



# Современные тенденции в автоматической обработке текстов

Лукашевич Наталья Валентиновна, д.т.н.  
ведущий научный сотрудник НИВЦ МГУ имени М.В.  
Ломоносова, профессор МГТУ имени Н.Э. Баумана, профессор  
филологического факультета МГУ имени М.В. Ломоносова

[louk\\_nat@mail.ru](mailto:louk_nat@mail.ru)

# План


- Задачи и проблемы автоматической обработки текстов
- Данные в задачах АОТ
  - Размеченные данные vs. неразмеченные данные
- Особенности применения методов машинного обучения
  - Традиционные методы vs. глубокие нейронные сети
  - Пример подходов в области извлечения именованных сущностей
  - Достижения и проблемы методов на основе нейронных сетей

# Рынок инструментов обработки естественного языка

Natural Language Processing Market to Reach \$22.3 Billion by 2025




Natural Language Processing Total Revenue by Segment, World Markets: 2016-2025




Source: Tractica

(slides by R.Dale 2017)



# The Major Categories



# Структура информационно-аналитической системы



# Большие текстовые коллекции (ср. понятие деловой прозы А.П. Ершова)



# Сложность обработки текстов на ЕЯ

- Язык – многоуровневая знаковая система
- Описать всю информацию (словари, правила), необходимую для качественной обработки текстов, очень сложно
  - Многозначность на всех уровнях
  - Изменчивость, зависимость от контекста,
  - Изменение со временем
  - Необходимость использование больших объемов знаний о мире

# Многозначность

- Фонетическая: *лук (луг или лук)*
- Морфологическая: *стали*
- Синтаксическая:
  - *Девочка шла по полю с цветами*
- Семантическая: *Возьми лук*



# Свободные и устойчивые словосочетания: анекдоты о Штирлице

- Штирлиц выстрелил в упор, упор упал.
- Штирлиц шел по улице и поднял глаза. Это были голубые глаза пастора Шлага.
- Штирлиц стрелял из двух автоматов по очереди. Очередь заметно редела.
- Штирлица бил озноб. Озноб служил в Гестапо.
- Штирлиц топил печку. Через час печка утонула.
- Штирлиц порол чушь. Чушь отчаянно визжала.

# Необходимость знаний о мире

- “Time flies like an arrow”
  - Сколько интерпретаций?

# Необходимость знаний о мире

- “Time flies like an arrow”
  - Сколько интерпретаций?
    - 1. time passes quickly like an arrow?
    - 2. command: time the flies the way an arrow times the flies
    - 3. command: only time those flies which are like an arrow
    - 4. “time-flies” are fond of arrows

# Подходы в компьютерной лингвистике

- До 90-х годов 20 века
  - Model-driven – модели, словари, правила
- 1995-2005
  - Переходный период
- После 2005
  - Data-driven – подходы, основанные на закономерностях, обнаруженных в данных
  - => машинное обучение
    - С 2013 года глубокие нейронные сети


# Данные

- **Размеченные данные**
  - Развитие алгоритмов, воспроизводящих ручную разметку
  - Машинное обучение с учителем (supervised machine learning)
  
- **Неразмеченные данные**
  - Набор данных (тексты, речь, диалоги)
  - Автоматический вывод закономерностей
  - Машинное обучение без учителя (unsupervised machine learning)

# Разметка данных

- Экспертная разметка
  - Дорого
  - Может не отражать восприятие «обыкновенных» людей
- Краудсорсинг – набор неквалифицированных людей для подготовки данных
  - Подготовка заданий
  - Вознаграждение
  - Контроль качества
- Пользовательская разметка (user-generated content)
  - Хэштеги и смайлики для твитов
  - Ссылки в Википедии


# Экспертная разметка: Syntagrus



# Краудсорсинг


- Специальные платформы:
  - Mechanical turk (Mturk) – мало русскоязычных разметчиков
  - Yandex Toloka
- Индивидуальные проекты сбора ответов людей
- Игры со специальной целью: Game with a purpose (GWAP)
  - Как сделать так, чтобы многим людям было интересно играть и тем самым цель игры достигалась

# Оценка семантической близости слов краудсорсингом

№	Первое слово	Второе слово	Насколько <i>связаны</i> эти слова?
1	чашка	напиток	
2	автомобиль	машина	
3	производство	поход	
4	Арафат	терроризм	
5	поездка	машина	
6	психология	наука	
7	перечисление	категория	
8	среда	новости	
9	любовь	секс	

# GWAP (GAME WITH A PURPOSE)

- Players have fun, creators get data as by-product






# Пользовательский контент

- Википедия
  - Энциклопедическая статья
  - Соответствия между языками
  - Привязка статей к категориям и др.
- Твиттер: разметка смайликами и хэштегам




# Размеченные данные: машинное обучение с учителем

- Классические методы
  - Деревья решений
  - Наивный байесовский классификатор
  - Метод опорных векторов (SVM) и др.
- Методы анализа последовательностей
  - Скрытые марковские модели (HMM)
  - Случайные условные поля (CRF)
- Комбинация классификаторов
  - Gradient boosting
  - Random Forest
- Пакеты машинного обучения:
  - например <http://scikit-learn.org/stable/>
- Нейронные сети
  - Глубокое обучение




# Структура искусственного нейрона

---



$$a_i = g\left(\sum_j W_{j,i} a_j\right)$$

# Пример: Прогресс в машинном переводе



From [Sennrich 2016, [http://www.meta-net.eu/events/meta-forum-2016/slides/09\\_sennrich.pdf](http://www.meta-net.eu/events/meta-forum-2016/slides/09_sennrich.pdf)]

# Неразмеченные данные

- Кластеризация – группирование сходных объектов
- Кластеризация документов
  - Кластеризация похожих новостей в новостных сервисах
  - Кластеризация похожих документов
  - Анализ текстовых коллекций
- Кластеризация слов
  - Статистическое выделение тем
  - Выделение похожих слов
    - Традиционные подходы дистрибутивной семантики
    - **Подходы на основе нейронных сетей:**


# Кластеризация слов: традиционный дистрибутивный подход

he curtains open and the stars shining in on the barely  
ars and the cold , close stars " . And neither of the w  
rough the night with the stars shining so brightly , it  
made in the light of the stars . It all boils down , wr  
surely under the bright stars , thrilled by ice-white  
sun , the seasons of the stars ? Home , alone , Jay pla  
m is dazzling snow , the stars have risen full and cold  
un and the temple of the stars , driving out of the hug  
in the dark and now the stars rise , full and amber a  
bird on the shape of the stars over the trees in front  
But I could n't see the stars or the moon , only the  
they love the sun , the stars and the stars . None of  
r the light of the shiny stars . The splash of flowing w  
man 's first look at the stars ; various exhibits , aer  
rief information on both stars and constellations, inc

## Construct vector representations


	shining	bright	trees	dark	look
stars	38	45	2	27	12

## Similarity in meaning as vector similarity



# Word2vec – Continuous Bag of Word

- “The cat sat on floor”
  - Window size = 2



# Новые подходы к представлению слов на основе векторов сокращенной размерности

- Word embeddings
- Размерность 300-1000 измерений
- Пакет - word2vec
- Высокая эффективность расчетов
- В последнее время еще более качественные и эффективные представления слов, конструкций, предложений

*linguistics* =

0.286  
0.792  
-0.177  
-0.107  
0.109  
-0.542  
0.349  
0.271

# Проект Rusvectors: близкие слова по корпусу

RusVectōrēs

Similar words

Visualizations

Calculator

About

Contacts

RU/EN

Choose the model:

Ruscorpora and Russian Wikipedia  News corpus  Ruscorpora  Web corpus

Show only:

Nouns  Verbs  Adverbs  Adjectives  All of them  Query part of speech

Find similar words!

## Semantic associates for *книга* (ALL)

### Ruscorpora

1. [рукопись](#) 0.71250
2. [книжка](#) 0.70046
3. [брошюра](#) 0.68174
4. [монография](#) 0.61449
5. [сочинение](#) 0.61337
6. [страница](#) 0.60901
7. [учебник](#) 0.60460
8. [сборник](#) 0.59852
9. [двухтомник](#) 0.59572
10. [повесть](#) 0.59471

## Computing similarity

# Модели на сайте RusVectors


## Модели

Все модели можно скачать и свободно использовать на условиях лицензии [CC-BY](#) (**жирным** выделены модели, доступные для использования в веб-интерфейсе).

Таблицу можно (и нужно) пролистывать по горизонтали!

Постоянный идентификатор ▲▼	Скачать ▲▼	Корпус ▲▼	Размер корпуса ▲▼	Объём словаря ▲▼	Частотный порог ▲▼	Target ▲▼	Алгоритм ▲▼	Размерно вектора ▲
<b>ruscorpora_upos_cbow_300_20_2019</b>	<b>462 Мбайт</b>	НКРЯ	270 миллионов слов	189 193	5 (потолок словаря 250К)	<b>Universal Tags</b>	Continuous Bag-of-Words	300
<b>ruwikiscorpora_upos_skipgram_300_2_2019</b>	<b>608 Мбайт</b>	НКРЯ и Википедия за декабрь 2018	788 миллионов слов	248 978	5 (потолок словаря 250К)	<b>Universal Tags</b>	Continuous Skipgram	300
<b>tayga_upos_skipgram_300_2_2019</b>	<b>610 Мбайт</b>	Тайга	почти 5 миллиардов слов	249 565	5 (потолок словаря 250К)	<b>Universal Tags</b>	Continuous Skipgram	300
<b>tayga_none_fasttextcbow_300_10_2019</b>	<b>839 Мбайт</b>	Тайга	почти 5 миллиардов слов	192 415	5 (потолок словаря 250К)	Нет	fastText CBOW (3..5-граммы)	300
<b>news_upos_skipgram_300_5_2019</b>	<b>611 Мбайт</b>	Русскоязычные новости	2.6 миллиарда слов	249 318	5 (потолок словаря 250К)	<b>Universal Tags</b>	Continuous Skipgram	300
<b>araneum_none_fasttextcbow_300_5_2018</b>	<b>854 Мбайта</b>	Araneum	около 10 миллиардов слов	195 782	400	Нет	fastText CBOW (3..5-граммы)	300
<b>ruscorpora_none_fasttextskipgram_300_2_2019</b>	<b>710 Мбайт</b>	НКРЯ	270 миллионов слов	164 996	5 (потолок словаря 250К)	Нет	fastText Skipgram (3..5-граммы)	300
<b>ruwikiscorpora-func_upos_skipgram_300_5_2019</b>	<b>606 Мбайт</b>	НКРЯ и Википедия за декабрь 2018 (с функциональными словами)	788 миллионов слов	248 118	5 (потолок словаря 250К)	<b>Universal Tags</b>	Continuous Skipgram	300

# Word2vec: Семантические закономерности



## НКРЯ и Wikipedia

1. **англия**<sub>PROPN</sub> 0.58 
2. **европа**<sub>PROPN</sub> 0.54 
3. **великобритания**<sub>PROPN</sub> 0.52 
4. **страна**<sub>NOUN</sub> 0.48 
5. **франция**<sub>PROPN</sub> 0.47 

# Извлечение именованных сущностей

Пример задачи

# Извлечение именованных сущностей


В штабе **Зеленского** заявили о принадлежности **Крыма** **Украине**

В штабе кандидата в **президенты Украины Владимира Зеленского** заявили, что **Крым**? был, остается и будет частью **Украины**, сообщил телеканал «112 Украина».

«**Разговор** о размене **Крыма** на мир на **Донбассе** быть не может ни при каких обстоятельствах. Так же, как не может быть предметом переговоров сепаратизация отдельных **районов** или **регионов Украины**», — говорится в сообщении команды **Зеленского**. Отмечается, что **Крым** должен вернуться в состав **Украины** с компенсацией от **России**.

В штабе добавили, что **представителям Киева** придется вести переговоры с **Москвой**, однако делать это необходимо при участии западных партнеров и не на «оккупированных территориях».


Лучший метод до появления нейронных сетей CRF



# CRF: Представление слов в виде признаков

- Признаки токена
  - слово, часть речи, написание, суффиксы, знак препинания
- Такие же признаки для соседних слов (два влево – два вправо)
- Присутствие в словарях
  - Имена, фамилии, отчества
  - Географические названия
  - Названия должностей, типы организаций и т.п.
- Семантические кластеры слов

# Сети LSTM: общая картина



Первый слой вычисляет, насколько на данном шаге ему нужно забыть предыдущую информацию — по сути множители к компонентам вектора памяти

Второй слой вычисляет, насколько ему интересна новая информация, пришедшая с сигналом — такой же множитель, но уже для наблюдения.

На третьем слое вычисляется линейная комбинация памяти и наблюдения с только вычисленными весами для каждой из компонент. Так получается новое состояние памяти, которое в таком же виде передаётся далее.

# Все вместе

- Первый слой вычисляет, насколько на данном шаге ему нужно забыть предыдущую информацию.

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f)$$

- Второй слой вычисляет, насколько ему интересна новая информация, пришедшая с сигналом

$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] + b_i)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

- На третьем слое вычисляется линейная комбинация памяти и наблюдения с только вычисленными весами для каждой из компонент

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

- Выходной слой:  
$$o_t = \sigma (W_o [h_{t-1}, x_t] + b_o)$$
$$h_t = o_t * \tanh (C_t)$$

# BI-LSTM-CRF



- На первом слое не слова, а векторные представления слов
- Можно делать посимвольные представления слов – дает возможность обрабатывать неизвестные слова
- Не нужно отдельное представление в виде признаков

# Сравнение моделей (Huang et al., 2015)

Pos – предсказание частей речи


CONLL 2000 - chunking, выделение именных групп

CONLL 2003 – извлечение именованных сущностей

		POS	CoNLL2000	CoNLL2003
Random	Conv-CRF (Collobert et al., 2011)	96.37	90.33	81.47
	LSTM	97.10	92.88	79.82
	BI-LSTM	97.30	93.64	81.11
	CRF	97.30	93.69	83.02
	LSTM-CRF	<b>97.45</b>	93.80	84.10
	BI-LSTM-CRF	97.43	<b>94.13</b>	<b>84.26</b>
Senna	Conv-CRF (Collobert et al., 2011)	97.29	94.32	88.67 (89.59)
	LSTM	97.29	92.99	83.74
	BI-LSTM	97.40	93.92	85.17
	CRF	97.45	93.83	86.13
	LSTM-CRF	97.54	94.27	88.36
	BI-LSTM-CRF	<b>97.55</b>	<b>94.46</b>	<b>88.83 (90.10)</b>


Random – векторные представления слов обучаются в процессе обучения Решения; Senna – заранее рассчитанные векторные представления на большой коллекции; Значения в скобках – добавлены признаки на словарях

# 2018: Контекстные представления слов: ELMO, BERT



Слово **play** получает разные векторные представления в разных контекстах

# Применение контекстных представлений дает улучшения во многих задачах (ELMO)



\*Kitaev and Klein, ACL 2018 (see also Joshi et al., ACL 2018)

# Результаты на данных CONLL-2003 для новых способов подсчетов контекстных представлений слов: Bert 2018


System	Dev F1	Test F1
ELMo+BiLSTM+CRF	95.7	92.2
CVT+Multi (Clark et al., 2018)	-	92.6
BERT <sub>BASE</sub>	96.4	92.4
BERT <sub>LARGE</sub>	96.6	92.8

sults. The hyperparameters were selected using the Dev set, and the reported Dev and Test scores are averaged over 5 random restarts using those hyperparameters.

# Однако

- Машинное обучение не решает все задачи
  - Полного искусственного интеллекта пока не создано
  - Нейронная сеть решает точно ту задачу, для которой она обучалась
  - Нужны хорошо подготовленные обучающие выборки
  - Обучающие выборки устаревают со временем
- Возможность намеренного искажения ввода для обхода системы построенной на глубоком обучении
  - Adversarial learning is a technique employed in the field of machine learning which attempts to fool models through malicious input

# Добавление специального «шума» заставляет нейронную сеть ошибиться



In a [paper](#) by Goodfellow, Shlens, and Szegedy, modern machine learning methods are described as building “a Potemkin village that works well on naturally occurring data, but is exposed as a fake when one visits points in space that do not have high probability in the data distribution”



# THE LANGUAGE RESOURCE SPECTRUM: A PERSPECTIVE FROM GOOGLE

Ryan McDonald



Google NLU team  
Google Linguistics team



2016



WIKIPEDIA  
The Free Encyclopedia



Wiktionary  
The free dictionary



unsupervised



weakly supervised



fully supervised




$\alpha$

$\beta$

$\gamma$

$\delta$



High quality  
annotations

Crowd-sourced

Pre-existing resources

Software Engineer  
Auto resources  
Models  
Active Learning

# Заключение

- Задачи автоматической обработки текстов
  - Необходимость данных (размеченных и неразмеченных)
  - Большинство лучших результатов на разных эталонных данных получено на основе нейронных сетей
  - На практике все сложнее:
    - меньше или нет данных,
    - возможность специального искажения данных (вопросы безопасности)
- Решение задач АОТ в настоящее время - это поиск подхода, в котором могут комбинироваться
  - Готовые ресурсы, сделанные вручную (словари и правила)
  - Ресурсы, построенные автоматически на основе больших объемов текстовых данных
  - Методы машинного обучения с учителем, работающие на основе специально подготовленной обучающей коллекции