

Векторные представления текстов и графов

К. В. Воронцов

vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Машинное обучение (курс лекций, К.В.Воронцов)»

13 октября 2020 • ШАД Яндекс

- 1 Векторные представления текста**
 - Гипотеза дистрибутивной семантики
 - Модели word2vec
 - Модель FastText
- 2 Векторные представления графов**
 - Многомерное шкалирование
 - Случайные блуждания
 - GraphEDM: обобщённый автокодировщик на графах
- 3 Векторные представления гиперграфов**
 - Тематические модели транзакционных данных
 - EM-алгоритм для тематической модели гиперграфа
 - Примеры транзакционных моделей на гиперграфах

Дистрибутивная гипотеза и виды семантической близости слов

«Смысл слова определяется множеством его контекстов»

- Words that occur in the same contexts tend to have similar meanings [Harris, 1954].
- You shall know a word by the company it keeps [Firth, 1957].

Синтагматическая близость слов:

сочетаемость слов в одном контексте

(здание–строитель, кран–вода, функция–точка)



Парадигматическая близость слов:

взаимозаменяемость слов в одном контексте

(здание–дом, кран–смеситель, функция–отображение)



Z. Harris. Distributional structure. 1954.

J.R. Firth. A synopsis of linguistic theory 1930-1955. Oxford, 1957.

P.Turney, P.Pantel. From frequency to meaning: vector space models of semantics. 2010.

Формализация дистрибутивной гипотезы

Дано: текст $(w_1 \dots w_n)$, состоящий из слов словаря W

Найти: векторные представления слов $v_w \in \mathbb{R}^d$, так, чтобы близкие по смыслу слова имели близкие векторы

Модель CBOW (continuous bag-of-words) для вероятности слова w_i по его контексту $C_i = (w_{i-k} \dots w_{i-1} w_i w_{i+1} \dots w_{i+k})$:

$$p(w_i = w | C_i) = \underset{w \in W}{\text{SoftMax}} \langle u_w, v^{-i} \rangle \equiv \underset{w \in W}{\text{norm}} (\exp \langle u_w, v^{-i} \rangle),$$

$v^{-i} = \frac{1}{2k} \sum_{w \in C_i} v_w$ — средний вектор слов из контекста C_i ,

v_w — векторы предсказывающих слов,

u_w — вектор предсказываемого слова, в общем случае $u_w \neq v_w$.

Критерий максимума log-правдоподобия, $U, V \in \mathbb{R}^{|W| \times d}$:

$$\sum_{i=1}^n \log p(w_i | C_i) \rightarrow \max_{U, V}$$

Ещё одна формализация дистрибутивной гипотезы

Дано: текст $(w_1 \dots w_n)$, состоящий из слов словаря W

Найти: векторные представления слов $v_w \in \mathbb{R}^d$, так, чтобы близкие по смыслу слова имели близкие векторы

Модель Skip-gram для предсказания вероятности слов контекста $C_i = (w_{i-k} \dots w_{i-1} w_{i+1} \dots w_{i+k})$ по слову w_i :

$$p(w|w_i) = \underset{w \in W}{\text{SoftMax}} \langle u_w, v_{w_i} \rangle \equiv \underset{w \in W}{\text{norm}} (\exp \langle u_w, v_{w_i} \rangle),$$

v_w — вектор предсказывающего слова,

u_w — вектор предсказываемого слова, в общем случае $u_w \neq v_w$.

Критерий максимума log-правдоподобия, $U, V \in \mathbb{R}^{|W| \times d}$:

$$\sum_{i=1}^n \sum_{w \in C_i} \log p(w|w_i) \rightarrow \max_{U, V}$$

Сравнение моделей CBOW и Skip-gram

- Различие — в структуре оптимизационного критерия:

$$\text{CBOW: } \sum_{i=1}^n \log \text{SoftMax} \left(\frac{1}{2k} \sum_{c \in C_i} \langle u_{w_i}, v_c \rangle \right) \rightarrow \max_{U, V}$$

$$\text{Skip-gram: } \sum_{i=1}^n \sum_{c \in C_i} \log \text{SoftMax} \langle u_c, v_{w_i} \rangle \rightarrow \max_{U, V}$$

- Skip-gram точнее моделирует вероятности редких слов
- Обе модели можно обучать с помощью SGD
- Оба критерия трудно оптимизировать из-за SoftMax
- Что делать? Заменять либо SoftMax, либо критерий

Иерархический SoftMax

Идея: заменить SoftMax на другую функцию потерь, сложность вычисления которой $O(\log |W|)$ вместо $O(|W|)$.

Предварительный этап:

- По словарю частот строится *бинарное дерево Хаффмана*
- Каждая внутренняя вершина n хранит вектор $u_n \in \mathbb{R}^d$
- Каждый лист вычисляет вектор v_w для слова $w \in \mathbb{R}^d$
- Модель переходов из внутренних вершин дерева:

$$\text{направо: } p(+1|n, w) = \sigma(\langle u_n, v_w \rangle)$$

$$\text{налево: } p(-1|n, w) = \sigma(-\langle u_n, v_w \rangle) = 1 - p(+1|n, w)$$

Обучаются векторы u_n во внутренних вершинах дерева

Иерархический SoftMax: обучение модели

Модель $p(w|w_i)$, гарантирующая нормировку $\sum_w p(w|w_i) = 1$:


$$p(w|w_i) = \prod_{j=1}^{\ell(w)} p(\beta_{jw}|n_{jw}, w_i) = \prod_{j=1}^{\ell(w)} \sigma(\beta_{jw} \langle u_{n_{jw}}, v_{w_i} \rangle)$$

где $\ell(w)$ — длина пути к листу w ,

n_{jw} — j -я внутренняя вершина на пути к листу w ,

$\beta_{jw} \in \{-1, +1\}$ — поворот из j -й вершины на пути к w .

Пример: $p(w|w_i) = p(-1|n_{1w}, w_i) p(-1|n_{2w}, w_i) p(+1|n_{3w}, w_i)$



Подмена задачи: классификация пар слов на два класса

Критерий log-loss для SGNS (Skip-gram Negative Sampling):

$$\sum_{i=1}^n \sum_{w \in C_i} \left(\log p(+1|w, w_i) + \log p(-1|\bar{w}, w_i) \right) \rightarrow \max_{U, V}$$

где $p(y|w, w_i) = \sigma(y\langle u_w, v_{w_i} \rangle)$ — модель классификации, $y = \pm 1$;
 $y = +1$, если пара слов (w, w_i) находится в общем контексте;
 $y = -1$, если пара слов (w, w_i) не находится в общем контексте;
 $\bar{w} \sim p(w)^{3/4}$ сэмплируется из $W \setminus C_i$ в методе SG.

Эвристики и прочие замечания:

- Dynamic window: случайный выбор $k \sim [3..10]$
- Итоговые векторы слов: $\alpha v_w + (1 - \alpha)u_w$
- Приём NS применяют, когда не хватает второго класса
- Что делать со словами, которые встречаются впервые?

Модель векторных представлений FastText

Идея: векторное представление слова w определяется как сумма векторов всех его буквенных n -грамм $G(w)$:

$$u_w = \sum_{g \in G(w)} u_g$$

В Skip-gram вместо векторов слов u_w обучаются векторы u_g

Пример: $G(\text{дартмюб}) = \{\langle\text{да}, \text{арм}, \text{рмо}, \text{мол}, \text{олю}, \text{люб}, \text{юб}\rangle\}$

Преимущества:

- Это решает проблемы новых слов и слов с опечатками
- Подходит для обработки текстов социальных медиа
- Словарь 2- и 3-грамм обычно меньше словаря W
- Существует много предобученных моделей




Проверка на задачах семантической близости и аналогии слов

Задача семантической близости слов:

по выборке пар слов (a, b) оценивается корреляция Спирмена между $\cos(v_a, v_b)$ и экспертными оценками близости $y(a, b)$

Задача семантической аналогии слов:

по трём словам угадать четвёртое



Связь word2vec с матричными разложениями

d — размерность векторов слов v_w и u_w

$V = (v_w)_{W \times d}$ — матрица предсказывающих векторов слов

$U = (u_w)_{W \times d}$ — матрица предсказываемых векторов слов

SGNS строит матричное разложение $P \approx UV^T$ матрицы

Shifted PMI (Point-wise Mutual Information):

$$P_{ab} = \ln \frac{n_{ab}n}{n_a n_b} - \ln k,$$

n_{ab} — частота пары слов a, b в окне $\pm k$ слов,

n_a, n_b — число пар с участием слова a и b соответственно,

n — число всех пар слов в коллекции.

В качестве эвристики используют также Shifted Positive PMI:

$$P_{ab}^+ = \left(\ln \frac{n_{ab}n}{n_a n_b} - \ln k \right)_+$$

Модели векторных представлений для текстов и графов

word2vec: эмбединги (векторные представления) слов

T.Mikolov et al. Efficient estimation of word representations in vector space. 2013.

paragraph2vec: эмбединги фрагментов или документов

Q.Le, T.Mikolov. Distributed representations of sentences and documents. 2014.

sent2vec: эмбединги предложений

M.Pagliardini et al. Unsupervised learning of sentence embeddings using compositional n-gram features. 2017.

FastText: эмбединги символьных *n*-грамм

<https://github.com/facebookresearch/fastText>

node2vec: эмбединги вершин графа

A.Grover, J.Leskovec. Node2vec: scalable feature learning for networks. 2016.

graph2vec: более общие эмбединги на графах

A.Narayanan et al. Graph2vec: learning distributed representations of graphs. 2017.

StarSpace: эмбединги чего угодно от Facebook AI Research

L.Wu, A.Fisch, S.Chopra, K.Adams, A.B.J.Weston. StarSpace: embed all the things! 2018.

BERT: эмбединги фраз и предложений от Google AI Language

J.Devlin et al. BERT: pre-training of deep bidirectional transformers for language understanding. 2018.

GPT-3: эмбединги, предобученные по 570Gb текстов от OpenAI

T.B.Brown et al. Language Models are Few-Shot Learners. 2020.

Многомерное шкалирование (multidimensional scaling, MDS)

Дано: $(i, j) \in E$ — выборка рёбер графа $\langle V, E \rangle$,

R_{ij} — расстояния между вершинами ребра (i, j) .

Например, в IsoMAP R_{ij} — длина кратчайшего пути по графу.

Найти: векторные представления вершин $z_i \in \mathbb{R}^d$, так, чтобы близкие (по графу) вершины имели близкие векторы.

Критерий стресса (stress):

$$\sum_{(i,j) \in E} w(R_{ij}) (\rho(z_i, z_j) - R_{ij})^2 \rightarrow \min_Z, \quad Z \in \mathbb{R}^{V \times d},$$



где $\rho(z_i, z_j) = \|z_i - z_j\|$ — обычно евклидово расстояние,

$w(R_{ij})$ — веса (какие расстояния важнее, большие или малые).

Обычно решается методом стохастического градиента (SG).

Многомерное шкалирование для визуализации данных

При $d = 2$ осуществляется проекция выборки на плоскость



- Используется для визуализации кластерных структур
- Форму облака точек можно настраивать весами и метрикой
- Недостаток — искажения неизбежны
- Наиболее популярный метод для визуализации — t-SNE

Laurens van der Maaten, Geoffrey Hinton. Visualizing data using t-SNE. 2008

Матричные разложения (graph factorization)

Дано: $(i, j) \in E$ — выборка рёбер графа $\langle V, E \rangle$,

S_{ij} — близость между вершинами ребра (i, j) .

Например, $S_{ij} = [(i, j) \in E]$ — матрица смежности вершин.

Найти: векторные представления вершин $z_i \in \mathbb{R}^d$, так, чтобы близкие (по графу) вершины имели близкие векторы.

Критерий для неориентированного графа (S симметрична):

$$\sum_{(i,j) \in E} (\langle z_i, z_j \rangle - S_{ij})^2 \rightarrow \min_Z, \quad Z \in \mathbb{R}^{V \times d}$$

Критерий для ориентированного графа (S несимметрична):

$$\sum_{(i,j) \in E} (\langle \varphi_i, \theta_j \rangle - S_{ij})^2 \rightarrow \min_{\Phi, \Theta}, \quad \Phi, \Theta \in \mathbb{R}^{V \times d}$$

Обычно решается методом стохастического градиента (SG).

Модель случайных блужданий

Аналог модели Skip-gram (текст ведь тоже граф, но линейный):

$$\sum_{i \in V} \left(\sum_{j \in C_i} \log \sigma(\langle \varphi_i, \theta_j \rangle) + \sum_{j \in \bar{C}_i} \log \sigma(-\langle \varphi_i, \theta_j \rangle) \right) \rightarrow \max_{\Phi, \Theta}$$


C_i — окрестность («контекст») вершины i , сэмплируемая случайным блужданием длины k (DeepWalk, node2vec),
 \bar{C}_i — вершины, далёкие от i , сэмплируемые $j \sim p(j)^{3/4}$

Параметризация случайных блужданий:

вероятность $p(v \rightarrow w)$ после перехода $t \rightarrow v$

$p \downarrow q \uparrow$ — ближе к поиску в ширину (BFS)

$p \uparrow q \downarrow$ — ближе к поиску в глубину (DFS)




B.Perozzi et al. DeepWalk: online learning of social representations. SIGKDD-2014.

A.Grover, J.Leskovec. node2vec: scalable feature learning for networks. SIGKDD-2016.

GraphEDM: обобщённый автокодировщик на графах

Graph Encoder Decoder Model — обобщает более 30 моделей:



$W \in \mathbb{R}^{V \times V}$ — входные данные о рёбрах

$X \in \mathbb{R}^{V \times n}$ — входные данные о вершинах, признаковые описания

$Z \in \mathbb{R}^{V \times d}$ — векторные представления вершин графа

$\text{DEC}(Z; \Theta^D)$ — декодер, реконструирующий данные о рёбрах

$\text{DEC}(Z; \Theta^S)$ — декодер, решающий supervised-задачу

y^S — (semi-)supervised данные о вершинах или рёбрах

\mathcal{L} — функции потерь

Примеры транзакционных данных

Коллекция текстов — двудольный граф, выборка пар (d, w)

Транзакционные данные — n -ки термов разных модальностей

Примеры:

- **Данные социальной сети:**
 (d, u, w) — пользователь u записал слово w в блоге d
- **Данные сети интернет-рекламы:**
 (u, d, b) — пользователь u кликнул баннер b на странице d
- **Данные финансовых организаций:**
 (b, s, g) — покупатель s купил у продавца g товар b
- **Данные о пассажирских авиаперелётах:**
 (u, a, b, c) — перелёт клиента u из a в b авиакомпанией c

Задача: по наблюдаемой выборке рёбер гиперграфа выявить латентные темы его вершин.

Тематическая модель гиперграфа: определения и обозначения

$\Gamma = \langle V, E \rangle$ — неориентированный гиперграф.

$V = V^1 \sqcup \dots \sqcup V^M$ — разбиение вершин по модальностям

M — множество модальностей:


□ ○ Δ

K — множество типов рёбер:

□○ □△ ○○ ○△ ○○△

T — множество тем:

● ● ● ● ●



Исходные данные:

E_k — наблюдаемая выборка транзакций — рёбер типа k
 ребро (d, x) : вершина-контейнер $d \in V$ и вершины $x \subset V$,
 n_{kdx} — число вхождений ребра (d, x) в выборку E_k

Тематическая модель гиперграфа: основные предположения

- в ребре (d, x) подмножество $x \subset V$ может быть любым, независимо от типа ребра k
- первая гипотеза условной независимости: тематика контейнера $p(t|d)$ не зависит от типа ребра k
- вторая гипотеза условной независимости: распределение $p(v|t)$ термов v модальности V^m в теме t не зависит ни от контейнера d , ни от типа ребра k
- третья гипотеза условной независимости: термы $v \in x$ в ребре (d, x) не зависят друг от друга
- гипотеза «мешка транзакций»: выборка транзакций типа k порождается случайно и независимо из

$$p_k(d, x) = p(d) \sum_{t \in T} p(t|d) \prod_{v \in x} p(v|t)$$

Тематическая модель гиперграфа

Вероятностная тематическая модель рёбер типа k

$$p_k(x|d) = \sum_{t \in T} \theta_{td} \prod_{v \in x} \varphi_{vt}$$

Задача максимизации взвешенной суммы log-правдоподобий по всем типам рёбер:

$$\sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} n_{kdx} \ln \sum_{t \in T} \theta_{td} \prod_{v \in x} \varphi_{vt} \rightarrow \max_{\Phi, \Theta},$$

при ограничениях неотрицательности и нормировки:

$$\varphi_{vt} \geq 0, \quad \sum_{v \in V^m} \varphi_{vt} = 1; \quad \theta_{td} \geq 0, \quad \sum_{t \in T} \theta_{td} = 1;$$

где $\tau_k > 0$ — веса типов рёбер.

ЕМ-алгоритм для гиперграфовой ARTM

Задача максимизации регуляризованного правдоподобия:

$$\sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} n_{kdx} \ln \sum_{t \in T} \theta_{td} \prod_{v \in x} \varphi_{vt} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}.$$

ЕМ-алгоритм: метод простой итерации для системы уравнений со вспомогательными переменными $p_{tdx} = p(t|d,x)$:

$$\left\{ \begin{array}{l} \text{E-шаг: } p_{tdx} = \text{norm}_{t \in T} \left(\theta_{td} \prod_{v \in x} \varphi_{vt} \right) \\ \text{M-шаг: } \left\{ \begin{array}{l} \varphi_{vt} = \text{norm}_{v \in V^m} \left(\sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} [v \in x] n_{kdx} p_{tdx} + \varphi_{vt} \frac{\partial R}{\partial \varphi_{vt}} \right) \\ \theta_{td} = \text{norm}_{t \in T} \left(\sum_{k \in K} \tau_k \sum_{(d,x) \in E_k} n_{kdx} p_{tdx} + \theta_{td} \frac{\partial R}{\partial \theta_{td}} \right) \end{array} \right. \end{array} \right.$$

Модели предложений и коротких текстов TwitterLDA, senLDA

S_d — множество предложений документа d

n_{sw} — сколько раз терм w встречается в предложении s

Тематическая модель предложения s :

$$p(s|d) = \sum_{t \in T} p(t|d) \prod_{w \in s} p(w|t)^{n_{sw}} = \sum_{t \in T} \theta_{td} \prod_{w \in s} \varphi_{wt}^{n_{sw}}$$

Максимизация регуляризованного log-правдоподобия

$$\sum_{d \in D} \sum_{s \in S_d} \ln \sum_{t \in T} \theta_{td} \prod_{w \in s} \varphi_{wt}^{n_{sw}} + R(\Phi, \Theta) \rightarrow \max_{\Phi, \Theta}$$

это частный случай гиперграфовой модели, предложения являются гипер-ребрами.

Wayne Xin Zhao et al. Comparing Twitter and traditional media using topic models.
ECIR 2011.

G.Balikas, M.-R.Amini, M.Clausel. On a topic model for sentences. SIGIR 2016.

Гиперграфовые тематические модели языка

Что ещё может быть ребром гиперграфа?

Любое подмножество термов, связанных друг с другом по смыслу, и порождаемых одной общей темой.

- предложение
- синтагма, ветка синтаксического дерева
- именная группа
- факт «объект, субъект, действие»
- пары термов в соседних предложениях:
два синонима, гипоним–гипероним, мероним–холоним
- лексическая цепочка
- текст сообщения и его автор
- финансовая транзакция с текстом платёжного поручения

Анализ транзакций корпоративных клиентов банка

Данные:

лесная отрасль, 2016 г., 10.7M транзакций, 1M компаний.

Транзакция — это тройка \langle покупатель, продавец, текст \rangle .

Некоторые тексты платёжных поручений (далеко не все!) содержат названия товаров и услуг.

Документ — это история транзакций одной компании

Семь модальностей:

- компании: поставщики / покупатели
- слова в платёжных поручениях: поставщики / покупатели
- ОКВЭДы данной компании
- ОКВЭДы контрагентов: поставщики / покупатели

Примеры тем — видов деятельности компаний

покупка	продажа
0.11: услуга	0.12: лдсп
0.07: классик	0.08: дсп
0.05: дрова	0.03: мдф
0.05: пиловочник	0.03: поставка
0.05: материал	0.02: услуга
0.03: порода	0.02: охранный
0.03: лесоматериал	0.02: ламинировать
0.03: сертум	0.02: хдф
0.02: хвойный	0.02: материал
0.01: дерево	0.01: накл
0.01: транспортный	0.01: товар

покупка	продажа
0.19: право	0.16: арендный
0.17: сбис	0.10: часть
0.16: использование	0.08: плата
0.03: аккаунт	0.04: минимальный
0.02: электронный	0.04: участок
0.02: лицевой	0.04: использование
0.02: устный	0.02: земля
0.01: устройство	0.02: лесничество
0.01: генерация	0.02: земельный
0.01: хранение	0.01: фонд
0.01: ключевой	0.01: федеральный

Примеры тем — видов деятельности компаний

покупка	продажа
0.09: ткань	0.16: мебель
0.09: поставка	0.05: плёнка
0.02: мебельный	0.04: стул
0.02: деревянный	0.03: кресло
0.02: транспортный	0.03: изделие
0.02: фанера	0.02: краска
0.02: поролон	0.02: фанера
0.01: механизм	0.01: лкм
0.01: плата	0.01: лакокрасочный
0.01: частичный	0.01: лак
	0.01: материал
	0.01: клеить

покупка	продажа
0.06: лдсп	0.37: товар
0.05: фурнитура	0.15: мебель
0.02: плёнка	0.04: поставка
0.02: материал	0.04: накладный
0.02: мебельный	0.03: накл
0.02: стекло	0.03: рубль
0.02: мdf	
0.02: кромка	
0.01: транспортный	
0.01: клеить	
0.01: профиль	
0.01: пвх	

- Векторные представления (эмбединги) — мощнейший инструмент анализа сложно структурированных данных
- Основное применение — векторизация объектов для дальнейшей обработки методами машинного обучения
- Эмбединги на графах обобщают задачи векторного представления текстов, дискретных сигналов, изображений
- Тематическое моделирование — тоже эмбединги, но вероятностные (на симплексе) и интерпретируемые