

Корпус вепсского языка: проблемы и перспективы

Veps corpus

¹Institute of Language, Literature and History

²Institute of Applied Mathematical Research
of the Karelian Research Centre of the RAS

¹Nina Zaitseva

²Andrew.Krizhanovsky

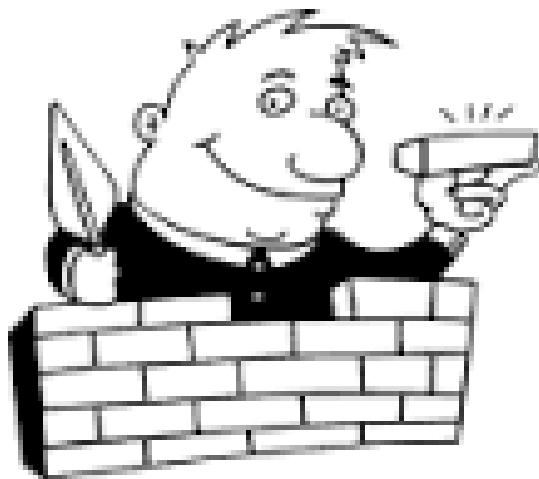


gmail.com



Goal

To create spoken
and written corpus



First task

Develop software
(corpus as a web-site).

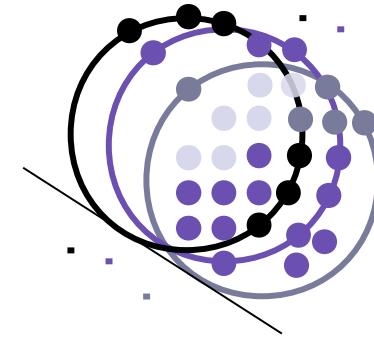
Second task

Fill data:
add texts, add words.





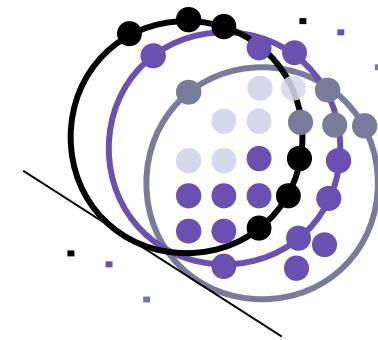
What is Corpus Linguistics?



Corpus Linguistics is the study of language/linguistic phenomena through the analysis of data obtained from a corpus.



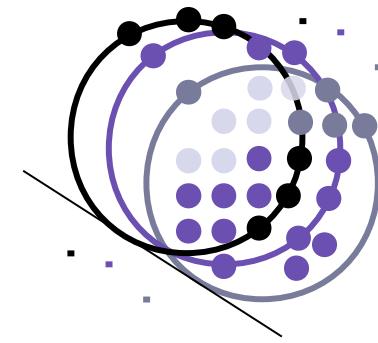
Why to use a *corpus*?



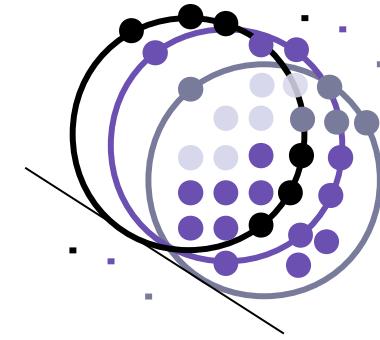
- Intuition alone is not enough
 - Is “*starting*” always replaceable by “*beginning*”?
 - Is it only “*time*” that is “*immemorial*”?
 - “*think of*” vs. “*think about*”
- Native speaker intuition is unreliable
 - provides no information on frequency of occurrence
 - “**head**” => body part - Is this the most used sense?
- Create corpus once, use for different linguistics tasks



Тексты, входящие в состав корпусов

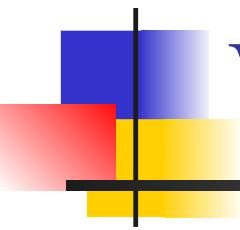


- отобраны исходя из определенных принципов,
- специально подготовлены и размечены,
 - машиночитаемый формат + разметка
- с помощью специальных программ в них можно искать необходимые фрагменты текста по заданным параметрам.



Types of corpora

- spoken vs. written
- monolingual vs. bi/multilingual
- parallel vs. comparable corpora
(translation corpora)
- general language purpose vs.
specialised language purpose
- diachronic vs. synchronic
- plain text vs. annotated (tagged)
text

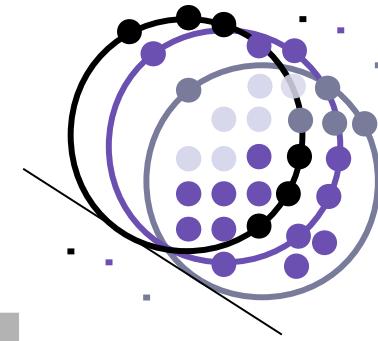


Web corpora

Корпусы(а) в Интернете



Russian corpora



Национальный корпус
русского языка

>500 млн слов

<http://ruscorpora.ru>

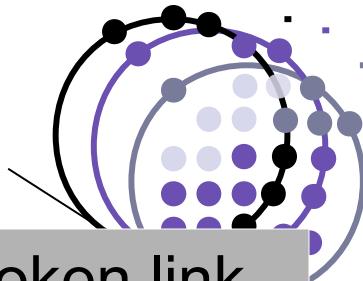
Открытый корпус
русского языка

> 1 млн слов

<http://opencorpora.org>



Finno-Ugric corpora



Языковой банк Финляндии
<http://www.csc.fi/tutkimus/alat/kielitiede>

Broken link

Справочный корпус эстонского языка
http://www.keeletehnoloogia.ee/projects-1/the-reference-corpus-of-the-estonian-language/comprehensive-corpus-of-estonian?set_language=en

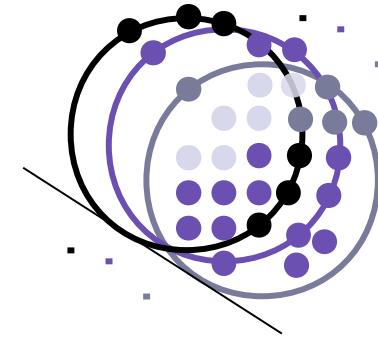
Broken link

Фонетический корпус
спонтанной эстонской речи
<http://www.murre.ut.ee/phonetic-corpus/>

20 hours,
20 speakers

Венгерский национальный корпус
http://mnsz.nytud.hu/index_eng.html

> 187
million
words



Veps corpus

Veps dictionary + corpus are available at:

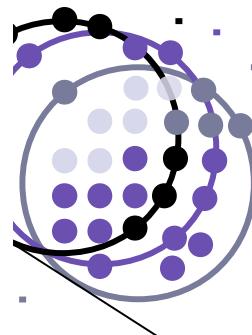
<http://vepsian.krc.karelia.ru/>

Корпус вепсского языка

[О проекте](#) [Поиск в словаре](#) [Поиск по текстам](#) [Тексты](#) [Подкорпус притчаний](#) [Ссылки](#)



Поиск в словаре



Statistics 1

Статистика

Новые материалы: леммы, словоформы, переводы, омонимы

Число лемм в словаре: 2750

Число словоформ в словаре: 8408

Wild card 2: % _

- везде**
- в леммах**
- в словоформах**

_lud%

Найти

ä ö ü č š ž '

Umlaut 3

Ваш запрос: _lud%

лемма: **kuluda**, POS: V (глагол)

№	словоформы	Грамматические признаки
1.	kulub	
2.	kulu	
3.	kului	

Перевод
русский: слышаться
английский: to be heard

лемма: **kuludas**, POS: V (глагол)

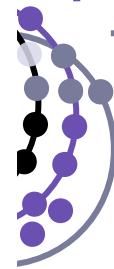
№	словоформы	Грамматические признаки
1.	kuluškanzihe	

Перевод
русский: послышаться
английский: to be heard

лемма: **polut**, POS: N (существительное)

№	словоформы	Грамматические признаки
1.	polut	

Поиск по текстам



Статистика

Новые материалы: тексты, источники

Число текстов в корпусе: 1097

Число библиографических источников: 871

Пример: vasan, minä или ленточка, или %о_о_ни%

В текстах vasan

ä ö ü č š ž '

приближённый поиск лемм и словоформ в текстах,
то есть поиск подстрок (по умолчанию выполняется точный поиск)

Ваш запрос: vasan

Леммы в словаре: vas

Перевод лемм: vas (квас || bread juice | kvass | quass)

Словоформы в словаре: vasan, vas-se, vas

По запросу найдено текстов: 2

1. Kut tegiba vasan

Язык и народ: тексты и комментарии, (2002), с. 67-68

Карпов Никанор Леонтьевич, г.р. 1897, место записи: Ладва (Ladv), Подпорожский р-н,
Ленинградская обл.

1. Kut tegiba vasan

Язык и народ: тексты и комментарии, (2002), с. 67-68

Карпов Никанор Леонтьевич, г.р. 1897, место записи: Ладва (Ladv), Подпорожский р-н, Ленинградская обл.

1. Potom liiban paned sin'n'a da kipetkoižuu valad viluu, da vuu sepid paned dei **vas** tegese čoma.
2. Ende tegiba **vasan**, ka rugihen ligotadas da id'atadas da päčhe pandas.
3. Tegižihe imen, nu da sit' kuivatas da jouhtas da paštas liibežiks, nu i **vasan** pandas.
4. Otad, **vasan** valad, lukhiinežid da ret'kašt da babušt.
5. Uuged ezmäks paned mišto ii jokseiž liib, riigun kohtha, riig mi jokseb **vas-se**.

2. Van'ka-vor

Вепсские народные сказки, (1996), с. 122-124; ф/архив ИЯЛИ КарНЦ РАН: № 2624/2, НА КарНЦ, кол.83, ед. хр.146

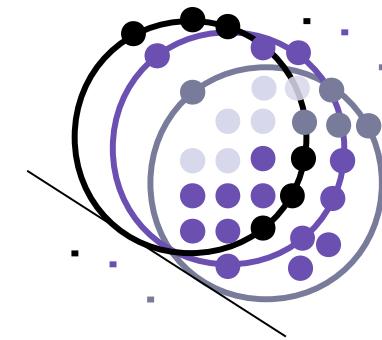
Микшина Марфа Захарьевна, г.р. 1910, место записи: Ладва (Ladv), Подпорожский р-н, Ленинградская обл., г. записи: 1980, записали: Онегина Нина Федоровна

По запросу найдено текстов: 2,

из этих текстов найдено цитат, содержащих искомые слова из словаря: 5



Veps corpus



User

- Search in dictionary
- Search in corpus

Editor (admin)

- Edit dictionary
- Edit texts in corpus

Все тексты

Выберите подкорпус

- диалектные тексты (199)
- библейские тексты (переводные) (431)
- младописьменный подкорпус (89)
- подкорпус вепсских причитаний (47)
- подкорпус вепсских сказок (55)

свойство текста

- северновепсский диалект (27)
- средневепсский диалект (214)
- южновепсский диалект (57)
- восточные говоры (32)
- западные говоры (31)
- свадебные причитания (29)
- похоронные и поминальные причитания (18)
- публицистические тексты (51)
- художественные тексты (21)
- тексты для детей (17)

[выбрать](#)

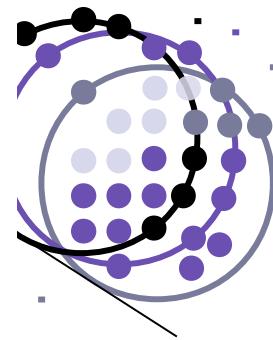
Подкорпус вепсских причитаний

Список текстов только для одного языка: вепсский

Северновепсский диалект

Найдено текстов: 5.

1. [Nevestan voik svad'ban päiväl](#)
северновепсский диалект, свадебные причитания



Nevestan voik svad'ban päiväl

подкорпус вепсских причитаний

северновепсский диалект, свадебные причитания

*Информант: Ермолаева Анастасия, г.р. 1899, урожд. Шелтозеро (Šoutaru),
Прионежский р-н, Республика Карелия, место записи: Шелтозеро (Šoutaru),
Прионежский р-н, Республика Карелия, г. записи: 1962, записали: Лонин
Рюрик Петрович*

Nevestan voik svad'ban päiväl

Tänambeižel päivaižel om milei-d'o
svad'baine.

Kogozuhe kaik minun rodn'aine.

Milei vaise üht ii täudu bat'uškod-se
rodnijad.

Arihad tö minun kaik läheližed,
armhad tö minun susedaižed,
avaikat tö mili dorogaine,

Плач невесты в день свадьбы

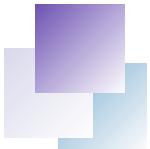
В сегодняшний денечек у меня уже
свадьба.

Собралась вся моя родня.

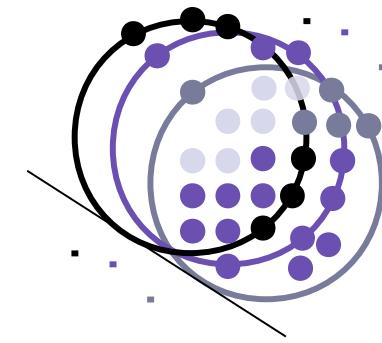
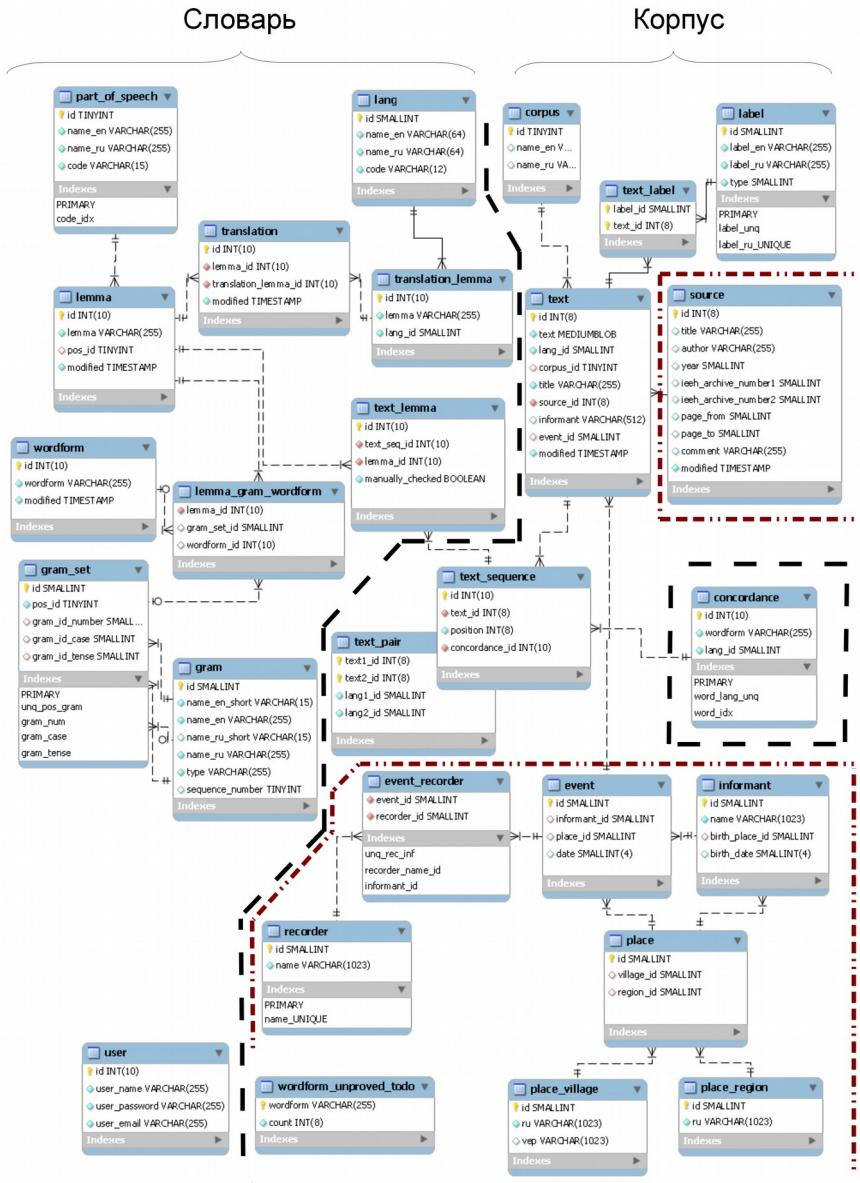
Не хватает мне одного батюшки
родного.

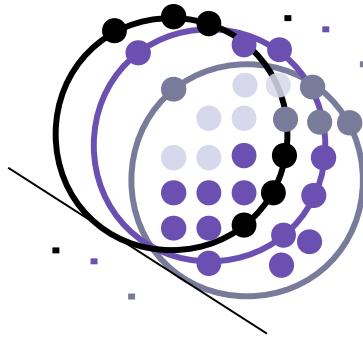
Любимые вы мои родственники,
любимые вы мои соседушки,
откройте вы мне дороженьку,





dictorus





Future work

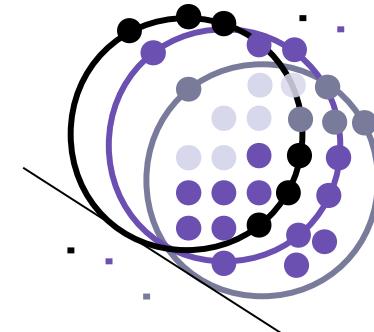
Open corpus of Veps and Karelian languages

(VepKar) (Открытый корпус вепсского и
карельского языков)

- Open software license,
- Open (Creative-commons cc-by) data



Thank you



Veps corpus:

<http://vepsian.krc.karelia.ru/>

The paper “Корпус вепсского языка”:

<http://scipeople.com/publication/121149/>

Корпус вепсского языка

[О проекте](#) [Поиск в словаре](#) [Поиск по текстам](#) [Тексты](#) [Подкорпус притчаний](#) [Ссылки](#)

