




Автоматический морфемный анализ слов русского языка: сравнение подходов

Выполнила: Мальтина Людмила



- 
- Analysis of Images, Social Networks and Texts. 8th International Conference, AIST 2019 (Kazan). Мальтина Л.П., Малафеев А.Ю. Morpheme Segmentation for Russian: Evaluation of Convolutional Neural Network Models (17.07.2019 - 19.07.2019)

Подходы к морфемному анализу:

- униграммная вероятностная модель
 - условные случайные поля
 - свёрточные нейронные сети
- 

Актуальность исследования

- **векторные представления внесловарных слов** (Galinsky et. al., 2017; Arefyev, Gratianova, Popov, 2018; Sadv, Kutuzov, 2018)
- **машинный перевод** (Fritzing, Fraser, 2010)
- **распознавание речи** (Карпов, 2007)
- **информационный поиск** (Bernhard, 2006)
- **разметка корпусов** (Гришина и др., 2009; <http://www.ruscorpora.ru/search-main.html>)
- **проверка морфемного анализа, выполненного учащимися** (<https://www.morphemeonline.ru>)

Формирование выборок

**неразмеченные данные на основе униграмм
из НКРЯ**

(<http://www.ruscorpora.ru/new/corpora-freq.html>)

Предобработка:

- отбор словоформ, которые содержали только буквы русского алфавита и дефисы
 - приведение к нижнему регистру
 - исключение незнаменательных частей речи (pymorphy2)
 - объём выборки – 674940 словоформ
- + лемматизированная версия – 146907 лемм**

Формирование выборок

размеченные данные на основе словаря
А. Н. Тихонова

- словарь с полуавтоматическим указанием типов морфов
(<https://github.com/AlexeySorokin/NeuralMorphemeSegmentation>)
- исправление неточностей разметки вручную (78 слов):

| Слово | Разбор в словаре | Исправленный разбор |
|-------------|---|---|
| управляемый | у:PREF/ правл:ROOT/ я:SUFF/ ем:ROOT / ый:END | у:PREF/ правл:ROOT/ я:SUFF/ ем:SUFF / ый:END |

- обучающая, валидационная и тестовая выборки – 40/30/30 (38368/28777/28777 слов)

Формирование выборок

размеченная выборка из слов, содержащих корни, которые отсутствуют в обучающей выборке

- отбор слов, в которых хотя бы один корень отсутствовал в обучающей выборке (https://gufo.me/dict/orthography_lopatin, <https://russkiiyazyk.ru/leksika/slovar-neologizmov.html>, https://github.com/kpopov94/morpheme_seq2seq)
- добавление однокоренных слов с использованием сервиса (<https://wordroot.ru>)
- выполнение морфемного анализа этих слов

Формирование выборок

Размеченная выборка из слов, содержащих корни, которые отсутствуют в обучающей выборке

- Выборка (800 слов) включает в себя много заимствований (например, *буккроссинг*). В неё вошли:
 - термины (*аденозинтрифосфорный*)
 - неологизмы (*загуглиться*)
 - слова, образованные от имён собственных (*неогумбольдтианство*)

Характеристики размеченных выборок

| Выборка | Среднее кол-во морфов в слове | Доля префиксов | Доля корней | Доля суффиксов | Доля окончаний | Доля интерфиксов | Доля постфиксов |
|-----------------------------------|--|-------------------|----------------|-------------------|-------------------|---------------------|--------------------|
| Обучающая | 3,823 | 0,114 | 0,319 | 0,367 | 0,137 | 0,036 | 0,028 |
| Валидационная | 3,836 | 0,116 | 0,318 | 0,367 | 0,135 | 0,036 | 0,029 |
| Тестовая | 3,829 | 0,116 | 0,318 | 0,366 | 0,136 | 0,036 | 0,028 |
| Слова с незнакомыми корнями | 2,726 | 0,022 | 0,436 | 0,377 | 0,145 | 0,012 | 0,006 |

Униграммная вероятностная модель Morfessor

- Morfessor 2.0 (Virpioja et al., 2013; Smit et al., 2014)

- **принцип апостериорного максимума:**

$$\theta_{MAP} = \arg \max_{\theta} p(\theta | D_w) = \arg \max_{\theta} p(\theta) p(D_w | \theta)$$

- **функция потерь:**

$$L(\theta, D_w) = -\log p(\theta) - \log p(D_w | \theta)$$

- **упрощающее предположение:** как морфы в слове, так и символы, образующие морф, встречаются независимо друг от друга
- **правдоподобие данных** $p(D_w | \theta)$ – произведение вероятностей морфов, входящих в выбранные варианты морфемного анализа
- **априорная вероятность** $p(\theta)$ выше для словарей, которые состоят из меньшего числа морфов и содержат более короткие морфы

Униграммная вероятностная модель Morfessor

- **функция потерь для модели, использующей обучение без учителя:**

$$L(\theta, D_w) = -\log p(\theta) - \alpha \log p(D_w | \theta)$$

чем выше α , тем длиннее могут быть морфы

- **функция потерь для модели, использующей частичное обучение:**

$$L(\theta, D_w) = -\log p(\theta) - \alpha \log p(D_w | \theta) - \beta \log p(D_w \rightarrow A | \theta)$$

β регулирует количество разбиений для размеченных данных

Униграммная вероятностная модель Morfessor

Grid search для подбора параметров:

- лемматизация неразмеченной обучающей выборки: да/нет
- представление данных неразмеченной выборки: типы/токены
- α и β : эвристика;
 $\alpha \in \{0,1;1,0\}$
 $\beta \in \{1;1000;10000\}$
- Всего – 28 моделей

Униграммная вероятностная модель Morfessor

Лучший результат на валидационной выборке:

- лемматизация неразмеченной обучающей выборки: нет
- представление данных неразмеченной выборки: типы

$$\alpha = 0,1$$

$$\beta = 1000$$

Униграммная вероятностная модель Morfessor

- hard voting classifier: наилучший результат – с 14 лучшими моделями

Результаты на валидационной выборке:

| | F1-мера | Word accuracy без учёта типа морфов |
|---|---------|--|
| одна лучшая модель Morfessor | 0,9026 | 0,6883 |
| hard voting classifier из 14 лучших моделей Morfessor | 0,9100 | 0,6958 |

Условные случайные поля

- Ruokolainen et al., 2013

BMS-схема:

- B – begin
- M – middle
- S – single

Linear-chain CRF:

T – количество символов в слове

$y = (y_1, y_2, \dots, y_T)$ – последовательность меток для каждого символа этого слова

$x = (x_1, x_2, \dots, x_T)$ – словоформа, рассматриваемая как последовательность символов

t – позиция символа

w – вектор параметров модели

ϕ – признаковая функция, значение которой является вектором

$$p(y | x; w) \propto \prod_{t=2}^T \exp(w \times \phi(y_{t-1}, y_t, x, t))$$

Условные случайные поля

выбор признаков эмиссии: intuition

talk + ed, play + ed, speed

- в позиции t проводится морфемная граница, если правым контекстом выступает ed:

talk + ed, play + ed, spe + ed

- в позиции t проводится морфемная граница, если правым контекстом выступает ed, но spe не является левым контекстом:

talk + ed, play + ed, speed

Условные случайные поля

- **признаки эмиссии:**

$$\{\chi_m(x, t) [y_t = y'_t] \mid m \in 1, \dots, M, \forall y'_t \in \{B, M, S\}\}$$

набор бинарных функций $\{\chi_m(x, t)_{m=1}^M\}$ описывает правый и левый контекст позиции:

- *driv + ers* ?
- δ - максимальная длина символов для контекста (в примере $\delta = 5$)
- является ли элемент из множества $\{v, iv, riv, driv, <w>driv\}$ левым контекстом?
- является ли элемент из множества $\{e, er, ers, ers</w>\}$ правым контекстом?

- **признаки перехода:**

$$\{[y_{t-1} = y'_{t-1}] [y_t = y'_t], y'_t, y'_{t-1} \in \{B, M, S\}\}$$

Условные случайные поля

Результаты на валидационной выборке:

| | F1-мера | Word accuracy без учёта типа морфов |
|----------------|---------|---|
| Supervised CRF | 0,9358 | 0,7157 |

Свёрточные нейронные сети

• Sorokin, Kravtsova, 2018

Типы морфов: BMES-схема:

- PREF
- ROOT
- SUFF
- END
- POSTFIX
- LINK
- HYPH
- B – begin
- M – middle
- E – end
- S – single

▶ **Вход:** one-hot-encoding векторы для букв в словах

▶ **Выход:** распределение вероятностей классов (по расширенной BMES-схеме) для каждого символа

Сегментация *уч:корень/и:суффикс/тель:суффикс*
для слова *учитель*

| у | ч | и | т | е | л | ь |
|--------|--------|--------|--------|--------|--------|--------|
| B-ROOT | E-ROOT | S-SUFF | B-SUFF | M-SUFF | M-SUFF | E-SUFF |

Свёрточные нейронные сети

- Sorokin, Kravtsova, 2018
- **memorization:**
 - кодирование контекста каждой позиции с помощью 15-мерного вектора:
 - могут ли морфы данного типа начинаться в данной позиции? (5)
 - могут ли морфы данного типа заканчиваться в данной позиции? (5)
 - могут ли текущий символ являться морфом данного типа, состоящим из одной буквы? (5)
 - с помощью проверки условий определяется, возможна ли предсказываемая последовательность морфов
- **soft voting classifier:** ансамбль из нескольких моделей с различными случайными инициализациями

Свёрточные нейронные сети

| Гиперпараметр | Рассмотренные значения |
|---|------------------------|
| количество свёрточных слоёв | 3; 4 |
| размер окна | 3; 5; 7 |
| количество фильтров | 192; 240 |
| количество нейронов в полносвязанном выходном слое | 48; 64; 96 |
| dropout rate | 0,2; 0,3; 0,4 |
| количество моделей | 1; 3 |
| меморизация морфем | true; false |
| меморизация n-грамм | true; false |

Свёрточные нейронные сети

| | Гиперпараметры | Точность | Полнота | F1-мера | Word accuracy с учётом типа морфов | Word accuracy без учёта типа морфов |
|-----|--|---------------|---------------|---------------|------------------------------------|-------------------------------------|
| №5 | свёрточные слои: 3 ширина окна: 5 фильтры: 192 полносвязанные нейроны в выходном слое: 64 dropout rate: 0,2 количество моделей: 3 меморизация: да | 0,9612 | 0,9634 | 0,9623 | 0,8363 | 0,8307 |
| №15 | свёрточные слои: 4 ширина окна: 5 фильтры: 240 полносвязанные нейроны в выходном слое: 64 dropout rate: 0,4 количество моделей: 3 меморизация: да | 0,9638 | 0,9676 | 0,9657 | 0,8512 | 0,8456 |

Свёрточные нейронные сети

- hard voting classifier: наилучший результат – с 4 лучшими моделями

| | F1-мера | Word accuracy с учётом типа морфов |
|--|---------|------------------------------------|
| одна лучшая модель CNN | 0,9657 | 0,8456 |
| hard voting classifier из 4 лучших моделей CNN | 0,9672 | 0,8510 |

Результаты на тестовой выборке

| | Точность | Полнота | F1-мера | Word accuracy без учёта типа морфов | Word accuracy с учётом типа морфов |
|-----------|----------|---------|---------|---|--|
| Morfessor | 0,9143 | 0,9078 | 0,9110 | 0,6990 | - |
| CRF | 0,9424 | 0,9279 | 0,9351 | 0,7143 | - |
| CNN | 0,9666 | 0,9688 | 0,9677 | 0,8583 | 0,8522 |

Анализ ошибок (CNN)

| Причина и количество ошибок этого типа | Пример (правильный вариант в скобках) | Комментарий к примеру |
|--|--|---|
| Влияние более частых морфов (28) | <i>с/холаст/ик/а</i> (схоласт/ик/а) | Частота морфа с- выше, чем частота морфа -схоласт- |
| Наличие морфов с низкой частотой в обучающей выборке (менее 15 вхождений) (24) | <i>делик/атес</i> (деликатес) | Корень -деликатес- не встречается в обучающей выборке |
| Опрощение (23) | <i>о/город/нич/еск/ий</i> (огород/нич/еск/ий) | Диахронически в слове огороднический был корень -город-, с точки зрения синхронии выделяется корень -огород- |
| Чередования (4) | <i>почт/о/обработ/ыва/ющ/ий</i> (почт/о/об/рабат/ыва/ющ/ий) | У морфа -работ- есть алломорф -рабат- |
| Переразложение (1) | <i>кост/оч/к/а</i> (кост/очк/а) | Диахронически в слове выделяются корень -косточ- и суффикс -к-, с точки зрения синхронии есть корень -кост- и суффикс -очк- |
| Другое (20) | <i>бегл/янк/а</i> (бег/л/янк/а) | Морфы -бег- и -л- есть в обучающей выборке, а морф -бегл- отсутствует, но несмотря на это программа допускает ошибку |

Результаты на выборке с незнакомыми корнями

| | Точность | Полнота | F1-мера | Word accuracy без учёта типа морфов | Word accuracy с учётом типа морфов |
|-----------|----------|---------|---------|---|--|
| Morfessor | 0,5028 | 0,7867 | 0,6135 | 0,1850 | - |
| CRF | 0,8177 | 0,7751 | 0,7958 | 0,4963 | - |
| CNN | 0,8204 | 0,8192 | 0,8198 | 0,5687 | 0,5475 |

CNN: высокое качество, если аффиксы имеют высокую частоту:

- постфикс *-ся*
- суффиксы *-ть-*, *-вш-*, *-и-*, *-изм-*, *-ист-*, *-ова-*
- префиксы *рас-*, *за-*

качество ниже, если аффиксы имеют низкую частоту:

- префикс *ре-*
- суффикс *-инг*

Перспективы

- использование автоматического морфемного анализа в прикладных задачах:
 1. создание эмбедингов слов:
 - на основе сложения эмбедингов морфов, входящих в слово
 - на основе сложения эмбедингов однокоренных слов
 - эмбедингов, не учитывающих морфемику и словообразование
 2. сравнение полученных эмбедингов на задачах:
 - определения семантической близости
 - классификации текстов

СПИСОК ОСНОВНЫХ ИСТОЧНИКОВ

1. Гришина, Е. А. [и др.] О задачах и методах словообразовательной разметки в корпусе текстов / Е. А. Гришина, И. Б. Иткин, О. Н. Ляшевская, М. Г. Тагабилева // Полярный вестник. – 2009. – Т. 12. – С. 5-25.
2. Карпов, А. А. Модели и программная реализация распознавания русской речи на основе морфемного анализа: дис. на соискание научной степени канд. техн. наук. — СПб, 2007. — 129 с.
3. Разбор слов по составу: [Электронный ресурс]. URL: <http://www.morphemeonline.ru> (дата обращения: 24.09.2018).
4. Arefyev, N. V., Gratsianova, T. Y., Popov, K. P. Morphological segmentation with sequence to sequence neural network / N. V. Arefyev, T. Y. Gratsianova, K. P. Popov // Computational linguistics and intellectual technologies: proceedings of the international conference "Dialogue 2018". – 2018. – P. 85-95.
5. Bernhard, D. Unsupervised Morphological Segmentation Based on Segment Predictability and Word Segments Alignment / D. Bernhard // Proceedings of the Pascal Challenges Workshop on the Unsupervised Segmentation of Words into Morphemes. – Venice, Italy, April 2006. – P. 19–23.
6. Fritzinger, F., Fraser, A. How to Avoid Burning Ducks: Combining Linguistic Analysis and Corpus Statistics for German Compound Processing // Proceedings of the Joint Fifth Workshop on Statistical Machine Translation and MetricsMATR. — 2010. — P. 224-234.

СПИСОК ОСНОВНЫХ ИСТОЧНИКОВ

7. Galinsky, R. [et al.] Morpheme level word embedding / R. Galinsky, T. Kovalenko, Ju. Yakovleva, A. Filchenkov // Artificial Intelligence and Natural Language 6th Conference, AINL 2017. – 2017. – P. 143-155.
8. Ruokolainen, T. [et al.]. Supervised morphological segmentation in a low-resource learning setting using conditional random fields / T. Ruokolainen, O. Kohonen, S. Virpioja, M. Kurimo // Proceedings of the 17th Conference on Computational Natural Language Learning (CoNLL). – 2013. – P. 29–37.
9. Sadov, M. A., Kutuzov, A. B. Use of morphology in distributional word embedding models: Russian language case / M. A. Sadov, A. B Kutuzov // Computational linguistics and intellectual technologies: proceedings of the international conference "Dialogue 2018". – 2018. URL: <http://www.dialog-21.ru/media/4554/sadovmapluskutuzovab.pdf>.
10. Smit, P. [et al.]. Morfessor 2.0: Toolkit for statistical morphological segmentation / P. Smit, S. Virpioja, S. A. Grönroos, M. Kurimo // The 14th Conference of the European Chapter of the Association for Computational Linguistics (EACL) – 2013. – P. 21 - 24.
11. Sorokin, A., Kravtsova, A. Deep Convolutional Networks for Supervised Morpheme Segmentation of Russian Language / A. Sorokin, A. Kravtsova // Artificial Intelligence and Natural Language. AINL 2018. Communications in Computer and Information Science, vol. 930. – Springer, Cham, 2018. – P. 3-10.
12. Virpioja, S. [et al.]. Morfessor 2.0: Python implementation and extensions for Morfessor Baseline / S. Virpioja, P. Smit, S. A. Grönroos, M. Kurimo. – Report in Aalto University publication series SCIENCE + TECHNOLOGY, Department of Signal Processing and Acoustics, Aalto University, Helsinki, Finland, 2013. – 32 p.