INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Realizováno za finanční podpory ESF a státního rozpočtu ČR v rámci v projektu *Zkvalitnění a rozšíření možností studia na TUL pro studenty se SVP* reg. č. CZ.1.07/2.2.00/29.0011

Strom dokumentu

XML strom

- textový soubor je *zápisem* datového souboru
- zpracovávající software si zpravidla staví strom odpovídající XML datům – interní reprezentace odrážející vzájemné vztahy prvků
- výhodné pro posuzování struktury a manipulaci s ní

Příklad: XML dokument...

```
<?xml version="1.0" encoding="UTF-8"?>

<diskoteka>

<disk id="d1">
    <interpret>Divokej Bill</interpret>
    <nazev>Propustka do pekel</nazev>
</disk>

<disk id="d2">
    <interpret>AC/DC</interpret>
    <nazev>Highway to Hell</nazev>
</disk>

</diskoteka>
```

...a jeho strom

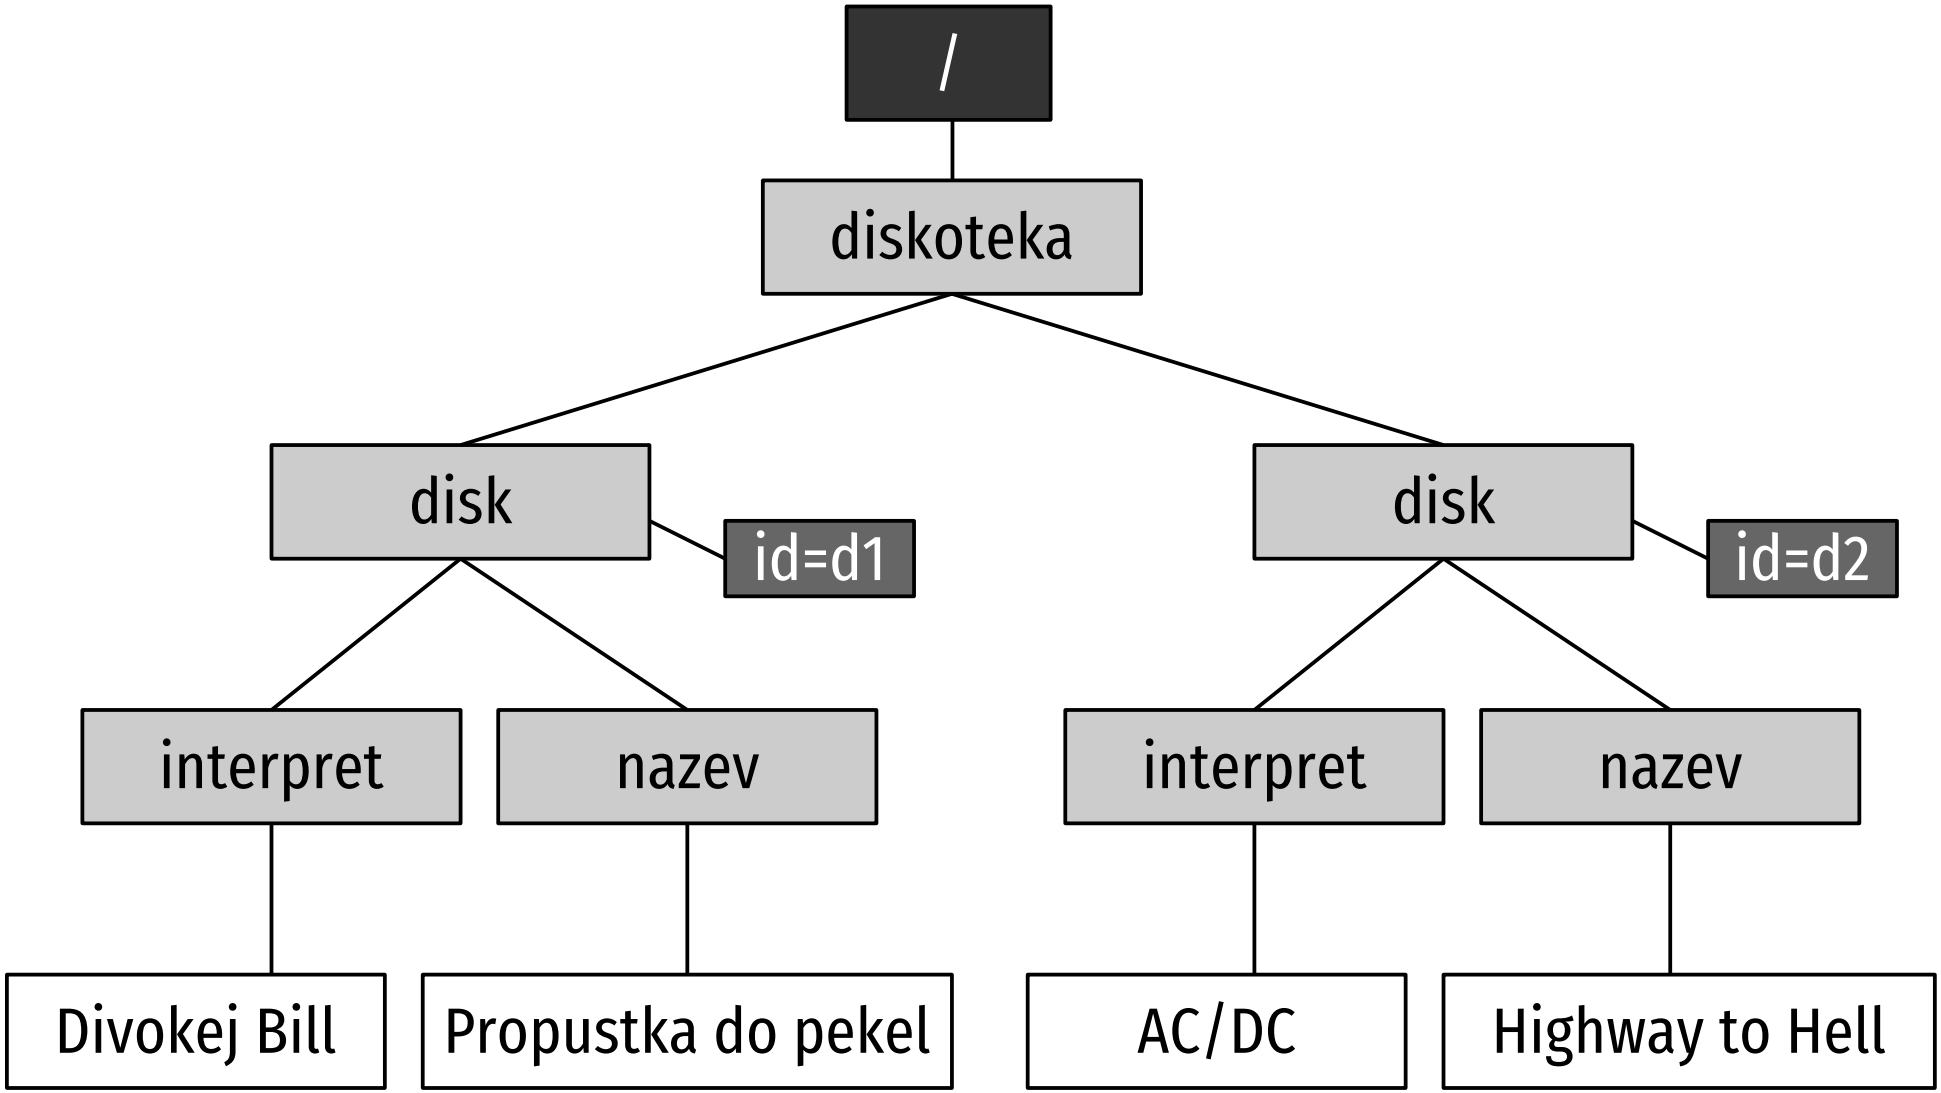
/
diskoteka
disk
id=d1
disk
id=d2
interpret
nazev
interpret
nazev
Divokej Bill
Propustka do pekel
AC/DC
Highway to Hell

Typy uzlů

- **kořen** – uměle přidaný
- **prvek** – odpovídají prvkům dokumentu
- **text** – textový obsah, bezejmenné, vždy listové
- **atribut** – připojen k prvku, který jej nese (ten je jeho rodičem, ale atribut není považován za dítě)
- **jmenný prostor** – název=prefix, dědí se
- **instrukce pro zpracování** – názvem je její cíl
- **komentář** – bezejmenný

Vztahy prvků

- **A je předkem B, B je potomkem A:**
  - B je obsažen v A
- **A je rodičem B, B je dítětem A:**
  - B je přímo obsažen v A (je ve struktuře právě o jednu úroveň níže)
  - rodič je vždy právě jeden
- **A je sourozencem B:**
  - mají stejného rodiče

XPath

XPath

- nástroj pro vyhledávání informací v XML dokumentech – identifikaci uzlů a jejich skupin ve stromě (prvků, atributů,...)
- řada (více než sto) vestavěných funkcí
- není samostatný jazyk
  - definuje syntax výrazů
  - používány jako součást dalších mechanismů (zejména XSLT, XQuery)

XPath

- nemá XML syntaxi
  - nepotřebuje – typicky tvoří hodnotu atributu
  - připomíná cestu v systému souborů
- **výsledkem** XPath výrazu je hodnota nebo skupina uzlů XML stromu vyhovujících podmínkám
- interpretace začíná ve **výchozím uzlu**
  - může/nemusí být kořen
  - typicky identifikuje uzly relativně vůči výchozímu

XPath cesta

- **XPath cesta** je sekvencí kroků, oddělovány lomítky
  - *krok1/krok2/.....*
- každý **krok** může mít tři části
  - **identifikátor osy** – směr procházení, výchozí množina
  - **test uzlu** – kterých uzlů se týká, povinná část
  - **podmínka (predikát)** – zužuje výsledky předchozího výběru
  - plný tvar: *osa::uzel[podmínka]*

Vyhodnocení cesty

- každý krok se vyhodnocuje v určitém **kontextu** – vychází se z konkrétního uzlu
  - první krok: z aktuálního nebo kořenového uzlu
  - další kroky: z uzlů vybraných předchozím krokem (postupně pro každý z nich)
- části kroku postupně omezují množinu vyhovujících uzlů: osa vybere základní množinu, test uzlu z ní vybere jen některé a případné podmínky ponechají jen ty, jež jim vyhovují

Oddělování kroků

- **znak /**
  - prostý oddělovač
  - díky implicitní ose child:: se další krok typicky týká dětí uzlů vybraných předchozím krokem
  - na začátku cesty: absolutní cesta, začíná v kořeni
- **dvojice //**
  - mezi uzly se může nacházet libovolný počet mezilehlých
  - na začátku cesty: začíná se v kořeni, první prvek může být libovolně hluboko, trvá tak báječně dlouho…

Vybírání uzlů podle názvu

- nejjednodušší je uvést jméno prvku
  - nazev – nazev jako dítě aktuálního uzlu
- často požadujeme prvek v určitém kontextu, vyjádřen sekvencí kroků s příslušnými oddělovači
  - /diskoteka/disk/nazev
  - /diskoteka//nazev – nazev kdekoli uvnitř diskoteka
  - //nazev – nazev kdekoli v dokumentu
- * – vyhoví libovolný prvek

Vybírání uzlů podle typu

- lze požadovat libovolný uzel zadaného typu
- nezáleží na jménu, jen na charakteru
- dostupné typy:
  - text() – textový uzel, např. nazev/text()
  - comment() – uzel s komentářem
  - processing-instruction() – instrukce pro zpracování, v závorkách lze uvést i její požadované jméno
  - node() – libovolný uzel

Osy a podmínky

Identifikátor osy (1)

- child:: děti aktuálního uzlu, implicitní osa
- descendant:: všichni potomci aktuálního uzlu
- descendant-or-self:: uzel sám a jeho potomci
- parent:: rodič aktuálního uzlu
- ancestor:: všichni předci aktuálního uzlu
- ancestor-or-self:: uzel sám a jeho předci
- self:: sám aktuální uzel

Identifikátor osy (2)

- following-sibling:: následující sourozenci uzlu
- preceding-sibling:: předchozí sourozenci uzlu
- following:: uzly následující v dokumentu za aktuálním uzlem, kromě jeho potomků
- preceding:: uzly předcházející v dokumentu před aktuálním uzlem, kromě jeho předků
- attribute:: atributy aktuálního uzlu
- namespace:: jmenné prostory aktuálního uzlu

Rozdělení dokumentu

- osy
  - self
  - ancestor
  - preceding
  - descendant
  - following

  rozdělují dokument na pět navzájem disjunktních částí a kompletně jej pokrývají
- nezahrnují atributy a jmenné prostory

Příklad rozdělení

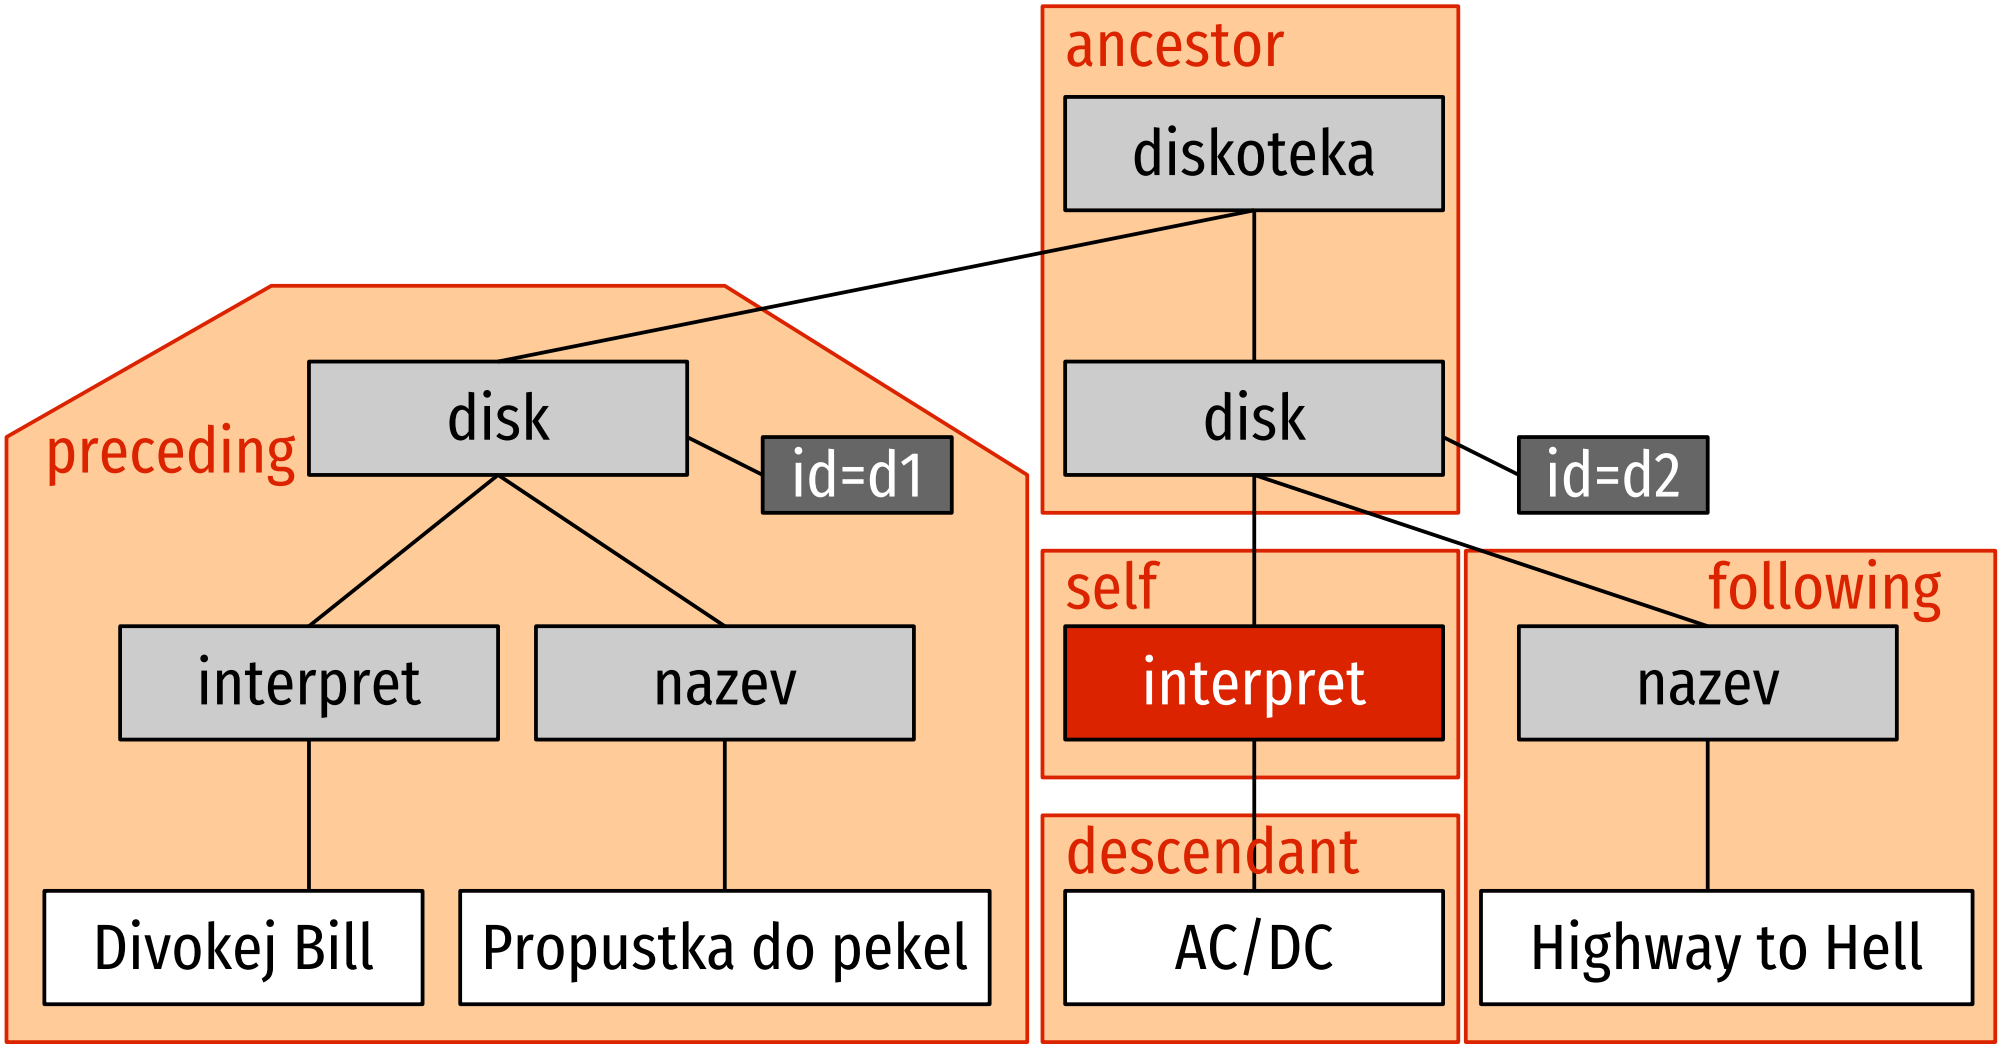

Zkratky

- **.** aktuální uzel self::node()
  .//nazev názvy, které jsou potomky akt. uzlu
- **..** rodič parent::node()
  ../interpret interpret jako sourozenec
- **@** atribut attribute::
  ../@id rodičův atribut id
  @* všechny atributy aktuálního prvku
- **//** lib. část cesty /descendant-or-self::node()/
  //@id/.. všechny prvky obsahující atribut id

Podmínky

- v hranatých závorkách za testem uzlu
- [*n*]*n*-tý uzel v množině
  - *[3] … třetí dítě aktuálního prvku
  - (//nazev)[2] … druhý nazev v dokumentu
  - following::*[1] … první prvek následující za aktuálním
  - osy mířící zpět (ancestor, preceding,…) číslují odzadu
    preceding::*[1] … nejbližší předchozí prvek
- častou podmínkou je hodnota atributu
  - //disk[@medium=“dvd“]

Funkce

Funkce (1)

- position() … číslo
  - pozice (pořadí, číslováno od 1) aktuálního uzlu v množině
  - [3] je zkratka za [position()=3]
- last() … číslo
  - pozice posledního uzlu v množině
- count(*množina_uzlů*) … číslo
  - počet uzlů v dané množině

Funkce (2)

- id(*objekt*) … množina uzlů
  - vydá uzel nesoucí daný identifikátor
  - id(“d1“) … prvek s identifikátorem „d1“
  - id(“d1“)/nazev … jeho název
- name(*množina_uzlů?*) … řetězec
  local-name(*množina_uzlů?*) … řetězec
  namespace-uri(*množina_uzlů?*) … řetězec
  - vydají kvalifikované jméno, lokální jméno a URI jmenného prostoru daného (aktuálního) uzlu

Řetězcové funkce (1)

- string(*objekt?*) … řetězec
  - převede svůj argument na řetězec znaků
  - prvky typicky převedeny na svůj textový obsah
  - neexistující hodnota: NaN; nekonečno: Infinity (–Infinity)
- concat(*řetězec1, řetězec2,…*) … řetězec
  - spojí (zřetězí) své argumenty
- string-length(*řetězec*) … číslo
  - počet znaků v řetězci

Hledání řetězců

- contains(*kde*, *co*) … boolean
  - vydá true, pokud je řetězec *co* obsažen v řetězci *kde*
- starts-with(*kde*, *co*) … boolean
  - vydá true, pokud řetězec *kde* začíná podřetězcem *co*
- substring-before(*kde*, *co*) … řetězec
  substring-after(*kde*, *co*) … řetězec
  - vydá část řetězce *kde* před/za prvním výskytem řetězce *co* v něm; prázdný řetězec, pokud *kde* neobsahuje *co*

Řetězcové funkce (2)

- substring(*řetězec, začátek, počet_znaků?*) … řetězec
  - vydá část řetězce začínající daným znakem a obsahující zadaný počet znaků (až do konce, pokud chybí)
- normalize-space(*řetězec?*) … řetězec
  - vrátí řetězec s normalizovaným volným místem
- translate(*kde, vzor, náhrada*) … řetězec
  - v řetězci *kde* změní znaky ze *vzoru* za *nahrazující* znaky
  - nahrazují se znaky, ne řetězce (viz tr z Unixu)

Logické funkce

- boolean(*objekt*) ... boolean
  - konverze (false=NaN, 0, prázdný řet. a prázdná množina)
- true(), false()
- lang(*řetězec*) .. boolean
  - má aktuální uzel atribut xml:lang s hodnotou odpovídající zadanému *řetězci*?
  - např. lang(“en“) pro .. je true
- not(*boolean*) ... boolean
- operátory (ne funkce) and a or

Číselné funkce

- number(*objekt?*) … číslo
  - řetězec: přeskočí počáteční mezery, pokud následuje zápis čísla, výsledkem je toto číslo; jinak NaN
  - boolean: true=1, false=0
  - množina uzlů: převede se na řetězec voláním string()
- sum(*množina_uzlů*) … číslo
  - uzly se převedou na čísla a následně sečtou

Aritmetické a relační operátory

- standardní sada aritmetických operací
  - +, −, * v obvyklých významech
  - div je dělení *reálných* čísel (v plovoucí desetinné čárce)
  - mod je zbytek po celočíselném dělení
- obvyklé relační operátory
  - =, !=
  - >, >=, <, <=

Zaokrouhlovací funkce

- round(*číslo*) … číslo
  - nejbližší celé číslo
- floor(*číslo*) … číslo
  - nejbližší nižší celé číslo
- ceiling(*číslo*) … číslo
  - nejbližší vyšší celé číslo

Složitější podmínky

- podmínek může být několik
  - //disk[@medium="dvd"][5] ... páté DVD v dokumentu
  - vyhodnocují se zleva doprava
- podmínka se nemusí nutně vztahovat přímo k aktuálnímu uzlu
  - //disk[.//nazev] ... všechny prvky disk obsahující (libovolně hluboko zanořený) nazev
  - //nazev[../interpret] ... všechny prvky nazev, které mají sourozence interpret

Kombinování XPath výrazů

- | v obvyklé roli „nebo“
  - výsledek je sjednocením množin uzlů vybraných jednotlivými výrazy
  - //interpret | //nazev ... všechny prvky interpret a nazev
  - pro hodnoty atributů je zpravidla vhodnější použít or: //cena[@jednotka=“EUR“ or @jednotka=“USD“] versus //cena[@jednotka=“EUR“] | //cena[@jednotka=“USD“]

Další vývoj

XPath 2.0

- vyvíjeno společně s XQuery 1.0
- **podpora typů** – základní jednoduché typy podle XML Schema (19 typů) plus uzly
- každá hodnota má 2 složky:
  - vlastní hodnotu
  - typ
- **vše je sekvence**

Sekvence

- libovolně dlouhá posloupnost obsahující atomické hodnoty a uzly
  - záleží na pořadí
  - může obsahovat duplicity
- **uzel nebo atomická hodnota je ekvivalentní jednoprvkové sekvenci obsahující tuto položku**
- sekvence jsou jednoúrovňové
  - při vnoření se zploští – (1, (2, 3)) se převede na (1, 2, 3)

Složité výrazy

- **for cyklus:**
  for $cd in //disk return $cd/nazev
- **podmíněný výraz:**
  if (count(//disk)>100) then "moc" else "málo"
- **kvantifikátory:**
  some $cd in //disk satisfies $cd/nazev="Cosi"
  every $cd in //disk satisfies $cd/nazev="Cosi"

XPath 3.0

- standardizováno 2014
- plný funkcionální jazyk
  - funkce je hodnota jako každá jiná
  - může být argumentem a/nebo výsledkem jiné funkce
  - více o funkcionálních jazycích viz *Alternativní metody programování*

XPath 3.1

- standardizováno 2017
- přidána podpora polí a asociativních polí (map)