

Семинар 3: немного про эмбединги, Neural Nets + Topic Modeling, и про интерпретируемость моделей

Алексеев Василий

МФТИ, группа 874

23 июня 2020

- 1 Geometry-aware Domain Adaptation for Unsupervised Alignment of Word Embeddings
- 2 Sentence Meta-Embeddings for Unsupervised Semantic Textual Similarity
- 3 Neural Topic Modeling with Bidirectional Adversarial Training
- 4 Towards Faithfully Interpretable NLP Systems: How should we define and evaluate faithfulness?

Задача

Представить слова двух языков в одном векторном пространстве.

Постановка задачи

- $X \in \mathbb{R}^{n \times d}$ – эмбединги n слов в исходном языке
- $Z \in \mathbb{R}^{n \times d}$ – эмбединги n слов в целевом языке
- $W: \mathbb{R}^d \rightarrow \mathbb{R}^d$ – цель

Pratik Jawanpuria et al. *Geometry-aware Domain Adaptation for Unsupervised Alignment of Word Embeddings* //arXiv preprint arXiv:2004.08243. – 2020.

Обучение с учителем

$$\begin{cases} \|XW - YZ\|_{Fro}^2 \rightarrow \min_{W \in \mathbb{R}^{d \times d}} \\ W^T W = 1 \end{cases}$$

где $Y \in \{0, 1\}^n$ – матрица соответствия (alignment matrix): элемент Y_{ij} равен 1, если j -ое слово в целевом языке есть перевод i -го слова из исходного языка, и 0 в противном случае.

Если же словарь соответствия Y – тоже *не известен*, то

- можно обучать W и Y совместно
- можно сначала найти и зафиксировать Y , потом искать W . Например, Y можно искать¹ как *дважды стохастическую матрицу* из \mathbb{DS}^n


$$-\text{Sp}(Y^T \cdot XX^T \cdot Y \cdot ZZ^T) \rightarrow \min_{Y \in \mathbb{DS}^n}$$

¹David Alvarez-Melis D., and Tommi S. Jaakkola *Gromov-wasserstein alignment of word embedding spaces* //arXiv preprint arXiv:1809.00013. – 2018.

Суть работы

- Учёт информации второго порядка о связи слов в языках.
- Если Y делает выравнивание между языками X и Z , то Y^T должна выравнивать Z и X .
- Alignment learning problem \rightarrow Domain adaptation problem¹

$$\|Y^T \cdot XX^T \cdot Y - ZZ^T\|^2 + \|Y \cdot ZZ^T \cdot Y^T - XX^T\|^2 \rightarrow \min_{Y \in \mathbb{D}S^n}$$



https://en.wikipedia.org/wiki/Domain_adaptation

¹Baochen Sun et al. *Return of frustratingly easy domain adaptation* //Thirtieth AAAI Conference on Artificial Intelligence. – 2016.

Получение оценок:

- Bilingual induction (BLI) task
- Cross-Domain Similarity Local Scaling (CSLS)
- Precision@1

Method	de-xx	en-xx	es-xx	fr-xx	it-xx	pt-xx	xx-de	xx-en	xx-es	xx-fr	xx-it	xx-pt	avg.
GW	62.6	77.4	78.2	75.4	77.5	77.2	62.6	75.9	79.7	79.0	76.2	74.9	74.7
MBA	63.3	78.4	78.2	75.3	77.0	77.5	63.1	77.3	79.4	78.7	76.2	75.0	75.0

Table 1: P@1 for BLI on six European languages: English, German, Spanish, French, Italian, and Portuguese. Here 'en-xx' refers to the average P@1 when English is the source language and others are target language. Similarly, 'xx-en' implies English as the target language and others as source language. Thus, 'avg.' shows P@1 averaged over all the thirty BLI results for each algorithm. The proposed algorithm MBA performs similar when the language pairs are closely related to each other.

Method	en-bg	en-cs	en-da	en-el	en-fi	en-hu	en-nl	en-pl	en-ru
GW	22.8	42.1	54.4	21.5	37.7	43.7	72.9	49.1	36.1
MBA	38.1	46.8	56.1	40.0	40.4	46.1	73.8	50.4	37.5

Method	bg-en	cs-en	da-en	el-en	fi-en	hu-en	nl-en	pl-en	ru-en	avg.
GW	29.9	52.9	60.7	32.7	49.5	57.6	70.9	57.7	48.3	47.0
MBA	50.0	57.7	62.3	54.4	54.4	61.0	71.0	60.5	54.1	53.0

Table 2: P@1 for BLI on English and nine European languages: Bulgarian, Czech, Danish, Greek, Finnish, Hungarian, Dutch, Polish, and Russian. The 'avg.' shows P@1 averaged over all the eighteen BLI results. The proposed algorithm MBA outperforms GW when the bilingual mapping is learned between distant languages.

Для пар разных языков качество лучше, чем у baseline-решений.

- Понравилась задача :)
- Пример того, как можно видоизменять оптимизируемый функционал, чтобы можно было получить численное решение.

- 1 Geometry-aware Domain Adaptation for Unsupervised Alignment of Word Embeddings
- 2 Sentence Meta-Embeddings for Unsupervised Semantic Textual Similarity**
- 3 Neural Topic Modeling with Bidirectional Adversarial Training
- 4 Towards Faithfully Interpretable NLP Systems: How should we define and evaluate faithfulness?

Постановка задачи

$\mathcal{F}_1, \dots, \mathcal{F}_J$ – отображения из множества предложений \mathbb{S} в множества векторов размерностей d_1, \dots, d_J . Применить способы получения мета-эмбеддингов¹ слов для получения мета-эмбеддингов предложений $\mathcal{F}: s \mapsto \mathbb{R}^d$.

Мотивация

- Мета-эмбеддинги предложений могут показывать лучшее качество, чем отдельные эмбеддинги²
- Обычные эмбеддинги зависят от архитектуры, данных, задачи.

Nina Poerner et al. *Sentence Meta-Embeddings for Unsupervised Semantic Textual Similarity* //arXiv preprint arXiv:1911.03700. – 2019.

¹Мета-эмбеддинги – объединения предобученных разными способами векторных представлений

²Wenpeng Yin et al. *Learning word meta-embeddings*, 2016.




Figure 1: Schematic depiction: Trainable sentence meta-embeddings for unsupervised STS.

Разные способы объединения эмбедингов:

- Конкатенация
- Конкатенация и SVD
- Линейная проекция
- Generalized canonical correlation analysis (GCCA)
- Автоенкодеры¹

¹Для каждого F_j обучать энкодер $\mathcal{E}_j: R^{d_j} \rightarrow R^d$ и декодер $\mathcal{D}_j: R^d \rightarrow R^{d_j}$. И тогда $\mathcal{F}^{ae}(s) = \sum_j \mathcal{E}_j(\mathcal{F}_j(s))$.

Описание эксперимента:

- Semantic Textual Similarity (STS) task: множество троек $\{(s_{i1}, s_{i2}, y_i)\}$, состоящих из пары предложений и их оценки сходства $y_i \in \mathbb{R}$.
- Корреляции Спирмена и Пирсона между разметкой y и получаемыми оценками $\cos(\mathcal{F}(s_1), \mathcal{F}(s_2))$.

	dimensionality	STS12	STS13	STS14	STS15	STS16	STS-B
single:ParaNMT	$d = 600$	<u>67.5/66.3</u>	62.7/62.8	<u>77.3/74.9</u>	<u>80.3/80.8</u>	<u>78.3/79.1</u>	79.8/78.9
single:USE	$d = 512$	62.6/63.8	57.3/57.8	69.5/66.0	74.8/77.1	73.7/76.4	76.2/74.6
single:SBERT	$d = 1024$	66.9/66.8	<u>63.2/64.8</u>	74.2/74.3	77.3/78.3	72.8/75.7	76.2/79.2
single:ParaNMT – up-projection*	$d = 1024$	67.3/66.2	62.1/62.4	77.1/74.7	79.7/80.2	77.9/78.7	79.5/78.6
single:USE – up-projection*	$d = 1024$	62.4/63.7	57.0/57.5	69.4/65.9	74.7/77.1	73.6/76.3	76.0/74.5
meta:conc	$d = 2136$	72.7/71.3	68.4/68.6	81.0/79.0	84.1/ 85.5	82.0/83.8	82.8/83.4
meta:avg	$d = 1024$	72.5/71.2	68.1/68.3	80.8/78.8	83.7/85.1	81.9/83.6	82.5/83.2
meta:svd	$d = 1024$	71.9/70.8	68.3/68.3	80.6/78.6	83.8/85.1	81.6/83.6	83.4/83.8
meta:gcca (hyperparams on dev set)	$d = 1024$	72.8/71.6	69.6/69.4	81.7/79.5	84.2/85.5	81.3/83.3	83.9/84.4
meta:ae (hyperparams on dev set)	$d = 1024$	71.5/70.6	68.5/68.4	80.1/78.5	82.5/83.1	80.4/81.9	82.1/83.3
Ethayarajh (2018) (unsupervised)		68.3/-	66.1/-	78.4/-	79.0/-	-/-	79.5/-
Wieting and Gimpel (2018) (unsupervised)		68.0/-	62.8/-	77.5/-	80.3/-	78.3/-	79.9/-
Tang and de Sa (2019) (unsupervised meta)		64.0/-	61.7/-	73.7/-	77.2/-	76.7/-	-
Hassan et al. (2019) [†] (unsupervised meta)		67.7/-	64.6/-	75.6/-	80.3/-	79.3/-	77.7/-
Poerner and Schütze (2019) (unsupervised meta)		-/-	-/-	-/-	-/-	-/-	80.4/-
Reimers and Gurevych (2019) (sup. siamese SoTA)		-/-	-/-	-/-	-/-	-/-	-86.2
Raffel et al. (2019) (supervised SoTA)		-/-	-/-	-/-	-/-	-/-	93.1/92.8

Table 2: Results on STS12–16 and STS Benchmark test set. STS12–16: mean Pearson’s $r \times 100$ / Spearman’s $\rho \times 100$. STS Benchmark: overall Pearson’s $r \times 100$ / Spearman’s $\rho \times 100$. Evaluated by SentEval (Conneau and Kiela, 2018). **Boldface**: best in column (except supervised). Underlined: best single-source method. *Results for up-projections are averaged over 10 random seeds. [†]Unweighted average computed from Hassan et al. (2019, Table 8). There is no supervised SoTA on STS12–16, as they are unsupervised benchmarks.

- Мысль: любые эмбединги – не эталон, они зависят от данных и задачи.
- Эмбединги документов?

- 1 Geometry-aware Domain Adaptation for Unsupervised Alignment of Word Embeddings
- 2 Sentence Meta-Embeddings for Unsupervised Semantic Textual Similarity
- 3 Neural Topic Modeling with Bidirectional Adversarial Training**
- 4 Towards Faithfully Interpretable NLP Systems: How should we define and evaluate faithfulness?

Задача

Предложить нейросетевую тематическую модель.

Мотивация

Существующие NN модели

- либо используют неподходящие априорные распределения на темах (например, нормальное распределение вместо Дирихле).
- либо не способны предсказывать темы для данного документа (!!)

Rui Wang et al. *Neural Topic Modeling with Bidirectional Adversarial Training*
//arXiv preprint arXiv:2004.12331. – 2020.

Bidirectional Adversarial Topic (BAT) model: получение отображений между распределениями: тем в документах и слов в документах.





Figure 2: The framework of the Bidirectional Adversarial Topic (BAT) model.

Bidirectional Adversarial Topic model with Gaussian (Gaussian-BAT): использование эмбедингов.



$$p(\vec{e}_v | t) = \mathcal{N}(\vec{e}_v; \vec{\mu}_k, \Sigma_k) = \frac{\exp\left(-\frac{1}{2}(\vec{e}_v - \vec{\mu}_k)^T \Sigma_k^{-1} (\vec{e}_v - \vec{\mu}_k)\right)}{\sqrt{(2\pi)^{D_e} |\Sigma_k|}}$$

$$\varphi_{k,v} = \frac{p(\vec{e}_v | t)}{\sum_{u=1}^V p(\vec{e}_u | t)} \quad \vec{d}_f = \sum_{k=1}^K \vec{\varphi}_k \cdot \theta_k$$

Результаты 1/3: Когерентности в зависимости от учитываемой части тем

- Тренируются модели на 20, 30, 50, 75, 100 тем.
- Когерентности считаются по топ 50, 70, 90, 100% тем.
- Результаты усредняются по моделям с разным числом тем.




Figure 4: The comparison of average topic coherence vs. different topic proportion on three datasets.

Michael Röder et al. *Exploring the space of topic coherence measures* // Proceedings of the eighth ACM international conference on Web search and data mining. – 2015. – С. 399-408.

Результаты 2/3: Когерентности в зависимости от числа тем в модели




Figure 5: The comparison of average topic coherence vs. different topic number on 20Newsgroups, Grolier and NYTimes.

Описание эксперимента:

- Сопоставление разметок (известной и полученной) с помощью вергерского алгоритма¹
- Оценка точности

Dataset	NVLDA	ProdLDA	LDA	BAT	G-BAT
20NG	33.31%	33.82%	35.36%	35.66%	41.25%

Table 4: Text clustering accuracy on 20Newsgroups (20NG). ‘G-BAT’ refers to ‘Gaussian-BAT’. The best result is highlighted in bold.

¹Harold W. Kuhn *The Hungarian method for the assignment problem* //Naval research logistics quarterly. – 1955. – Т. 2. – №. 1-2. – С. 83-97.

- Нейросети + ТМ
- Учёт эмбедингов слов
- Пример сравнения тематических моделей
- Два датасета, которые ещё ни разу не использовали

- 1 Geometry-aware Domain Adaptation for Unsupervised Alignment of Word Embeddings
- 2 Sentence Meta-Embeddings for Unsupervised Semantic Textual Similarity
- 3 Neural Topic Modeling with Bidirectional Adversarial Training
- 4 **Towards Faithfully Interpretable NLP Systems: How should we define and evaluate faithfulness?**

Что есть интерпретируемость?

Примеры

- Байесовские сети
- Attention, heat-map

Предположения

- по модели: две модели дают одинаковые предсказания **iff** они используют одни и те же рассуждения,
- по предсказанию: модель выдаёт похожие предсказания на похожих входах **iff** её рассуждения похожи,
- по линейности: для рассуждений модели какие-то части входа важнее других.

Alon Jacovi, and Yoav Goldberg *Towards Faithfully Interpretable NLP Systems: How should we define and evaluate faithfulness?* //arXiv preprint arXiv:2004.03685. – 2020.

- Чтобы задуматься
- Пример небольшого (по объёму) полностью теоретического исследования