

Математические методы анализа текстов


Векторные представления слов (word embeddings)

Потапенко Анна Александровна

24 октября 2018

Семантическая близость слов

- Со-встречаемости первого порядка
syntagmatic associates / relatedness (bee and honey)
- Со-встречаемости второго порядка
paradigmatic parallels / similarity (bee and bumblebee)



Schutze, H., & Pedersen, J. (1993). A vector model for syntagmatic and paradigmatic relatedness. In *Making Sense of Words: Proceedings of the Conference*, pp. 104-113, Oxford, England.

Дистрибутивная гипотеза

“You shall know a word by the company it keeps.”

— Firth, 1957.

- Скользящее окно фиксированной ширины
- Счетчики со-встречаемости n_{uv}

Дистрибутивная гипотеза

“You shall know a word by the company it keeps.”
— Firth, 1957.

- Скользящее окно фиксированной ширины
- Счетчики со-встречаемости n_{uv}
- **Лучше:** Pointwise Mutual Information:

$$PMI = \log \frac{p(u, v)}{p(u)p(v)} = \log \frac{n_{uv}n}{n_u n_v}$$

Дистрибутивная гипотеза

“You shall know a word by the company it keeps.”

— Firth, 1957.

- Скользящее окно фиксированной ширины
- Счетчики со-встречаемости n_{uv}
- **Лучше:** Pointwise Mutual Information:


$$PMI = \log \frac{p(u, v)}{p(u)p(v)} = \log \frac{n_{uv}n}{n_u n_v}$$

- **Еще лучше:** positive Pointwise Mutual Information:

$$pPMI = \max(0, PMI)$$

Проблемы?


- Со-встречаемости первого порядка
syntagmatic associates / relatedness (bee and honey)
- Со-встречаемости второго порядка
paradigmatic parallels / similarity (bee and bumblebee)





Schutze, H., & Pedersen, J. (1993). A vector model for syntagmatic and paradigmatic relatedness. In *Making Sense of Words: Proceedings of the Conference*, pp. 104-113, Oxford, England.

Векторные модели семантики

- **Вход:** со-встречаемости слов (counts, PMI, ...)
- **Метод:** понижение размерности (SVD, ...)
- **Выход:** близость между векторами слов




Что такое контекст?



WORD	CONTEXTS
australian	scientist/amod ⁻¹
scientist	australian/amod, discovers/nsubj ⁻¹
discovers	scientist/nsubj, star/dobj, telescope/prep_with
star	discovers/dobj ⁻¹
telescope	discovers/prep_with ⁻¹


Что такое контекст?

- \mathbf{C} – это словарь контекстов (напр., [australian/amod](#))
- Но обычно контексты это слова из окна
- Тогда $\mathbf{W} = \mathbf{C}$ и X – это симметричная матрица




Низкоранговые матричные разложения

Сингулярное разложение (SVD)




Truncated SVD

Оставляем только k компонент $\hat{X}_k = U_k \Sigma_k V_k^T$



Truncated SVD

Оставляем только k компонент $\hat{X}_k = U_k \Sigma_k V_k^T$




Лучшая аппроксимация ранга k в смысле нормы Фробениуса:

$$\|X - \hat{X}\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \hat{x}_{ij})^2}$$


Как использовать SVD разложение?

Опция 1:



$$\Phi = U_k \Sigma_k \quad \Theta = V_k^T$$


Опция 2:



$$\Phi = U_k \sqrt{\Sigma_k} \quad \Theta = \sqrt{\Sigma_k} V_k^T$$

Векторные модели семантики


- **Вход:** со-встречаемости слов (counts, PMI, ...)
- **Метод:** понижение размерности (SVD, ...)
- **Выход:** близость между векторами слов



Взвешенные квадратичные потери: GloVe

Составим X из $\log n_{uv}$ и рассмотрим функцию потерь:

$$\sum_{u \in W} \sum_{v \in W} f(n_{uv}) (\langle \phi_u, \theta_v \rangle + b_u + b'_v - \log n_{uv})^2 \rightarrow \min_{\phi_u, \theta_v, b_u, b'_v}$$



Языковая модель: Skip-Gram

Предсказываем *контексты* по слову:

$$p(w_{i-h}, \dots, w_{i+h} | w_i) = \prod_{-h \leq k \leq h, k \neq 0} p(w_{i+k} | w_i)$$

Каждую вероятность моделируем как *softmax*:

$$p(u|v) = \frac{\exp \langle \phi_u, \theta_v \rangle}{\sum_{u' \in W} \exp \langle \phi_{u'}, \theta_v \rangle}$$

Две матрицы параметров (как и в других методах).

Как обучать модель?

Максимизация *лог-правдоподобия*:

$$\mathcal{L} = \sum_{u \in W} \sum_{v \in W} n_{uv} \log p(u|v)$$

со-встречаемость



Метод:

- SGD по парам слов в корпусе

Проблема:

- *softmax* по словарю считать медленно.

Skip-gram Negative Sampling (SGNS)

Вместо того чтобы предсказывать слова,
будем предсказывать «да» и «нет» для пар слов:

$$\sum_{u \in W} \sum_{v \in W} n_{uv} \log \sigma (\langle \phi_u, \theta_v \rangle) +$$

$$k \mathbb{E}_{\bar{v}} \log \sigma (-\langle \phi_u, \theta_{\bar{v}} \rangle) \rightarrow \max_{\phi_u, \theta_v}$$


- **Положительные примеры:** со-встретившиеся пары u , v
- **Отрицательные примеры:** k случайных \bar{v} для каждого u

Обучается все еще стохастическим градиентным спуском.

SGNS как неявное матричное разложение

Функция потерь в SGNS принимает максимум, когда $\langle \phi_u, \theta_v \rangle$ равно shifted Pointwise Mutual Information:

$$\text{sPMI} = \log \frac{n_{uv}n}{n_u n_v} - \log k$$



Оценивание моделей

Оценивание моделей: близость слов

Как проверить что *близкие слова* имеют *близкие вектора*?

- Лингвисты выделяют несколько типов близости
- Можно использовать *экспертные оценки* пар слов.
- Сравнить *корреляцию Спирмена* для двух списков:



tiger	tiger	10.00
media	radio	7.42
tiger	cat	7.37
train	car	6.31
...

tiger	tiger	$\cos(\phi_u, \phi_v)$
media	radio	...
tiger	cat	...
train	car	...
...

Оценивание моделей: задача аналогий

- В когнитивных науках известна как *relational similarity* (vs. *attributional similarity*).
- $a : a'$ как $b : b'$ (man : woman как king : ?)

$$\cos(b - a + a', x) \rightarrow \max_x$$



Gentner, D. Structure-mapping: A theoretical framework for analogy. Cognitive Science, 1983.
Mikolov et. al. Linguistic Regularities in Continuous Space Word Representations, 2013.

Сравнение моделей

- *Count-based* подходы не уступают *predictive* подходам

win	Method	WordSim Similarity	WordSim Relatedness	Bruni et al. MEN	Radinsky et al. M. Turk
2	PPMI	.732	.699	.744	.654
	SVD	.772	.671	.777	.647
	SGNS	.789	.675	.773	.661
	GloVe	.720	.605	.728	.606
5	PPMI	.732	.706	.738	.668
	SVD	.764	.679	.776	.639
	SGNS	.772	.690	.772	.663
	GloVe	.745	.617	.746	.631

Сравнение моделей


- Задача аналогий решается с точностью 70%

win	Method	Google	MSR
		Add / Mul	Add / Mul
2	PPMI	.552 / .677	.306 / .535
	SVD	.554 / .591	.408 / .468
	SGNS	.676 / .689	.617 / .644
	GloVe	.649 / .666	.540 / .591
5	PPMI	.518 / .649	.277 / .467
	SVD	.532 / .569	.369 / .424
	SGNS	.692 / .714	.605 / .645
	GloVe	.700 / .712	.541 / .599

Paragraph2vec, он же doc2vec

And the only reason for being a **bee** that I know of is making honey.

КОНТЕКСТЫ СЛОВО КОНТЕКСТЫ



DM (Distributed Memory):

$$p(w_i | w_{i-h}, \dots, w_{i+h}, d)$$

DBOW (Distributed Bag Of Words):

$$p(w_{i-h}, \dots, w_{i+h} | d)$$

Оценивание моделей: близости документов

Как оценить что *близкие документы* имеют *близкие вектора*?

- ArXiv: статья А, похожая статья В, не похожая статья С
- Точность угадывания, какая из статей В и С не похожа

<http://arxiv.org/pdf/1206.5743>

<http://arxiv.org/pdf/cond-mat/0403258>

<http://arxiv.org/pdf/1408.0189>

<http://arxiv.org/pdf/1209.0268>

<http://arxiv.org/pdf/1307.7598>

<http://arxiv.org/pdf/math/0504051>

<http://arxiv.org/pdf/hep-ph/9908436>

<http://arxiv.org/pdf/nucl-th/9707019>

<http://arxiv.org/pdf/1112.3014>

<http://arxiv.org/pdf/1111.2905>

<http://arxiv.org/pdf/1303.2538>

<http://arxiv.org/pdf/1109.1922>

<http://arxiv.org/pdf/nucl-ex/0112013>

<http://arxiv.org/pdf/physics/9704013>

<http://arxiv.org/pdf/1408.4595>

<http://arxiv.org/pdf/0709.3419>

<http://arxiv.org/pdf/quant-ph/0611134>

<http://arxiv.org/pdf/0902.0616>

<http://arxiv.org/pdf/hep-th/9609148>

<http://arxiv.org/pdf/solv-int/9710009>

<http://arxiv.org/pdf/astro-ph/0508060>

Оценивание моделей: близости документов

Integral formula of Minkowski type and new characterization of the Wulff shape

Yijun He *

Haizhong Li †

Abstract

Given a positive function F on S^n which satisfies a convexity condition, we introduce the r -th anisotropic mean curvature M_r for hypersurfaces in \mathbb{R}^{n+1} which is a generalization of the usual r -th mean curvature H_r . We get integral formulas of Minkowski type for compact hypersurfaces in \mathbb{R}^{n+1} . We give some new characterizations of the Wulff shape by use of our integral formulas of Minkowski type, in case $F = 1$ which reduces to some well-known results.

2000 Mathematics Subject Classification: Primary 53C42, 53A30; Secondary 53B25.

Key words and phrases: Wulff shape, F -Weingarten operator, anisotropic principal curvature, r -th anisotropic mean curvature, integral formula of Minkowski type.

[xiv.org/pdf/1408.0189](https://arxiv.org/pdf/1408.0189)

[xiv.org/pdf/math/0504051](https://arxiv.org/pdf/math/0504051)

[xiv.org/pdf/1112.3014](https://arxiv.org/pdf/1112.3014)

[xiv.org/pdf/1109.1922](https://arxiv.org/pdf/1109.1922)

[xiv.org/pdf/1408.4595](https://arxiv.org/pdf/1408.4595)

[xiv.org/pdf/0902.0616](https://arxiv.org/pdf/0902.0616)

[xiv.org/pdf/astro-ph/0508060](https://arxiv.org/pdf/astro-ph/0508060)

Оценивание моделей: близости документов

Integral formula of Minkowski type and new characterization of the Wulff shape

COMPLEX CURVES IN ALMOST-COMPLEX MANIFOLDS AND MEROMORPHIC HULLS

Sergei IVASHKOVICH – Vsevolod SHEVCHISHIN

G
introc
is a g
of Mi
teriza
in cas

Preface

Chapter I. Local Properties of Complex Curves.

Lecture 1. Complex Curves in Almost-Complex Manifolds. ... pp. 1–12

1.1. Almost-Complex Manifolds, Hermitian Metrics, Associated (1,1)-Forms. 1.2. Existence of Calibrating and Tame Structures. 1.3. Almost-Complex Submanifold, Complex Curves, Energy and Area. 1.4. Symplectic Surfaces. 1.5. Adjunction Formula for Immersed Symplectic Surfaces.

2000 Ma
53B25.

Key word
curvature,

051

508060

Оценивание моделей: близости документов

Accepted for publication in *Solar Physics*, waiting for the authoritative version and a DOI which will be available at <http://www.springerlink.com/content/0038-0938>

In

Time-dependent Stochastic Modeling of Solar Active Region Energy

M. Kanazir and M. S. Wheatland¹

Received: 7 July 2010 / Accepted: 31 July 2010 / Published online: ●●●●●●●●●●

Abstract A time-dependent model for the energy of a flaring solar active region

in
is
of
te
in

2000 Ma
53B25.


Key word
curvature,

Lecture 1. Complex Curves in Almost-Complex Manifolds. ... pp. 1–12

1.1. Almost-Complex Manifolds, Hermitian Metrics, Associated (1,1)-Forms. 1.2. Existence of Calibrating and Tame Structures. 1.3. Almost-Complex Submanifold, Complex Curves, Energy and Area. 1.4. Symplectic Surfaces. 1.5. Adjunction Formula for Immersed Symplectic Surfaces.

**Задача аналогий без магии:
king + man – woman != queen**

Магическое свойство модели word2vec



Вектора слов учатся по предсказаниям контекстов.

Получаются вектора, которые решают задачу аналогий:


- king – man + woman = queen
- Moscow – Russia + France = Paris

Демо: rare-technologies.com/word2vec-tutorial/

Присмотримся внимательнее

$$\cos(b - a + a', x) \rightarrow \max_{x \notin \{a, a', b\}}$$


king – man + woman = king:




Rogers et. al. The (Too Many) Problems of Analogical Reasoning with Word Vectors, 2017.

Достаточно взять ближайшего соседа для b ?

Для категории множественного числа в датасете Google алгоритм, выдающий ближайшего соседа b , дает точность 70%. Как это возможно?



Точность высокая, когда b и b' близки



Корзины основаны на близости между b и b' .

BATS (Bigger analogies test set)

Инфлекссионная морфология:

- *student:students, strong:stronger, follow:following, ...*

Деривационная морфология:

- *bake:baker, edit:editable, home:homeless, ...*


Лексикографическая семантика:

- Гипонимы, меронимы: *peach:fruit, sea:water, player:team, ...*
- Антонимы, синонимы: *up:down, clean:dirty, cry:scream, ...*

Энциклопедическая семантика:


- Животные: *cat:kitten, dog:bark, ...*
- География: *Athens:Greece, Peru:Spanish, ...*
- Люди: *Lincoln:president, Lincoln:American, ...*
- Другое: *blood:red, actor:actress, ...*

Качество по категориям



Finley et. al. What Analogies Reveal about Word Vectors and their Compositionality, 2017.

Аналогии на пол и на страны – лучшие




Finley et. al. What Analogies Reveal about Word Vectors and their Compositionality, 2017.

Почему только слова?
Вектора для символов и предложений

Морфология

Проблемы:

- Языки с богатой морфологией
- Редкие слова, OOV слова



Использование морфологии для улучшения векторов слов.

FastText

Представим слово мешком буквенных n -грамм, для $n = 3$:

$G_{where} : \text{_wh, whe, her, ere, re_ , _where_}$

Моделируем вектор слова как сумму векторов n -грамм:

SGNS:

$$sim(u, v) = \langle \phi_u, \theta_v \rangle$$

FastText:

$$sim(u, v) = \sum_{g \in G_v} \langle \phi_u, \theta_g \rangle$$

Код и вектора: <https://fasttext.cc/>

Sent2vec

Первые идеи:

- Усреднить *предобученные* вектора слов (*word2vec*, *GloVe*).
- Возможно, использовать TF-IDF веса.

Sent2vec:

- *Обучить* вектора предложений как усреднение векторов:

$$\text{sim}(u, s) = \frac{1}{|G_s|} \sum_{g \in G_s} \langle \phi_u, \theta_g \rangle$$

где G_s это множество n-грамм для предложения s .

Код и вектора: <https://github.com/epfml/sent2vec>

StarSpace

Общий инструмент:

сущности (предложения) и *признаки* (слова)

Множество приложений:

- Классификация текстов, например, сентимент
- Ранжирование, например, выдачи поиска
- Рекомендательные системы
- Представления графов
-

Код и тьюториал: github.com/facebookresearch/Starspace

StarSpace

Mode 3 (вектора для предложений):

Задача: обучить вектора предложений, используя коллекцию пар близких предложений.

Формат данных: близкие предложения в одной строке:

```
sent1_word1 sent1_word2 ... <tab> sent2_word1 sent2_word2 ...
```


Обучение:

- Каждое предложение представляется как мешок признаков (слов и n-грамм).
- Предсказывается попарная близость предложений.
- Негативные примеры пар сэмплируются случайно.

Skip-thought vectors

- Предсказываем предыдущее и следующее предложение
- Архитектура: RNN encoder-decoder

Thought vector



SOTA ушла за два года вперед...

	Words Embed.	Sentences Embed.
Strong baselines	FastText	Bag-of-Words
State-of the-art	ELMo	<div style="display: flex; flex-direction: column; align-items: center;"> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Unsupervised Uses unannotated or weakly-annotated dataset</p> <p>Skip-Thoughts Quick-Thoughts DiscSent Google's dialog input-output</p> </div> <div style="border: 1px solid black; padding: 5px; margin-bottom: 5px;"> <p>Supervised Uses annotated dataset</p> <p>InferSent Machine translation</p> </div> <div style="border: 1px solid black; padding: 5px;"> <p>Multi-task learning Uses several annotated or unannotated datasets</p> <p>MILA/MSR's General Purpose Sent. Google's Universal Sentence Enc.</p> </div> </div> <p style="text-align: right; margin-top: 20px;">recent trend</p>

<https://medium.com/huggingface/universal-word-sentence-embeddings-ce48ddc8fc3a>