



Using language corpora and wordnets in the translator's work: pros and cons

Łukasz Grabowski
University of Opole (Poland)

Translating Europe Workshop
23.05.2018, Warsaw

Plan of my talk

- Introduction
 - Language corpora
 - Wordnets
- Using language corpora in the translator's work
 - Parallel corpora
 - Monolingual reference corpora
- Using wordnets in the translator's work
 - Polish wordnet (*Słowosieć*) mapped onto Princeton WordNet of English
- Conclusions

What are language corpora?

- Custom-designed **collections of authentic linguistic data (texts)**, either **written texts** or **transcriptions of recorded spoken data**
- Compiled according to a number of criteria
 - Size
 - Text availability / copyright
 - Representativeness
 - Balance
 - Computer-readable format

Language corpora for translators

- Language corpora specifically designed for translators may include:
 - **originals and translations**
 - **Parallel corpora**
 - proved to be of great value for translators (Google Translate, TAUS Data Association, Linguee, Reverso Context etc. are all built on parallel corpora)
 - **Professional translators are more familiar with parallel search (or parallel concordancing) feature of translation memory systems (TMs)**
 - **non-translations** (i.e. native texts written originally in a given language)
 - **monolingual reference corpora**
 - **texts in different languages**
 - **originals and translations in the same language, or**
 - **only native texts originally produced in different languages)**
 - **bilingual and monolingual comparable corpora**
 - primarily used for research purposes (Descriptive Translation Studies)

Why should translators bother with language corpora?

- **Corpus as a source of linguistic information** helps to answer various questions related to how we use language
 - across genres, text types and registers
 - adherence to discourse norms and conventions of text production in the target language and culture is essential in translation
 - this information is implicitly recorded in texts collected in language corpora
 - particularly important when translators deal with creative and stylistically varied texts (rather than cliched and highly-repetitive ones)
- Corpora enable the translators to go beyond their linguistic intuition
 - linguistic preferences of translators, in particular those rendering texts into a target language which is not their native one, may not always coincide with the native speakers' preferences
- Corpora may help activate the translators' memory of relevant contexts of use of words and expressions (Pęzik 2017)
 - Lexical priming theory (Hoey 2005)

Monolingual reference corpora

Examples

- *British National Corpus*
- *Corpus of Contemporary American English*
- *Narodowy Korpus Języka Polskiego*
- *Национальный корпус русского языка*
- *English Web 2015 (enTenTen15)*
- *Polish Web 2012 (plTenTen12)*
- *Russian Web 2011 (ruTenTen11)*
- Monco (<http://monitorcorpus.com/>)
 - a collection of English texts updated on a regular basis (circa 11 billion words, as of 9 May 2018)
- Frazeo (<http://frazeo.pl>)
 - an innovative search engine of press articles published on Polish news portals

OPUS Project

Open Source Parallel Corpus

Tiedemann (2009), <http://opus.nlpl.eu/>

Home | Query | Workshop | Wiki | Posts | [DOI] | [DOCC] | [CB] | [BMLA] | [TBossard] | [EUS] | [Europarl] | [GNOME] | [Statistical] | [BMT] | [KDE4 doc] | [BDB] | [Montaigne] | [MultiN] | [NC-9-11] | [OO-OO]

OPUS ... the open parallel corpus

OPUS is a growing collection of translated texts from the web. In the OPUS project we try to convert and align online data, add linguistic annotation, and to provide the community with a publicly available parallel corpus. OPUS is based on open source products and the corpus is also delivered as an open content package. We used several tools to compile the current collections. All processing is done automatically. No manual corrections have been carried out.

The OPUS collection is growing! Check this page from time to time to see new data arriving...

Contributions are very welcome! Please contact sieg.tiedemann@tuhh.de.

Search & download resources | select |

... | select |

| all |

Search & Browse

- OPUS multilingual search interface
- Europarl v1 search interface
- Europarl v3 search interface
- European Parliament search interface
- ECLib search interface
- Word Alignment Database (old DB)

Tools & Info

- OPUS Wiki
- OPUS API by Yanneth Koenen
- Upgr at http://bucket

Some Projects using OPUS

- [LwMT++](#) - On-line SMT toolkit
- [CASSIACAT](#) - Computer Aided Translation

Sub-corpora (downloads & info):

- Books - A collection of translated literature (Books tar.gz - 535 MB)
- DOT - A collection of EU Translation Memories provided by the ITC
- DOCC - Documents from the Catalan Government (DOCC.tar.gz - 2.3 GB)
- EUD - European Union Delegations (EUD.tar.gz - 1.0 GB)
- EMEA - European Medicines Agency documents (EMEA.tar.gz - 13.0 GB)
- The EU bookshop corpus (EUbookshop.tar.gz - 42 GB)
- EURLEX - European Union Legislative acts (EURLEX.tar.gz - 12 MB)
- EUROPARL v.7 - European Parliament Proceedings (Europarl.tar.gz - 20 GB)
- GNOME - GNOME localizations files (GNOME.tar.gz - 9 GB)
- Giga - Gigaword 2003 (Giga.tar.gz - 1.2 GB)
- The Croatian - English W4C corpus (CroatW4C.tar.gz - 59 MB)
- JRC-Acquis - legislative EU texts (JRC-Acquis.tar.gz - 11 GB)
- UD-treebank - Universal Dependencies treebanks (UD-treebank.tar.gz - 1.5 GB)
- KDEde - the KDE manual corpus (KDEde.tar.gz - 45 N)
- MBS - Belgisch Staatsblad corpus (MBS.tar.gz - 1.5 GB)
- Monolinguals - Monolingual news articles

- Collection of translated texts from the web
- Free online data
 - Based on open-source products
 - Delivered as an open content package
 - Downloadable in many formats, including TMX
- The corpus contains medical texts, legal texts, software documentation, subtitles etc.

Paralela

(Pęzik 2016)

Lp	Polish	English
1	"Zródł em każdego dzisiejszego wybuchu epidemii jest potomek średniowiecznej dzumy"	'Every outbreak across the globe today stems from a descendant of the medieval plague'
2	A jednak był te fakty niezwykły - jakkolwiek nie podobało mu się to, aby wiedzieć, że jego żona, Boundary edzied w over, poddała sobie kapelusz wówczas, ów spodnicy chodzący potomek Scadgersów	Yet it is an indubitable fact, within the cognizance of this history, . . . that five minutes after he had left the house in the self-same hat, the same descendant of the Scadgerses and his wife, Boundary, edzied in over, . . . showed her right-hand mittens at his portrait, made a contemptuous grimace at that work of art, and said 'Serve you right, you Noodle, and I am glad of it.'
3	ta paralela Pomerana, skróciła w kulej prawia swa rękę, wyciągnęła ja nieprzyzwyczajnie ku portretowi bankiera - i z pogardliwym grymasem patrząc na nią, wyciągnęła sztuki, zawiązła - Dobraż o tak, stary durniu!	Hard Times - For These Times

- An English-Polish and Polish-English parallel corpus
 - It includes **262 million words in 10,877,000 translation segments** found predominantly in legal texts
 - EU legislation, proceedings of the European Parliament etc.), press releases, medical texts (provided by the EMA) as well as film subtitles
 - Translation segments are aligned at the sentence level (Pęzik 2016: 70), with **5.3% of the segments aligned manually.**

Everything in one place

SketchEngine (Kilgarriff et al. 2014)

<https://www.sketchengine.co.uk/>

The screenshot shows the SketchEngine web interface. On the left, there's a sidebar with links for 'Create corpora', 'WebDocumentCat', 'Upload TCM or XLS', 'Parallel corpora', 'Compare corpora', 'My jobs', 'Advanced features', 'Genre categories', 'Stemming grammars', 'Stopword definitions', 'GDEX configurations', 'User groups', 'Subscription overview', 'Admin', and 'Support' (which is currently selected). The main area is titled 'Corpora' and shows a table of available corpora. The columns are 'Name', 'Words', and 'Actions'. The table includes entries for Afrikaans, Albanian, Arabic, Bosnian, Bulgarian, Chinese Simplified, Chinese Traditional, Croatian, Czech, Danish, Dutch, English, French, German, Greek, Hebrew, Italian, Japanese, Korean, Latvian, Lithuanian, Norwegian, Polish, Portuguese, Romanian, Russian, Spanish, Swedish, Turkish, Ukrainian, Vietnamese, and Welsh. Each entry shows the number of words and a small icon.

- A software platform for text analysis and text mining applications
- Access to **aligned parallel corpora** of various text types and genres
- Access to many **large monolingual corpora** with texts extracted from the web
 - **Term extraction** (from subject-specific texts uploaded by users) and **bilingual term extraction** (performed on TMs uploaded by users)
- A possibility to create **subject-specific corpora**
 - By **uploading materials provided by users**
 - By **providing keywords and extracting relevant texts automatically from the web**

Example 1

- **Multi-word terms (nominalizations) extracted from a custom-designed corpus of car reviews (Top Gear)**
 - 100 texts (60,372 words)

Multi-word	Score	F	Reff
inside layout	W 1,385.85	100	0
all-wheel drive	W 230.43	17	3
hot hatch	W 206.09	16	9
driving position	W 167.12	15	28
four-wheel drive	W 155.95	17	58
six-speed manual	W 153.33	11	0
city car	W 149.45	11	3
cruise control	W 139.78	11	11
boot space	W 131.34	10	7
climate control	W 128.08	10	10
turbo engine	W 119.31	9	6
automatic gearbox	W 117.61	10	21
front-wheel drive	W 116.33	9	9
6-litre diesel	W 111.79	8	0
turbo petrol	W 111.79	8	0
petrol engine	W 108.42	12	61
fuel economy	W 104.16	12	68
steering wheel	W 102.21	19	178
body roll	W 101.90	8	11
wind noise	W 100.26	8	13
infotainment system	W 97.94	7	0
4-litre petrol	W 97.16	7	1
driving experience	W 97.12	8	17
engine range	W 96.30	7	2
manual gearbox	W 93.81	7	5
2-litre diesel	W 84.09	6	0
infotainment screen	W 84.09	6	0
trim level	W 83.42	6	1
material quality	W 83.42	6	1
centre console	W 79.86	6	6
base model	W 79.86	6	6
torsion beam	W 70.24	5	0
km co2	W 70.24	5	0
adaptive cruise	W 70.24	5	0
radar cruise	W 70.24	5	0

three-cylinder engine	W 70.24	5	0
boot floor	W 70.24	5	0
rear headroom	W 70.24	5	0
plug-in hybrid	W 70.24	5	0
blind-spot warning	W 70.24	5	0
head-up display	W 69.68	5	1
front end	W 69.26	10	114
5-litre diesel	W 69.07	5	2
six-speed gearbox	W 67.87	5	4
company car	W 67.49	11	143
ride quality	W 67.28	5	5
standard car	W 66.14	5	7
company car tax	W 65.59	5	8
sweet spot	W 64.50	5	10
list price	W 63.85	7	60
rear axle	W 58.34	5	23
old car	W 58.12	7	77
electric power	W 57.87	6	51
cross-traffic alert	W 56.39	4	0
eight-speed auto	W 56.39	4	0
air con	W 56.39	4	0
safety kit	W 56.39	4	0
collision mitigation	W 56.39	4	0
three-cylinder petrol	W 56.39	4	0
electric power steering	W 56.39	4	0
rear suspension	W 56.24	5	28
standard kit	W 55.95	4	1
supple ride	W 55.95	4	1
driving environment	W 55.45	4	2
5-litre turbo	W 55.45	4	2
handling balance	W 54.96	4	3
rear-wheel drive	W 54.96	4	3
6-litre engine	W 54.96	4	3
active safety	W 54.49	4	4

five-year warranty	W 54.49	4	4
rear legroom	W 54.02	4	5
low speed	W 53.95	5	34
standard equipment	W 51.50	5	41
electric motor	W 51.50	5	41
turning circle	W 50.17	4	14
drive system	W 50.17	4	14
car tax	W 49.64	6	78
big car	W 49.22	5	48
automatic transmission	W 45.81	4	26
big news	W 45.15	4	28
small car	W 44.51	5	65
diesel engine	W 43.89	6	103
front passenger	W 43.61	4	33
driver assist	W 42.55	3	0
reversing camera	W 42.55	3	0
practical car	W 42.55	3	0
dual-zone climate	W 42.55	3	0
instrument cluster	W 42.55	3	0
adaptive cruise control	W 42.55	3	0
dual-zone climate control	W 42.55	3	0
radar cruise control	W 42.55	3	0
small crossover	W 42.55	3	0
lane departure	W 42.55	3	0
autonomous emergency	W 42.55	3	0
five-door hatch	W 42.55	3	0
central infotainment	W 42.55	3	0
crossover market	W 42.55	3	0
seven-seat mpv	W 42.55	3	0
5-litre petrol	W 42.55	3	0
supple suspension	W 42.55	10	0

Example 2

- **Bilingual wordsketches**
 - matched headwords and collocations extracted from parallel corpora
 - *Declaration/deklaracja* preceded by modifiers in EUROPARL7, English and Polish

declaration	(noun)	EUROPARL7, English freq = 5,532 (91.07 per million)	deklaracja	(noun)	EUROPARL7, Polish freq = 1,620 (106.77 per million)
Use another candidate translation: pisemny oświadczenie patrzec niepodleglosc wpisac protokol skladac protokol rejestr					
Click on collocates to access reciprocal bilingual search or find translated collocations					
modifier			a_modifier		
written	236	52.62	powszechny	99	68.58
written declaration		10.46	Powszechniej Deklaracji Praw Czlowieka		10.27
Written	76	9.62	paryski	21	9.18
: see Minutes Written declarations included in the			deklaracji paryskiej z		
unilateral	77	9.16	jednostronny	26	9.12
unilateral declaration of independence			jednostronnej deklaracji niepodleglosci Kosowa		
joint	258	9.08	pisemny	47	9.09
a joint declaration			pisemna deklaracje		
solemn	53	9.08	golostowny	13	8.56
solemn declarations			golostowne deklaracje		
Lapsed	45	8.96	berliński	11	8.16
: see Minutes Lapsed written declarations : see Minutes			deklaracji berlińskiej		
Laeken	35	8.22	koñcowy	14	7.63
the Laeken declaration			deklaracji koñcowej		
mere	36	8.01	pusty	8	7.56
mere declarations of			krajowy	58	7.47
grand	19	7.55	krajowych deklaracji w sprawie zarzadzania		
the grand declarations			manhattański	6	7.45
final	79	7.50	wspólny	96	7.42
the final declaration			wspolnej deklaracji		
open	66	7.07	praski	6	7.42
the open declaration			jednoznaczny	8	7.29
formal	23	7.06	otwarty	12	7.25
a formal declaration			" otwartej deklaracji "		
Doha	17	6.98	samozwañczy	5	7.16
of the Doha declaration			uroczysty	5	7.07
non-binding	12	6.97	boloński	5	7.07
non-binding declarations			polityczny	60	6.85
fine	19	6.85	falszywy	5	6.82
fine declarations of			dauhański	5	6.79
ministerial	12	6.62	jasny	14	6.78
the ministerial declaration			milenijny	6	6.78
secret	13	6.55	wyrażny	11	6.66
secret declarations			ministerialny	4	6.66

- We can see which collocations for English *declaration* do not have their Polish equivalent with *deklaracja*

Example 2.1

- If we click on collocates, we obtain access to translated collocations

written (adjective) Alternative PoS: [write verb](#) (freq: 4,279)
 EUROPARL7, English freq = 2,431 (40.02 per million)
 Use another candidate translation: 142 [oswiadczenie](#) [regulamin](#) 149 [art](#) [wyjasnienie](#) . . [patrzec](#)
 Click on collocates to access reciprocal bilingual search or find [translated collocations](#)

modifies	98.03
statement	<u>1,041</u> 10.10
. Written statements (Rule 149	
explanation	<u>154</u> 9.23
. Written explanations of vote in	
declaration	<u>236</u> 9.17
written declaration	
answer	<u>171</u> 8.25
will receive written answers	
reply	<u>74</u> 8.09
a written reply	
STATEMENT	<u>11</u> 7.23
. WRITTEN STATEMENT (RULE 120	
press	<u>33</u> 7.01
the written press ,	
Statement	<u>7</u> 6.48
consent	<u>11</u> 6.24
written consent	
questionnaire	<u>6</u> 6.15
confirmation	<u>7</u> 6.05
translation	<u>8</u> 5.90
question	<u>150</u> 5.71
a written question	
Declaration	<u>9</u> 5.63
constitution	<u>12</u> 5.53
written constitution	
notification	<u>5</u> 5.52
exam	<u>3</u> 5.29
version	<u>9</u> 5.11
assurance	<u>5</u> 4.95
record	<u>7</u> 4.86
submission	<u>3</u> 4.82
summary	<u>3</u> 4.79
authorisation	<u>4</u> 4.71
form	<u>27</u> 4.68

pisemny (adjective) EUROPARL7, Polish freq = 1,700 (112.05 per million)

Use another candidate translation: 142 [oswiadczenie](#) [regulamin](#) 149 [art](#) [wyjasnienie](#) . . [patrzec](#)
 Click on collocates to access reciprocal bilingual search or find [translated collocations](#)

and/or	6.50
verbal	<u>6</u> 8.96
oral	<u>29</u> 7.89
written and oral	
express	<u>4</u> 7.86
prior	<u>3</u> 6.22
audiovisual	<u>3</u> 6.08
formal	<u>4</u> 5.50
detailed	<u>4</u> 4.70
parliamentary	<u>7</u> 4.58
original	<u>3</u> 4.49
annual	<u>3</u> 3.84
comprehensive	<u>3</u> 3.83
urgent	<u>3</u> 3.71
s	<u>3</u> 2.36

When do translators typically use language corpora? Or should use?

- **Monolingual reference corpora** (e.g. *Narodowy Korpus Języka Polskiego*)
 - When we are worried that **the translation does not fit the norms and conventions (grammatical, stylistic etc.) of the target language** (Polish language)
 - Excessive **lexical or syntactic calques** and **idiosyncratic collocations** (*massage baths – wannы masażowe, computer key – guzik komputerowy* etc.), **overuse or underuse of certain grammatical structures** (e.g. passive voice in Polish) or **prefabricated formulas** etc.
- **Parallel corpora**
 - When we want to see **how translators dealt with similar translational problems in the past** (Zanettin 2003), and
 - to verify translational choices / equivalents (textual)
 - to verify dictionary equivalents

Deleveraging – delewarowanie?

- *Most notably, in the wake of the Lehman collapse, the pattern of **deleveraging** and forced sales has been so intense that traditional price relationships have completely broken down, sending trading models haywire.*
- *W szczególności, po upadku Lehmanów, **delewarowanie** i wymuszone sprzedaży tak się nasiliły, że doszło do całkowitego załamania się tradycyjnych stosunków cenowych i rozchwiania modeli prowadzenia interesów.*
 - Financial world is stumbling blindly through a cognitive fog, Gillian Tett, published 6 March 2009. At:
<http://www.ft.com/cms/s/0/da26af7c-09ee-11de-add8-0000779fd2ac.html>
 - Świat finansów potyka się i błądzi. At: <http://ft.onet.pl>

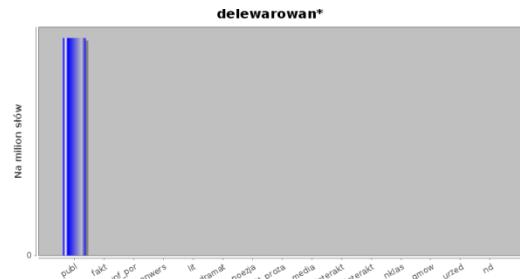
Deleveraging – delewarowanie?

- Data from Paralela
 - 12 occurrences of *deleveraging* (10 in RAPID subcorpus (EU Press Releases), 1 in EPP proceedings, 1 in NBP subcorpus)
 - Polish equivalents:
 - *oddłużanie*
 - *ograniczanie zadłużenia*
 - *pozbywanie się pasywów*
 - *eliminacja dźwigni finansowej*
 - ***delewarowanie (5 occurrences)*** ✓
 - *zrównoważanie (budżetów domowych) - deleveraging (of households' balance sheets)*

delewarowanie

- Data from NKJP

- 10 occurrences of *delewarowanie*



Przeszukiwany zbiór zawiera 240,192,461 słów. Znaleziono 10 akapitów pasujących do zapytania w 0.003s. Bieżąca strona zawiera 13 przykłady z 9 różnych tekstów.

1.	gdy nadmuchany balon pękł, rozpoczął się odwrotny proces - delewarowania - czyli zmniejszania się rynku aktywów finansowych, głównie	Polityka	
2.	minionych kilku lat prowadzą dziś intensywny proces delewarowania , czyli spisywania na straty części aktywów, przy	Polityka	
3.	przebiegało w trzech fazach: fazie stabilizacji, fazie delewarowania oraz długotrwałej fazie zredukowanego zadłużenia i	Gazeta Ubezpieczeni...	
4.	wzrost produktu krajowego brutto (PKB) w miarę postępującego delewarowania portfeli konsumentów, wzrostu bezrobocia, stagnacji cen	Gazeta Ubezpieczeni...	
5.	starań rządów i banków centralnych, biorąc pod uwagę procesy delewarowania w bankach, firmach i gospodarstwach domowych, nie ma zbyt	Gazeta Ubezpieczeni...	
6.	finansowej z sektora prywatnego do publicznego. Skala delewarowania potwierdza, że potencjalny wzrost w większości krajów	Gazeta Ubezpieczeni...	
7.	pełni dojrzeć do wzrostów. Sądzimy zatem, że trwający proces delewarowania i wysoki stopień wzajemnych zależności ekonomicznych w skali	Gazeta Ubezpieczeni...	
8.	azjatyckich w połączeniu z trwającym w tej chwili procesem delewarowania w USA mogą w przyszłych latach wyprowadzić Azję na ścieżkę	Gazeta Ubezpieczeni...	
9.	minęła pierwsza panika, w wieżowcach na Manhattanie ruszyło delewarowanie . W czasach hossy ulubionym narzędziem bankierów z Wall	Polityka	
10.	wskutek utraty zaufania do instytucji finansowych, z drugiej delewarowanie , czyli pozbywanie się nadmiernego zadłużenia przez banki i	Polityka	
11.	ale póki trwa, podgrzewa koniunkturę w gospodarce. Delewarowanie jest niezbędne, ale procesowi temu towarzyszyć muszą	Polityka	
12.	rządy na ratowanie sektora bankowego bilionów dolarów - bo delewarowanie to proces, którego skala nie idzie w biliony, ale grube	Polityka	
13.	o wysokiej rentowności i kredytów bankowych. Błyskawiczne delewarowanie systemu finansowego także miało swój negatywny wpływ na	Gazeta Ubezpieczeni...	

Delewarowanie

- Data from plTenTen12
 - 60 occurrences of *delewarowanie*

Query (delewarowanie)-n 60 (0.01 per million) ⓘ

Page 1 of 3 Go Next | Last

blogbank.p... poprzednio) czy pozwolić na naturalne **delewarowanie**. Stymulowanie za wszelką cenę i jego skutki
blogbank.p... wczoraj w dół. Dane nieciekawe, może być dalsze **delewarowanie** na dolarze. Za dużo niewiadomych Zatem AT i z
blogbank.p... wypłynęła na nim. Teraz mamy powszechnie **delewarowanie** (czynnik działający deflacyjnie), a Grecja
blogbank.p... banki", bo była wcześniej, od lat przezywają " **delewarowanie** "... Juz myślałem, że ze swym postem się nieco
mises.pl , ze komunikat jest w porządku. Murphy: Czy **delewarowanie** ma negatywny wpływ na gospodarkę? Autor:
obserwator... instytucje finansowe będą prowadzić **delewarowanie** zbyt szybko i na zbyt dużą skalę. Na razie władze
obserwator... budzi nie tylko to, że prowadzone w Europie **delewarowanie** może negatywnie wpływać na notowania
bossa.pl oszczędności o około 3 p.p. PKB przy czym **delewarowanie** dotyczyło jedynie sektora przedsiębiorstw -
blogbank.p... co dzieje się ze złotem i srebrem bez dodruku = **delewarowanie**) a nie interwencjonizm w realną gospodarkę:
ifin24.pl ... przy zwiększającym się zadłużeniu (niestety, **delewarowanie** będzie długie i bolesne). "Zamożność" jest w
trystero.p... racjonalnego zarządzania, jak się rozpoczęcie **delewarowanie** bezrobocie skoczy do 25%, bo gdzie indziej w
obserwator... do 3-procentowego deficytu względem PKB oraz **delewarowanie** i rekapitalizacja sektora finansowego.
obserwator... . Jeszcze kilka lat restrukturyzacji Tak zwane **delewarowanie** - czyli zmniejszanie stosunku aktywów do
internacj... kanałami. W języku Banku Światowego "globalne **delewarowanie**" (masowa wyprzedaż aktywów firm celem
trystero.p... w nieruchomościach a więc majątek w dol, dalsze **delewarowanie** , mniejsza konsumpcja. I tak praktycznie z
ibs.edu.pl... Obecnie wariant ekstremalny jest możliwy, bo **delewarowanie** objął całym glob. W moim szkicu są dwa punkty
pkpplewiat... recesją u naszych partnerów eksportowych w UE " **delewarowanie** " w UE i potrzeba sanacji banków, co pociągnie za
gb.pl funduszy i ich jakości, jak też poprzez **delewarowanie** . Konieczność szybkiego podniesienia
wp.pl banków jest nadal pilna". Dodał też, że " **delewarowanie** jest potencjalnie bardziej niebezpieczne w
wp.pl i uchroni nas przed kryzysem . a teraz **delewarowanie** jest potencjalnie bardziej niebezpieczne w

Page 1 of 3 Go Next | Last

Sprowokować poprawę?

- Example from Paralela (JRC-Acquis sub-corpus)
 - *Another important issue is then discussed – the forced sale of mortgaged property . The GP notes that this area is characterised by a large number of procedures , timeframes and costs and that this would hinder cross-border lending activity. It therefore suggests a gradual approach to **encourage improvements** in forced sales procedures: (...)*
 - *Inną ważną kwestią omówioną w dalszej kolejności jest wymuszona sprzedaż nieruchomości obarczonej hipoteką . ZK zaznacza , że obszar ten charakteryzuje duża liczba procedur , okresów i kosztów i stanowioby to przeszkodę dla transgranicznej działalności kredytowej . Sugeruje zatem zastosowanie stopniowego podejścia do **sprowokowania poprawy** w zakresie procedur wymuszonej sprzedaży*

Sprowokować poprawę

- Data from NKJP
 - No occurrences of *sprowokować poprawę*
- Data from Frazeo
 - No occurrences of *sprowokować poprawę*
- Data from plTenTen12
 - 2 occurrences of *sprowokować poprawę* (in 7.7 billion words)
 - Jakość mediów – tych drukowanych i tych elektronicznych – jego zdaniem, dramatycznie spada. Na dodatek, nie widać żadnego mechanizmu w mediach prywatnych, który mógłby ***sprowokować poprawę*** sytuacji. (Source: <http://www.dziennikarzerp.pl/2010/12/kulawa-debata-publiczna/>)
 - Dodam jeszcze, że zamiast ubolewać, co jest nie tak, trzeba było samemu ***sprowokować poprawę*** - ale nie przez narzekanie, tylko przez rzucenie konkretnymi propozycjami- co i jak poprawić. (Source: <http://www.forum.fantazyzone.pl/printview.htm?t=51&start=0&sid=63ee71cac16f6f8ccdd3d53d34eb6104>)

- Data from plTenTen12



– Przynieść poprawę, sprzyjać poprawie,
 (s)powodować poprawę, zaowocować poprawą,
 skutkować poprawą

poprawa <small>(noun)</small> Polish Web 2012 (plTenTen12, RFTagger) freq = 568,711 (60.58 per million)				
a_modifier	15.59	prec_prep	30.38	prec_verb
znaczyń + 10,974 9.06	znaczną poprawę	poprzez + 2,201 5.54	ulec + 10,917 9.75	wpływać + 5,439 9.89
znaczący + 4,513 8.73	znaczącą poprawę	celem + 253 5.23	obiecywać + 3,057 9.50	wptynie + 3,944 9.61
zdecydowany + 3,319 8.46	zdecydowaną poprawę	ku + 585 4.99	nastąpić + 4,944 8.46	nadzieja + 4,891 8.90
wyraźny + 2,446 8.24	wyraźna poprawa	nad + 3,791 4.82	ulegać + 3,454 8.30	wptyna + 5,773 8.37
widoczny + 1,834 7.83	widoczną poprawą	pomimo + 504 4.64	odczuć + 1,097 8.05	sposób + 3,641 8.35
radykalny + 1,081 7.61	radykalnej poprawy	mimo + 922 4.59	przynieść + 4,155 7.97	perspektywa + 336 7.51
stopniowy + 638 7.39	stopniowej poprawy	dla + 11,264 4.36	następować + 1,648 7.69	recepta + 403 7.37
systematyczny + 796 7.32	systematyczną poprawę	do + 48,123 4.33	następuje poprawa	liczyć + 1,859 7.33
zauważalny + 493 7.31	zauważalną poprawę	na + 70,355 4.19	zauważylam + 591 7.60	liczyć na poprawę
chwilowy + 688 7.21	chwilową poprawą	oprócz + 656 4.17	zauważylam poprawę	metoda + 338 7.25
zadnej + 589 7.15	zadnej poprawy .	zamiast + 336 4.17	obiecać + 742 7.59	metoda na poprawę
odczuwalny + 406 7.07	odczuwalną poprawę	dzięki + 1,131 3.84	zauważyć + 1,670 7.51	wpływ + 2,586 7.09
natychmiastowy + 835 7.01	natychmiastowej poprawy	odnośnie + 170 3.78	zaobserwować + 661 7.40	wpływ na poprawę
nieznaczny + 396 6.89	nieznacznej poprawie	o + 12,387 3.48	spodziewać + 1,350 7.37	pomyst + 1,057 6.87
kliniczny + 555 6.54	poprawy klinicznej	wskutek + 56 2.59	przynosić + 1,742 7.18	pomyst na poprawę
ogólny + 2,453 6.53	ogólną poprawę	bez + 1,270 2.48	odnotować + 708 7.18	zależeć + 447 6.75
trwaty + 881 6.50	trwającej poprawy	obok + 91 2.08	oczekiwać + 1,160 7.13	zależy na poprawie
ciągły + 1,178 6.48	ciąglej poprawy	prócz + 36 2.08	stużyć + 2,149 7.05	pozwolić + 789 6.74
iednoczesny + 448 6.46	poza +	postanawiać + 249 6.46	slużyć poprawie	zakazywać + 502 6.44
	, Poza poprawą	postanawiam poprawę	zauważać + 535 6.75	nacisk + 667 6.22
		obserwować + 792 6.33	spowodować + 1,502 6.71	nacisk na poprawę
			zaowocować + 495 6.66	oczekiwać + 277 6.08
			skutkować + 525 6.53	oczekiwaniem na poprawę
			postanawiać + 249 6.46	lek + 169 5.94
			postanawiam poprawę	przeznaczyć + 199 5.83
			obserwować + 792 6.33	przeznaczyć na poprawę
				oczekiwanie + 145 5.82

sprowokować

- Sprowokować coś
- Sprowokować kogoś do czegoś

<u>has_obj4</u>		4.00
zajście	<u>34</u>	8.46
sprowokował całe zajście		
dyskusja +	<u>225</u>	8.02
zamieszki	<u>16</u>	7.89
reakcja +	<u>126</u>	7.49
bójka	<u>9</u>	7.23
debata	<u>25</u>	7.15
skandal	<u>12</u>	6.98
awantura	<u>22</u>	6.92
kłótnia	<u>11</u>	6.92
konflikt	<u>31</u>	6.77
odwet	<u>7</u>	6.68
wybuch	<u>12</u>	6.63
pojawić	<u>9</u>	6.48
zamieszka	<u>5</u>	6.44
incydent	<u>8</u>	6.40
odzew	<u>7</u>	6.38
interwencja	<u>9</u>	6.34
burda	<u>5</u>	6.28
zadyma	<u>5</u>	6.19
katastrofa	<u>9</u>	6.13
wojna	<u>50</u>	6.10
korekta	<u>15</u>	6.09
lawina	<u>6</u>	6.08
inwazja	<u>5</u>	6.01
refleksja	<u>13</u>	5.98

» the verb *sprowokować*, 'provoke sth'

has a negative aura of meaning in Polish

<u>post_do</u>		4.91
kłótnia	<u>66</u>	8.16
się sprowokować do kłótni		
brać	<u>54</u>	8.08
sprowokować do brania		
bójka	<u>34</u>	7.75
sprowokować do bójki .		
pyskówka	<u>15</u>	7.63
reakcja	<u>41</u>	7.58
agresja	<u>28</u>	7.58
sprowokować do agresji .		
zastanowić	<u>34</u>	7.36
sprowokować do zastanowienia się nad		
dyskusja +	<u>325</u>	7.18
sprowokować do dyskusji		
przemyślenie	<u>39</u>	7.13
sprowokować do przemyśleń		
rozprawiać	<u>9</u>	7.01
prawić	<u>9</u>	7.01
myślenie +	<u>120</u>	6.96
sprowokować do myślenia		
odpowiedź	<u>41</u>	6.95
sprowokować do odpowiedzi		
polemika	<u>16</u>	6.93
zabrac	<u>17</u>	6.93
sprowokować do zabrania głosu		
bałakać	<u>8</u>	6.85
awantura	<u>19</u>	6.84
sprowokować do awantury		
odezwac	<u>8</u>	6.84
atak +	<u>116</u>	6.83
sprowokować do ataku .		
zadać	<u>14</u>	6.83
sprowokować do zadania		
wypowiedź	<u>70</u>	6.68
sprowokować do wypowiedzi		
pleść	<u>7</u>	6.66
trajkotać	<u>7</u>	6.66
powiadac	<u>7</u>	6.66
zachowanie	<u>35</u>	6.64

Limitations of language corpora

from the perspective of translators

- **Lack of sense disambiguation**
 - When we translate, we search for sense rather than form
 - *e.g. balkonik* (see later example)
 - framework for walking, part of a buliding, an undergarment?
- **Limited size of some language corpora**
 - **Negative evidence**
 - the fact that a given word or expression does not occur in the corpus does not mean that it is not used
- **If not updated, corpora do not catch up with reality**
 - No occurrences of *fake news*, *lokowanie produktu*, *hejtować* in NKJP
- **Loads of data mean problems with their filtering and interpretation**
 - The need to learn corpus functionalities (corpus search engines, query syntax etc.)
 - **Translators are busy people**
 - They may not have time for learning all this
 - Resource allocation for specific roles in the translation project

Wordnets

- Large **relational lexico-semantic databases**
- **Princeton WordNet** (Fellbaum 1998) was built on psycholinguistic principles
 - <http://wordnetweb.princeton.edu/perl/webwn>
 - **intended to reflect the structure of human lexical memory** (cf. Miller 1998)
 - originated as an experiment on mapping lexical memory of children,
 - gradually evolved into a huge electronic resource covering a large part of the lexical system of English (Fellbaum, 1998).
- Words are grouped in the so-called **synsets**
 - nouns, verbs, adjectives and adverbs
 - **represent lexicalised concepts** (Miller 1998)
 - **(cognitive) sets of synonymous lexical units (LUs)**
 - Synonymy is a **conceptual relation established on the basis of a linguist's intuition and dictionary definitions**
- **Synsets** are linked via semantic relations
 - hyponymy, hypernymy, partial-synonymy etc.

Polish wordnet (plWordNet), Słowosieć

- <http://plwordnet.pwr.wroc.pl/wordnet/>
- In PIWordNet, **synsets are sets of synonymous LUs that enter the same constitutive relations**
 - e.g. hyponymy, hypernymy, meronymy, antonymy (Piasecki et al. 2009, Maziarz et al. 2012)
- **Each word is defined implicitly with reference to other words**
 - *samochód* 'car' is a kind of *pojazd drogowy* 'road vehicle'; it is a whole consisting of *silnik* 'engine', *spryskiwacz* 'windscreen washer', *podwozie* 'chassis' and so on; its close counterpart is the colloquial *fura* and *bryka* 'wheels, etc.

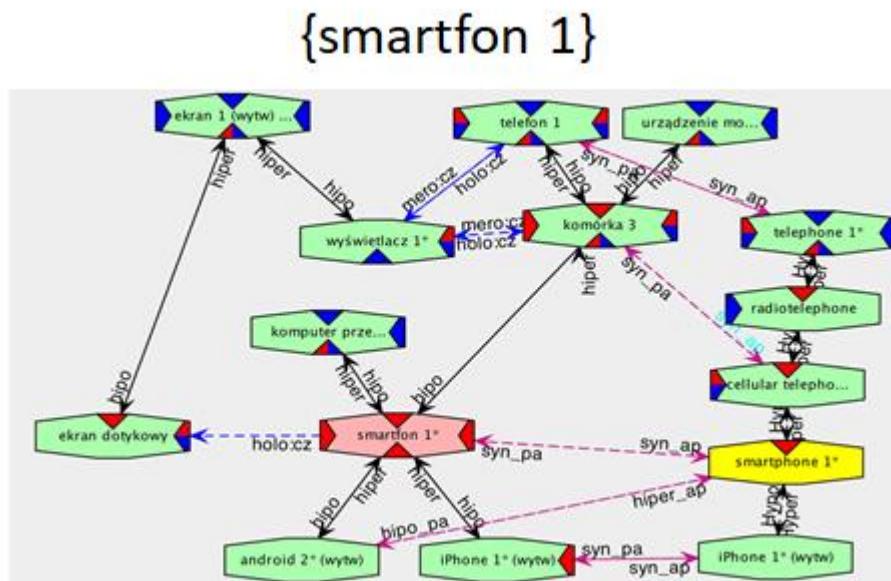
plWordNet	No. of lemmas	No. of LUs	No. of synsets	Monosemous lemmas	Polysemous lemmas
Verbs	19984	41017	29892	11283	8701
Nouns	133845	176938	132628	109652	24193
Adverbs	8010	14040	11260	4692	3318
Adjectives	29228	54021	46705	16580	12648
All	191067	286016	220485	142207	48860

Mapping of wordnets (at synset level)

- **Linking plWordNet and Princeton WordNet**
synsets corresponding in meaning and position in wordnet structure
 - Currently nouns
- Mapping direction: **plWordNet > Princeton WordNet**
 - using a set of interlingual relations
 - I-synonymy
 - I-hyponymy and hypernymy
 - I-meronymy and holonymy
 - I-partial synonymy
 - I-inter register synonymy
 - I interparadigmatic synonymy

Wordnets as bilingual lexicons

- Wordnets provide a list of senses of a given word, yet unlike traditional dictionaries, they also place each specific sense - in the form of a synset - in a network of lexico-semantic relations
- Example



Słownięć

Oglądasz 1 z 1 dostępnych znaczeń tego słowa

Zmień język strony

Hiperonimy

RZECZNIK	smartfon 1
DOMENA	wybory ludzkie (nazwy)
ZBÓRKO	Słownięć
HIPERONIM	Pokażściekę do najbliższego hiperonimu
GRAPH	Wyświetl wizualizację graficzną

Hiponimy

IPHONE 1	smartfon przygotowany przez Apple Inc., p...
ANDROID 2	smartfon z systemem android

Kolokacyjność

PORECZYKI	wygodny, odpowiedni, taki, który odpowiad...
-----------	--

Meronymy (części)

EKRAN DOTYKOWY 1	domena: wybory ludzkie (nazwy)
ZBÓRKO	Słownięć

Synonimy międzyjęzykowe

SMARTPHONE 1	a mobile phone with more advanced comp...
--------------	---

Using wordnets in translation practice

- Using mapped wordnets can be summarized as follows:
 - Determining the sense of a source language word
 - Finding possible translations (candidates)
 - Choosing a target language equivalent (a definitive translation) (Rudnicka & Piasecki 2013)
- Examples

Situation 1

A known word in an unfamiliar context

- *After I finished studying for my courses one weekend, I called my mum. I told her that we were going to have a confirmation service during **chapel**, and I was not looking forward to attending. The topics chosen for **chapel** often seemed negative and left me feeling down.*
 - *Encountering Angels: True Stories of How They Touch Our Lives Every Day*, by Judith MacNutt (2016), Chosen Books*
 - Source:
https://books.google.pl/books?id=mgI_CgAAQBAJ&pg=PT23&dq=%22during+chapel%22&hl=pl&sa=X&ved=0ahUKEwi0iu6kpqrbAhUD2SwKHQYODd4Q6AEIMDAB#v=onepage&q=%22during%20chapel%22&f=false

* Thanks to E. Rudnicka and T. Piotrowski (2017) for suggesting this example

chapel

- Synsets in Princeton WordNet
 - {**chapel 1**} (artefact)
 - a place of worship that has its own altar
 - {**chapel 2; chapel service 1**} (act)
 - a service conducted in a place of worship that has its own altar

- Relevant synset in Princeton Wordnet
 - {**chapel service 1; chapel 2**} (act)
 - a service conducted in a place of worship that has its own altar;
 - he was late for chapel
 - Hypernymy to {service 3, religious service 1, divine service 1}
 - I-hypernymy {**nabożeństwo 1**} ✓
 - forma modlitewnego zgromadzenia wiernych danego wyznania

Situation 1.2

We don't know the equivalent

At Low Mass with a congregation present, or if the church is large, incense may be blessed beforehand by the celebrant. At Missa Cantata, or Low Mass with an opening hymn, the thurible may be taken in procession.

- Cooper, I. (2010). Ceremonies of The Young Rite, p. A-3

Source: <https://books.google.pl/books?id=hxX9AgAAQBAJ&pg=RA1-PA3&dq=%22low+mass%22+%2B+church&hl=en&sa=X&ved=0ahUKEwjlr5fQ-MPaAhUQmrQKHaNhA544ChDoAQg8MAU#v=onepage&q=%22low%20mass%22%20%2B%20church&f=false>

- Relevant synsets in Princeton WordNet
 - **{low mass 1}**
 - a Mass recited without music
 - Hypernymy to {Mass 4}
 - (Roman Catholic Church and Protestant Churches) the celebration of the Eucharist
 - I-synonymy to **{cicha msza 1}** ✓
 - msza, podczas której nie ma muzyki, diakona ani subdiakona, a na ołtarzu palą się dwie świece; inaczej nazywana mszą czytaną
 - **{thurible 1; censer 1}**
 - a container for burning incense (especially one that is swung on a chain in a religious ritual)
 - Hypernymy to {vessel 3}
 - an object used as a container (especially for liquids)
 - I-synonymy to **{kadzielnica 1; trybularz 1}** ✓
 - naczynie kościelne, które służy do spalania kadzidła

Situation 2

We know the meaning of a SL word but we don't know its TL equivalent

*At Low Mass with a congregation present, or if the church is large, incense may be blessed beforehand by the **celebrant**. At Missa Cantata, or Low Mass with an opening hymn, the thurible may be taken in procession.*

- Cooper, I. (2010). Ceremonies of The Young Rite, p. A-3

- Synsets in Princeton Wordnet
 - {**celebrant 1**; celebrater 1; celebrator 1}
 - A person who is celebrating
 - {**celebrant 2**}
 - an officiating priest celebrating the Eucharist

- Relevant synset in Princeton WordNet
 - {celebrant 2}
 - an officiating priest celebrating the Eucharist
 - Hypernymy to {priest 1}
 - a clergyman in Christian churches who has the authority to perform or administer various religious rites
 - I-synonymy to {**celebrans 1; celebrant 1; oficjant 1**} ✓
 - duchowny odprawiający nabożeństwo

Situation 3

We are not sure about the meaning of a SL word and we don't know its TL equivalent

- *Kiedy przechodząc do kuchni pokonuje próg, **balkonik**, o który się opiera, wydaje cichy, ale wyraźny stukot.*
 - (Super Express, 2006; PWN_1302900002719)

Synsets in Słowościeć

- **{balkonik 1}** (art) ✓
 - specjalne urządzenie na kółkach, przy pomocy którego osoby starsze, niepełnosprawne i mające problem z chodzeniem, mogą się łatwiej poruszać
- **{balkonik 2}** (loc)
 - Markedness (diminutives) to {balkon 1}
 - element architektoniczny, przestrzeń wystająca poza mury budynku, często ogrodzona balustradą
- **{balkonik 3; balkonetka 1}** (art.)
 - rodzaj biustonosza z miseczkami skrojonymi z trzech części, który podnosi i zaokrąglą piersi

- *Kiedy przechodząc do kuchni pokonuje próg, **balkonik**, o który się opiera, wydaje cichy, ale wyraźny stukot.*
(Super Express, 2006; PWN_1302900002719)
- Relevant PLWordNet synset
 - {**balkonik 1**} (domain: artifact)
 - specjalne urządzenie na kółkach, przy pomocy którego osoby starsze, niepełnosprawne i mające problem z chodzeniem, mogą się łatwiej poruszać
 - Hypernomy to {chodziak 1} {podpora 1; podpórka 1; podparcie 2}
 - I-synonymy to {**walker 5**; **Zimmer frame 1**; **Zimmer 1**}
 - a light enclosing framework (trade name Zimmer) with rubber ✓ castors or wheels and handles

Situation 4

A known word in an unfamiliar context

- Skoro jest wilgoć, to i pojawiły się wreszcie moje **kołpaki** (...) Moje dwie gromady, umiejscowione w odległych od siebie miejscowościach, wysypują się zawsze w październiku. Chociaż podobno powinny to czynić już od maja. Grzyby te trochę mi się kojarzą z czubajkami kaniami- także mają gładki jasnobrązowy wierzchołek kapelusza i odstające łuski – u młodych białawe, u starszych brązowiejące.

- Source: <http://puszcza.net.pl/ciesza-sie-sojki-i-slimaki>
 - Czernidłak kołpakowy

- **Identifying the sense of the source language word**
 - {**kołpak 1**; dekiel 1}
 - osłona felgi samochodowej
 - Kołpak może być wykonany z metalu lub tworzyw sztucznych.
 - {**kołpak 2**}
 - nakrycie głowy pochodzenia tureckiego, popularne w XIV-XVII wieku w Europie Wschodniej; była to czapka bez daszka, obrzeżona futrem wilczym, rysim lub lisim z aksamitną główką, niekiedy przybierała kształt cylindryczny, zakończony spiczasto
 - Tatarskie kołpaki przypominały za to Czapka Monomacha, nakrycie głowy moskiewskich carów, wskazując też na powiązania kulturowe państw russkich stanowiących lenno Złotej Ordy.
 - {**kołpak 3**; bełdka kołpak 1; sowa 2; kołpaczek 2; czubajka 2} ✓
 - inna nazwa czernidłaka kołpakowatego
 - {**kołpak 4**; dzwoniak 1; delikatka 1; rumieniaczek 1; bedłka 2; rumieniak 2}
 - ludowa nazwa niektórych grzybów z rodzaju dzwonków
 - {**kołpak 5**; podbołotuszka; rozeta pomarszczona 1; płachetka 1; bydlarka 1; niemka 2; płachta 2; turek 3}
 - inna nazwa płachetki zwyczajnej - grzyba jadalnego z rodziny zasłonakowatych

- **Finding possible translation candidates**
 - {**kołpak** 3; bełdka kołpak 1; sowa 2; kołpaczek 2; czubajka 2}
 - inna nazwa czernidłaka kołpakowatego
 - Inter-register synonyms
 - {czernidłak kołpakowy 1}
 - I-inter-register synonyms
 - {shaggymane 1; Coprinus comatus 1; shaggy cap 1; shaggymane mushroom 1}
- **Choosing a target language equivalent**
 - {**shaggymane** 1; Coprinus comatus 1; **shaggy cap** 1; **shaggymane mushroom** 1} ✓

Limitations of wordnets

- **Polish WordNet has been mapped onto Princeton WordNet only partially, which translates into limited coverage**
 - and at the level of synsets (abstract units)
- **Translators do not deal with synsets but with lexical units (form-meaning mappings)**
 - Mapping at the level of lexical units (nouns) is in the pipeline (Rudnicka et al. 2017)
 - It considers formal, semantic and translational criteria
- **There may be gaps and mismatches between PWN and plWN (Rudnicka et al. 2016), which are due to:**
 - Wordnet-specific structural and methodological differences
 - Specificity of inter-wordnet mapping procedure
 - Systemic differences between English and Polish
 - Differences in terms of lexicalization of concepts
 - often due to cross-cultural differences
- **Wordnets for different languages (other than English) are created using different methods**
 - Transfer, transfer-and-merge (automatic), transfer-and-merge (semi-automatic and corpus-based) - plWN

Conclusions

- Using parallel and reference corpora as well as wordnets is a **realistic scenario in the translator's work**
 - It offers **exposure to authentic linguistic data** ☺
 - It may help **improve the textual fit of translations** ☺
 - But it can be **time-consuming and labour-intensive** and it may require learning new skills related to the use of those resources ☹
- **Language corpora and wordnets may complement (e-)dictionaries, CATs and TMs**
 - Notably when translating creative texts

References (selected)

- Grabowski, Ł. (2018). "Stance bundles in English-to-Polish translation: a corpus-informed study". *Russian Journal of Linguistics*, 22 (2), 404-422
- Kilgarriff, A., Baisa, V., Bušta, J., Jakubícek, M., Kovář, V., Michelfeit, J., Rychlý, P. & Suchomel, V. (2014). "The Sketch Engine: ten years on". *Lexicography* 1(1): 7–36.
- Krueger, R. (2017). Working with corpora in the translation classroom
- Pęzik, P. (2017). Korpusy referencyjne, korpusy równoległe, ekwiwalencja frazeologiczna. Presentation delivered at CLARIN-PL workshops (3-4 Feb 2017) in Łódź
- Podhajecka, M. (2013). Calques in Polish translations of English press articles: Linguistic innovations or mistranslations?" In B. Lewandowska-Tomaszczyk and M. Thelen (eds.), Translation and Meaning Part 10. Maastricht: Zuyd University of Applied Sciences. 165–179.
- Rudnicka, E. & Piotrowski, T. (2015). Dwujęzyczna Słowność – możliwości wykorzystania w pracy tłumacza. Presentation delivered at CLARIN-PL workshops in IBL in Warsaw.
- Rudnicka, E., Witkowski, W. & Grabowski, Ł. (2016). "Towards a methodology for filtering out gaps and mismatches across wordnets: the case of noun synsets in plWordNet and Princeton WordNet". In: B. Barbu Mititelu, C. Forascu, Ch. Fellbaum, P. Vossen (Eds.), *Proceedings of the Eighth International Global WordNet Conference 2016*, 27-30 Jan 2016, Bucharest, Romania, pp. 344-351
- Rudnicka, E., Bond, F., Grabowski, Ł., Piasecki, M. & Piotrowski, T. (2017). "Towards equivalence links between senses in plWordNet and Princeton WordNet". *Lodz Papers in Pragmatics*, 13 (1), 3-24.
- Zanettin, F. (2002). Corpora in Translation Practice. In: Proceedings of the LREC Workshop, Language Resources for Translation Work and Research. 2002. 10-14.

Thank you

- for your attention
 - lukasz@uni.opole.pl
 - ResearchGate: LukaszGrabowski2