

# Vybrané aktuální projekty Laboratoře NLP

Pavel Šmerk, Miloš Husák

E-mail: xsmerk@fi.muni.cz, xhusak@fi.muni.cz  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

Obsah:

- Guesser – značkování českých neznámých slov
- GDEX – Good Dictionary Examples

# Guesser

## Značkování českých neznámých slov

Pavel Šmerk

[xsmerk@fi.muni.cz](mailto:xsmerk@fi.muni.cz)

# Problém

Není možné mít všechna slova, která lze při zpracování přirozeného jazyka "potkat", předem ve slovníku. Je tedy potřeba umět řešit situaci, kdy slovo ve slovníku není.

Potřebné informace o neznámém slovu mohu odhadnout buďto z jeho větného kontextu, nebo z jeho podoby, konkrétně z jeho konce. Optimální řešení bude pochopitelně kombinovat oba přístupy.

Dále bude řeč o druhé variantě. Tedy dostanu slovo *napipetovaná*, řeknu si, aha, to je jako *malovaná*, tedy lemma *napipetovaný* podle *malovaný*, značky stejné.

# Produktivita

Čeština má relativně velké množství vzorů pro ohýbání i odvozování slov. Velká část z nich ale není v součastnosti "produktivních", jsou to jen pozůstatky z minulosti (*den, husa, myš, kost; dřevěný vs. umakartový, ...*), případně jsou produktivní jen nějak omezeně (*pařba x \*krvácba*).

Nově se objevující česká slova budou tedy patřit k nějaké podmnožině produktivních vzorů. Při odhadování konkrétního vzoru budou neproduktivní vzory nadbytečné, naopak dokonce budou tvořit šum a "překážet". My ale (zatím) nemáme informaci, které vzory jsou produktivní.

# Předpoklad

Můžeme předpokládat, že slovníky zahrnují všechna nepravidelně se chovající slova, která lze reálně “potkat” (pokud bychom se dostali k nějakému historickému textu, nemuselo by to tak být). Zároveň byly jistě tvořeny se snahou o co největší pokrytí reálného jazyka. To znamená, že se přidávala “nová”, pravidelně se chovající slova, např. z různých oborů.

Jde si to představit i jinak: máme-li 390 000 lemmat, není možné, aby naprostá většina z nich nebyla pravidelná, to by člověk nezvládl udržet v hlavě.

Pak si lze myslet, že to, co je produktivní, poznáme podle četnosti ve stávajících datech. Cílem je tedy z dat extrahovat jen jejich produktivní (častou) část a pouze na jejím základě pak odhadovat morfologické vlastnosti neznámých slov.

# Konstrukce dat pro guesser

- ze slovníku ajky (.dic) vyhodím lemmata od vzorů, u kterých je méně než 20 lemmat (tedy cca 6000 lemmat z 390 000, 55 000 slovních tvarů)
- pro všechny tvary každého lemmatu vygeneruju trojice word-lemma-tag ve formátu  
abaraks:a::k1gMnSc2,k1gMnSc4,  
kde nejprve je obrácený slovní tvar, dále, co musím utrhnout, a za další dvojtečkou, co musím přidat, abych dostal lemma, nakonec značky
- beru jen slova délky alespoň 7, vyhazuju eN, d3 a věci mimo k[1256], neberu wH a pod.
- setřídím podle abecedy (nikoli česky)

# Konstrukce dat pro guesser

- procházím a zaznamenávám do pole, min. kořen 3 znaky, max. konec 10 znaků
- pokud v daném místě pole bylo něco jiného, zkusím vypsat. Pro výpis to musí mít aspoň 20 výskytů, jednotlivé značky aspoň 10x, pokud je něčeho více než 20x méně než zbytku, ignoruju.
- vypsané odečítám od levých podřetězců
- setřídím podle abecedy
- slučuju stejné věci (s ohledem na počty), ignoruju vid
- setřídím retrográdně kvůli snadnému nacpání do \$re (...|ab|a), viz dále

# Použití

- hádáná slova otáčím a zkouším  $\sim /(\$re). \{ \$minroot \} /$   
`# $minroot == 3`
- díky "uspořádání"  $/^ (ab|a) /$  se pro *abxyz* namatchuje *ab*, a nikoli *a*, tedy obecně nejdelší možný konec
- k nalezenému konci slova mám v hashi info o změně konce na lemma a příslušných značkách

`/nlp/projekty/rule_ind/stat/guesser.pl`, očekává vertikál, případně označkovaný něčím jako ajka `-c -` (existující značkování ponechává beze změny)

Problém: zdaleka ne všechna neznámá slova jsou česká, tedy začleněná do systému jazyka. Zejména asi nesklonné názvy, jména, případně i cizojazyčná slova či celé citáty. Hodně z nich by asi bylo možné odhadovat pomocí velkého písmena na začátku a absence diakritiky. Zatím nijak netestováno/neřešeno.

# Obsah

- 1 Guesser – značkování českých neznámých slov
  - Úvod

- 2 GDEX – Good Dictionary Examples
  - Úvod
  - Implementace
  - Ukázky
  - Závěr

# Good Dictionary EXamples

## Dobré slovníkové příklady

Miloš Husák  
[xhusak@mail.muni.cz](mailto:xhusak@mail.muni.cz)

# Slovníkový příklad

## crawl

**PHRASE** **be crawling with** 1 to be too full of people: *The town was crawling with police*  
 2 to be full of unpleasant insects or animals



crawl

**crawl**<sup>1</sup> /kroʊl/ noun [singular] 1 a very slow speed 2 a style of swimming in which you move one arm over your head and then the other while you are kicking your legs

**crayon** /kreɪɒn/ noun [c] a stick of coloured wax that is used for drawing

**craze** /kreɪz/ noun [c] something that suddenly becomes very popular for a short time

**crazed** /kreɪzd/ adj completely crazy and

## 161

**crease**<sup>2</sup> /kri:s/ verb [V/T] to make lines on cloth or paper by folding or crushing it, or to become covered in these lines

**crazy** /'kreɪzi/ adj *informal* ★★ not at all sensible or practical: *It's crazy. Who would do a thing like that?* ♦ **be crazy to do sth** *She knew she would be completely crazy to refuse.*

**PHRASES** **crazy about sb** very much in love with someone

**crazy about sth** very enthusiastic about something

**drive sb crazy** to make someone very annoyed

**go crazy** 1 to become very angry about something 2 to become very bored and upset 3 to become very excited

**like crazy** to a very great degree = **MAD**: *The games are selling like crazy.*

**crazily** adv

## credit

C

### Words that may cause offence: crazy

Avoid using words like **crazy**, **mad**, and **insane** about people who have mental illnesses or mental health problems. Instead, use an expression such as **mentally ill**.

# Jak jsem ke slovníkům přišel/přešel

- brigáda “na léto”
- řecký korpus
- ohodnocování slovníkových příkladů
- Python, Manatee, SkE, WebBootCat ....
- bakalářská práce

# Jak jsem ke slovníkům přišel/přešel

- brigáda “na léto”
- řecký korpus
- ohodnocování slovníkových příkladů
- Python, Manatee, SkE, WebBootCat ....
- bakalářská práce

# Jak jsem ke slovníkům přišel/přešel

- brigáda “na léto”
- řecký korpus
- ohodnocování slovníkových příkladů
- Python, Manatee, SkE, WebBootCat ....
- bakalářská práce

# Jak jsem ke slovníkům přišel/přešel

- brigáda “na léto”
- řecký korpus
- ohodnocování slovníkových příkladů
- Python, Manatee, SkE, WebBootCat ....
- bakalářská práce

# Jak jsem ke slovníkům přišel/přešel

- brigáda “na léto”
- řecký korpus
- ohodnocování slovníkových příkladů
- Python, Manatee, SkE, WebBootCat ....
- bakalářská práce

# Cíl práce

Zautomatizovat (alespoň částečně) vyhledávání slovníkových příkladů v korpusu.

- zjistit, jak se dobré příklady dají rozpoznat
- zkombinovat různé přístupy
- vytvořit snadno použitelné rozhraní

# Cíl práce

Zautomatizovat (alespoň částečně) vyhledávání slovníkových příkladů v korpusu.

- zjistit, jak se dobré příklady dají rozpoznat
- zkombinovat různé přístupy
- vytvořit snadno použitelné rozhraní

# Cíl práce

Zautomatizovat (alespoň částečně) vyhledávání slovníkových příkladů v korpusu.

- zjistit, jak se dobré příklady dají rozpoznat
- zkombinovat různé přístupy
- vytvořit snadno použitelné rozhraní

# Cíl práce

Zautomatizovat (alespoň částečně) vyhledávání slovníkových příkladů v korpusu.

- zjistit, jak se dobré příklady dají rozpoznat
- zkombinovat různé přístupy
- vytvořit snadno použitelné rozhraní

# Dobrý příklad je ...

- informativní, samopopisný
  - pozice slova ve větě
  - synonyma
  - redundancy
- snadno čitelný
  - jednoduchá větná struktura
  - krátká slova
  - běžná jména (politické problémy)
  - častá slovní spojení

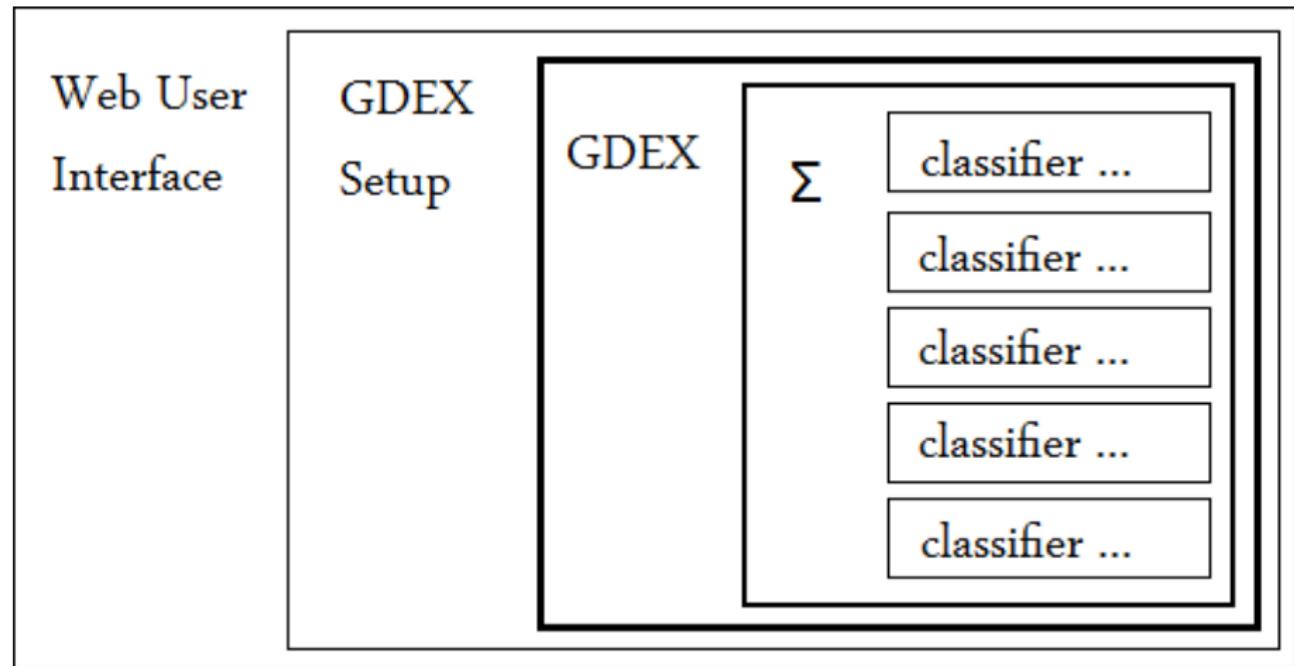
# Dobrý příklad je ...

- informativní, samopopisný
  - pozice slova ve větě
  - synonyma
  - redundancy
- snadno čitelný
  - jednoduchá větná struktura
  - krátká slova
  - běžná jména (politické problémy)
  - častá slovní spojení

# Dobrý příklad je ...

- informativní, samopopisný
  - pozice slova ve větě
  - synonyma
  - redundancy
- snadno čitelný
  - jednoduchá větná struktura
  - krátká slova
  - běžná jména (politické problémy)
  - častá slovní spojení

# GDEX



# GDEX

GDEX je srdcem a tělem ohodnocování vět.

- hostí hlavní klasifikátor
- poskytuje jednotné rozhraní všem klasifikátorům
- spravuje dostupné prostředky

# GDEX

GDEX je srdcem a tělem ohodnocování vět.

- hostí hlavní klasifikátor
- poskytuje jednotné rozhraní všem klasifikátorům
- spravuje dostupné prostředky

# GDEX

GDEX je srdcem a tělem ohodnocování vět.

- hostí hlavní klasifikátor
- poskytuje jednotné rozhraní všem klasifikátorům
- spravuje dostupné prostředky

# GDEX

GDEX je srdcem a tělem ohodnocování vět.

- hostí hlavní klasifikátor
- poskytuje jednotné rozhraní všem klasifikátorům
- spravuje dostupné prostředky

# Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- každou větu ohodnotí číslem z  $<0,1>$
- silné a slabé klasifikátory
- délka vět, délka slov, četnost slov, počty významů, ...
- vážený průměr, progresivní skóre, přibližné progresivní skóre

# Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- každou větu ohodnotí číslem  $z < 0, 1 >$
- silné a slabé klasifikátory
- délka vět, délka slov, četnost slov, počty významů, ...
- vážený průměr, progresivní skóre, přibližné progresivní skóre

# Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- každou větu ohodnotí číslem z  $< 0, 1 >$
- silné a slabé klasifikátory
- délka vět, délka slov, četnost slov, počty významů, ...
- vážený průměr, progresivní skóre, přibližné progresivní skóre

# Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- každou větu ohodnotí číslem  $z < 0, 1 >$
- silné a slabé klasifikátory
- délka vět, délka slov, četnost slov, počty významů, ...
- vážený průměr, progresivní skóre, přibližné progresivní skóre

# Klasifikátory

Klasifikátory jsou mozkem ohodnocování vět.

- každou větu ohodnotí číslem  $z < 0, 1 >$
- silné a slabé klasifikátory
- délka vět, délka slov, četnost slov, počty významů, ...
- vážený průměr, progresivní skóre, přibližné progresivní skóre

# Měření efektivity

$$\text{benchmark} = 1 - \frac{\sum_{i \in \text{concordances}} \frac{\sum_{j \in \text{goodexamples}_i} n_{i,j}}{n_{\text{last\_good\_example}_i} + 1}}{\sum_{i \in \text{concordances}} |\text{goodexamples}_i|}$$

# Měření efektivity

- průměrná pozice dobrých slovníkových příkladů
- ručně značkované konkordance
- optimalizace parametrů klasifikátorů
- vyvažování důležitostí klasifikátorů

# Měření efektivity

- průměrná pozice dobrých slovníkových příkladů
- ručně značkované konkordance
- optimalizace parametrů klasifikátorů
- vyvažování důležitostí klasifikátorů

# Měření efektivity

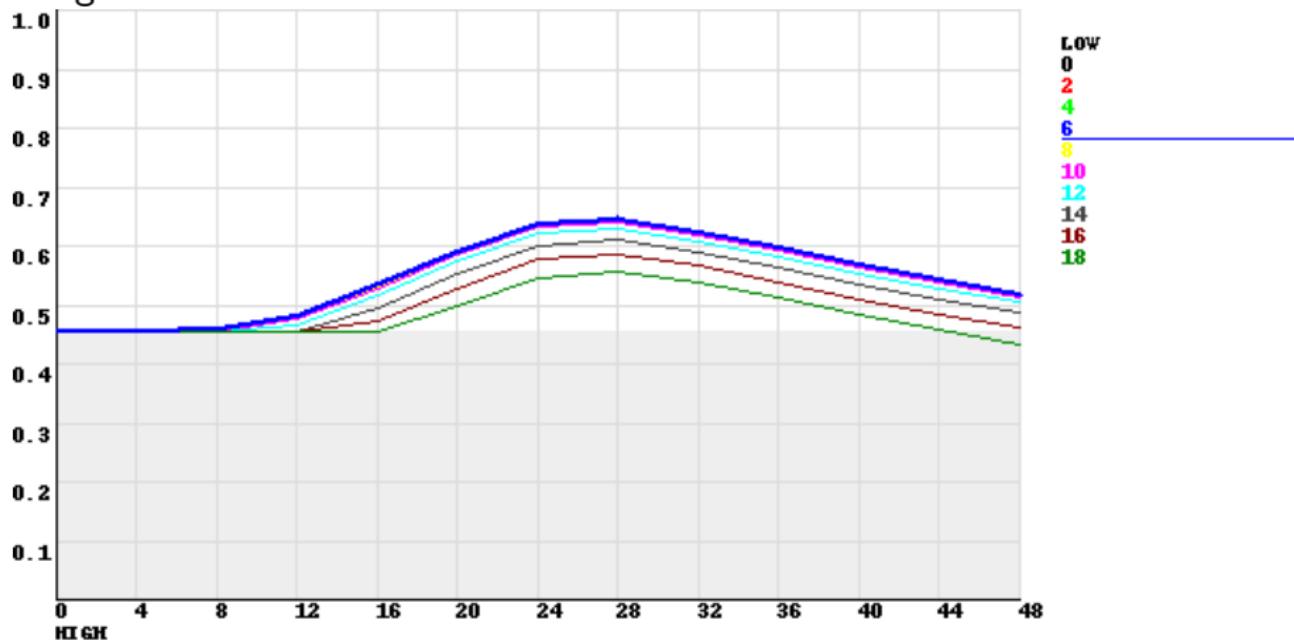
- průměrná pozice dobrých slovníkových příkladů
- ručně značkované konkordance
- optimalizace parametrů klasifikátorů
- vyvažování důležitostí klasifikátorů

# Měření efektivity

- průměrná pozice dobrých slovníkových příkladů
- ručně značkované konkordance
- optimalizace parametrů klasifikátorů
- vyvažování důležitostí klasifikátorů

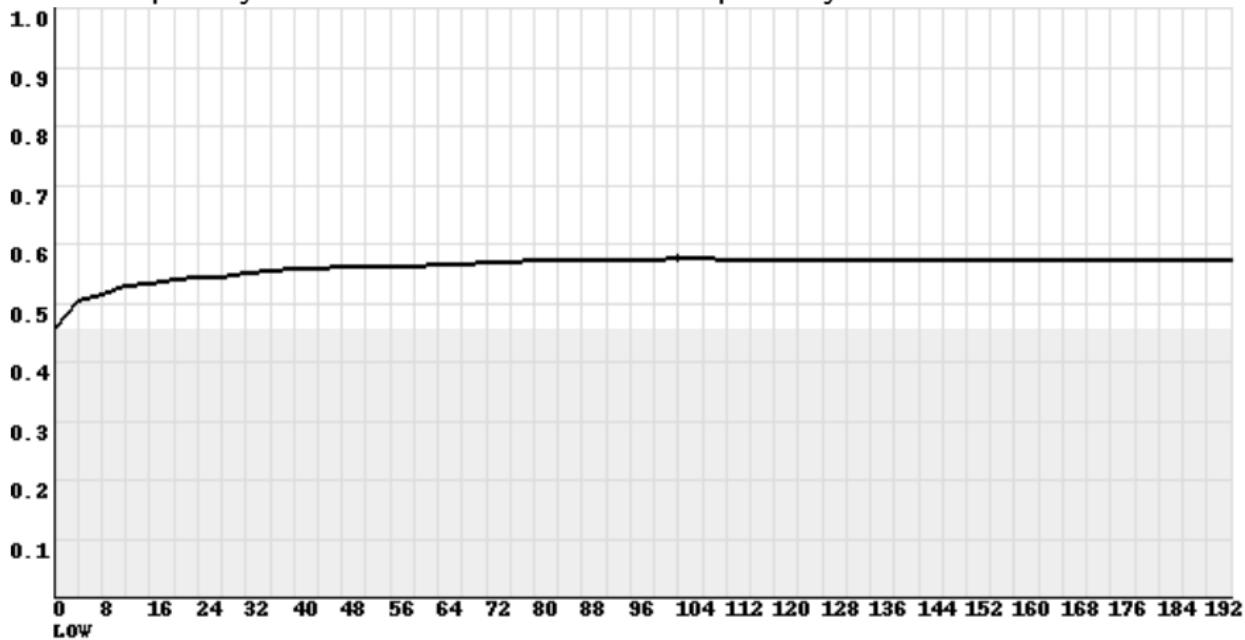
# Dobrý klasifikátor I.

Length score - délka vět



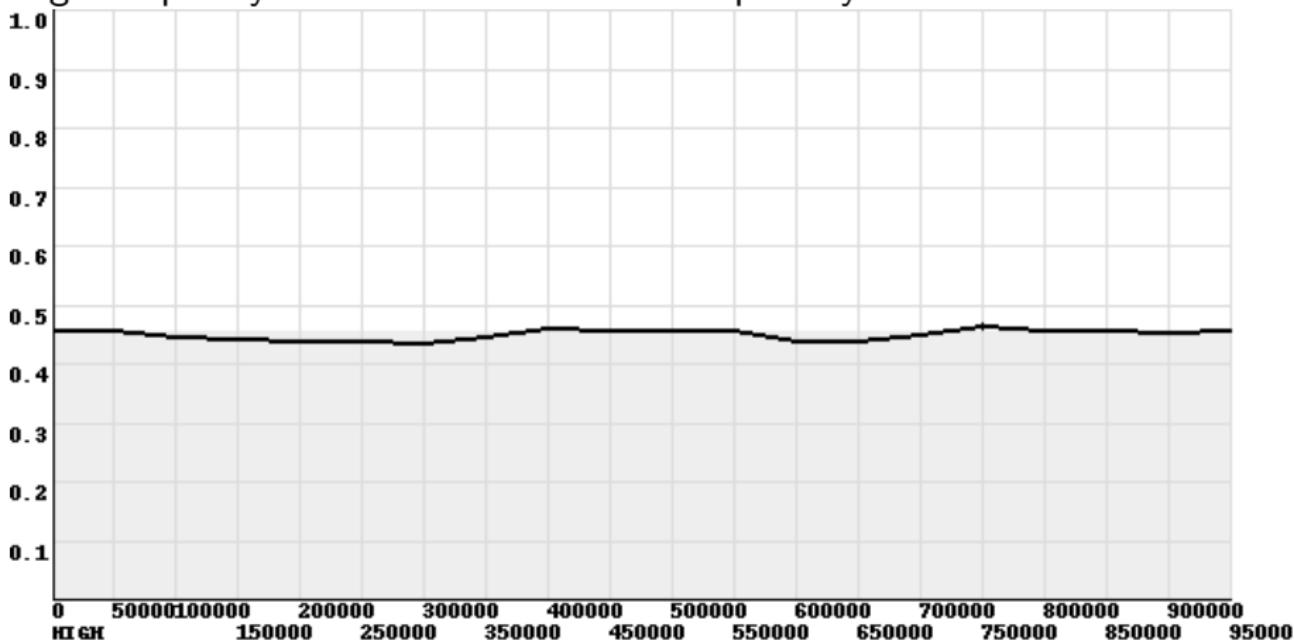
# Dobrý klasifikátor II.

Low frequency score - minimální četnost použitých slov



# Špatný klasifikátor

High frequency score - maximální četnost použitých slov



# Ukázky

- GDEX Setup
- Sketch Engine
- GDEX Demo Dictionary

# GDEX Setup

Config file    Constants    Classifiers    Preview    Learn    Archive

Name	Weight	Parameters
weighted score	0 ( <a href="#">weighted</a> )	<input type="text" value="0"/>
length score	1 ( <a href="#">length</a> )	<input type="text" value="15"/> LOW : <input type="text" value="10"/> <input type="checkbox"/> HIGH : <input type="text" value="25"/>
low frequency score	1 ( <a href="#">low-freq</a> )	<input type="text" value="15"/> LOW : <input type="text" value="44"/>
verbs score	2 ( <a href="#">verbs</a> )	<input type="text" value="5"/> VERBNUM : <input type="text" value="3"/>
position score	1 ( <a href="#">position</a> )	<input type="text" value="1"/> IDEAL : <input type="text" value="0.2"/> <input type="checkbox"/> TOLERANCE : <input type="text" value="0.6"/>
whole sentence	3 ( <a href="#">sentence</a> )	<input type="text" value="4"/>
long words score	1 ( <a href="#">wordlen</a> )	<input type="text" value="10"/> MAX : <input type="text" value="7"/> <input type="checkbox"/> PENALTY : <input type="text" value="0.2"/>
wordlist min	3 ( <a href="#">wordlist_min</a> )	<input type="text" value="5"/> WORDLIST : <input type="text" value="['the', 'be', 'to']"/> <input type="checkbox"/> MIN : <input type="text" value="0.25"/>
all colloc. avg	2 ( <a href="#">all_colloc_avg</a> )	<input type="text" value="10"/> FUNC : <input type="text" value="DICE"/>
		<input type="button" value="Create new classifier"/> <input type="checkbox"/> Strong classifier <input type="button" value="Create/Update"/>

# SketchEngine

<http://beta.sketchengine.co.uk/>

[Home](#) [Concordance](#) [Word List](#) [Word Sketch](#) [Thesaurus](#) [Sketch-Diff](#) [View](#)

Corpus: British National Corpus  
[conc description](#)

## View options

Attributes	Structures	References
<input checked="" type="checkbox"/> word <input type="checkbox"/> amntag <input type="checkbox"/> lempos <input type="checkbox"/> tag <input type="checkbox"/> lemma <input type="checkbox"/> lc	<bncdoc> <s> <text> <s> <p> <align> <caption> <hi> <lb> <bibl> <body> <div> <div1>	Token number bncdoc.id bncdoc.date bncdoc.author bncdoc.title bncdoc.info Text availability Text type Publication date David Lee's classification Domain for written corpus texts Domain for context-governed spoken material Medium for written corpus texts
Display attributes <input type="radio"/> For each token <input checked="" type="radio"/> KWIC tokens only		
Page size (number of lines): <input type="text" value="20"/>		
KWIC Context size (number of characters): <input type="text" value="40"/>		
<input checked="" type="checkbox"/> Icon for one-click sentence copying <input type="checkbox"/> Sort concordance lines best-first. Number of lines to be sorted: <input type="text" value="100"/>		
<a href="#">Change View Options</a>		

# GDEX Demo Dictionary

<http://forbetterenglish.sketchengine.co.uk/>

## The GDEX Demo Dictionary

This is an experimental automatic collocations dictionary, based on the Sketch Engine technology. Methods are described in Kilgarriff et al 2008: GDEX: Automatically finding good dictionary examples in a corpus. Proc EURALEX, Barcelona, Spain.

Enter an (English) word here to see its collocations, each with an example sentence.

### example (n)

pp_of	practice :	There are many <b>examples</b> of good practice being carried out by them on a daily basis .
	architecture :	Weir Hall, Silver Street The original building , opened in 1938 , was a striking <b>example</b> of library architecture of the nineteen-thirties .
	type :	The following are examples of the various types of groups .
	kind :	An example of this kind of mistaken identity , occurred in 1932 , when a crocodile-like creature was seen in the loch .
	genre :	However , this is only one , startling , <b>example</b> of the genre .
	latter :	An example of the latter is the specific knowledge attribute , used for holding subordinate and cross references .
object_of	cite :	We can cite numerous <b>examples</b> throughout history in connection with this topic .
	give :	Here she <b>gives</b> two examples of companies that are finding a way to do all three .
	follow :	If you have ever been tempted to believe what you are told then consider some of the following <b>examples</b> .
	shine :	A shining <b>example</b> for all of humanity she is super awesome .
	set :	Show Them How Jamie is a highly visible leader who sets a great <b>example</b> to his team .
	see :	To see the next <b>example</b> , use the 'page down' button .
a_modifier	prime :	You just had to choose your favourite marque and there would be prime <b>examples</b> parked up across the circuit .
	typical :	A typical <b>example</b> of this condition of anxiety hysteria is seen in the case of a man who suffered from Averter's 'cramp' .
	fine :	The Edna Wright LP is a fine <b>example</b> of mid seventies soul .
	classic :	Physics is a classic <b>example</b> of complexity in studies .
	above :	Alasring Alasring means that more than one reference is tied to the same object , as in the above <b>example</b> .
	excellent :	An excellent <b>example</b> is at Rey Cross near Bowes in County Durham .
modifies	sentence :	If the mouse is placed on an <b>example sentence</b> , the English translation will pop up on the screen .
n_modifier	case :	In all cases <b>examples</b> are given for both the humanities style and the scientific style .

# Budoucí práce

- implementovat další klasifikátory
- naučit GDEX i na jiných datech/jazycích
- reimplementovat GDEX v C/C++

# Budoucí práce

- implementovat další klasifikátory
- naučit GDEX i na jiných datech/jazycích
- reimplementovat GDEX v C/C++

# Budoucí práce

- implementovat další klasifikátory
- naučit GDEX i na jiných datech/jazycích
- reimplementovat GDEX v C/C++