

Conjugate, decline and spell like years ago

A corpus-based morphological analyzer of 19th century Polish

Joanna Bilińska Witold Kieraś Magdalena Derwojedowa

Chair of Formal Linguistics

Institute of Polish Language
University of Warsaw



Slavic Diachronic Corpus Linguistics Conference
Tromsø, April, 21-22, 2015

The project

Automatic morphological analysis of Polish texts from 1830-1918 period with respect to evolution of inflection and spelling, grant awarded by Polish National Science Centre (DEC-2012/07/B/HSS/00570)

2013-2016

<http://www.f19.uw.edu.pl>




Motivation

- growing interest in NLP of old(er) Polish
- availability of adaptable tools
- extensive, detailed inflectional description of Polish
- computer-readable text from the period




A diachronic morphological analyzer in three steps



--
| | I
-- , --
. . . fXIX_ . |
. . . ()

The corpus



Samples collected per style

- 5 stylistic subcorpora, 200,000 segments each
- 5-13 samples/year (at least one sample of each style per year)
- more than 500 authors (inc. 119 anonymous), 480 books, 135 newspapers & magazines, 54 digital libraries
- repository ownCloud
- downloadable at <http://www.f19.uw.edu.pl/>



The good, the bad and the ugly: excerpting samples

- stroke of luck: a text in original spelling and inflection
- time machine: aging a text from modern edition with original spelling and forms (a trick for poor quality scans)
- everyday humdrum: OCR of the digital scans (Fine Reader, tesseract)
- bad luck: typing in a text (good text, no contemporary re-editions, poor scan)

Jako bezwarunkową tezę stawiam:

„Ropa w Galicyi, gdziekolwiek takowa występuje, znajduje się na powtórkiem złożysku” (sekundärer Lagerstätte) i jest skutkiem suchej destylacji z wielkiej ilości nagromadzonych szczątków organicznych, zawartych w starszych warstwach, jak są dotychczas w Karpatach znane pokłady luźnego bitumicznego utworu neokomskiego.

Wielu innych wyjątków odrzuści! Ależ gdy z drugiej strony, swajakim chciwości wielu dzierżawców, niektórych dziedziców, mianowicie spekulantów, kupujących dobra bez pieniędzy, którzy w folwarkach, gdzie w porównaniu pól dworskich, pańszczyzna jest zamala, nie chcąc wydawać na najem, a pragnąc przez wyciągnięcie iatrat wyjść z interesów, nieraz

Good and poor quality scans.

A sample and metadata

Jako bezwarunkową tezę stawiam: „Ropa w Galicyi, gdziekolwiek takowa występuje, znajduje się na powtórnem złożysku” (sekundäre Lagerstätte) i jest skutkiem suchej destylacji z wielkiej ilości nagromadzonych szczątek organicznych, zawartych w starszych warstwach, jak są dotalyczczas w Karpatach znane pokłady łupku bitumicznego utworu neokomskiego.

autor: Olszewski, Stanisław
tytuł: Przyczynek do teoryi pochodzenia i występowania nafty w Galicyi
data wydania: 1881
miejsce wydania: Lwów
redaktor: Radziszewski, Br.
tytuł książki:
tytuł gazety, czasopisma, serii wydawniczej: Kosmos. Czasopismo Polskiego Towarzystwa Przyrodników im. Kopernika
nr: R. 6
wydawnictwo: nakł. Polskiego Towarzystwa Przyrodników im. Kopernika
numery stron: 524-527
styl: popularnonaukowy
źródło: Śląska Biblioteka Cyfrowa
link: <http://www.sbc.org.pl/dlibra/docmetadata?id=20199>
uwagi: nie ma w HINT, chemia?



A sample: in yellow — 19 c. forms,
underlined — alien elements.

The dictionary

Hasło	Część mowy	Rodzaj/aspekt
podbieg	subst	m3
podbiegać	v	ndk
podbiegający	pect	ndk
podbieganie	ger	ndk
podbiegły	adj	
podbiegać	v	dk
podbiegnięcie	subst	n2
podbiegnięcie	ger	dk
podbiegunowość	osc	f
podbiegunowy	adj	
podbiełać	v	ndk
podbielający	pect	ndk
podbielanie	ger	ndk
podbielany	ppes	ndk
podbielenie	ger	dk
podbielić	v	dk
podbielony	ppes	dk
podbielacz	subst	m1
podbierać	v	ndk

Wszystkie formy | Formy bazowe
przymiotnik [SJPor.]
P4

	I. p.					I. m.		
	m1	m2	m3	n1,n2	ż	p1	m1 ndepr depr	pozostałe
M./(W.)	podbiegunowy		podbiegunowe	podbiegunowa	podbiegunowi	podbiegunowe		
D.	podbiegunowego		podbiegunowej	podbiegunowej	podbiegunowych			
C.	podbiegunowemu		podbiegunowej	podbiegunowym	podbiegunowym			
B.	podbiegunowego	podbiegunowy	podbiegunowe	podbiegunową	podbiegunowych	podbiegunowym		
N.	podbiegunowym		podbiegunową	podbiegunowymi	podbiegunowymi			
Ms.	podbiegunowym		podbiegunowej	podbiegunowych	podbiegunowych			
Złoz.	podbiegunowo+							

Odsyłacze
nazwa cechy podbiegunowość
przymiotnik „zanebowy” niepodbiegunowy

PODBIEGUNOWY 'polar' in *Grammatical dictionary of Polish*
("Słownik gramatyczny języka polskiego", Saloni et al. 2012)


<http://www.sjgp.pl/kuznia/slownik/>

The analyzer for modern Polish

```
Morfeusz analyzer, version: 1.9.0
Setting dictionary search path to: .
Using dictionary: sgjp (default)
Utwór iłów solnych odznacza się mniejszemi ilościami zazwyczaj cięszszej
[0,1,Utwór,utwór,subst:sg:acc:m3,pospolita,_
 0,1,Utwór,utwór,subst:sg:nom:m3,pospolita,_]
[1,2,iłów,ił:s1,subst:pl:gen:m3,pospolita,geol.
 1,2,iłów,ił:s2,subst:pl:gen:m2,pospolita,_
 1,2,iłów,ił:s2,subst:pl:gen:m3,pospolita,_
[2,3,solnych,solny,adj:pl:acc:m1.p1:pos,_
 2,3,solnych,solny,adj:pl:gen:m1.m2.m3.f.n1.n2.p1.p2.p3:pos,_,_
 2,3,solnych,solny,adj:pl:loc:m1.m2.m3.f.n1.n2.p1.p2.p3:pos,_,_]
[3,4,odznacza,odznaczać,fin:sg:ter:imperf,_,_]
[4,5,się,sie,qub, , ]
[4,6,mniejszemi,mniejszemi,ign, , ]
[6,7,ilosciami,ilość,subst:pl:inst:f,pospolita,_
[7,8,zazwyczaj zazwyczaj,adv,_,_]
[8,9,cięszszej,cięszszej,ign, ]
```

A string from a sample analyzed by *Morfeusz 2.0* (Woliński, 2014)
with SGJP-based lexicon. Marked not analyzed 19c. forms.

The performance of non-modified analyzer on 1830-1918 corpus



Modifications

1 † slab y Wybierz × +

2 † slab ego Wybierz × +
† slab égo SGJP: daw. × +

3 † slab emu Wybierz × +

3+ † slab u Wybierz × +

4 † slab ym Wybierz × +
† slab ém SGJP: daw. × +
† slab em SGJP: daw. × +

5 † slab e Wybierz × +

6 † slab a Wybierz × +

7 † slab ej Wybierz × +
† slab éj SGJP: daw. × +

8 † slab a Wybierz × +

9 † slab i Wybierz × +

10 † slab ych Wybierz × +

11 † slab emi SGJP: daw. × +
† slab émi SGJP: daw. × +
† slab ymi Wybierz × +

Kuźnia (Smithy) editor

Days of future past: modified lexicon

- 1 podbiegunowy
- 2 podbiegunowego
- 3 podbiegunowemu
- 4 podbiegunowym
- 5 podbiegunowe
- 6 podbiegunowa
- 7 podbiegunowej
- 8 podbiegunową
- 9 podbiegunowi
- 10 podbiegunowych
- 11 podbiegunowymi
- 12 podbiegunowo+

2 G/A masc sg

4 I masc sg

7 D/C/L/V fem sg

11 I pl

- 1 podbiegunowy
- 2 podbiegunowego
- 3 podbiegunowemu
- 4 podbiegunowym
- 5 podbiegunowe
- 6 podbiegunowa
- 7 podbiegunowej
- 8 podbiegunową
- 9 podbiegunowi
- 10 podbiegunowych
- 11 podbiegunowymi
- 12 podbiegunowo+




Wavering instrumental

Kopczyński (1780) differentiate between instrumentalis of masculine and neuter:

	<i>sg</i>	<i>pl</i>
<i>masc</i>	y m	y mi
<i>neut, fem</i>	e m	e mi



Distribution of instrumental endings across genders




Applications

- part-of-speech tagging,
- tracing dynamics of language change (spelling and inflection)
- following adaptation stages of loanwords
- marking neologisms/disused/obsolete words with date




Example: dynamics of é



-- --
I I I
-- --
. . . fXIX . .
. . . 0

Example: *ge:gie:je* alternations



Distribution of *je:gie:ge* spelling



References

- DERWOJEDOWA M., KIERAŚ W., SKOWROŃSKA D. i Wołosz R., *Współczesne narzędzia leksykograficzne a analiza tekstów dawniejszych*, „Polonica”, t. XXXIV s. 21–27 2014a.
- DERWOJEDOWA M., KIERAŚ W., SKOWROŃSKA D. i Wołosz R., *Zasób leksykalny polszczyzny II poł. XIX wieku a możliwość automatycznej analizy morfologicznej tekstów z tego okresu*, [w:] *Leksyka języków słowiańskich w badaniach synchronicznych i diachronicznych*, red. M. GĘBKA-WOLAK, J. KAMPER-WAREJKO i A. MOROZ, s. 183–195, 2014b.
- DERWOJEDOWA M., SKWROŃSKA D. i KIERAŚ W., *Korpus polszczyzny XIX wieku – od mikrokorpusu do korpusu średniej wielkości*, „Prace Filologiczne”, s. 249–254 2014c.
- KOPCZYŃSKI O., *Gramatyka dla szkół narodowych*, I wyd., Warszawa 1780.
- SALONI Z., WOLIŃSKI M., Wołosz R., GRUSZCZYŃSKI W. i SKOWROŃSKA D., *Słownik gramatyczny języka polskiego*, I wyd., Warszawa 2012, CD.
- WOLIŃSKI M., *Morfeusz Reloaded*, [w:] *Proceedings of the Ninth International Conference on Language Resources and Evaluation, LREC 2014*, red. N. CALZOLARI, K. K. CHOUKRI, T. DECLERCK, H. LOFTSSON, B. MAEGAARD, J. MARIANI, A. MORENO, J. ODijk i S. PIPERIDIS, s. 1106–1111, ELRA, Reykjavík, Iceland 2014, ISBN 978-2-9517408-8-4, URL <http://www.lrec-conf.org/proceedings/lrec2014/index.html>.

<http://www.f19.uw.edu.pl/>

funded by the Polish National Science Centre
grant DEC-2012/07/B/HS2/00570

