

Triplifikace

Reprezentace a zpracování znalostí
na WWW, 5. 11. 2012

Jindřich Mynarz

Triplifikace

- Triplifikace = **převod non-RDF dat do RDF**
- Jak se vyrovnat s tím, že nevšechna data jsou k dispozici v RDF?
- Chicken and egg problem (deadlock)

Nástroje pro zdrojové formáty

- Text
 - Zpracování přirozeného jazyka
- HTML
 - Screen-scraping
- XML
 - XSLT transformace do RDF/XML
- Tabulka
- Relační DB
 - Mapování ze SQL
- Web API
 - Wrappery
- ...a mnoho dalších; viz [1](#) nebo [2](#)

Příklady

- [DBpedia](#) (zdroj: [Wikipedia](#))
- [World Bank Linked Data](#) ([zdroj](#))
- [LinkedGeoData](#) (zdroj: [OpenStreetMap](#))
- [Linked Data Cup](#) (dříve [LOD Triplification Challenge](#)): [vítěz za rok 2012](#)

Tipy

- Separation of concerns
 - Nesnažte se během triplifikace vyřešit vše (např. linkování, kvalitu dat).
- Streaming parsery
 - Zvláště pro velká data, nevytěžují tolik paměť.
- ~~RDF model~~
- Turtle (a la NTriples)
 - Výstup: stream 1 řádek/1 trojice
- SPARQL Update
 - Výstup: stream SPARQL Update požadavků

Zdroje

- [LATC Triplification Experiences](#)
- Heath, Tom; Bizer, Christian. Linked data: evolving the Web into a global data space.
(část [5.1.1](#))