

Limbajul natural ca mod de interogare a colecțiilor LinkedData

Anca Mărginean

Universitatea Tehnică Cluj Napoca
Baritiu 26-28, Cluj Napoca, Romania
anca.marginean@cs.utcluj.ro

Oana Marc

Universitatea Tehnică Cluj Napoca
Baritiu 26-28, Cluj Napoca, Romania
oana.marc@yahoo.com

REZUMAT

Chiar dacă Linked Data e un concept relativ nou, interogarea colecțiilor sale reînnvoiește vechile provocări ale interogării datelor într-o formă simpă dar suficient de puternică expresiv. Din perspectiva facilitării accesului la date în absența unei cunoașteri prealabile a domeniului, cea mai firească abordare ar fi interogarea în limbaj natural. Acceptând limitările curente ale procesării limbajului natural, introducem primele rezultate obținute în direcția translatării interogării din limbaj natural în interogare SPARQL, translatată centrală pe analiza sintactică și şablonane structurale generale combinate cu descrierii ontologice.

Cuvinte cheie

Web Semantic; parsare semantică; interogare SPARQL

Clasificare ACM

H.3.3 Information Search and Retrieval: Query formulation

INTRODUCERE

Linked Data înseamă utilizarea Web-ului pentru conectarea datelor care nu au fost conectate în prealabil în vederea facilitării accesului integrat și uniform la date. Unul dintre cei mai mari jucatori ai acestui domeniu încă Tânăr este *DBpedia*[1] - un efort al comunității de a extrage informații structurate din Wikipedia. Domeniul guvernamental sau medical vin să completeze plaja de domenii în care Linked Data a luat un avânt deosebit. Problema interogării acestor date devine astfel complicată nu doar datorită diferențelor formalisme de reprezentare a datelor ci și datorită dimensiunii enorme atât a datelor cât și a ontologiilor de descriere.

Ne propunem să investigăm interogarea acestor date în limbaj natural, pornind de la premsa Web-ului Semantic de acceptare a limbajului RDF(Resource Description Framework) drept standard de reprezentare a datelor. În ciuda numeroaselor rezultate în domeniul prelucrării limbajului natural[5], [3], parsarea sintactică și mai ales cea semantică ridică încă o multitudine de probleme care vor limita expresivitatea sistemului nostru. Sistemul propus construiește interogări SPARQL (Protocol and RDF Query Language) din interogări în limbaj natural prin îmbinarea metodelor existente de parsare sintactică cu o formă proprie de parsare semantică. Domeniul ales în prezent pentru testare este cel al datelor medicale, și mai precis proiectul Bio2RDF.

LINKED DATA ȘI PROIECTUL BIO2RDF

În contextul acceptării tot mai largi a conceptului de Linked Data (Date interconectate), proiectul Bio2RDF se remarcă

printre alte proiecte ce încearcă integrarea colecțiilor bioinformaticе [2]. Cu Bio2RDF, documente din bazele de date bioinformaticе publice, precum Kegg (Kyoto Encyclopedia of Genes and Genomes), PDB (Protein Data Bank), MGI (Mouse Genome Informatics), HGNC (HUGO Gene Nomenclature) și baze ale centrului NCBI (National Center for Biotechnology Information) sunt accesibile în formatul RDF printr-un URI (Identifier Uniform de Resursă) unic.

DrugBank este o componentă a proiectului Bio2RDF care oferă informații despre medicamente, conținând în jur de 766,920 triple și 4,800 medicamente. În DrugBank, fiecare medicament este o resursă care are proprietăți șiuri de caractere precum *toxicitatea*, *categoria*, *indicațiile*, *mecanismul de acțiune*, *sinonim*, *descriere*, *absorbție*. Un alt tip de proprietăți sunt cele care au drept valori alte resurse în loc de șiuri de caractere, precum *ddi-interactor-in*, *patent*, *dosaj*, *target*, *tip*, *la fel ca*. Conectarea resurselor intra și inter vocabular se poate observa în exemplele din figura 1, unde o resursă din vocabularul bio2rdf din DrugBank este în relație cu o resursă din vocabularul Pharmacogenomics Knowledge Base.

În acest exemplu, se observă triplete ce descriu resursa asociată medicamentului cu eticheta Lepirudin: organisme afectate, absorbție și ruta. Dacă valorile primelor două proprietăți sunt șiuri de caractere, în cazul ultimei proprietăți, valoarea este o altă resursă a cărei proprietate *label* descrie modul de administrare "Intravenous".

ACCESUL LA DATE ÎN LINKED DATA

Dincolo de problemele de integrare, accesul la date din Linked Data este greoi datorită necesității cunoașterii prealabile a ontologiilor sau a vocabularului utilizat. Ceea ce propunem în aceasta lucrare este interogarea acestor date în limbaj natural. Considerăm că o astfel de abordare este justificată în ciuda limitărilor procesării limbajului natural prin faptul că utilizatorul uman nu este străin de domeniul interogat și se poate referi la entitățile domeniului în limbaj natural. Ceea ce nu cunoaște utilizatorul uman și considerăm că nici nu ar trebui să cunoască, sunt ontologiile utilizate pentru reprezentarea domeniului. Ontologia ar trebui să fie destinată mașinii, nu omului, iar modul în care este reprezentată semantică datelor ar trebui să fie cât mai transparent utilizatorului uman.

Structura și funcționalitățile sistemului

Figura 2 prezintă principalele module ale sistemului. Modulul *Parsare* determină arborele de parsare pentru interogarea furnizată de utilizator în limbaj natural în limba

```

http://bio2rdf.org/page/drugbank:DB00001 rdfs:label "Lepirudin"
http://bio2rdf.org/page/drugbank:DB00001 :affected-organism "Humans and other mammals"
http://bio2rdf.org/page/drugbank:DB00001 :absorption "Bioavailability is 100% following injection"

http://bio2rdf.org/drugbank_resource:13e8d5e28fb251ec51bdad66d6544621
:route http://bio2rdf.org/pharmgkb_vocabulary:361ee98c3d82f85e8095179351912761

http://bio2rdf.org/pharmgkb_vocabulary:361ee98c3d82f85e8095179351912761 rdfs:label "Intravenous"

<!-- Un exemplu de interacție între două medicamente -->
http://bio2rdf.org/drugbank:DB00001 drugbank:ddi-interactor-in http://bio2rdf.org/drugbank_resource:DB00001_DB00374
http://bio2rdf.org/drugbank:DB00374 drugbank:ddi-interactor-in http://bio2rdf.org/drugbank_resource:DB00001_DB00374
http://bio2rdf.org/drugbank:DB00374 rdfs:label "Ginkgo biloba"
http://bio2rdf.org/drugbank_resource:DB00001_DB00374 rdfs:label "DDI between Lepirudin and
Treprostinil - The prostacyclin analogue, Treprostinil, increases the risk of bleeding when combined with
the anticoagulant, Lepirudin. Monitor for increased bleeding during concomitant therapy."

```

Figura 1: Exemple de descrieri din cadrul proiectului Bio2RDF




Figura 2: Modulele sistemului

engleza. În primul rând, interogarea este preprocesată în vederea evitării dependențelor false, după care, folosindu-se API-ul Stanford Parser [6], se realizează analiza morfologică și sintactică a frazei, returnându-se arborele de parsare.

Modulul de *Analiza* identifică tipul de întrebare prin suprapunerea arborelui peste un set de şabloane predefinite. Scopul acestor şabloane este de a extrage semantica asociată frazei și de a identifica variabilele și proprietățile ce urmează a fi folosite în interogarea SPARQL. Lista de proprietăți și variabile astfel construită este preluată de către al treilea modul, cel de *Construire* a interogării SPARQL. În cele din urmă, interogarea generată este executată de către modulul de *Executare* care se conectează la serviciul Bio2RDF de tip endpoint¹ care furnizează date despre medicamente din colecția DrugBank.

ANALIZA INTEROGĂRII BAZATĂ PE SABLOANE STRUCTURALE

Semantic interogării utilizatorului este extrasă pe baza unor şabloane structurale corelate cu ontologia curentă. Vom prezenta câteva dintre ele împreună cu interogarea SPARQL generată de sistem, urmând ca algoritmul de construire a interogării să îl detaliem în secțiunea următoare.

Rezultatul modulului *Analiză* este o listă de variabile și proprietăți, mai exact o **listă de tuple** de forma *(coloana,*

¹<http://drugbank.bio2rdf.org/sparql>

proprietate, inSelect, deCăutat). Fiecărui aspect identificat în interogare îi corespunde o tuplă care în urmă va deveni un pattern de triplet SPARQL. Componenta *Coloana* reprezintă numele variabilei corespunzătoare unei proprietăți cerute prin textul de intrare, *proprietate* este numele proprietății corespunzătoare în vocabularul Bio2RDF, în timp ce *deCăutat* poate avea valoare nulă sau numele unei anumite entități pe baza căreia se va face o filtrare. *inSelect* indică dacă o valoare a unei proprietăți i) corespunde unui aspect solicitat de către client, caz în care variabila dată de *coloana* este inclusă în clauza *SELECT* sau ii) este o proprietate auxiliară ce trebuie inclusă doar în clauza *WHERE*.

Reamintim că o interogare *SPARQL* constă din două părți: clauza *Select* care identifică variabilele ce vor apărea în rezultat, respectiv clauza *Where* care descrie graful şablon care restricționează datele rezultat.

Şablonul 1




Figura 3: Şablonul 1 împreună cu un exemplu

Cel mai simplu şablon identificat este descris de structura din figura 3a. Interogările care respectă acest şablon sunt de forma **What is/are the list of properties for/of drug name ?** or **Find the list of properties for drug name**, unde proprietățile pot fi binare sau n-are cu $n \geq 3$. Exemple de întrebări: i) *What is the substructure of Lymecycline?* sau ii) *Find the composition for Lymecycline.*, iii) *Find the description and toxicity for Lepirudin*, iv) *What is the description and interactor drugs for Lepirudin?*

Numele entității căutate este extras din structura **NNP** (proper noun phrase), în timp ce proprietățile căutate sunt

extrase din substantivele sau adjectivele identificate în subarborele structurii **NP** aflat în relație de determinare cu structura prepozițională **PP**.

Pentru interogarea "What is the description and route of elimination for Lepirudin?" se obține un arbore sintactic din care componenta relevantă este cea inclusă în figura 3b. Pe baza acestui arbore, modulul de *Analiza* construiește următoarea listă de tuple din care ulterior modulul de *Construire* generează interogarea SPARQL.

coloana	proprietate	inSelect	deCăutat
description	http://purl.org/dc/terms/description	true	nul
route-of-elimination	http://bio2rdf.org/drugbank_vocabulary:route-of-elimination	true	nul
name	http://www.w3.org/2000/01/rdf-schema#label	false	Lepirudin

```
SELECT ?description ?routeofelimination
WHERE {
?a <http://www.w3.org/2000/01/rdf-schema#label> ?name .
?a <http://purl.org/dc/terms/description>
?descrip .
?a <http://bio2rdf.org/drugbank\_vocabulary:route-of-elimination> ?routeofelimination
FILTER REGEX( str(?name), "Lepirudin", "i" ) .}
```

Şablonul 2




Figura 4: Şablonul 2 împreună cu un exemplu

Al doilea şablon structural (figura 4) permite ca proprietățile solicitate să nu fie ale unui anumit medicament ci ale unei clase de medicamente. Această clasă poate fi determinată de

2.1 apartenența sau lipsa apartenenței la o categorie, respectiv prezența interacțiunii: *drugs that are (not) in Anticoagulant category*

2.2 sinonimia cu alt medicament: *drugs that are synonymous with Lepirudin*

2.3 lipsa interacțiunii cu alt medicament: *(do not) interact with Lepirudin*

2.4 combinație ale primelor trei criterii: *drugs that interact with Ginkgo Biloba, are in anticoagulants category, do not interact with Lepirudin, and are synonymous with Hirudin?*

Şablonul 2 identifică structuri de genul **What are/is the list of properties for drugs that una dintre cele patru clase mai sus menționate**. Similar şablonului 1, proprietățile solicitate sunt identificabile pe baza substantivelor sau a adjectivelor din structura **NP**. Clasa medicamentelor este furnizată de subarborele structurii verbale **VP** pentru care în figura 5 se detaliază câteva dintre tiparele posibile. Menționăm că arborii includ cuvinte de instanțiere doar pentru o mai bună intelegeră, şabloanele conținând doar structuri sintactice sau morfologice, nu și cuvinte concrete.




Figura 5: Clase de entitati - Sub-şabloane ale şablonului 2

Din motive de spațiu nu vom prezenta celelalte şabloane utilizate în sistem, dar menționăm câteva tipuri de întrebări acoperite de acestea:

- What type of drug is Lepirudin?
- What are the drugs from analgesics category ?
- Is there an interaction between Lepirudin, Thrombin, Hirudin?
- Is it safe/unsafe/dangerous to combine Lepirudin with Thrombin?

CONSTRUIREA INTEROGĂRII SPARQL

Odată extrase variabilele și relațiile dintre ele, modulul de *Construire* generează interogarea SPARQL.

Algorithm 1 Construirea interogarii SPARQL

```

1: L ← analyse(arboreledeparsare)
2: select ← "SELECT"
3: where ← "WHERE{"
4: for all el în L do
5:   if el.inSelect then
6:     column ← el.getColumn()
7:     if column contains "interact" then
8:       column ← "nameb"
9:     end if
10:    select+ ← "?" + column + " "
11:  end if
12: end for{Construirea clauzei Select }
```

Construirea interogării SPARQL - continuare

```

13: for all el în L do
14:   column  $\leftarrow$  el.getColumn()
15:   select+  $\leftarrow$  "?a" + el.getProperty+"?" + column + "."
16:   if column contains "interact" then
17:     select+  $\leftarrow$  "?b" + el.getProperty + "?" + column + "."
18:     select+  $\leftarrow$  "?b rdfs:label ?" + nameb + "."
19:     filter (?name != ?nameb) ."
20:   end if
21:   if el.searchingFor then
22:     where+  $\leftarrow$  "FILTER REGEX(str(" +
23:       "?" + column + "), " + el.getSearchingFor + ", i)"
24:   end if{REGEX for drug name}
25: end for
26: where+  $\leftarrow$  "{}" {construirea clauzei Where}

```

Pentru construirea clauzei *select* se parcurge lista de tuple *L* și pentru fiecare tuplă cu componenta *inSelect* setată la valoarea *true* se adaugă în clauză o variabilă cu numele dat de componenta *coloana* a tuplei. În cazul clauzei *Where*, pentru fiecare tuplă se adaugă câte un triplet format dintr-o variabilă *?a*, proprietatea *property* și variabila din *coloana*. Dacă componenta *deCautat* a tuplei este *true*, se va adăuga o filtrare după proprietatea din tuplă.

Se poate remarcă tratarea specială a proprietății *interact*, motivul fiind faptul că această proprietate nu există între două medicamente, ci între fiecare dintre cele două și o instanță a conceptului *Drug-Drug-Interaction* (figura 1 - interacțiunea dintre Lepirudin și Ginkgo Biloba). Pentru o întrebare de forma “What is the description and interactor drugs for Lepirudin?”, rezultatul va fi

```

SELECT ?description ?nameb
WHERE {
  ?a <http://purl.org/dc/terms/description> ?description.
  ?a <http://bio2rdf.org/drugbank\_vocabulary:ddi-interactor-in> ?interactor.
  ?b <http://bio2rdf.org/drugbank\_vocabulary:ddi-interactor-in> ?interactor.
  ?b <http://www.w3.org/2000/01/rdf-schema#label> ?nameb.
  FILTER( ?name != ?nameb .
  ?a <http://www.w3.org/2000/01/rdf-schema#label> ?name.
  FILTER REGEX( str(?name), "Lepirudin", "i").
}

```

ALTE REZULTATE SI CONCLUZII

Potențialul uriaș al colecțiilor din Linked Data a fost demonstrat și de câștigarea premiului al treilea în cadrul competiției Semantic Web Challenge 2012 de către aplicația Open Self Medication[4]. În ce privește construirea interogărilor, menționăm metoda descrisă în [8]. Este vorba de o metodă incrementală în care se pornește de la cuvinte cheie urmând ca apoi, pe baza conceptelor din ontologia domeniului, utilizatorul să poată opta pentru anumite extinderi. În cazul nostru, ontologia nu e utilizată la nivelul utilizatorului, ci facilitează maparea pe un domeniu particular a unor metode generale, adică a şabloanelor structurale propuse.

QUEPY² este o aplicație în dezvoltare care încearcă interogarea datelor Web-ului Semantic în limbaj natural. Din

²<http://quepy.machinalis.com/>

ce cunoaștem noi, la momentul actual permite doar interogări simple, fără posibilitatea de a descrie clase de entități precum cele permise de Şablonul 2 al sistemului nostru. Direcția de cercetare care a condus însă la abordarea propusă aici este cea a limbajelor de reprezentare a înțelesului (Meaning Representation Language) urmată în [3] sau [7]. În aceste două lucrări nu este vorba despre interogarea datelor RDF ci se prezintă metode de învățare a parsării semantice sau a translatării către un MRL. Considerăm că în absența învățării, nu se poate ajunge la un sistem de parsare semantică de un nivel acceptabil, aceasta fiind una dintre direcțiile următoare de lucru.

În concluzie, s-au prezentat primele rezultate obținute în direcția interogării colecțiilor LinkedData în limbaj natural. Sistemul nostru are drept input un text în limbaj natural din care, pe baza analizei sintactice, a unor şabloane structurale și a vocabularului de descriere a datelor, se obține interogarea SPARQL. Şabloanele structurale facilitează extragerea semantică interogării, de aceea considerăm că reprezinta cea mai importantă componentă a sistemului nostru. În mod cert, setul de şabloane trebuie extins, rafinat și îmbogățit cu metode de compunere și de adaptare dinamică la ontologii.

Parte din cercetare s-a derulat în cadrul proiectului ”Argumentare structurata pentru suport decizional cu conștiință normative”, programul PN-II Cooperari Bilaterale Romania-Republica Moldova, 2013-2014, UEFSCDI.

REFERINȚE

1. Auer, S., Bizer, C., Kobilarov, G., Lehmann, J., Cyganiak, R., and Ives, Z. G. Dbpedia: A nucleus for a web of open data. In *ISWC/ASWC* (2007), 722–735.
2. Belleau, F., Nolin, M.-A., Tourigny, N., Rigault, P., and Morissette, J. Bio2rdf: Towards a mashup to build bioinformatics knowledge systems. *Journal of Biomedical Informatics* 41, 5 (2008), 706–716.
3. Chen, D. L., and Mooney, R. J. Learning to interpret natural language navigation instructions from observations. In *the Twenty-Fifth AAAI Conference on Artificial Intelligence, USA* (2011).
4. Cur, O. Open Self Medication on LOD. In *Proceedings of the Semantic Web Challenge co-located with ISWC2012* (Boston, US, November 2012).
5. Manning, C. D. Part-of-speech tagging from 97% to 100%: Is it time for some linguistics? In *Computational Linguistics and Intelligent Text Processing - 12th International Conference, Japan* (2011), 171–189.
6. Marie-Catherine de Marneffe, B. M., and Manning, C. D. Generating typed dependency parses from phrase structure parses (2006).
7. Wong, Y. W., and Mooney, R. J. Learning for semantic parsing with statistical machine translation. In *HLT-NAACL* (2006).
8. Zenz, G., Zhou, X., Minack, E., Siberski, W., and Nejdl, W. From keywords to semantic queries - incremental query construction on the semantic web. *Journal Web Semantic* 7, 3 (2009), 166–176.