

Способы оценки корпусов

Е. Клячко

Оплинг

Корпус устных полевых записей: сомнения

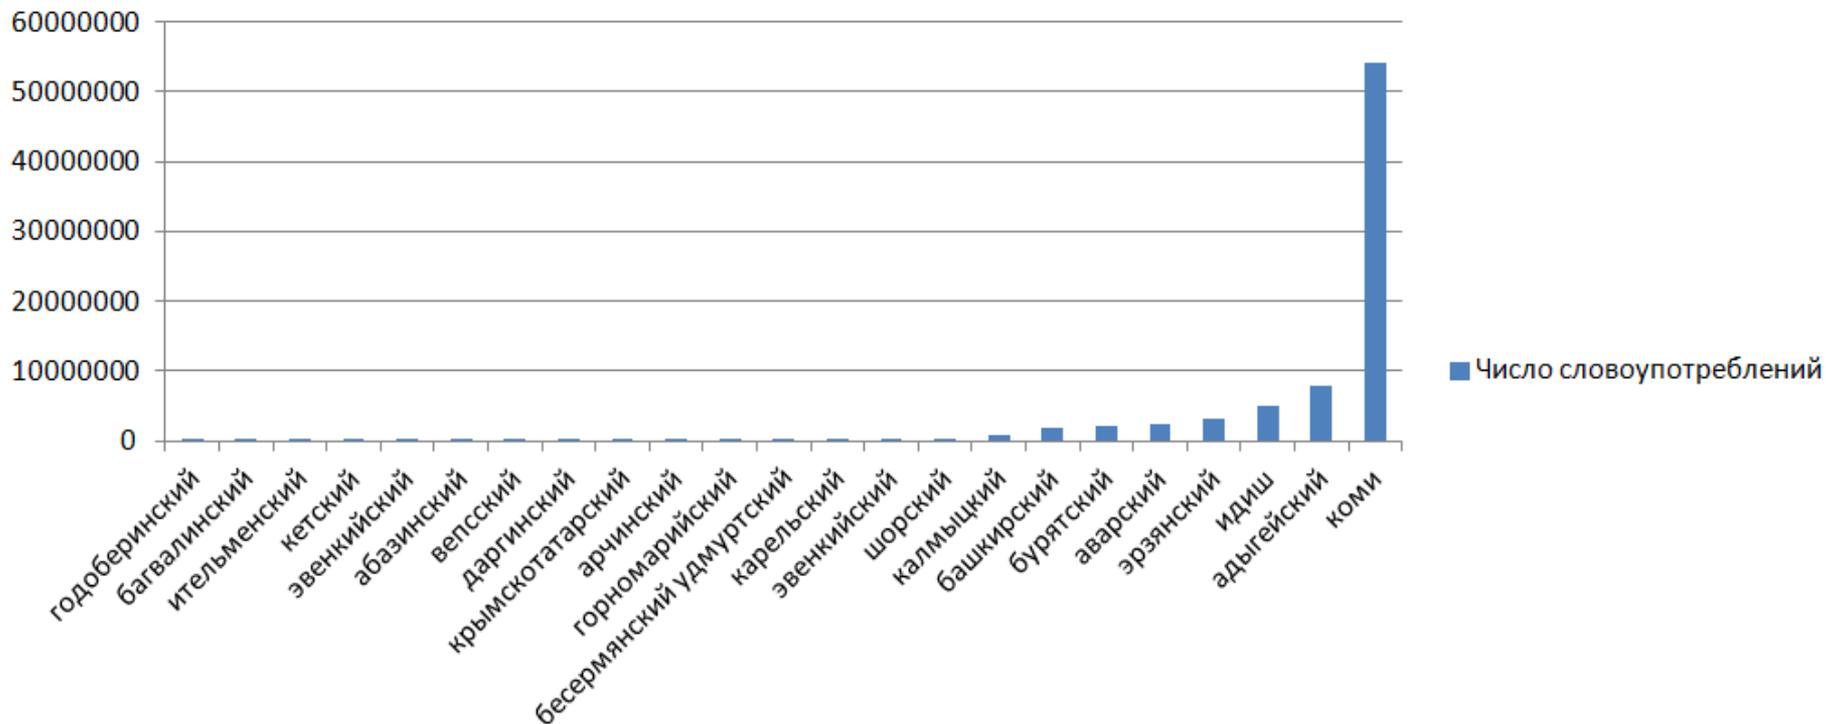
- мало данных — насколько имеем право применять статистические методы
- несбалансированность
- большая вариативность

⇒ Есть ли способ формализовать эти проблемы?
и разрешить сомнения?

Объем корпусов текстов на языках России

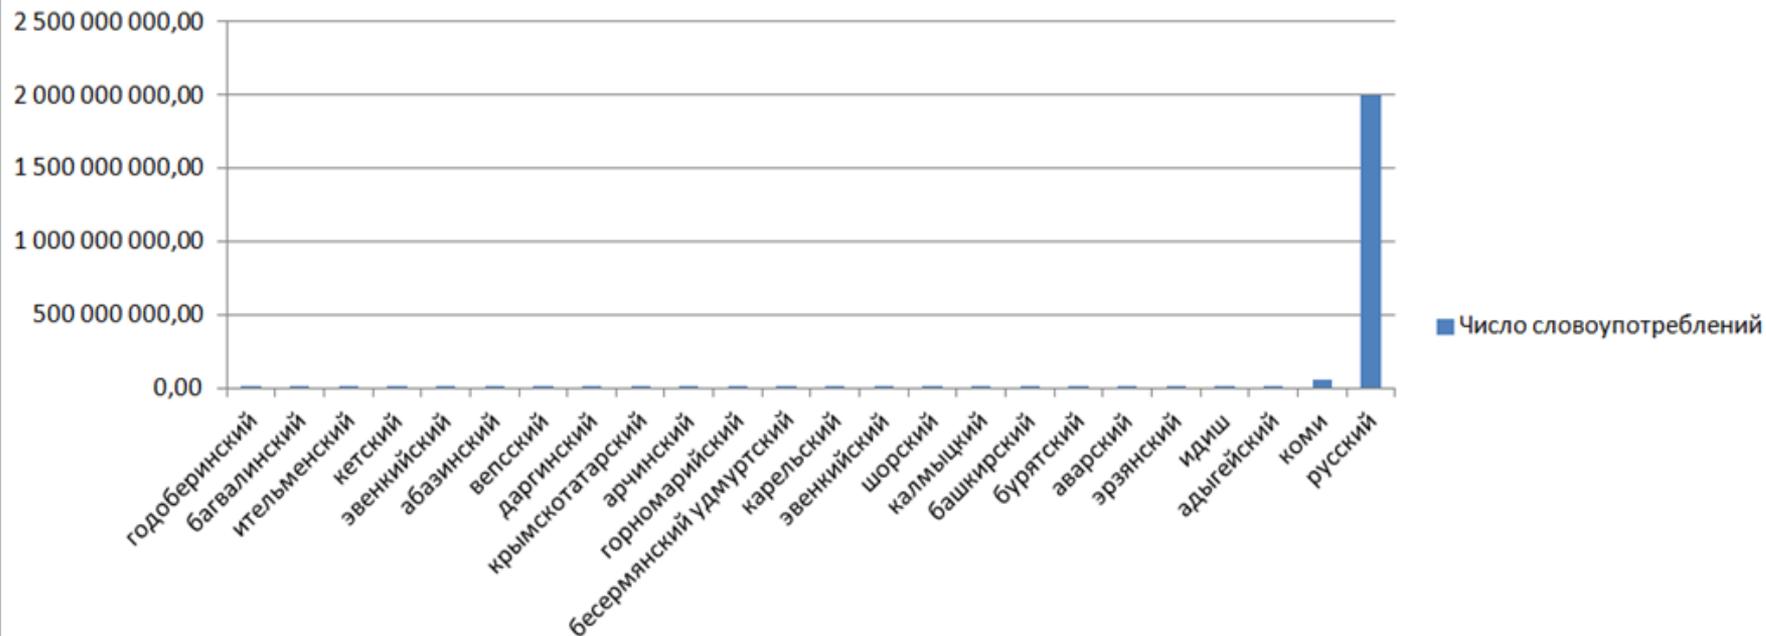


Число словоупотреблений (суммарно по доступным корпусам для языков)



Объем корпусов текстов на языках России

Число словоупотреблений (суммарно по доступным корпусам для языков)



Критерии “пригодности”

- для лингвистических исследований
- для машинной обработки

Проблемы: вариативность

- устная речь: стандартизация?
- расхождения в разметке
 - изменения к подходу в глоссировании
 - “омонимичные” показатели
 - ошибки человека
 - ошибки автоматической разметки

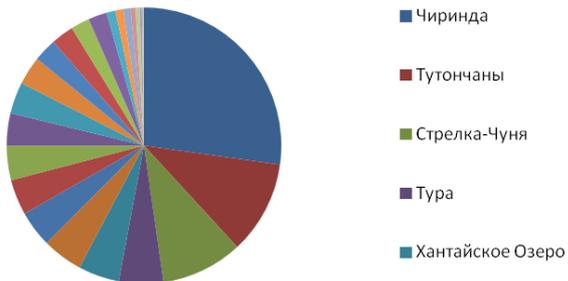
⇒ инструменты поиска “подозрительных” разборов

Репрезентативность и сбалансированность

- число словоупотреблений
- жанры и тематика
 - фольклор, этнография, воспоминания
- монолог vs диалог vs полилог
- выбор рассказчиков / текстов для включения в корпус
 - ограниченность ресурсов
 - гендер / возраст / профессия / ...
 - “хороший рассказчик”
 - предпочтения разметчика
- выбор при самозаписи
- представленность диалектов

Пример эвенкийского корпуса: <https://minlang.iling-ran.ru/corpora/evenki>

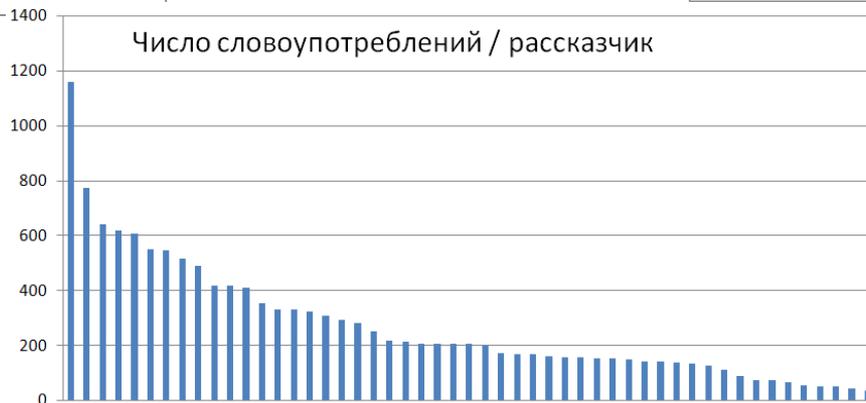
Количество словоупотреблений/
населенный пункт



Количество
словоупотреблений/ группа
диалектов



Число словоупотреблений / рассказчик



Литература?

- автоматизированная чистка наборов данных:
 - поиск ошибок
 - outlier detection – выявление аномалий
- ручная оценка качества
- энтропия как оценка сбалансированности?
- рекомендации по статистическим методам:
 - Egbert J., Larsson T., Biber D. Doing linguistics with a corpus: Methodological considerations for the everyday user. – Cambridge University Press, 2020.
 - Paquot M., Gries S. T. (ed.). A practical handbook of corpus linguistics. – Springer Nature, 2021.

Интерпретируемо ли то, что мы можем получить по корпусу?

- частотные списки
- коллокации
- языковые модели

**коллокация (по словоформам,
порог=10)**

перевод

a to

‘а то’ (рус.)

tar kiŋgit

‘тот Кингит’ (персонаж сказки)

tak i

‘так и’ (рус.)

tar ahī

‘та женщина’

tar bəjə

‘тот мужчина’

tar ələ

дискурсивный маркер (‘так вот...’)

taduk hələ

дискурсивный маркер (‘потом вот...’)

i wot

‘и вот’ (рус.)

taduk nuŋan

‘потом он(а/о)’

**коллокация (по леммам,
порог=10)**

перевод

tuŋ níkə-

так делать

d'u d'u-

дом дом

toɣo hī-

огонь дуть

bira d'apka

река берег

a to

а то (*рус.*)

mō mō-

дерево дерево

ə hula-

INTJ оставить

tar kiŋgit

тот Кингит

aun- tərəkə-

сказать кричать

Языковые модели, вектора (word embeddings), опыт с TTS

- [https://www.tensorflow.org/tutorials/text/word2vec?
hl=en](https://www.tensorflow.org/tutorials/text/word2vec?hl=en)
- <https://huggingface.co/blog/how-to-train>
- The final training corpus has a size of 3 GB, which is still small – for your model, you will get better results the more data you can get to pretrain on.

Рекомендации по статистическим подходам (Egbert et al. 2020)

- пример, когда “проверка гипотезы” подводит
- использование conditional inference tree (деревья условного вывода)
 - интерпретируемая методика
 - меньше требований к объему и составу данных
- “возвращаться” от статистики к данным

Результаты

- публиковать подробные метаданные
- балансировать состав корпуса (?)
- автоматически отлавливать ошибки
- анализировать частотные списки