

SERVICII WEB INTEROPERABILE ȘI MULTILINGUALE

RADU ION, ALEXANDRU CEAȘU, DAN ȘTEFĂNESCU, DAN TUFIȘ

Institutul de Cercetări pentru Inteligență Artificială, Academia Română

{radu, aceausu, danstef, tufis}@racai.ro

Rezumat

Problemele interoperabilității instrumentelor și resurselor lingvistice sunt preocupări majore ale cercetării actuale în domeniul prelucrării limbajelor naturale. Cele mai noi tehnologii, bazate pe arhitecturi orientate pe servicii web, constituie un pas important în direcția asigurării interoperabilității. Atunci când serviciile web sunt independente de limbă sau facil adaptabile la diverse limbi criteriile de interoperabilitate și multilingualitate sunt în mare măsură satisfăcute. Orchestrarea diverselor servicii se face de obicei prin alegerea unui format comun al datelor de intrare/ieșire. În acest sens, au apărut deja o serie de platforme de integrare a resurselor și instrumentelor lingvistice dezvoltate și rezidente în locații diferite, implementate în limbaje de programare și sub sisteme de operare variate. În această lucrare prezentăm câteva dintre serviciile web ale Institutului de Cercetări pentru Inteligență Artificială (ICIA) adaptate la platforma de servicii web WebLicht. WebLicht reprezintă un mediu în care serviciile web înregistrate pot interacționa unele cu altele datorită conversiei parametrilor de intrare/ieșire la formatul TCF (engl. Text Corpus Format).

1. Introducere

Tehnologiile Web Service, un palier fundamental în filosofia noilor generații ale web-ului, înlesnesc utilizatorilor dezvoltarea de aplicații ce integrează diverse module, implementate de autori diferiți, în limbaje diferite, și chiar aflate pe alte mașini decât cea locală. Conceptul de arhitectură orientată spre servicii (SOA) a apărut dintr-o nevoie imperioasă de a structura și standardiza colecția eterogenă și vastă de instrumente și documente care există în spațiul virtual al intra- și inter-rețelelor informatice locale, regionale sau mondiale. Derivat din conceptul SOA, dar mai general, este conceptul de infrastructură de servicii web care oferă răspunsuri la construcția de fluxuri de prelucrare pe baza serviciilor web dar și la identificarea serviciilor relevante pentru o anumită aplicație, a datelor necesare diferitelor servicii, a publicării de resurse și instrumente de prelucrare a acestor resurse, a documentării lor etc. O astfel de infrastructură este în curs de construcție în cadrul proiectului european CLARIN¹.

CLARIN își propune să reunească aplicații și resurse din domeniul Prelucrării Automate a Limbajului Natural (PLN) și să le prezinte sub o formă în care nespecialiștii în prelucrarea limbajului natural (PLN) să le poată identifica și utiliza cât mai ușor în activitățile pe care le întreprind. Altfel spus, CLARIN urmărește realizarea unei infrastructuri europene a tehnologiilor limbajului natural (scris și vorbit) astfel încât

¹ <http://www.clarin.eu>

acestea să fie *integrate* (aplicațiile și resursele se află în centre specializate care utilizează servere dedicate interconectate prin rețele de tip GRID), *interoperabile* (resursele și serviciile vor fi descrise cu limbajele proprii Web-ului semantic (engl. Semantic Web) pentru a depăși barierele puse de diversitatea formatelor de intrare/ieșire), *stabile* (garantarea funcționării neîntrerupte și existența personalului de suport tehnic), *persistente* (garantarea funcționării continue pe o perioadă lungă de timp – cel puțin pe durata proiectului), *accesibile* (resursele și aplicațiile sunt accesibile online pe Web) și *extensibile* (întreg mediul trebuie să încorporeze ușor noi aplicații și resurse). CLARIN reunește și armonizează la nivel european o multitudine de proiecte naționale. Astfel de proiecte sunt, printre altele, proiectul german D-SPIN și proiectul românesc CLARIN-RO.

D-SPIN² (Hinrichs et al., 2008) a implementat o platformă de servicii web care să asigure interoperabilitatea unor aplicații de PLN dezvoltate independent. Metoda de interconectare a fost aceea a expunerii acestor aplicații ca servicii web de tip REST³ (și nu SOAP⁴ pentru că s-a considerat că volumul de lucru suplimentar necesar împachetării/despachetării formatului SOAP va introduce un timp suplimentar și inutil de adaptare pentru noile aplicații care doresc înregistrarea). Această platformă se numește **WebLicht**⁵ și a fost dezvoltată în colaborare de universitățile din Tübingen, Stuttgart, Leipzig și Berlin. În prezent conține peste 70 de aplicații de PLN (pentru limbile germană, engleză, franceză, română, spaniolă, italiană și finlandeză) expuse ca servicii web și care *sunt compatibile între ele ca formate de intrare/ieșire*. Acest lucru permite în mod evident posibilitatea extraordinară a compunerii de operații simple pentru obținerea unor rezultate care altfel ar fi fost imposibil de obținut – de exemplu, combinarea adnotării cu etichete morfosintactice a unui text din două surse (programe) diferite. Dintre operațiile ce se pot efectua asupra unui text putem menționa: segmentare lexicală, adnotare cu etichete morfo-sintactice, lematizare, analiză sintactică etc.

Formatul parametrilor de intrare/ieșire este unul XML care a fost definit special pentru a facilita integrarea aplicațiilor care prelucrează texte. Acesta se numește Text Corpus Format (TCF, (Schmid, 2009)) și reprezintă o stivă de adnotări care sunt produse de operații elementare de procesare a textelor (de exemplu, segmentarea la nivel de unitate lexicală este o adnotare necesară operației de etichetare morfo-sintactică). Astfel, fiecare serviciu web din WebLicht așteaptă la intrare un fișier XML care conține textul prelucrat până la un anumit nivel și întoarce același fișier XML la care adaugă un nou nivel care conține adnotările pe care le produce (niciunei operații nu-i este permis să șteargă vreun nivel de adnotare). Menționăm că platforma Weblicht este una dintre componentele ECD (European Clarin Demonstrator) prototipul funcțional al etapei de specificare (preparatory phase) a proiectului CLARIN, prototip a cărui implementare este coordonată de ICIA.

² <http://weblicht.sfs.uni-tuebingen.de/englisch/index.shtml>

³ Representational State Transfer, un tip de comunicare de tip client-server.

⁴ Ajuns la versiunea 1.2, SOAP (<http://www.w3.org/TR/soap12-part0/>) este un protocol descris în XML cu care diverse aplicații distribuite pe calculatoare conectate în rețea, pot comunica prin schimb de mesaje împachetate în formatul SOAP.

⁵ <http://weblicht.sfs.uni-tuebingen.de:8080/WebLicht1/>

În cele ce urmează, vom descrie procesul de adaptare, în cadrul proiectului RO-CLARIN, a câtorva dintre serviciile web ale ICIA la platforma WebLicht. O serie de alte servicii web proprii sau în curs de implementare la ICIA vor fi adăugate în viitorul apropiat platformei WebLicht. De asemenea vom exemplifica avantaje ale adoptării de standarde pentru ușurința adaptării unor aplicații diverse (expuse ca servicii web) la rezolvarea unor probleme care altfel nu ar fi putut fi abordate. În acest sens, vom arăta cum anume putem combina rezultatele mai multor programe de etichetare morfo-sintactică operând pe aceeași segmentare lexicală cu metoda descrisă în (Tufiş, 1999) care opera cu același program de etichetare morfo-sintactică antrenat însă pe diverse corpusuri.

2. TTL în platforma WebLicht

TTL⁶ este un modul Perl care oferă următoarele adnotări ale textelor în limbile română, engleză și franceză: segmentare la nivel de frază și unitate lexicală, adnotare cu etichete morfo-sintactice (engl. POS tagging), lematizare, recunoașterea entităților denumite (engl. named entity recognition) și analiză sintactică de suprafață (engl. chunking). A ajuns la versiunea 7.9 și a fost implementat deja ca serviciu web (Tufiş et al., 2007).

Pentru adaptarea TTL la WebLicht a fost nevoie de următoarele modificări asupra implementării anterioare ca serviciu web:

- renunțarea la suportul pentru SOAP întrucât WebLicht specifică comunicarea de tip REST ca fiind standardul acceptat. În acest caz, un client care dorește să folosească serviciul web va trimite o cerere HTTP POST către serverul de web care găzduiește serviciul comunicându-i acestuia un șir de caractere codificat UTF-8 care reprezintă un document XML TCF bine format. Serviciul web procesează documentul și îl returnează clientului cu stratul de adnotări suplimentar pe care l-a produs.
- renunțarea la serverul de web implementat de pachetul Perl **SOAP::Lite** și adoptarea serverului de web **Apache**⁷ ca gazdă pentru TTL. În acest fel am rezolvat o problemă gravă a serverului de web din SOAP::Lite care nu accepta decât o singură conexiune la serviciul web la un moment dat și care de altfel, era și instabil. Cu Apache a trebuit să utilizăm modulul Fast CGI⁸ care permite serverului de web să încarce *o singură dată* o instanță a serviciului web (moment în care se încarcă toate resursele necesare – operație costisitoare ca timp de execuție) iar apoi să servească mai mulți clienți folosind această instanță. De asemenea, FCGI permite distribuția uniformă a încărcării pe instanțele serviciului web existente și un întreg management al pornirii/opririi instanțelor serviciului web.

Serviciul web TTL pentru platforma WebLicht expune câte un URL pentru fiecare operație elementară pentru fiecare limbă în parte (`{lang}` poate lua una din valorile engleză (`en`), română (`ro`) sau franceză (`fr`):

⁶ Abrevierea din engleză pentru “Tokenizing, Tagging and Lemmatizing free running texts”.

⁷ <http://httpd.apache.org/>

⁸ FCGI, <http://www.fastcgi.com/>

- segmentare la nivel de frază și apoi la nivel lexical: `http://ws2.racai.ro/TTL-{lang}-tokenizer;`
- adnotare cu etichete morfo-sintactice: `http://ws2.racai.ro/TTL-{lang}-postagger;`
- lematizare: `http://ws2.racai.ro/TTL-{lang}-lemmatizer;`
- analiza sintactică de suprafață: `http://ws2.racai.ro/TTL-{lang}-chunker;`

În afară de aceste operații, orice serviciu web din WebLicht necesită conversia textelor primare (care nu sunt adnotate în vreun fel) la formatul TCF de bază (fișierul XML care este preluat de prima operație care, de obicei, este segmentarea la nivel de frază/unitate lexicală). În prezent, WebLicht conține astfel de servicii web care convertesc texte UTF-8 și RTF la formatul TCF de bază exemplificat în figura 1.

```
<?xml version="1.0" encoding="UTF-8"?>
<D-Spin xmlns="http://www.dspin.de/data" version="0.3">
  <tns:MetaData xmlns:tns="http://www.dspin.de/data/metadata">
    <tns:source></tns:source>
  </tns:MetaData>
  <tns:TextCorpus xmlns:tns="http://www.dspin.de/data/textcorpus" lang="ro">
    <tns:text>Acesta este o propoziție de test.</tns:text>
  </tns:TextCorpus>
</D-Spin>
```

Figura 1: Formatul TCF pentru propoziția „*Acesta este o propoziție de test.*”

Figura 2 reprezintă o sesiune de lucru în WebLicht. Primul pas pe care trebuie să-l facă utilizatorul este să selecteze limba textului pentru care dorește procesarea. Apoi, alegând orice operație din coloana din partea stângă, sistemul va adăuga automat în lanțul de prelucrare toate operațiile care aduc textul din forma brută în formatul TCF necesar la intrarea operației selectate de utilizator. De exemplu, dacă am fi selectat operația de adnotare cu etichete morfo-sintactice, WebLicht ne-ar fi adăugat automat în lanțul de prelucrare operațiile de conversie la formatul TCF de bază (cel din figura 1) și segmentare la nivel de frază și unitate lexicală.

Lanțul de prelucrare final apare în chenarul „Selected Tools:” iar apăsarea butonului „Run” produce rezultatele vizibile în partea de jos a coloanei din partea dreaptă. Acestea se pot descărca de pe site în formatul XML TCF produs de lanțul de prelucrare.

Anterior aminteam de posibilitatea extraordinară de a combina diverse operații WebLicht pentru a obține rezultate care altfel (în absența acestei platforme) ar fi fost destul de dificil (sau imposibil în cazul în care aplicațiile nu erau disponibile) de obținut. Studiul de caz este combinarea rezultatelor a două adnotatoare cu etichete morfo-sintactice care rulează pe același text segmentat lexical și frazal în același fel pentru ambele programe. Tufiș (1999) discută posibilitatea obținerii unei adnotări morfo-sintactice mai bune în cazul în care același program de adnotare morfo-sintactică rulează cu modele de limbă diferite. WebLicht ne permite însă să obținem o adnotare mai bună (aplicând deci aceleași procedee ca în lucrarea citată – calculul matricelor de confuzie) folosind două adnotatoare diferite: în cazul nostru, TTL și TreeTagger pentru limba engleză. În figura 3 avem rezultatele celor două programe pentru propoziția „*A very simple test sentence is the test bed for the combined classifiers model.*”

SERVICII WEB LINGVISTICE ALE ICIA ÎN CADRUL PROIECTULUI CLARIN

The screenshot displays the WebLicht web interface. At the top, there's a header with the logo and the title "WebLicht: Web-Based Linguistic Chaining Tool". Below this, there are navigation tabs and a "Tool Filters" section with dropdown menus for "Language" (set to "ro") and "TCF Version". A table lists available tools:

Name	Creator	Lang	Version
POS Tagger Romanian	RACAI: Romanian Acad...	ro	0.3
Chunker for Romanian	RACAI: Romanian Acad...	ro	0.3
PlainText To TCF	RACAI: Romanian Acad...	ro	0.3
Lemmatization for Ro...	RACAI: Romanian Acad...	ro	0.3

A detailed view of the "Lemmatization for Romanian" tool is shown, including its description, creator (RACAI: Romanian Academy), contact, URL, ID (183), and wrappers (textcorpus,0.3 / textcorpus,0.3). The I/O section shows inputs (tokens, postags, -tagset: msd) and outputs (lemmas).

The "Build Chain" section shows a sequence of tools: PlainText To TCF, Tokenizer and Sentence Splitter, and POS Tagger Romanian. The output window displays XML metadata and the lemmatized text: "Aceasta este o propoziție de test." with tokens and their corresponding lemmas.

Figura 2: O sesiune de lucru în WebLicht

Pentru a reuși combinarea rezultatelor avem nevoie de corespondența etichetelor folosite (o altă aplicație extrem de utilă pe care WebLicht o face posibilă). TTL folosește mulțimea de etichete Multext-East (MSD) iar TreeTagger-ul folosește mulțimea de etichete Penn Treebank. Știm de exemplu că substantivele la singular se codifică cu „NN” în Penn Treebank și cu „Ncns” în MSD, substantivele la plural cu „NNS” respectiv „Ncnp”, adjectivele cu „JJ” respectiv „Afp”, ș.a.m.d. În exemplul considerat, ambele programe au găsit adnotarea corectă, dar, în cazul textelor mari, acest lucru este puțin probabil iar cu tehnica din (Tufiș, 1999) (după ce am fixat corespondența etichetelor), putem obține rezultate mai bune.

Tokenization	TreeTagger	TTL
A	DT	Ti-s
very	RB	Rsp
simple	JJ	Afp
test	NN	Ncns
sentence	NN	Ncns
is	VBZ	Vmip3s
the	DT	Dd
test	NN	Ncns
bed	NN	Ncns
for	IN	Sp
the	DT	Dd
combined	JJ	Afp
classifiers	NNS	Ncnp
model	NN	Ncns
.	.	PERIOD

Figura 3: Rezultatele adnotatoarelor TTL și TreeTagger pe o propoziție de test

3. *Servicii REST de procesare a textului bazate pe metode statistice de maximizare a entropiei*

Pe lângă TTL, ICIA mai dispune de aplicații performante de prelucrare primară a textelor care au fost de asemenea adaptate ca servicii web SOAP așa cum se raportează în (Tufiș et al., 2007). Ca o noutate față de aceste servicii web de tip SOAP dezvoltate folosind platforma .Net Framework⁹ pentru engleză și română, noile servicii conforme cu specificațiile WebLicht (apel de tip REST și parametri de intrare/ieșire în format TCF) sunt disponibile și pentru limbile franceză și germană. Adaptarea la noile limbi a fost posibilă datorită flexibilității metodei de antrenare statistică, serviciul REST de adnotare morfo-sintactică¹⁰ folosind modulul de adnotare stratificată METT – Maximum Entropy Tiered Tagging (Ceașu, 2006), pe principiul maximizării entropiei, similar modelului ME al lui Ratnaparkhi (1988). Ca și TTL, tagger-ul METT utilizează pentru fiecare limbă un set de descrieri morfo-sintactice compatibil cu specificațiile Multex-East și un tagset redus pentru adnotarea stratificată (Tufiș & Dragomirescu, 2004).

⁹ <http://www.microsoft.com/NET/>

¹⁰ [http://www.racai.ro/RestWS/Service.svc/ws-
{lang}-postagger](http://www.racai.ro/RestWS/Service.svc/ws-
{lang}-postagger) unde „{lang}” poate lua valorile „en”, „ro”, „fr” și „de”.

Noile servicii web de procesare a textului care implementează METT pentru WebLicht sunt disponibile la adresa:

`http://www.racai.ro/RestWS/Service.svc/ws-{lang}-{webservice}`

unde `{lang}` este limba textului ce urmează a fi procesat, iar `{webservice}` este tipul de procesare ce urmează a fi invocat ca serviciu web. `{lang}` poate lua valori română (ro), engleză (en), franceză (fr) și germană (de) iar `{webservice}` poate fi înlocuit cu unul din următoarele tipuri de prelucrări: segmentare lexicală (`tokenizer`), segmentare la nivel de frază (`sentsplitter`), adnotare morfo-sintactică (`postagger`) și lematizare (`lemmatizer`). Trebuie să notăm faptul că este obligatoriu ca în orice interogare HTTP la unul din aceste URL-uri, să specificăm în preambulul interogării tipul „application/xml” pentru fișierul TCF pe care îl vom trimite spre prelucrare (în antetul „Content-type”).

Pentru conversia în formatul TCF folosim serviciul web:

`http://www.racai.ro/RestWS/Service.svc/converter-{lang}`

unde `{lang}` este codul ISO de două caractere al limbii textului care urmează a fi procesat. Dacă limba nu este precizată, va fi invocat automat serviciul web pentru recunoașterea limbii (descriș în secțiunea 4).

În figura 4 este prezentat un exemplu de interogare a serviciilor web pentru conversia de la text la formatul TCF, segmentare lexicală și segmentare la nivel de frază, adnotare morfo-sintactică și lematizare. În continuare, folosind exemplul din figura 4, descriem parametrii de intrare și ieșire necesare fiecărui serviciu.

La interogarea serviciului web de conversie a unui text în formatul TCF (`http://www.racai.ro/RestWS/Service.svc/converter-ro`) rezultatul va fi un document XML similar celui din figura 1. Noul document XML va avea sub elementul „tns:TextCorpus” doar un element „tns:text” cu textul conținut în interogarea HTTP. În cazul acestui serviciu, parametrul de intrare este de tipul „text/plain” (specificat în „Content-type”) iar cel de ieșire este de tipul „application/xml”.

Pentru următoarea etapă de procesare – segmentarea lexicală – rezultatul serviciului de conversie este folosit ca argument pentru serviciul web `http://www.racai.ro/RestWS/Service.svc/ws-ro-tokenizer`. Rezultatul interogării HTTP este un document XML care are, pe lângă elementul „tns:text”, și un alt element „tns:tokens” care conține atomii lexicali din „tns:text”. Fiecare element „tns:token” conține indexul din textul inițial și lungimea atomului lexical.

În continuare, documentul XML rezultat al serviciului de segmentare lexicală este folosit ca parametru de intrare pentru serviciul de segmentare la nivel de frază (`http://www.racai.ro/RestWS/Service.svc/ws-ro-sentsplitter`). Acest serviciu adaugă elementul „tns:sentences” în care sunt grupate elemente „tns:sentence” reprezentând frazele formate din atomii lexicali din „tns:tokens”. Serviciul de segmentare frazală necesită prezența unui element „tns:tokens” în documentul XML inițial, deoarece fiecare frază conține referințe către atomii lexicali.

În final, rezultatul serviciului de segmentare la nivel de frază este folosit ca parametru de intrare pentru serviciul de adnotare morfo-sintactică stratificată

(<http://www.racai.ro/RestWS/Service.svc/ws-ro-postagger>). Deși poate folosi ca parametru de intrare un document XML conținând doar segmentarea lexicală (cu element „tns:tokens”), este recomandat ca documentul XML ce urmează a fi prelucrat să conțină și segmentarea frazală (cu element „tns:sentences”), informația suplimentară contribuind la o viteză crescută a adnotării. Acest serviciu adaugă documentului XML inițial un nou element „tns:POSTags” în care sunt precizate descrierile morfo-sintactice ale atomilor lexicali.

Serviciul web de lematizare (<http://www.racai.ro/RestWS/Service.svc/ws-ro-lematizer>) necesită rezultatul tokenizării și al adnotării morfo-sintactice pentru a atribui o leamnă fiecărui atom lexical. Acest serviciu adaugă un element „tns:lemmas” documentului XML inițial.

```

<?xml version="1.0" encoding="utf-8" ?>
- <D-Spin version="3.0" xmlns="http://www.dspin.de/data"
  xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
  xmlns:xsd="http://www.w3.org/2001/XMLSchema">
  <tns:MetaData xmlns:tns="http://www.dspin.de/data/metadata" />
- <tns:TextCorpus lang="ro"
  xmlns:tns="http://www.dspin.de/data/textcorpus">
  <tns:text>Acesta este un exemplu.</tns:text>
- <tns:tokens>
  <tns:token ID="t1" start="0" end="6">Acesta</tns:token>
  <tns:token ID="t2" start="7" end="11">este</tns:token>
  <tns:token ID="t3" start="12" end="14">un</tns:token>
  <tns:token ID="t4" start="15" end="22">exemplu</tns:token>
  <tns:token ID="t5" start="22" end="23">.</tns:token>
</tns:tokens>
- <tns:sentences>
- <tns:sentence ID="s1">
  <tns:tokenRef tokID="t1" />
  <tns:tokenRef tokID="t2" />
  <tns:tokenRef tokID="t3" />
  <tns:tokenRef tokID="t4" />
  <tns:tokenRef tokID="t5" />
</tns:sentence>
</tns:sentences>
- <tns:POSTags tagset="MSD">
  <tns:tag tokID="t1">Pd3msr</tns:tag>
  <tns:tag tokID="t2">Vmip3s</tns:tag>
  <tns:tag tokID="t3">Timsr</tns:tag>
  <tns:tag tokID="t4">Ncms-n</tns:tag>
  <tns:tag tokID="t5">PERIOD</tns:tag>
</tns:POSTags>
- <tns:lemmas>
  <tns:lemma tokID="t1">acesta</tns:lemma>
  <tns:lemma tokID="t2">fi</tns:lemma>
  <tns:lemma tokID="t3">un</tns:lemma>
  <tns:lemma tokID="t4">exemplu</tns:lemma>
  <tns:lemma tokID="t5">.</tns:lemma>
</tns:lemmas>
</tns:TextCorpus>
</D-Spin>

```

Figura 4: Exemplu de rezultat al interogării serviciilor web de identificare a limbii, de segmentare lexicală și frazală, de adnotare morfo-sintactică și de lematizare.

4. *Identificarea limbii*

Acest serviciu¹¹ asigură identificarea automată a limbii unui text scris într-una dintre cele 22 de limbi ale Uniunii Europene. Textul ar trebui să conțină un număr minim de 10-15 cuvinte (în principiu, o propoziție). Serviciul web de identificare a limbii funcționează ca un convertor din text în formatul TCF care poate recunoaște automat limba textului, adăugând un atribut „lang” elementului „tns:TextCorpus”.

Identificarea limbii este făcută folosind modele statistice pentru fiecare limbă și un modul de predicție. Predicția este realizată prin calcularea unui scor de similaritate al textului de intrare cu fiecare model de limbă în parte. Modelele de limbă se realizează pe baza ponderii pe care o au prefixele și sufixele cuvintelor în textele de antrenare disponibile pentru limba respectivă.

În experimentele realizate până acum, am utilizat texte de antrenament (cu mărimi ce au variat între 0,5 și 1,2 MB) pentru cele 22 limbi oficiale ale Acquis-ului Communautaire (Steinberger et al, 2006). Textele, fiind însă din domeniul juridic și având o structură mai aparte¹², nu sunt tocmai reprezentative pentru limbile luate în discuție. Cu toate acestea, am obținut rezultate excelente folosind pentru prefixe o lungime de trei caractere iar pentru sufixe de patru.

5. *Concluzii*

De la intrarea lor în funcțiune pe data de 19 februarie 2010, serviciile web ale ICIA din cadrul platformei WebLicht au avut 1389 de accesări pentru toate operațiile expuse pentru toate limbile. Dintre acestea cele mai multe accesări au fost de test (câte aprox. 40 de bytes de text pe cerere) dar au fost și cazuri în care s-a cerut procesarea a mai mult de 2KB de text. Suntem astfel siguri că efortul de integrare a aplicațiilor noastre în standardele promovate de CLARIN va fi de folos atât nouă cât și comunității CLARIN care crește într-un ritm alert.

Proiectul CLARIN deschide o nouă cale în abordarea cercetărilor în Prelucrarea Automată a Limbajului Natural și Lingvistică Computațională prin operațiunile de standardizare, colectare și diseminare a unor colecții impresionante de resurse și aplicații ale acestor domenii care altfel ar fi fost în marea majoritate a cazurilor, inaccesibile. Astfel, noi probleme de cercetare pot să apară sau unele mai vechi își pot găsi rezolvarea. În orice caz, adoptarea standardelor CLARIN va asigura accesul neîngrădit al celor neinițiați la tehnologiile limbajului pe de o parte și îmbunătățirea considerabilă a șanselor cercetătorilor de a găsi rapid soluții la problemele lor de cealaltă.

Mulțumiri. Activitatea de cercetare descrisă în această lucrare a fost sprijinită de proiectul european FP7 „CLARIN – Common Language Resources and Technology Infrastructure” (nr. de proiect 212230) finanțat de Comisia Europeană și de proiectul

¹¹ <http://www.racai.ro/RestWS/Service.svc/converter>

¹² Textele juridice au adesea o structură formată din multe aliniate în care anumiți termeni se repetă de foarte multe ori afectând acoperirea lingvistică a modelelor de limbă.

românesc PC7 „CLARIN–RO: Infrastructură pentru resurse lingvistice interoperabile pentru limba română” (nr. de proiect 16EU/06.04.2009) finanțat de ANCS.

Referințe bibliografice

- Ceaușu, A. (2006). Maximum Entropy Tiered Tagging. Janneke Huitink & Sophia Katrenko (editors), *Proceedings of the Eleventh ESSLLI Student Session, ESSLLI 2006*, June 2006, Malaga, Spain, pp. 173—179.
- Hinrichs, E., Wittenburg, P., Lemnitzer, L., Geyken, A. (2008). D-SPIN - the German CLARIN initiative. In *CLARIN Newsletter #2*, 2008 (<http://www.clarin.eu/files/cnl02-web.pdf>).
- Kemps-Snider, M., Bel, N., Broeder, D. (2009). Proposal for a CLARIN Service CMDI Components. September, 2009, <http://www.clarin.eu/wp2/wg-26/wg-26-documents/cmdi-profile-for-web-services>
- Kemps-Snider, M., Bel, N. (2009). CLARIN Report on Web Services. March 2009 <http://www.clarin.eu/wp2/wg-26>
- Ratnaparkhi, A. (1998). Maximum Entropy Models for Natural Language Ambiguity Resolution. Ph.D. thesis, University of Pennsylvania, Philadelphia.
- Schmid, H. (2009). The technical details of the D-SPIN Architecture. Internal technical report, 2009 (<http://weblicht.sfs.uni-tuebingen.de/englisch/publikationen.shtml>).
- Steinberger, R., Pouliquen, B., Widiger, A., Ignat, C., Erjavec, T., Tufiș, D. (2006). The JRC-Acquis: A multilingual aligned parallel corpus with 20+ languages. In *Proceedings of the 5th LREC Conference*, Genoa, Italy, 22-28 May, 2006, pp.2142-2147, ISBN 2-9517408-2-4, EAN 9782951740822.
- Tufiș, D. (1999). Tiered Tagging and Combined Language Models Classifiers. In Václav Matousek, Pavel Mautner, Jana Ocelíková, and Petr Sojka, editors, *Text, Speech and Dialogue (TSD 1999)*, Lecture Notes in Artificial Intelligence 1692, pp. 28—33. Springer Berlin / Heidelberg, January 1999. ISBN 978-3-540-66494-9.
- Tufiș, D., Dragomirescu, L. (2004). Tiered Tagging Revisited. In *Proceedings of the 4th LREC Conference*, Lisabona, 2004, pp. 39—42.
- Tufiș, D., Ion, R., Ceaușu, A., Ștefănescu, D. (2007). Servicii Web lingvistice ale ICIA. În Ionuț Cristian Pistol, Dan Cristea, și Dan Tufiș, editori, *Lucrările atelierului RESURSE LINGVISTICE ȘI INSTRUMENTE PENTRU PRELUCRAREA LIMBII ROMÂNE*, pp. 61–68, Iași, România, 14–15 decembrie 2007. Editura Universității "Alexandru Ioan Cuza" Iași.