4IZ440 Propojená data na webu

Odvozování v RDFS

Vyučující: prof. Ing. Vojtěch Svátek, Dr.

Zimní semestr 2019

http://nb.vse.cz/~svatek/rzzw.html

Odvozování

- Odvozování (inference) není jen záležitostí úzkého okruhu systému umělé inteligence, např. expertních systémů
- I v systémech spravujících „běžná data“ může odvozování na straně zdrojových dat být náhradou za sofistikovanou tvorbu dotazů
  - Typicky jednoduché, deterministické, monotónní odvozování bez neurčitosti
- V sémantickém webu přichází odvozování
  - v menší míře s jazykem RDFS
  - v rozsáhlé míře s jazykem OWL, případně pravidlovými jazyky nad ním (SWRL, RIF)

Specifika odvozování na webu

- Předpoklad otevřeného světa
- Neunikátnost identifikátorů

Předpoklad otevřeného světa

- „Open-world assumption“ (OWA)
- Lze vyjádřit zhruba takto:
  v situaci kdy nevíme, jestli je nějaké tvrzení pravdivé, s ním nemůžeme pracovat tak, jako kdyby bylo nepravdivé
  - Opakem je předpoklad uzavřeného světa (CWA), běžně používaný v databázových systémech
- Na webu musíme téměř vždy předpokládat existenci relevantních tvrzení (a objektů), o kterých jen zatím nevíme

Neunikátnost identifikátorů

- Neplatí tzv. UNA (unique name assumption), tj. stejný zdroj může na sémantickém webu existovat pod různými identifikátory
- Dodatečně lze zdroje prohlásit za totožné
  - Jedna z nejdůležitějších operací v linked data

OWA a non-UNA v odvozování

- A: Jan má syna Karla.
- B: Jan má syna Hynka.
- Otázka: Co víme o tom, kolik má Jan synů?“

OWA a non-UNA v odvozování

- A: Jan má syna Karla.
- B: Jan má syna Hynka.
- Otázka: Co víme o tom, kolik má Jan synů?“

  Nejméně jednoho!
  - Možná i více než 2, jen o nich nevíme (OWA)
  - Možná jen jednoho se dvěma jmény (non-UNA)

K tomu ještě: princip AAA

- „Anyone can say Anything about Any topic“
  - Distribuovaná tvorba a zpracování dat
  - Absence kontroly nad přidávaným obsahem
- Vede k dostupnosti informací reflektujících
  - Rozporný postoj („Pluto pro astronomy a astrology“)
  - Úmyslný podvod
  - Nevědomý omyl
  - Starší, již neplatný stav věcí
- Lze řešit pouze v prostředí, které netrvá na jedinečných identifikátorech pro každý zdroj…

AAA a kvalita dokumentového vs. sémantického webu

- Sémantický by měl mít lepší kvalitu než dokumentový?
  - Proces publikování strukturovaných dat je většinou rigoróznější a lépe zdokumentovaný než prosté psaní textů
  - Strukturovaná data se lépe kontrolují než volný text
- Ale zase:
  - Data v RDF zpravidla nevznikají přímo, ale strojovým převodem, kterým se mohou zanést neúmyslné chyby

Jazyk RDFS

- (Už dobře známe z tvorby slovníků – nic zásadně nového teď neuslyšíte!)
- V RDFS (slovnících) lze
  - zavádět typy zdrojů (třídy a vlastnosti)
  - definovat logické (resp. množinové) vztahy mezi typy: *rdfs:subClassOf, rdfs:subPropertyOf, rdfs:domain, rdfs:range*
- Tyto vztahy ale nemusí sloužit jen pro informaci lidskému tvůrci dat, jak by data „měla vypadat“, ale umožňují i strojové odvozování nových dat (tvrzení)
- Strojové odvozování je něco jiného než strojové ověřování validity dat
  - Pro to existují jiné nástroje –zvl. SHACL (Shapes Control Language), viz další prezentace

Odvozovací konstrukty RDFS

- Všechny jsou současně predikáty RDF
  - rdfs:subClassOf
  - rdfs:subPropertyOf
  - rdfs:domain
  - rdfs:range
- Proto je možné trojice s těmito predikáty přidat k ostatním, a odvozovat nad elementárními fakty RDFS a tvrzeními RDF jako jedním celkem
- Odvozování lze popsat pomocí inferenčních pravidel typu IF – THEN nad grafy (zahrnujícími „data“ RDF i „pravidla“ RDFS)
  - Pozor, zápis s IF-THEN je jen pro účely vysvětlení, nejde o žádnou formální syntaxi!

Odvození nadtřídy

IF ?A rdfs:subClassOf ?B.
AND ?x rdf:type ?A.
THEN ?x rdf:type ?B.

IF ex:Professor rdfs:subClassOf ex:Teacher.
AND ex:Petr rdf:type ex:Professor.
THEN ex:Petr rdf:type ex:Teacher.

- Odvozování příslušnosti zdroje ke třídě „směrem nahoru“
- Pro lidi zvyklé na objektové modelování nezvyklé?
  - vs. dědění atributů a metod tříd v OOP „dolů“
  - neexistuje přepisování (overriding) na nižší úrovni
  - „vícenásobná dědičnost“ (více rodičovských tříd pro danou třídu) je definována jednoznačně
- Lze vysvětlit pomocí inkluze množin zdrojů

Lze řešit na úrovni SPARQL?

- Ve SPARQL 1.0 jen pro předem daný počet hierarchických úrovní, přepsáním dotazu na složitější

```
…WHERE          { ?x rdf:type ?B }
```

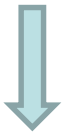

```
…WHERE
{
        { ?x rdf:type ?B }
UNION
        { ?A rdfs:subClassOf ?B.
          ?x rdf:type ?A .          }
}
```

- Ve SPARQL 1.1: rekurzivní „property path“ – nemusí být všude implementované: ?A rdfs:subClassOf+ ?B.
- Popřípadě ad hoc implementace s využitím direktiv

Odvození nadvlastnosti

IF ?P rdfs:subPropertyOf ?Q.
AND ?x P ?y.
THEN ?x Q ?y.

IF ex:isHeadOf rdfs:subPropertyOf ex:isEmployedBy.
AND ex:Vilem ex:isHeadOf ex:KIZI.
THEN ex:Vilem ex:isEmployedBy ex:KIZI.

- Funguje stejně, jako propagace tříd
  - ale na úrovni uspořádaných dvojic zdrojů
  - vlastnost je binární relace, tj. množina uspořádaných dvojic – tj. množinová inkluze platí stejně jako u tříd
- Nemá analogii v OOP

Odvozování vs. modelování

- Z hlediska odvozování je korektní vztah
  ex:returned rdfs:subPropertyOf ex:borrowed.
  - Pokud někdo něco vrátil, můžeme spolehlivě odvodit, že si to předtím půjčil
- Z hlediska modelování reality ale neplatí, že by vrácení věci bylo „specializovaným případem“ jejího půjčení!
  - Jde o sémanticky odlišný vztah, proto nelze takové modelování ve slovnících doporučit

Odvození dle definičního oboru

IF ?P rdfs:domain ?A.
AND ?x P ?y.
THEN ?x rdf:type ?A.

IF ex:isEmployedBy rdfs:domain ex:Person.
AND ex:Vilem ex:isEmployedBy ex:KIZI.
THEN ex:Vilem rdf:type ex:Person.

- Díky *předpokladu otevřeného světa* (OWA) definiční obor (domain) nefunguje jako integritní omezení

IF ex:isEmployedBy rdfs:domain ex:Person.
AND ex:LISp-Miner rdf:type ex:Software.
AND ex:LISp-Miner ex:isEmployedBy ex:KIZI.
THEN ???

Odvození dle definičního oboru

IF ?P rdfs:domain ?A.
AND ?x P ?y.
THEN ?x rdf:type ?A.

IF ex:isEmployedBy rdfs:domain ex:Person.
AND ex:Vilem ex:isEmployedBy ex:KIZI.
THEN ex:Vilem rdf:type ex:Person.

- Díky *předpokladu otevřeného světa* (OWA) definiční obor (domain) nefunguje jako integritní omezení

IF ex:isEmployedBy rdfs:domain ex:Person.
AND ex:LISp-Miner rdf:type ex:Software.
AND ex:LISp-Miner ex:isEmployedBy ex:KIZI.
THEN ex:LISp-Miner rdf:type ex:Person

- …ale jako odvozovací pravidlo!
  - Pozn.: odlišné třídy nejsou explicitně disjunktní

Odvození dle oboru hodnot

IF ?P rdfs:range ?A.
AND ?x P ?y.
THEN ?y rdf:type ?A.

IF ex:isEmployedBy rdfs:range ex:Organization.
AND ex:Vilem ex:isEmployedBy ex:KIZI.
THEN ex:KIZI rdf:type ex:Organization.

- Odvození dle oboru hodnot (range) funguje analogicky jako pro definiční obor

Subclass vs. domain/range

- Víceméně stejnou realitu a odvozování nad ní lze modelovat oběma způsoby

- ex:isEmployedBy rdfs:range ex:Organization.
  IF ex:Vojtech ex:isEmployedBy ex:KIZI.
  THEN ex:KIZI rdf:type ex:Organization.
- ex:Employer rdfs:subClassOf ex:Organization.
  IF ex:KIZI rdf:type ex:Employer.
  THEN ex:KIZI rdf:type ex:Organization.

RDFS – jednoduchý jazyk?

- RDFS „klame tělem“!
  - Syntakticky je velmi jednoduchý
  - Odvozování se implementuje také vcelku jednoduše
  - …ale pro uživatele není snadné si na ně zvyknout!
  - Největší díl nejasností připadá na domain/range
  - Ale při kvalifikovaném využívání může přinést užitečný efekt
- Pro srovnání
  - RDF je jednoduché na pohled i podstatou
  - OWL je komplikovanější na pohled i podstatou

„Směr“ tvrzení domain/range

- Mějme tvrzení P rdfs:domain ?A
  - Intuitivně bychom asi chápali jako: „Pro třídu A je definována vlastnost P“, tj. od A směrem k P
  - Správná interpretace ale je: „Pro levou stranu vlastnosti P je určena třída A“, tj. od P směrem k A !!!
- Analogicky pro range
- Na levé i pravé straně jakékoli vlastnosti se vždy může vyskytnout jakýkoli zdroj z univerza
  - tvrzení typu domain a range pouze umožňují tomuto zdroji odvozením přiřadit příslušnost k (další) třídě

Propagace domain/range

IF ?P rdfs:domain ?A.
AND ?A rdfs:subClassOf ?B.
THEN ?P rdfs:domain ?B.

IF ex:isEmployedBy rdfs:domain ex:Person.
AND ex:Person rdfs:subClassOf ex:BiologicalEntity.
THEN ex:isEmployedBy rdfs:domain ex:BiologicalEntity.

- Podobně jako příslušnost instance se v hierarchii tříd „dědí nahoru“ i definiční obor
  - a opět analogicky i obor hodnot
- Nejde o pravidla navíc, ale plynou ze zřetězení předchozích (pro subClass + domain/range)

Vícenásobná domain/range

ex:teaches rdfs:domain ex:Person.
ex:teaches rdfs:domain ex:Organization.

- Intuitivně: učit mohou lidé i celé organizace… je tato intuice správná?
- Ne! Jde o dvě nezávislé logické formule! Pokud se nějaký zdroj vyskytne na levé straně tvrzení s ex:teaches, bude přiřazen jako instance k oběma třídám, tj. do jejich průniku
- V RDFS je třeba pečlivě zvažovat, zda dva způsoby použití vlastnosti nevyžadují dvě odlišné vlastnosti; nebo je nutno původní vlastnost nechat bez domain/range
- V OWL lze řešit tzv. lokálními restrikcemi

Vlastnost jako propojení tříd?

- **Úroveň instancí:** dva zdroje propojené vlastností

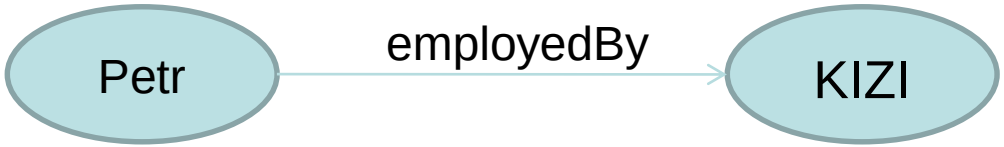

- **Úroveň tříd:** dvě třídy propojené vlastností, která je má v domain resp. range?

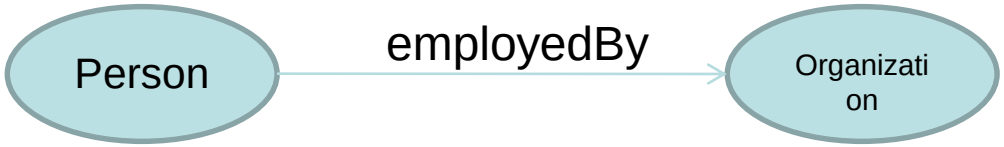

- Grafická notace a la RDF se často takto používá i pro úroveň tříd, to ale svádí k omylu
  - Nejde o jednu trojici RDF, ale o dvě; a u obou je employedBy subjektem, nikoliv predikátem!
  - Protože hodnotou domain/range nejsou jen explicitně zadané třídy, ale i jejich nadtřídy (viz o dva slidy zpět), nelze ani v obecném smyslu chápat jako vztah mezi dvěma třídami!

Modelování ekvivalence
(tříd, ale analogicky i vlastností)

- Přímo lze jen v OWL

```
?A owl:equivalentClass ?B.
```

- V RDFS lze nahradit dvěma jednosměrnými vztahy

```
?A rdfs:subClassOf ?B.
?B rdfs:subClassOf ?A.
```

- To ovšem vede k nižší srozumitelnosti

Výsledek odvození v RDFS

- Nové trojice se přidají do databáze (pokud v ní ještě nejsou)
- Nemůže dojít k nekonzistenci (sporu)
  - tj. výsledek odvození sice může být nesmyslný (např. LISp-Miner je zároveň osoba i software), ale kvůli chudému aparátu jazyka se to nemůže projevit
  - na rozdíl od odvození v OWL, kde může být spor odvozen (např. pokud jsou třídy Person a Software deklarovány jako disjunktní)

Odvozování při integraci dat
(viz hypotetická RDF data z publikační DB VŠE a z InSIS)

- Náhrada termínu při zachování vazby na stará data
  pcvse:Autor rdfs:subClassOf isis:Person.
- Propojení více terminologií
- Napojení proprietární vlastnosti na standardizovanou
  - Umožní např. zobrazovat hodnoty vlastnosti z proprietárního namespace v generické aplikaci
    insis:name rdfs:subPropertyOf rdfs:label.
- atd.

RDFS nad rámec odvozování a modelování reality

- rdfs:label
  - Lidsky srozumitelný název entity
- rdfs:seeAlso
  - URI odkaz na libovolný související zdroj
- rdfs:isDefinedBy
  - Jde o podvlastnost k seeAlso
  - Odkaz na „definující“ zdroj
- rdfs:comment
  - Textový komentář