- `@` przed nazwą zamiast osi `attribute`.
- `.` zamiast `self::node()`.
- `..` zamiast `parent::node()`.
- `//` zamiast `/descendant-or-self::node()/`.

## Przykład

```
.//obiekt[@id = 'E4']

self::node()/descendant-or-self::node()/
                          child::obiekt[attribute::id = 'E4']
```

## Sposób obliczania ścieżek

- Ścieżki obliczane od lewej do prawej.
- Dla każdego węzła z bieżącej sekwencji obliczany kolejny krok (wraz z predykatami).
  - `//oddział/pracownik[1]`
  - `(//oddział/pracownik)[1]`
- Po każdym predykacie zbierana cała sekwencja, przekazywana do kolejnego predykatu (zmiana kontekstu).
  - `//pracownik[@kierownik and position() = 5]`
  - `//pracownik[@kierownik][position() = 5]`

## Różnice w XPath 1.0 – podsumowanie

- Prostszy model danych:
  - 3 + 1 typy danych zamiast typów XML Schema,
  - zbiory węzłów zamiast sekwencji wszystkiego.
- Brak wyrażenia `if`.
- Brak wyrażeń `for`, `some`, `every`.
- Brak porównań atomowych i `is`.
- Mniej testów węzłów.
- Mniej standardowych funkcji.

# XQuery – język zapytań nad XML

## Status

- XQuery 1.0 – rekomendacja (styczeń 2007).

## Niektóre możliwości

- Wyciąganie danych z dokumentów XML.
- Sortowanie, grupowanie, przetwarzanie, ...
- Zapis wyniku jak w XSLT (XML / HTML / tekst).
- Konstruowanie nowych węzłów.
- Definiowanie własnych funkcji.

## XQuery a XPath

- Model danych, funkcje – wspólne z XPath 2.0.
- Język zdefiniowany niezależnie, ale w praktyce rozszerzenie XPath 2.0.

# Struktura zapytania XQuery

- Deklaracje i ciało.
- Deklaracje:
  - wersja (nagłówek zapytania / modułu),
  - import,
  - flagi i opcje (np. serializacji),
  - przestrzeń nazw,
  - zmienna / parametr całego zapytania,
  - funkcja.

## Przykład

```
xquery version "1.0" encoding "utf-8";

declare namespace foo = "http://example.org";
declare variable $id as xs:string external;
declare variable $doc := doc("przyklad.xml");

$doc//foo:obiekt[@id = $id]
```

# Wyrażenie FLWOR

- Od *For, Let, Where, Order by, Return*.
- Zamiast `for` z XPath.
- Jak `SELECT` w SQL.

## Przykład

```
for $obiekt in doc("przyklad.xml")/lista/obiekt
  let $pop := $obiekt/preceding-sibling::element()
  let $nazwa-pop1 := $pop[1]/@nazwa
  where $obiekt/@nazwa
  order by $obiekt/@nazwa
  return
    <wynik>
      Obiekt o nazwie {xs:string($obiekt/@nazwa)}
      ma {count($pop)} poprzedników.
      Najbliższym poprzednikiem jest obiekt o nazwie
      {xs:string($nazwa-pop1)}.
    </wynik>
```

# Konstruktory węzłów – bezpośrednie (*direct*)

## Stały element wynikiem zapytania

```
<book isbn="isbn-0060229357">
  <title>Harold and the Purple Crayon</title>
  <author>
    <first>Crockett</first><last>Johnson</last>
    <?cel Wartość?>
    <!--Wszystko jest brane do wyniku-->
  </author>
</book>
```

## Konstruktory i wyrażenia – nawiasy klamrowe

```
<wynik>{
  for $el in doc("przyklad.xml")//* return
    <elem głębokość="{count($el/ancestor::node())}">
      Element o nazwie: {name($el)}</elem>
}</wynik>
```

# Konstruktory węzłów – obliczane (*computed*)

## Ilustracja składni

```
element book {
   attribute isbn {"isbn-0060229357"},
   element {"title"} { "Harold and the Purple Crayon"},
   element author {
      element first { text { "Crockett" } },
      element last {"Johnson" }
      processing-instruction cel { "Wartość" }
      commment { "Wszystko jest brane do wyniku" }
}   }
```

## Przykład zastosowania – nazwa elementu nadawana dynamicznie

```
<wynik>{
  for $el in doc("przyklad.xml")//* return
    element {concat("elem-", name($el))} {
      attribute głębokość {count($el/ancestor::node())},
      text {"Element o nazwie: "},
      text {name($el)}
}    }
</wynik>
```

# Definicje funkcji

## Przykład

```
declare function
  local:podwoj($x)
{ 2 * $x };
```

## Przykład ze specyfikacją typów

```
declare function
  local:podwoj($x as xs:double)
  as xs:double
{ 2 * $x };
```

# Notacja dla typów

- Informacje o typie możliwe (ale nieobowiązkowe) dla:
  - zmiennych,
  - parametrów i wyników funkcji,
  - także w XSLT 2.0.
- Możliwości:
  - nazwa typu,
  - rodzaj węzła `|node()|item()`,
  - określenie krotności (`?`, `*`, `+`, brak – dokładnie jeden).
- Przykłady:
  - `xs:double`
  - `element()`
  - `node()*`
  - `xs:integer?`
  - `item()+`