

MORPHO-2: MEDIU DE PROIECTARE ȘI DEZVOLTARE A LEXICOANELOR MONOLINGVE

Ing. Cristian Dumitrescu

Institutul de Cercetări în Informatică

Rezumat

În lucrare se descrie sistemul MORPHO-2, sistem proiectat cu scopul gestiunii lexicoanelor monolingve și a manipulării on-line a proceselor lexicale. Serviciile asigurate de sistem permit modelarea și manipularea informațiilor de natură morfologică, sintactică și semantică la nivelul lexiconului. La proiectarea și dezvoltarea proceselor lexicale, se are în vedere realizarea unei distincții nete între procesele de prelucrare și cunoștințele care le guvernează. În acest mod, se asigură independența între limbajele (cu caracter preponderent flexionar) prelucrate și mediul de procesare.

1. Introducere

Cercetările și rezultatele obținute în domeniul prelucrării limbajului natural, cu precădere în dezvoltarea sistemelor de traducere automată, au demonstrat rolul deosebit de important al lexiconului. Abordarea inițială, care privea lexiconul ca pe o bază de date lexicală gestionată cu ajutorul unui Sistem de Gestire a Bazelor de Date (SGBD), este tot mai mult criticată [Domenig, 1986, 1988]. Principalele argumente împotriva acestei soluții pot fi rezumate astfel:

- a) un SGBD este inutil de general pentru problema lexicală, oferind un nivel scăzut de abstractizare și un timp de răspuns prea mare;
- b) un SGBD nu poate gestiona procese morfologice, iar limbajul de definire al datelor nu oferă mijloace pentru exprimarea acestor procese.

În accepția modernă, lexiconul încețează să mai fie privit ca o colecție amorfă de date, cercetările în acest sens concretizându-se prin modele și tehnici specifice agregate în medii procesuale, referite în literatura sub numele de sisteme de gestiune morfo-lexicală. Sistemul descris în lucrarea de față permite manipularea lexicoanelor monolingve și singlarea proceselor lexicale la nivelul lexiconului.

Întrucât procesele morfologice se circumscriz din punct de vedere teoretic unei morfologii de tip flexionar ([Tufiș, 1989], [Tufiș, 1990a]), analiza și sinteza cuvintelor iau în considerație numai terminațiile gramaticale, iar lexicoanele manipulate de MORPHO-2 sunt orientate numai pe rădăcini sau leme. Serviciile asigurate de sistem pot fi clasificate în raport cu următoarele obiective: proiectarea modelului morfologic, construirea fondului lexical și manipularea informațiilor lexicale (analiza și sinteza cuvintelor).

Pentru îndeplinirea acestor obiective sunt puse la dispoziția utilizatorilor trei tipuri de interfețe: interfața lexicologului, interfața lexicografului și interfața procesorului său.

2. Interfața Lexicologului

Pentru construirea unui model morfologic, lexicologul are la dispoziție un mediu integrat de dezvoltare ce permite editarea, vizualizarea și compilarea descrierii modelului morfologic.

Că urmare a specificațiilor furnizate de lexicolog, în final se obține un raport lexicografic și o reprezentare compilată a modelului morfologic.

Definirea unui model morfologic se face în mai multe etape, în care lexicologul specifică următoarele informații:

- părți de vorbire, caracteristicile și valorile lor, precum și dependențele dintre acestea;
- descrierile paradigmatici;
- specificările de caracteristici implicate atașate fiecărei descrieri paradigmatici;
- corespondența lema - intrare din descrierea paradigmatică pentru fiecare descriere paradigmatică;
- paradigmale flexionare și regulile de detectie a rădăcinilor.

Vom detalia în continuare, pe rînd, fiecare etapă din definirea unui model.

Unei părți de vorbire (SUBSTANTIV, VERB, PRONUME etc.) îi putem asocia mai multe caracteristici.

Ca exemple de caracteristici putem enumera MOD, TIMP, GEN, CAZ etc. Pentru caracteristica MOD vom avea valorile: INDICATIV, IMPERATIV, ..., GERUNIU.

Întrucât, în fază actuală, recunoașterea morfologică se face numai la nivel de cuvînt individual, caracteristicile și valorile acestora vor fi limitate la o submulțime corespunzătoare.

O relație de dependență pune în corespondență unei caracteristici mai multe valori:

MOD → (INDICATIV, IMPERATIV, ..., GERUNIU)

TIMP → (PREZENT, IMPERFECT, ..., VIITOR)

În mod practic pentru caracteristici și valori se folosesc abrevieri de genul:

NR → (SG, PL)

PER → (1, 2, 3)

Pentru uniformitatea reprezentării putem asocia o astfel de relație și părților de vorbire:

PV → (SB, ADJ, VB, ...)

În descrierea unui model morfologic, o relație de dependență este dată sub forma unei perechi de forme (caracteristică : valoare⁺).

Numim descriere paradigmatică o descriere ierarhică construită din mai multe perechi simple de tipul (caracteristică : valoare).

În figura următoare este prezentată parțial, sub formă unui arbore incomplet, descrierea ierarhică a

categoriilor gramaticale din modelul morfologic pentru limba română. Prin traversarea completă a arborelui, se pot genera toate descrierile paradigmatic ale modelului.

Într-un astfel de arbore fiecare nod neterminál conține o singură specificare de caracteristică, sub forma (caracteristică : valoare⁺). Nodurile terminale însă, pot conține una sau mai multe specificări de caracteristici.




Fig.1. Descrierea ierarhică într-un model morfologic

Pentru fiecare valoare a caracteristicii dintr-un nod neterminál există cîte un nod succesor. În funcție de criteriul de selecție a succesorilor, aplicat la traversarea unui nod neterminál, distingem noduri de tip CHOOSE sau de tip FOREACH.

Parcurgerea unui nod CHOOSE impune selecția unui singur succesor s_i , includerea perechii (caracteristică : valoare_i) în descrierea paradigmatică curentă și generarea în continuare a descrierii pentru subarborele dominat de s_i .

Prin traversarea celei mai lungi căi, ce pleacă din nodul rădăcină și care este formată numai din noduri CHOOSE se obține selectorul unei descrieri paradigmatic.

Pentru exemplul din figura anterioară expresiile următoare:

- a) (PV = SB) AND (TIP = COMUN) AND (GEN = FEM)
- b) (PV = VB)

sînt selectori.

Un selector astfel format reprezintă primul nivel în ierarhia descrierii paradigmatic.

Parcurgerea unui nod FOREACH impune selecția pe rînd a fiecărui succesor s_j ($j = 1$, ordin nod), includerea perechii (caracteristică : valoare_j) pe același nivel în ierarhia descrierii paradigmatic și generarea în continuare a descrierii pentru subarborele dominat de s_j . În figura un nod FOREACH este scos în evidență prin trasarea unei linii curbe peste arcele divergente din nod.

Descrierea atașată unui nod terminal este reprezentată

de un scenariu de achiziție morfologică. Un astfel de scenariu se construiește pe baza produsului cartezian al mulțimilor obținute prin expandarea perechilor (caracteristică : valoare⁺). Expandarea se face astfel încît pentru o pereche (caract_i; val_{i1}, val_{i2}... val_{ik})

să se obțină multimea:

{(caract_i; val_{i1}), (caract_i; val_{i2}), ... (caract_i; val_{ik})}

Unei intrări dintr-un scenariu (numită în continuare slot) îi este atașată o descriere morfologică, ce corespunde de fapt unui punct în spațiul paradigmatic al descrierii.

Pentru specificațiile din Fig.1, în contextul generării descrierilor conform celor prezентate, se vor obține următoarele descrieri paradigmatic:

PV = SB & TIP = COMUN & GEN = FEM

NR = SG

ART	CAZ	WORD_FORM
NU	N/A	
NU	G/D	
DA	N/A	
DA	G/D	

NR = PL

...

PV = VB

MOD = IND

TIMP = PZ

NR	PER	WORD_FORM
SG	1	
SG	2	
SG	3	
PL	1	
PL	2	
PL	3	

TIMP = IMPF

...

TIMP = VIIT

...

MOD = CJ

Fig.2. Meniuri de achiziție morfologică

Ultima coloană din fiecare scenariu (numita WORD_FORM) este adăugată automat de către sistem și permite lexicografului inserarea formelor flexate ale paradigmiei atașată cuvîntului curent.

Construirea unui model morfologic se face cu ajutorul unui limbaj adecvat [Dumitrescu, 1991a]. În acest limbaj există declarații speciale ce permit descrierea unui arbore de tipul celui descris.

Caracteristicile ultimei coloane dintr-un scenariu sînt specificate înaintea descrierii arborelui printr-o declarație de formă:

WORD_COLUMN = ("WORD_FORM", n)

unde n este lungimea cuvintului maxim ce va fi introdus în lexicon.

În urma compilării modelului morfologic se poate obține un raport lexicografic, la solicitarea explicită a lexicologului, ce va conține printre altele și meniurile de achiziție morfologică.

După prezentarea completă a descrierilor paradigmatici, în dezvoltarea modelului morfologic urmează etapa în care se stabilesc specificările de caracteristici implicate atașate fiecărei descrieri.

Selectoarelor de descrieri paradigmatici care acceptă specificări de caracteristici implicate li se pun în corespondență perechile (caracteristica: valoare⁺) ce sunt considerate ca implicate.

În exemplul nostru este posibilă următoarea asociere:

(PV = VB) --- (PER : 1 2 3)

și are următoarele semnificații:

a) perechea (PER : 1 2 3) se va atașa ca o proprietate a nodului ce conține perechea (MOD: IND CJ ... GER).

În cazul general proprietatea se atașează succesorului ultimului nod din calea ce definește selectorul.

b) proprietatea este globală subarborelui dominat de nod;

c) sloturile (generate la nivelul subarborelui) cărora le corespund puncte din spațiul descrierii paradigmatici ce nu conțin explicit caracteristica PER vor moșteni perechea (PER : 1 2 3).

d) pentru sloturile care conțin descrieri locale ale caracteristicii PER, proprietatea este inhibată.

În zona din modelul morfologic unde sunt descrise corespondentele (lema - intrare în descriere paradigmatică) sunt enumerate punctele din spațiile paradigmatici ale descrierilor ce characterizează cimpul lema din intrarea în lexicon.

Necesitatea cimpului lema apare evidentă în contextul problemei traducerii automate. Lexiconul monolingv trebuie privit în această situație ca o componentă într-o organizare bilingvă a lexicanelor (lexicon monolingv sursă, lexicon monolingv țintă și lexicon de transfer) [Tufiș, 1990c]. La nivelul lexiconului de transfer se manipulează doar leme, analiza cuvintelor și generarea formelor flexate fiind rezolvate la nivelul lexiconului sursă și respectiv țintă.

În ultima etapă din descrierea unui model morfologic, lexicologul are posibilitatea de a informa sistemul cum să construiască paradigmale flexionare și regulile de detecție a rădăcinilor.

Pentru fiecare descriere paradigmatică (identificată printr-un selector) lexicologul poate specifica mai multe mulțimi de terminații. Deoarece fiecare terminație dintr-o mulțime va corespunde unui slot din descrierea paradigmatică, vom numi o astfel de mulțime "familie paradigmatică de terminații".

O primă decizie luată de sistem, la interpretarea unei astfel de familii, se referă la memorarea terminațiilor. Terminațiile sunt organizate arborescent într-o structură *trie*. O astfel de structură este convenabilă identificării unei terminații, parcursarea arborelui fiind coordonată de caractere preluate de la sfîrșitul

cuvintului.

Nodurile terminale (care nu sunt neapărat frunze) au asociate puncte din spațiul descrierilor paradigmatici ce caracterizează terminațiile definite de nodurile respective.

Tot dintr-o familie paradigmatică de terminații sistemul construiește paradigmale flexionare. O paradigmă flexionară este o familie paradigmatică îmbogățită cu descrierile morfologice corespunzătoare terminațiilor. Pentru limba română au fost identificate 136 de paradigmă flexionare ([Tufiș, 1990a], [CPCOCLN, 1982]).

Pe baza paradigmelor flexionare, sistemul determină regulile de detectie a rădăcinilor și de generare a cuvintelor.

O astfel de regulă are următoarea formă:

<inflexiune> ↔ [<paradigma_flexionară> <număr_slot>]
și îi corespund următoarele interpretări:

a) dacă un cuvînt se termină cu <inflexiune> atunci
- rădâcina este ceea ce rămîne din cuvînt după ce s-a înălțurat inflexiunea <inflexiune>;
- rădâcina aparține paradigmelor <paradigma_flexionară>;
- informațiile contextuale valabile pentru cuvîntul curent sunt date de <număr_slot>.

b) dacă un cuvînt aparține paradigmelor <paradigma_flexionară> și cuvîntul este folosit în contextul dat de <număr_slot> atunci
- cuvîntul se obține din concatenarea rădăcinii date, cu inflexiunea <inflexiune>.

Interfața lexicografului este strict dependentă de specificațiile din interfața lexicologului, întrucît o mare parte din interfață de dialog a lexicografului este construită automat pe baza acestor specificații.

Dîndu-se o specificare compilată a modelului morfologic definit de lexicolog, MORPHO-2 poate genera un dialog care ghidează lexicograful, prin navigarea structurilor ierarhice, către identificarea descrierilor morfologice și a regulilor flexionare care trebuie activate la construirea unei noi intrări în lexicon.

3. Interfața Lexicografului

MORPHO-2 oferă lexicografului posibilitatea de a defini noi intrări în lexicon pe baza unui regim conversațional orientat pe lucrul cu ferestre.

O intrare în lexicon are următoarea structură:

(<lema>
 (<selector_descriere_paradigmatică>
 <paradigmă_flexionară>
 (<rădăcină> <descriere_morfologică>)*
 (<descriere_sintactică> <descriere_semantică>)*
)
)

În descrierea de mai sus cimpurile <lema> și <selector_descriere_paradigmatică> au înțelesul

evidență.

Lexicograful poate specifica identificatorul paradigmelor flexionare de care aparțin rădăcinile curente, prin selecția paradigmelor corespunzătoare din cele care îi sunt propuse de către sistem. În acest sens lexicograful poate consulta raportul obținut în urma compilării modelului morfologic sau poate activa o fereastră în care sistemul va pune la dispoziție paradigmile posibile pentru lema și partea de vorbire specificate.

Dacă nu există o astfel de paradigmă, MORPHO-2 solicită lexicografului specificarea unei noi paradigmă ce urmează a fi inserată în lexicon.

Cimpul <rădăcina> poate conține una sau mai multe rădăcini. Trebuie subliniat că în abordarea noastră ([Tufiș, 1989], [Tufiș, 1990c]), rădăcina este definită ca partea cea mai lungă din cuvânt care este stabilă în raport cu o paradigmă flexionară.

Comenzile accesibile lexicografului în această fază permit două moduri de operare: inserarea de rădăcini fără controlul sistemului și inserarea supervizată de sistem.

Primul mod de lucru este selectat în cazul cuvintelor regulate, cind este suficientă specificarea unei singure rădăcini. Pe baza paradigmelor flexionare și a rădăcinii, sistemul poate genera toate formele flexionare.

Al doilea mod de lucru este activat în cazul cuvintelor neregulate, cind sistemul, prin intermediul scenariilor de achiziție morfologică, va solicita pe rînd rădăcinile neregulate. Pentru a ușura sarcina lexicografului, sloturile sunt deja completeate cu terminațiile corespunzătoare.

Înserarea rădăcinilor în lexicon se face astfel încât acestea să mostenească descrierile morfologice corespunzătoare sloturilor unde apar. Pentru rădăcinile care au atașate mai multe descrieri morfologice, sistemul încearcă o compactare a acestora.

Cimpul <descriere_sintactică> conține referințe către şabioane sintactice (modele de valență), care guvernează utilizarea corectă a cuvîntului în frază [Tufiș, 1991].

În continuare, pentru fiecare descrierea sintactică, lexicograful poate furniza una sau mai multe descrieri semantice. Cimpul <descriere_semantică> conține numele unei structuri cadru plasată într-o ierarhie de tipul generic-specific. Descrierile semantice propriu-zise sunt memorate într-un spațiu de date separate de lexicon [Nirenburg, 1987], iar gestiunea acestora este independentă de MORPHO-2.

În abordarea noastră, lexicografului i se creează posibilitatea de a specifica descriptorii semantici în colaborare cu proiectantul sistemului întărit de prelucrare a limbajului natural, în conformitate cu categoriile utilizate de sistemul de prelucrare semantică. În acest mod, se asigură o independentă între sistemul de gestiune a lexicoanelor, ca o unealtă lingvistică de bază și un lexicon specific unei anumite aplicații.

Sistemul mai pune la dispoziția lexicografului comenzi pentru ștergerea, modificarea unei intrări în lexicon și listarea acestora, în conformitate cu diverse cereri ce

vizează cimpurile unei intrări [Dumitrescu, 1991b].

4. Interfața Procesorului Tintă

Procesorul Tintă este beneficiarul proceselor lexicale execuțiate de MORPHO-2. Analiza și sinteza cuvintelor sunt servite mediate de o interfață de proces.

În cazul analizei lexicale, dacă acestei interfețe î se da o secvență de cuvinte, atunci aceasta întoarce o secvență de atomi lexicali. Structura unui astfel de atom este prezentată mai jos.

```
(<rădăcina>
  (<lema>
    (<selector_descriere_paradigmatică>
      <descriere_morfologică>
        (<descriere_sintactică> <descriere_semantică>)*
    )
  )
)
```

O descriere morfologică conține atât informații contextuale, cît și informații independente de context. Primele sunt obținute din analiza terminației, iar cele din urmă din intrarea din lexicon corespunzătoare rădăcinii. Informațiile pentru celelalte cimpuri din structura unui atom sunt de asemenea preluate din intrarea din lexicon corespunzătoare rădăcinii.

În raport cu rezultatul congruentei morfologice și al regăsirii rădăcinii în lexicon, putem clasifica atomii lexicali ca fiind univoci, ambigu sau nedeterminați.

Atomii lexicali univoci pun în corespondență unui cuvînt analizat o singură lema.

Atomii lexicali ambigu provin din cuvintele cărora li se pot pune în corespondență mai multe leme. În acest caz, unei rădăcini îi corespund, fie mai multe leme, fie cuvîntul, avînd mai multe segmentări posibile și rădăcinile respective corespund unor leme diferite.

Asocierea unei rădăcini cu mai multe leme este posibilă fie datorită părților de vorbire diferite (ex: *vin* poate fi substantiv sau verb), fie datorită homografiilor aparente, generate de absența în grafia limbii române a marcatorilor prozodici (módele, modele, tórturi, tortúri, acéle, ácele, modúl, módul etc.).

Interpretările posibile sunt astfel ordonate, încât prevalează cele care provin din rădăcini mai scurte (deci terminații mai lungi).

Pentru o rădăcină care corespunde unei leme și are mai multe descrieri morfologice posibile pentru aceeași parte de vorbire, sistemul încearcă o compactare a acestor descrieri.

Atomii lexicali nedeterminați corespund cuvintelor pentru care nu există intrări în lexicon. Atomii generati în această situație au următoarea structură:

```
(UNKNOWN<cuvînt_necunoscut>
  (<rădăcina_posibilă> <descriere_morfologică>*))
```

Cuvîntului necunoscut și sunt asociate toate segmentările legale, pentru fiecare dintre ele fiind inserată informația morfologică dedusă din terminațiile identificate.

Sinteză lexicală este reversul analizei lexicale. Interfață de proces asigură transformarea unei sevențe de atomi lexicali într-un șir de cuvinte.

Spre deosebire de analiză, pentru sinteză MORPHO-2 solicită o descriere standard a atomilor lexicali sub forma:

(<identificator_intrare> <descriere_morfologică>

<descriere_sintactică>)

unde <identificator_intrare> poate fi o lema, o rădăcină, sau o descriere semantică.

Trebuie să subliniem că, într-o fază premergătoare analizei și sintezei lexicale, pe baza unui protocol de comunicație, procesorul țintă poate configura structura atomilor lexicali în raport cu aplicația proiectată.

5. Implementare

Proiectul MORPHO, început în 1986, a avut ca prim rezultat realizarea unei versiuni prototip [Tufiș,1990b] operațională în momentul de față pe un calculator compatibil PDP-11. Versiunea a doua a sistemului, cea prezentată în lucrarea de față, este implementată în C pe un calculator personal de tip IBM-PC.

Tehnicile utilizate în implementare, de indexare a lexicoanelor cu ajutorul arborilor de tip B⁺ virtual prefață [Dumitrescu,1988] precum și de grupare a datelor în structuri "cluster", au dus la obținerea unui timp mediu de răspuns al proceselor lexicale, care să nu se schimbe semnificativ în raport cu creșterea dimensiunii lexiconului.

Bibliografie

-[CPCOCLN,1982]-Cercetări privind comunicarea om-calculator în limbaj natural, Raport final la contractul de cercetare ICI - Universitatea Al.I.Cuza-Iași, 1982.

-[Dumitrescu,1988] - DUMITRESCU, C.- O metodă

de memorare și adresare pe baza arborilor B+ virtual prefață, Raport tehnic, I.C.I., București, 1988.

-[Dumitrescu,1991a] - DUMITRESCU, C.- Limbaj de descriere a categoriilor gramaticale, Raport tehnic, București, 1991.

-[Dumitrescu,1991b]- DUMITRESCU,C.- MORPHO-2 Manual de utilizare, I.C.I., București, 1991.

- [Domenig,1986] - DOMENIG, M., SKANN, P.

-Towards a Dedicated Data Base Management System for Dictionaries. In: Proceedings of COLING'86 Conference, Bonn, 1986, pp.91-96.

- [Domenig,1988] - DOMENIG, M.- Word Manager: A System for the Definition, Access and Maintenance of Lexical Data Bases. In: Proceedings of COLING'88, Budapest, 1988, pp.154-159.

- [Nirenburg,1987] - NIRENBURG, S., RASKIN, V.

-The Subworld Concept Lexicon and the Lexicon Management System. In: Computational Linguistics, Vol.13, No.3-4, 1987, pp.270-289.

- [Tufiș,1987] - TUFIȘ, D., DUMITRESCU, C. -O abordare paradigmatică a problematicii dicționarelor, Simpozionul "Aplicațiile inteligenței artificiale", București, 1987.


- [Tufiș,1989] - TUFIȘ, D.- It Would Be Much Easier if WENT Were GOED. In: Proceedings of ECACL'89, Manchester, 1989, pp.145-152.

- [Tufiș,1990a] - TUFIȘ, D.- Paradigmatic Morphology Learning.; In: Computers and Artificial Intelligence, Vol.9, No.3, 1990, pp.273-290.

- [Tufiș,1990b] - TUFIȘ, D., DUMITRESCU, C.- MORPHO - A Dictionary Management System; In: Proceedings of the 13th International Seminar on DBMS, Mamaia, 1990.

- [Tufiș,1990c] - TUFIȘ, D., DUMITRESCU, C., POPESCU, O.- Morfologia și dicționarul; Raport tehnic, București, 1990.

- [Tufiș,1991] - TUFIȘ, D., DUMITRESCU, C., POPESCU, O.- Teorii sintactice în lingvistica computațională, Studiu, București, 1991.



Institutul de Cercetare în Informatică

vă prezintă

Centrul Regional de Automatizare **SIEMENS**

Soluțiile cele mai moderne de automatizare

- urmărirea și conducerea producției;
- supravegherea și automatizarea instalațiilor și utilajelor în diverse ramuri economice;
- rețele industriale;
- sisteme distribuite pentru automatizări complexe;
- verificarea automată a calității produselor.

Echipamentele fiabile din gamele SIPART (regulatoare compacte), SIMATIC S5 (automate programabile), AS (calculatoare de proces), SICOMP PC (calculatoare compatibile IBM-PC pentru uz industrial), rețelele performante pentru aplicații industriale, precum și gama largă de traductoare și elemente de execuție conferă siguranță în exploatare și flexibilitate în alegerea configurațiilor optime. Programe de aplicație specializate precum și alte echipamente produse de firma **SIEMENS** completează sistemele de automatizare proiectate de noi.

Nu uitați !

**PENTRU ORICE PROBLEMĂ A DVS., SOLUȚIA
NOASTRĂ POATE FI CEA MAI BUNĂ, CEA MAI
IEFTINĂ, CEA MAI RAPIDĂ!**

Contactați-ne pe adresa:

B-dul Mareșal Averescu 8-10, Sector 1, cod 71316, București, ROMÂNIA
Tel. 66.58.05 (direct) sau 65.60.60, int. 277,286; Telex 11891; Fax 65.30.95