Векторные представления слов

Лекция 5

Майоров Владимир Дмитриевич

11 октября 2023

Векторное представление слов

- Атомарные единицы текста – слова

- Word embedding – вещественный вектор в пространстве с фиксированной размерностью
  - Пусть есть словарь всех слов языка $V = \{v_i\}$ размером $n = |V|$
  - Пусть задана фиксированная размерность d
  - Каждому слову $v_i \in V$ ставится в соответствие вектор $w_i \in \mathbb{R}^d$

Векторное представление слов

- Атомарные единицы текста – слова

- Word embedding – вещественный вектор в пространстве с фиксированной размерностью
  - Пусть есть словарь всех слов языка $V = \{v_i\}$ размером $n = |V|$
  - Пусть задана фиксированная размерность d
  - Каждому слову $v_i \in V$ ставится в соответствие вектор $w_i \in \mathbb{R}^d$

- Пример: one-hot encoding

One-hot encoding

- Пусть есть словарь всех слов языка $V = \{v_i\}$ размером $n = |V|$
- Пусть задана фиксированная размерность $d = n$
  - Каждому слову $v_i \in V$ ставится в соответствие вектор $w_i \in \mathbb{R}^d$,

$$w_{ij} = \begin{cases} 1, j = i \\ 0, j \neq i \end{cases}, j = \overline{1, d}$$

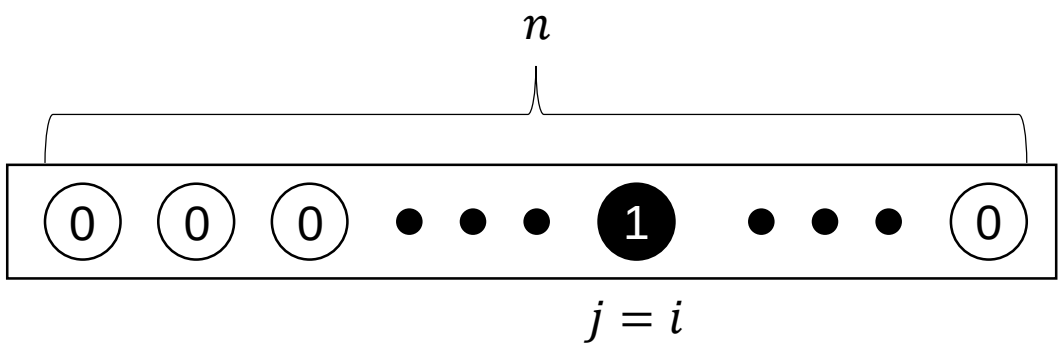

Многозначность (Синонимия)

- Для большинства задач NLP важен смысл слова (***лексическое значение***), а не само слово:

16 августа 1820 года Пушкин ***прибыл*** в Феодосию
приехал
пожаловал
…

- Похожесть слов (косинусная мера)

$$similarity(w_i, w_j) = \frac{(w_i, w_j)}{\|w_i\| \cdot \|w_j\|} = \frac{\sum_{k=1}^{n} w_{ik} \cdot w_{jk}}{\sqrt{\sum_{k=1}^{n} w_{ik}^2} \cdot \sqrt{\sum_{k=1}^{n} w_{jk}^2}}$$

Многозначность (Синонимия)

- One-hot encoding
  - $V = \{v_i\}, |V| = n$
  - $d = n$
  - Каждому слову $v_i \in V$ ставится в соответствие вектор из $w_i \in \mathbb{R}^d$, $w_{ij} = \begin{cases} 1, j = i \\ 0, j \neq i \end{cases}, j = \overline{1, n}$

- все слова одинаково непохожи:

$$\left(w_i, w_j\right) = 0, \qquad i \neq j$$
$$similarity\left(w_i, w_j\right) = 0, \qquad i \neq j$$

Embedding слой в нейронной сети

- Пусть задан one-hot encoding:
  - Словарь $V = \{v_i\}$, $|V| = n$
  - Каждому слову $v_i \in V$ поставлен в соответствие вектор $x_i \in \mathbb{R}^n$

- Пусть задана некоторая нейронная сеть

$$h = f(Wx),\ x \in \mathbb{R}^n,\ W \in \mathbb{R}^{d \times n}$$

- Преобразование перед первой активацией ($w = Wx$):
  - Словарь $V = \{v_i\}$, $|V| = n$
  - Фиксированная размерность d
  - Каждому слову $v_i \in V$ поставлен в соответствие вектор $w = Wx \in \mathbb{R}^d$

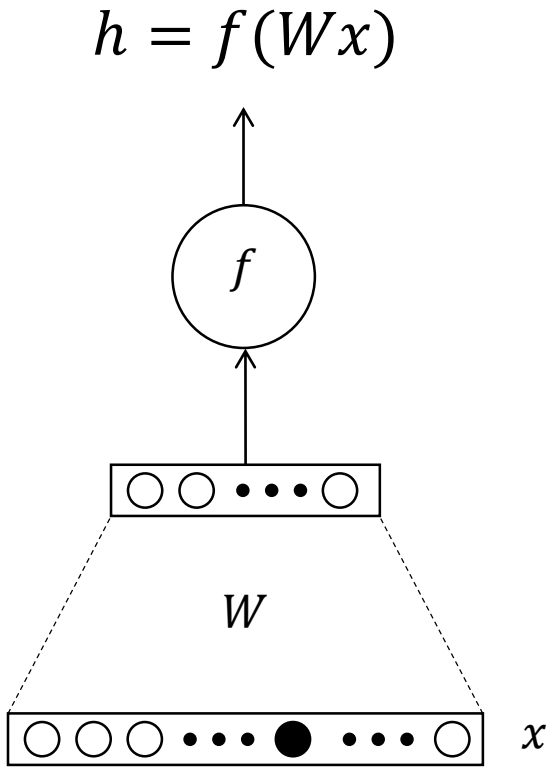

Embedding слой в нейронной сети

- В процессе обучения с учителем оптимизируются параметры сети (в том числе матрица W)
- В результате вектор $w = Wx$ отражает «хорошие» векторы слов с точки зрения целевой задачи

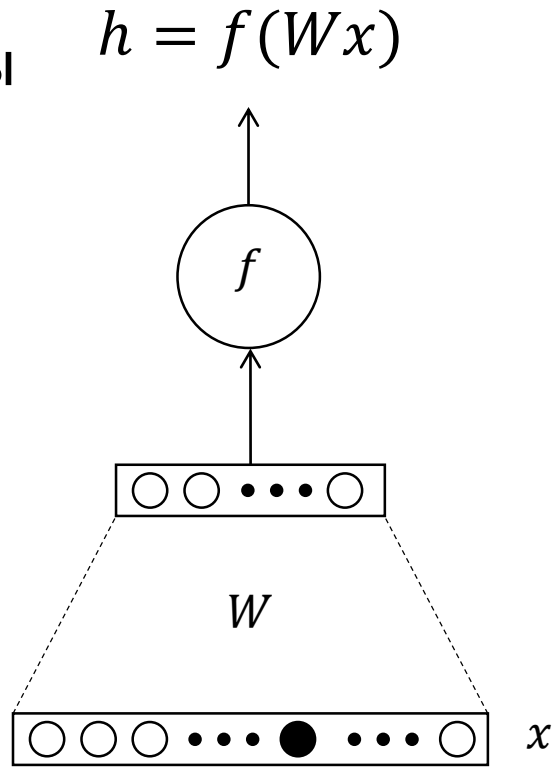

- Основная проблема:
  - Для большинства задач обработки текстов обучающих данных мало ⇒ построить «хорошую» матрицу W не удастся
- Решение:
  - Инициализировать матрицу W посчитанными заранее «хорошими» векторами

Векторное представление слов

Задача обучения без учителя (unsupervised learning):

По коллекции объектов (обучающей выборке) определить внутренние взаимосвязи, зависимости, существующие между объектами

По коллекции неразмеченных текстов построить векторные представления слов из этих текстов

причем хочется, чтобы $similarity$ близких по значению слов была выше, чем для различных по значению

Дистрибутивная гипотеза

- Firth, J. R. (1957):

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

- Бутылка ***tesgüino*** стоит на столе
- ***Tesgüino*** делает тебя пьяным
- Мы делаем ***tesgüino*** из кукурузы
- Вместо хмеля в ***tesgüino*** используется местная трава

Дистрибутивная гипотеза

- Слова, которые встречаются в схожих контекстах, имеют схожий смысл

- Контекстом слова может являться:
  - Соседние слова
    - Слева
    - Справа
    - Симметрично
  - Весь текст (параграф, предложение)

word2vec

- Continuous skip-gram

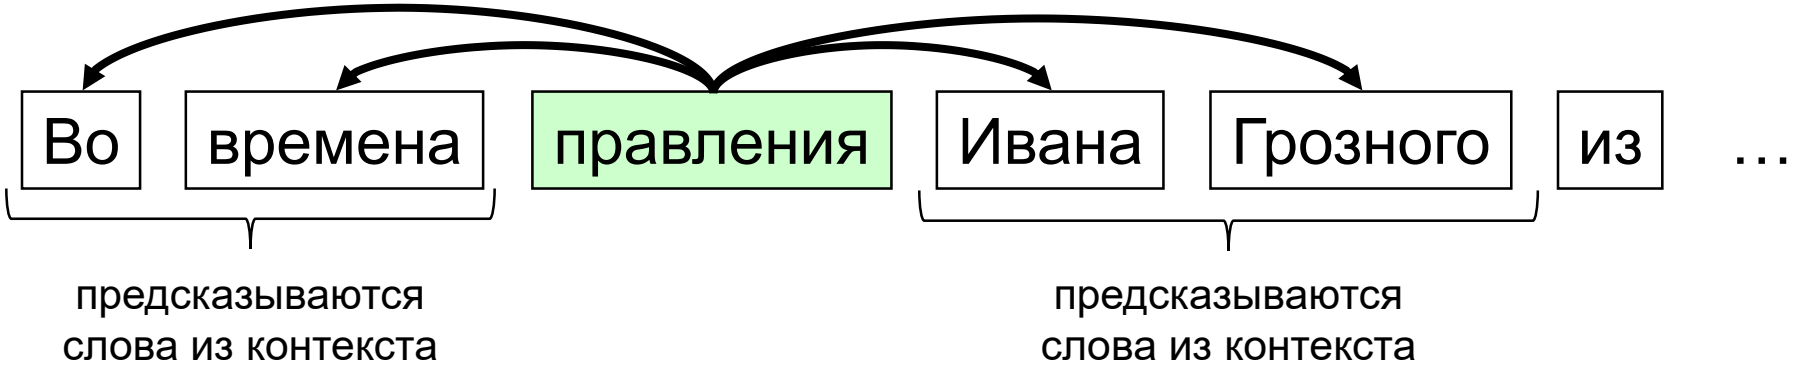

- Continuous bag of words

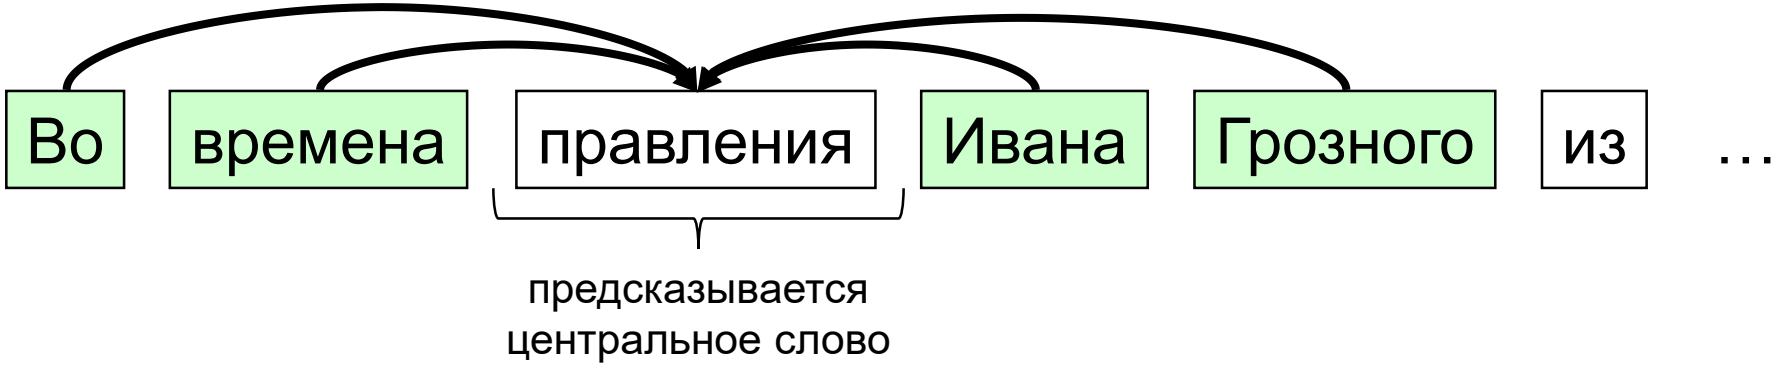

Mikolov T. et al. Efficient estimation of word representations in vector space – 2013.

word2vec

- Continuous skip-gram

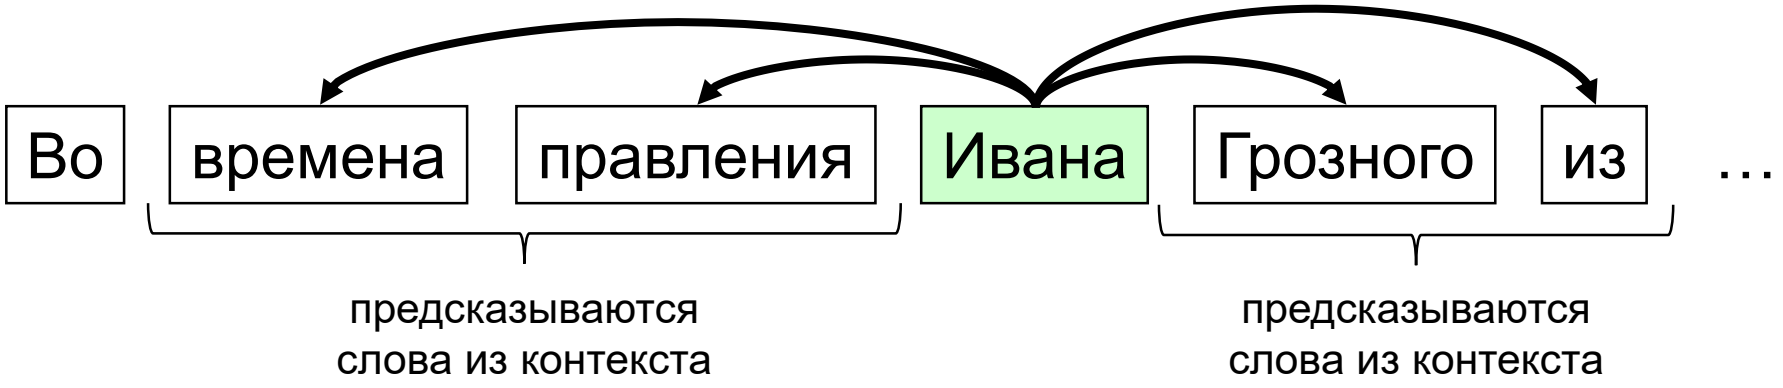

- Continuous bag of words

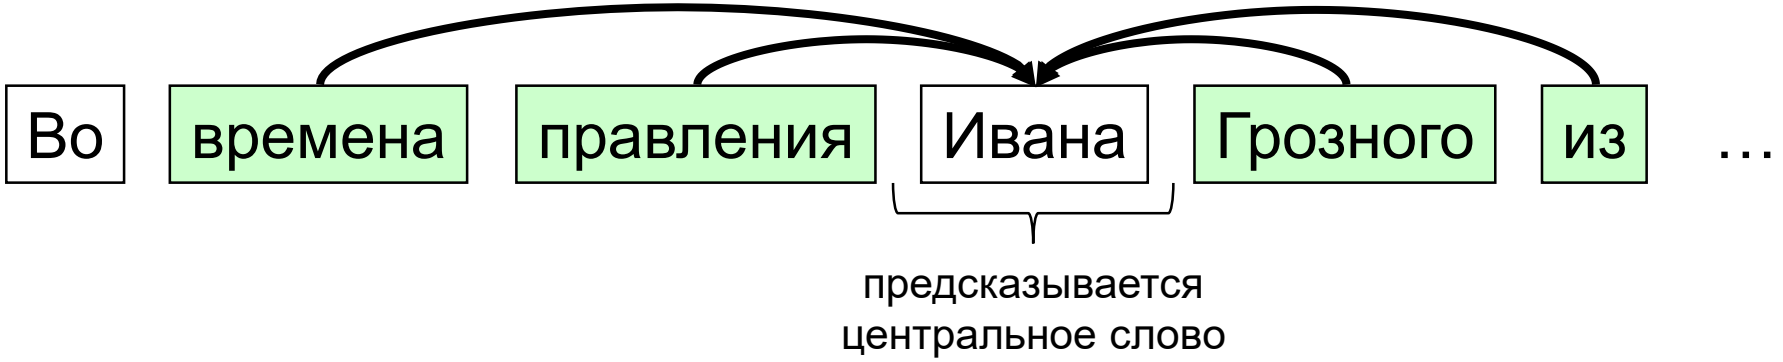

word2vec skip-gram

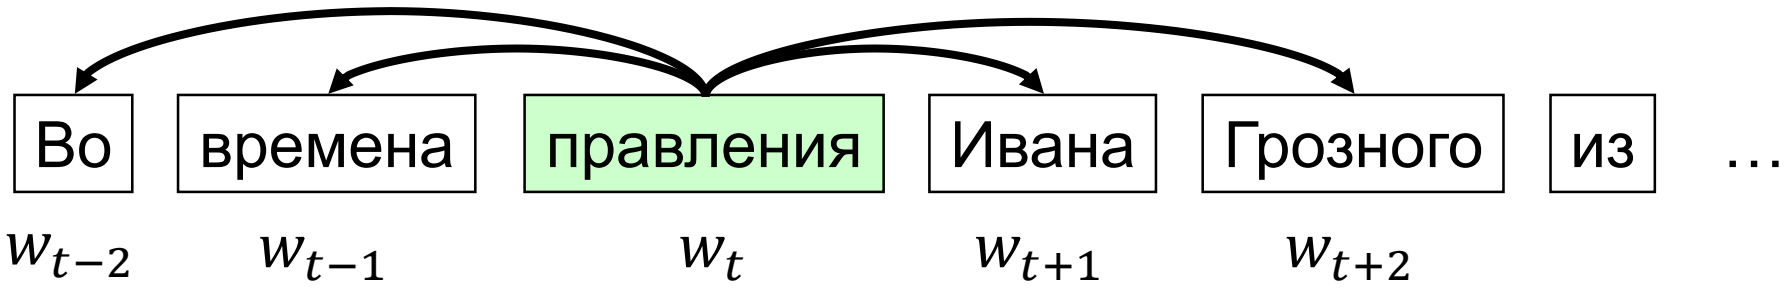

- Цель: максимизировать вероятность всех контекстных слов при данном центральном слове

$$J'(\theta) = \prod_{t=1}^{T} \prod_{-m \le j \le m, j \ne 0} p(w_{t+j} | w_t, \theta)$$

- θ – оптимизируемые параметры

word2vec skip-gram

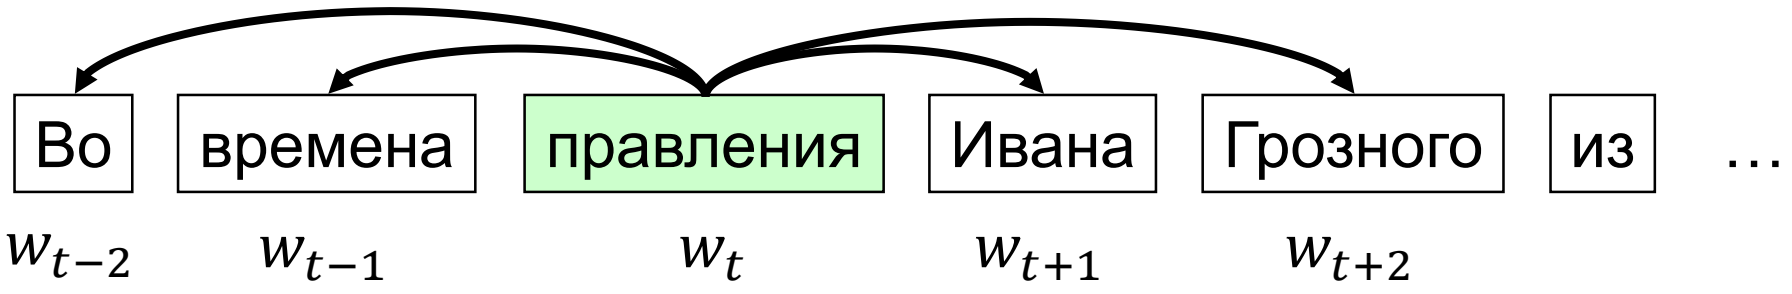

- Цель: максимизировать логарифм вероятности всех контекстных слов при данном центральном слове

$$J(\theta) = -\log J'(\theta) = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} \log p_\theta(w_{t+j} | w_t)$$

- θ – оптимизируемые параметры

word2vec skip-gram

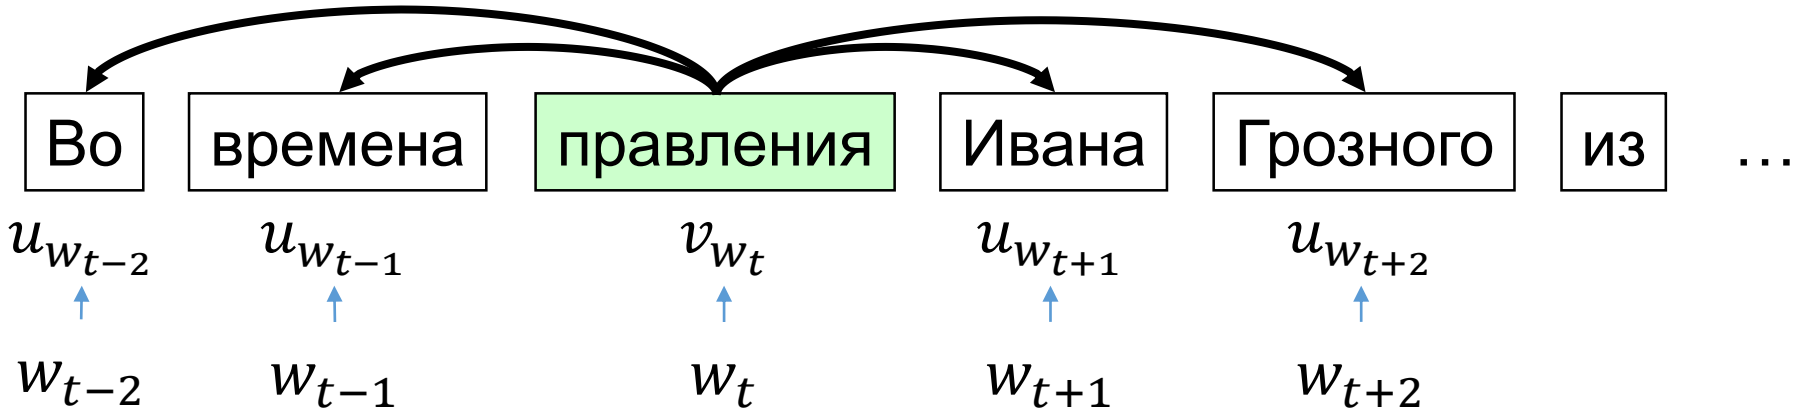

$$J(\theta) = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} \log p_\theta(w_{t+j} | w_t)$$

- $\theta = \{V, U\}$;
- V – векторы центрального слова
- U– векторы слова из контекста

$$p(o|c) = \frac{\exp(u_o^T v_c)}{\sum_{w=1}^{n} \exp(u_w^T v_c)};$$

word2vec skip-gram

Модель может быть представлена в виде нейронной сети:

- **Вход**: one-hot центрального слова
- **Скрытый слой**: линейный
- **Выходной слой**: softmax
- **Функция ошибки**: cross-entropy

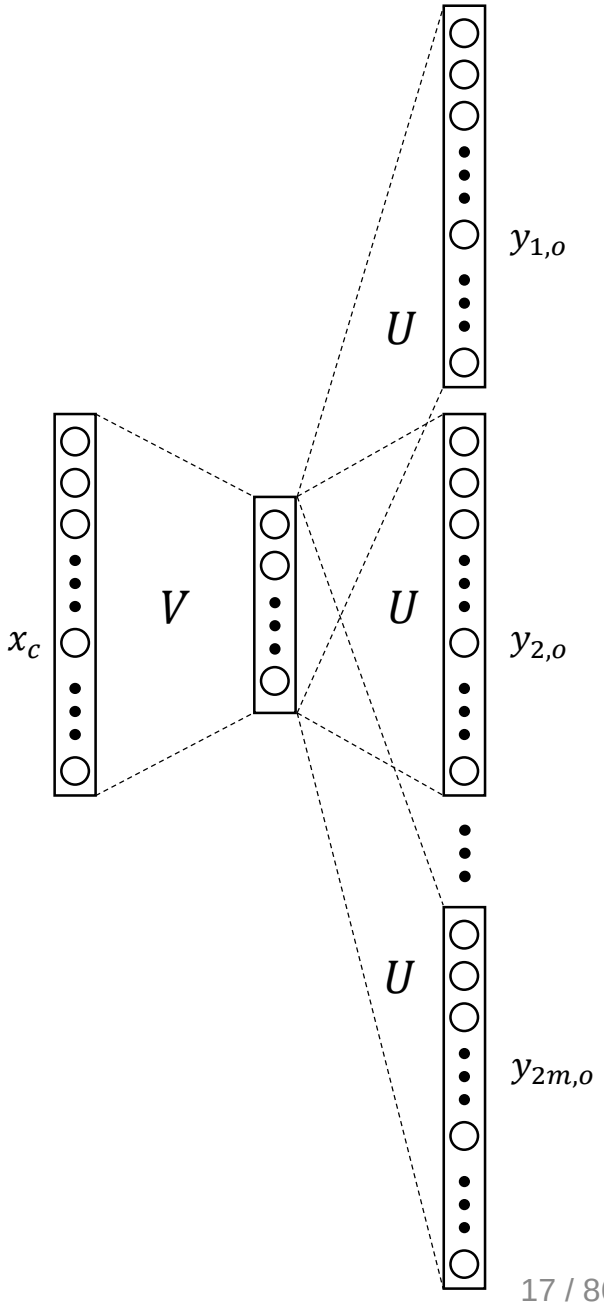

word2vec CBOW

Модель может быть представлена в виде нейронной сети:

- **Вход**: one-hot контекстных слов
- **Скрытый слой**: линейный
- **Выходной слой**: softmax
- **Функция ошибки**: cross-entropy

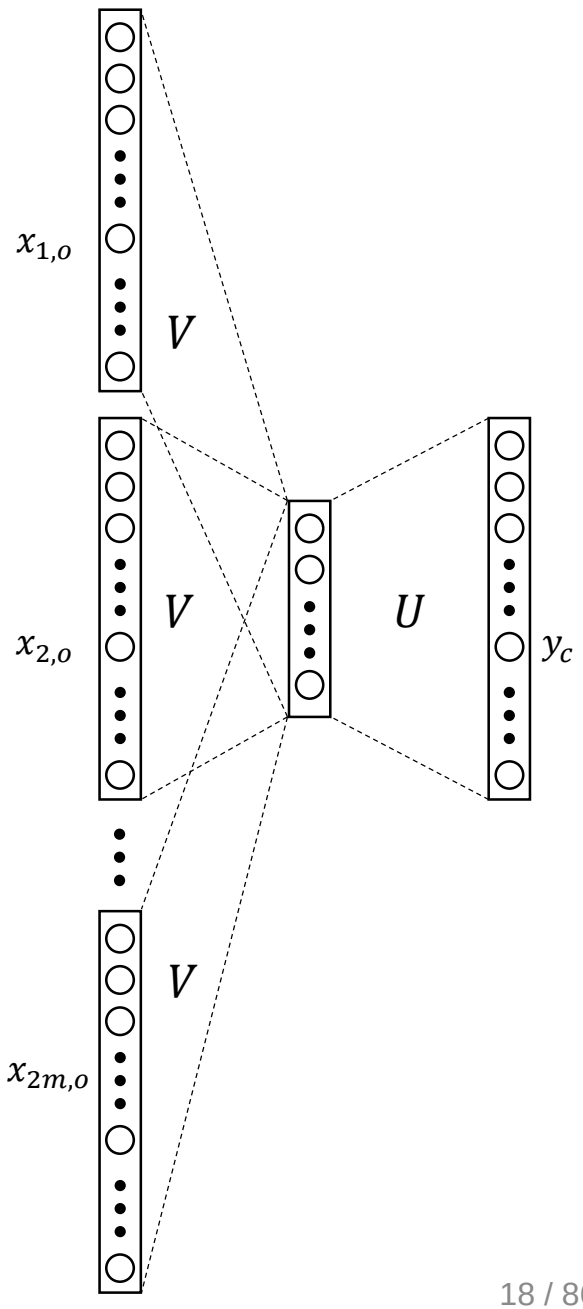

word2vec skip-gram

$$J(\theta) = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} \log p_\theta(w_{t+j} | w_t)$$

- Для каждого окна минимизируем

$$-\log p(o|c) = -\log \frac{\exp(u_o^T v_c)}{\sum_{w=1}^{n} \exp(u_w^T v_c)};$$

- Метод градиентного спуска

word2vec skip-gram

$$J(\theta) = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} \log p_\theta(w_{t+j} | w_t)$$

- Для каждого окна минимизируем

$$-\log p(o|c) = -\log \frac{\exp(u_o^T v_c)}{\sum_{w=1}^{n} \exp(u_w^T v_c)};$$

- Метод градиентного спуска

$$\frac{\partial(-\log p(o|c))}{\partial v_c} = -u_o + \sum_{i=1}^{n} \frac{\exp\left(u_i^T v_c\right)}{\sum_{w=1}^{n} \exp(u_w^T v_c)} u_i == -u_o + \sum_{x \in V} p(x|c) u_x$$

word2vec skip-gram

$$J(\theta) = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} \log p_\theta(w_{t+j} | w_t)$$

- Для каждого окна минимизируем

$$-\log p(o|c) = -\log \frac{\exp(u_o^T v_c)}{\sum_{w=1}^{n} \exp(u_w^T v_c)};$$

- Метод градиентного спуска

$$\frac{\partial(-\log p(o|c))}{\partial v_c} = -u_o + \underline{\sum_{i=1}^{n} \frac{\exp\left(u_i^T v_c\right)}{\sum_{w=1}^{n} \exp(u_w^T v_c)}} u_i == -u_o + \sum_{x \in V} p(x|c) u_x$$

word2vec skipgram

- Проблема:
  - На каждом шаге градиентного спуска вычисляется

$$\sum_{w=1}^{n} \exp\left(u_w^T v_c\right)$$

  словарь большой ⇒ долго

- Решения:
  - Hierarchical softmax
  - Negative sampling

Hierarchical softmax

- Основная идея:
  - Составить из словаря бинарное дерево

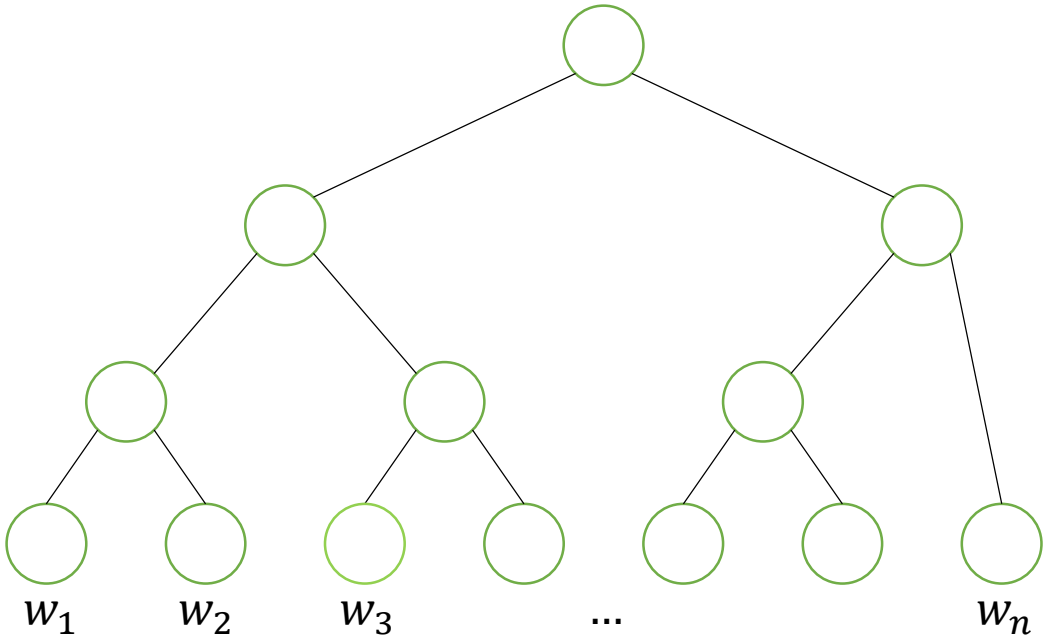

Hierarchical softmax

- Основная идея:
  - Составить из словаря бинарное дерево
  - Назначить каждому промежуточному узлу i вектор u_i

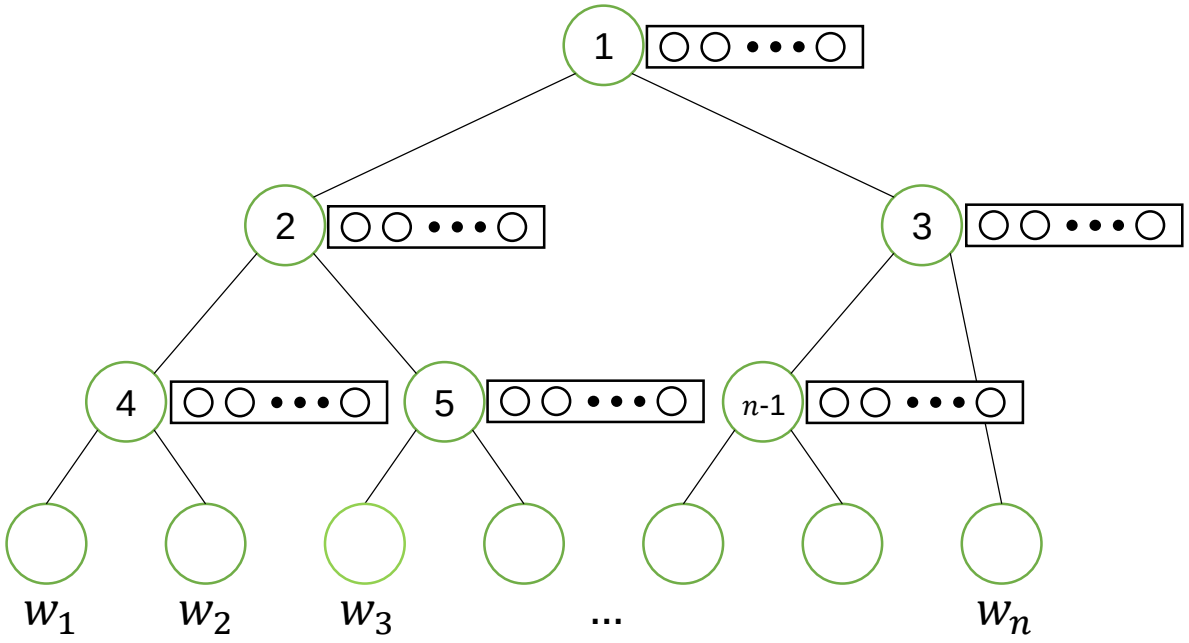

Hierarchical softmax

- Основная идея:
  - Составить из словаря бинарное дерево
  - Назначить каждому промежуточному узлу i вектор u_i
  - Предсказывать путь в дереве вместо слова из словаря

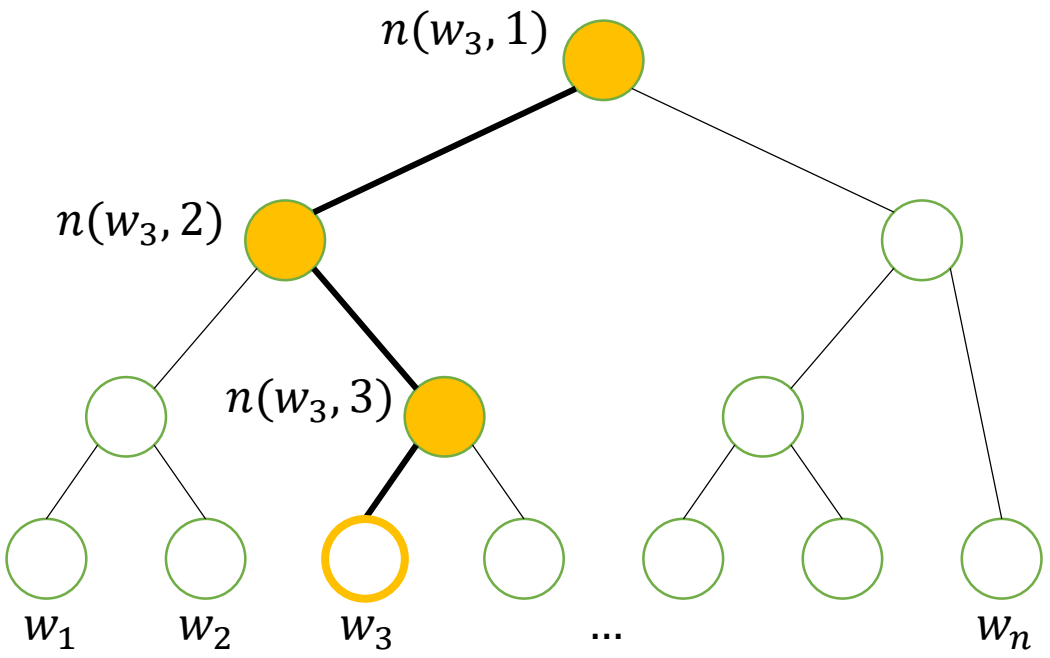

$n(w, p)$ – номер p-того узла в пути от корня к w

Hierarchical softmax

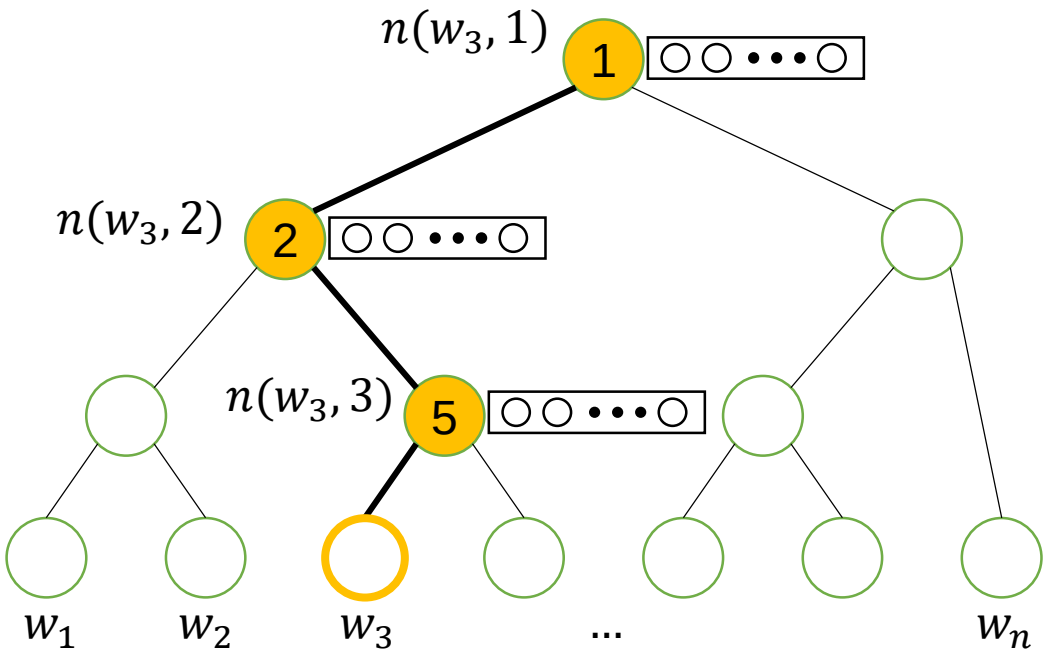

$$p(o|c) = \prod_{j=1}^{L(o)-1} \sigma([\![n(o, j+1) = ch(n(o, j))]\!]\, u_{n(o,j)}^T v_c)$$

$ch(n)$ – левый потомок узла n, $[\![x]\!] = \begin{cases} 1, & \text{если } x - \text{истина} \\ -1, & \text{если } x - \text{ложь} \end{cases}$

Negative sampling

- Сводим задачу к бинарной классификации:

$$z = \begin{cases} 1, & (\mathrm{c}, o) \in D \\ 0, & (\mathrm{c}, o) \notin D \end{cases};$$

$$p(z = 1 | o, \mathrm{c}) = \frac{1}{1 + \exp(-v_{\mathrm{c}}^T u_o)} = \sigma(v_c^T u_o)$$

- На каждый положительный пример берем K отрицательных:
  - Небольшие наборы данных – 5-20 примеров
  - Большие наборы данных – 2-5 примеров

Negative sampling

- Для каждого окна максимизируем

$$J_t(\theta) = \log p(z = 1|o, c) + \sum_{j \sim P(w)} \log p(z = 0|j, c)$$

$$= \log \sigma(v_c^T u_o) + \sum_{j \sim P(w)} \log \sigma(-v_c^T u_j)$$

  - $P(w_i) = \frac{f(w_i)^{3/4}}{\sum_{j=1}^{n} f(w_j)^{3/4}}$;
  - $f(w_i)$ – относительная частота слова w_i в D

Negative sampling

Во | времена | правления | Ивана | Грозного | из | …

- Набор данных:
  - Положительные примеры: пары слов из окон наших текстов
  - Отрицательные примеры: случайные слова из текстов

o	c	z
времена	правления	1
из	правления	0
слово	правления	0
Москвы	правления	0
…		

Проблема частых слов

- Слишком частые слова (предлоги, союзы, пунктуация)
  - часто встречаются в корпусе ⇒ вносят большое влияние на векторы слов
  - встречаются во всевозможных контекстах ⇒ векторы не отражают значение слова

Решение:

- Выкидывать слишком частые слова из корпуса

$$P(w_i) = 1 - \sqrt{\frac{t}{f(w_i)}};$$

- $f(w_i)$ – относительная частота слова w_i в D
- t – порог частоты (обычно около 10^{-5})

Оценка качества

- Intrinsic (in vitro)
  - Пытаемся оценить результат решения задачи сравнением с эталонным результатом
- Extrinsic (in vivo)
  - Пытаемся оценить результат решения задачи как подзадачи более сложной задачи

Оценка качества (Intrinsic)

- Задача аналогии слов:

Слово a относится к слову b также, как слово c относится к слову ___.

  - $d = \arg\max_i similarity(x_b - x_a + x_c, x_i)$

- Метрика:
  - $Accuracy = \frac{correct}{total}$;

Синтаксические аналогии

a	b	c	___
лекция	лекции	семинар	***семинары***
бежать	бегущий	лежать	***лежащий***

Оценка качества (Intrinsic)

- Задача аналогии слов:

Слово a относится к слову b также, как слово c относится к слову ___.

  - $d = \arg\max_i similarity(x_b - x_a + x_c, x_i)$

- Метрика:
  - $Accuracy = \frac{correct}{total}$;

Семантические аналогии

a	b	c	___
лететь	плыть	самолет	***корабль***
Россия	Москва	Франция	***Париж***

Оценка качества (Intrinsic)

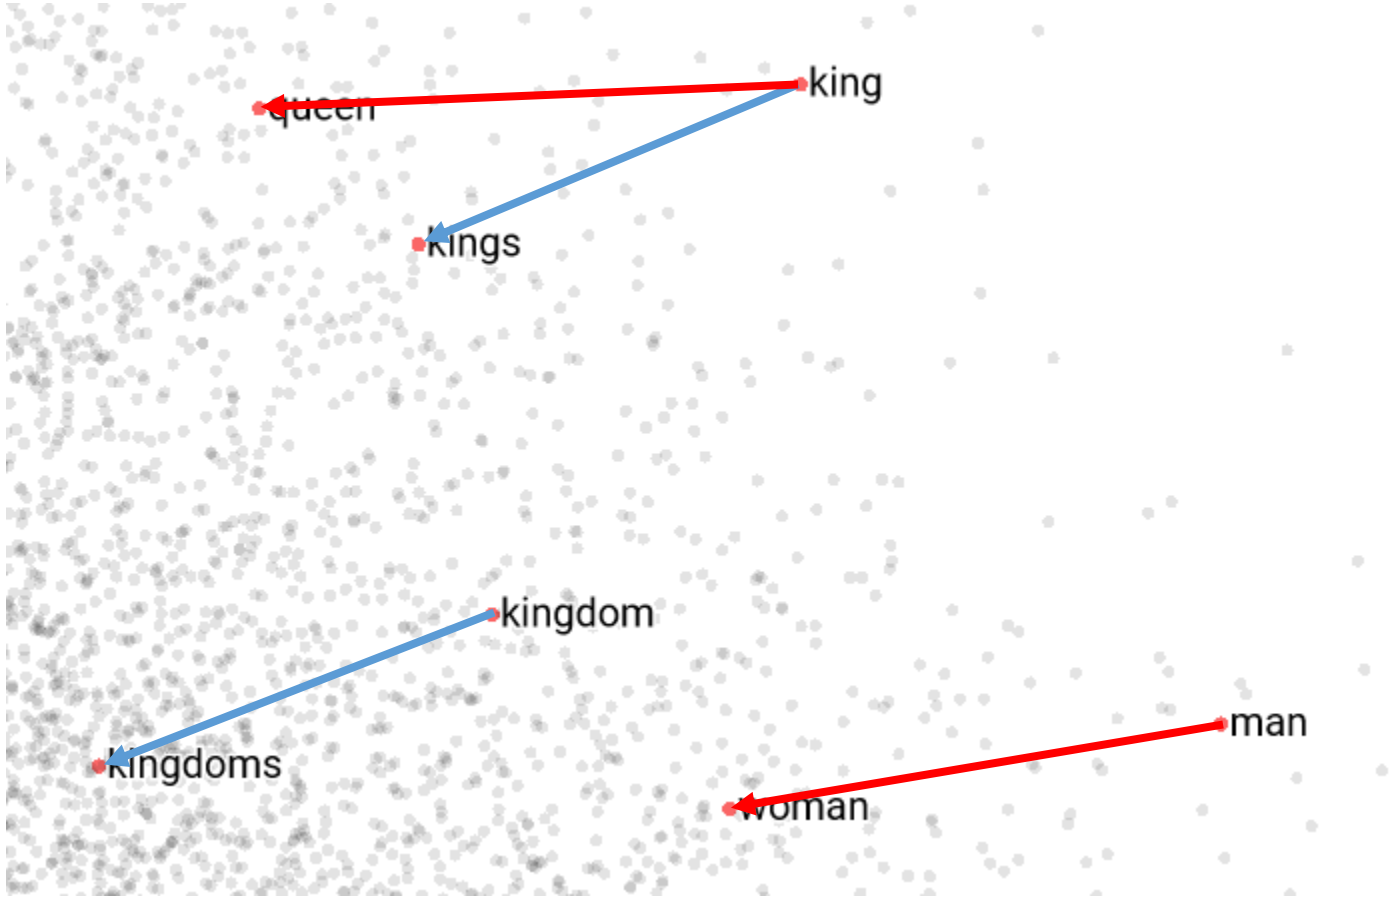

Оценка качества (Intrinsic)

- Задача аналогии слов
  - Найти слово по аналогии с другими
- Задача похожести пар слов
  - Отсортировать пары слов в соответствии со смысловой близостью
- Задача поиска синонимов
  - Для слова найти синонимы среди заданного множества слов
- Задача поиска лишнего слова
  - В множестве слов найти лишнее

Матрица совместной встречаемости

мама мыла раму.
раму мыла мама.
мыла мылом раму.

word-word

	мама	**мыла**	**раму**	**мылом**	**.**
мама	0	2	0	0	1
мыла	2	0	2	1	0
раму	0	2	0	1	2
мылом	0	1	1	0	0
.	1	0	2	0	0

Матрица совместной встречаемости

- Понижение размерности (SVD)
  - $A = U\Sigma V^T$;
    - Σ – матрица сингулярных значений(m*m)
  - $\hat{A} = \hat{U}\hat{\Sigma}\hat{V}^T$; (теорема Эккарта-Янга)
    - $\hat{U}$ –первые k столбцов матрицы U
    - $\hat{\Sigma}$ – k первых столбцов и строк матрицы Σ
    - $\hat{V}$ –первые k столбцов матрицы V

Матрица совместной встречаемости

- Понижение размерности (SVD)
  - $A = U\Sigma V^T$;
    - Σ – матрица сингулярных значений(m*m)

$$A = \begin{bmatrix} 0 & 2 & 0 & 0 & 1 \\ 2 & 0 & 2 & 1 & 0 \\ 0 & 2 & 0 & 1 & 2 \\ 0 & 1 & 1 & 0 & 0 \\ 1 & 0 & 2 & 0 & 0 \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} -0.385 & -0.435 & -0.359 & -0.557 & -0.472 \\ -0.557 & 0.557 & 0.411 & -0.435 & 0.142 \\ -0.557 & -0.557 & 0.411 & 0.435 & 0.142 \\ -0.286 & 0 & -0.636 & 0 & 0.716 \\ -0.385 & 0.435 & -0.359 & 0.557 & -0.472 \end{bmatrix}}_{U} * \underbrace{diag\begin{pmatrix} 3.895 \\ 3.562 \\ 1.292 \\ 0.562 \\ 0.397 \end{pmatrix}}_{\Sigma} * \underbrace{\begin{bmatrix} -0.385 & 0.435 & 0.359 & -0.557 & -0.472 \\ -0.557 & -0.557 & -0.411 & -0.435 & 0.142 \\ -0.557 & 0.557 & -0.411 & 0.435 & 0.142 \\ -0.286 & 0 & 0.636 & 0 & 0.716 \\ -0.385 & -0.435 & 0.359 & 0.557 & -0.472 \end{bmatrix}^T}_{V^T}$$

Матрица совместной встречаемости

- Понижение размерности (SVD)
  - $\hat{A} = \hat{U}\hat{\Sigma}\hat{V}^T$;
    - $\hat{U}$ – первые k столбцов матрицы U
    - $\hat{\Sigma}$ – k первых столбцов и строк матрицы Σ
    - $\hat{V}$ – первые k столбцов матрицы V

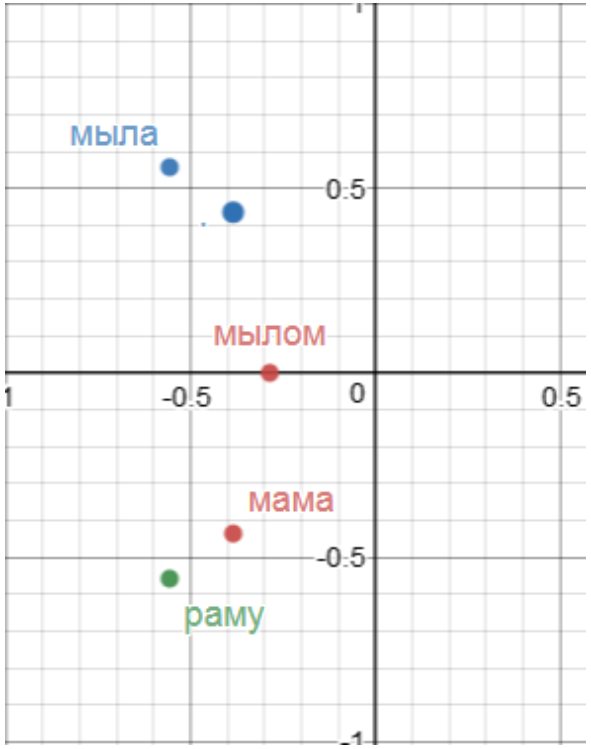

$$\hat{A} = \begin{bmatrix} -0.10 & 1.70 & -0.02 & 0.43 & 1.25 \\ 1.70 & 0.10 & 2.32 & 0.62 & -0.03 \\ -.03 & 2.32 & 0.10 & 0.62 & 1.70 \\ 0.43 & 0.62 & 0.62 & 0.32 & 0.43 \\ 1.25 & -0.03 & 1.70 & 0.43 & -0.10 \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} -0.385 & -0.435 & -0.359 & -0.557 & -0.472 \\ -0.557 & 0.557 & 0.411 & -0.435 & 0.142 \\ -0.557 & -0.557 & 0.411 & 0.435 & 0.142 \\ -0.286 & 0 & -0.636 & 0 & 0.716 \\ -0.385 & 0.435 & -0.359 & 0.557 & -0.472 \end{bmatrix}}_{U} * diag \underbrace{\begin{pmatrix} 3.895 \\ 3.562 \\ 1.292 \\ 0.562 \\ 0.397 \end{pmatrix}}_{\Sigma} * \underbrace{\begin{bmatrix} -0.385 & 0.435 & 0.359 & -0.557 & -0.472 \\ -0.557 & -0.557 & -0.411 & -0.435 & 0.142 \\ -0.557 & 0.557 & -0.411 & 0.435 & 0.142 \\ -0.286 & 0 & 0.636 & 0 & 0.716 \\ -0.385 & -0.435 & 0.359 & 0.557 & -0.472 \end{bmatrix}^T}_{V^T}$$

$\hat{U}$ $\hat{\Sigma}$ $\hat{V}$

GloVe

Основная идея:

Для понимания, насколько близки слова, не достаточно частоты совместной встречаемости – нужно сравнивать частоты встречаемости слова в разных контекстах

Probability and Ratio	$k = solid$	$k = gas$	$k = water$	$k = fashion$
$P(k\|ice)$	1.9×10^{-4}	6.6×10^{-5}	3.0×10^{-3}	1.7×10^{-5}
$P(k\|steam)$	2.2×10^{-5}	7.8×10^{-4}	2.2×10^{-3}	1.8×10^{-5}
$P(k\|ice)/P(k\|steam)$	$\boxed{8.9}$	$\boxed{8.5 \times 10^{-2}}$	1.36	0.96

- $solid$ больше относится к ice, чем к $steam$
- gas больше относится к $steam$, чем к ice
- $water$ и $fashion$ одинаково хорошо (плохо) относятся к ice и $steam$

Pennington J., et al. Glove: Global vectors for word representation – 2014.

GloVe

Обозначения:

- X – матрица совместной встречаемости
- X_{ij} – сколько раз слово j встретилось в контексте слова i
- $X_i = \sum_k X_{ik}$ – сколько раз любое слово встретилось в контексте i
- $P_{ij} = P(j|i) = X_{ij}/X_i$ – вероятность слова j встретиться в контексте i

GloVe

Основная идея:

Для понимания, насколько близки слова, не достаточно частоты совместной встречаемости – нужно сравнивать частоты встречаемости слова в разных контекстах

Probability and Ratio	$k = solid$	$k = gas$	$k = water$	$k = fashion$
$P(k\|ice)$	1.9×10^{-4}	6.6×10^{-5}	3.0×10^{-3}	1.7×10^{-5}
$P(k\|steam)$	2.2×10^{-5}	7.8×10^{-4}	2.2×10^{-3}	1.8×10^{-5}
$P(k\|ice)/P(k\|steam)$	$\boxed{8.9}$	$\boxed{8.5 \times 10^{-2}}$	1.36	0.96

$$F(i,j,k) = P(k|i)/P(k|j) = P_{ik}/P_{jk}$$

GloVe

$$F(i,j,k) = P(k|i)/P(k|j) = P_{ik}/P_{jk}$$

- V – векторы слов
- U – векторы контекстных слов

$$F\left(\underbrace{v_i, v_j}, u_k\right) = \underbrace{P_{ik}/P_{jk}}$$

Отношение
между векторами

GloVe

$$F(i,j,k) = P(k|i)/P(k|j) = P_{ik}/P_{jk}$$

- V – векторы слов
- U – векторы контекстных слов

$$F\left(v_i, v_j, u_k\right) = P_{ik}/P_{jk}$$

$$F\left(\underbrace{v_i - v_j, u_k}_{\text{векторы}}\right) = \underbrace{P_{ik}/P_{jk}}_{\text{скаляр}}$$

GloVe

$$F(i,j,k) = P(k|i)/P(k|j) = P_{ik}/P_{jk}$$

- V – векторы слов
- U – векторы контекстных слов

$$F\left(v_i, v_j, u_k\right) = P_{ik}/P_{jk}$$

$$F\left(v_i - v_j, u_k\right) = P_{ik}/P_{jk}$$

$$F\left(\left(v_i - v_j\right)^T u_k\right) = P_{ik}/P_{jk}$$

GloVe

$$F(i,j,k) = P(k|i)/P(k|j) = P_{ik}/P_{jk}$$

- V – векторы слов
- U – векторы контекстных слов

$$F\left(v_i, v_j, u_k\right) = P_{ik}/P_{jk}$$

$$F\left(v_i - v_j, u_k\right) = P_{ik}/P_{jk}$$

$$F\left(\left(v_i - v_j\right)^T u_k\right) = P_{ik}/P_{jk}$$

- F – гомоморфизм групп $(\mathbb{R}, +)$ и $(\mathbb{R}_{>0}, \times)$

$$F\left(\left(v_i - v_j\right)^T u_k\right) = F\left(v_i^T u_k\right)/F\left(v_j^T u_k\right) = P_{ik}/P_{jk}\,;$$

GloVe

- $F\left(\left(v_i - v_j\right)^T u_k\right) = F\left(v_i^T u_k\right) / F\left(v_j^T u_k\right) = P_{ik} / P_{jk}$;

- $F\left(v_i^T u_k\right) = P_{ik} = \frac{X_{ik}}{X_i}$

GloVe

- $F\left(\left(v_i - v_j\right)^T u_k\right) = F\left(v_i^T u_k\right) / F\left(v_j^T u_k\right) = P_{ik} / P_{jk}$;

- $F\left(v_i^T u_k\right) = P_{ik} = \frac{X_{ik}}{X_i}$

- $F = \exp$
- $v_i^T u_k = \log P_{ik} = \log X_{ik} - \log X_i$

GloVe

- $F\left(\left(v_i - v_j\right)^T u_k\right) = F\left(v_i^T u_k\right) / F\left(v_j^T u_k\right) = P_{ik} / P_{jk}$;

- $F\left(v_i^T u_k\right) = P_{ik} = \frac{X_{ik}}{X_i}$

- $F = \exp$
- $v_i^T u_k = \log P_{ik} = \log X_{ik} - \underline{\log X_i}$
- $v_i^T u_k + \underline{b_i} + \underline{\tilde{b}_k} - \log X_{ik} = 0$

GloVe

- $F\left(\left(v_i - v_j\right)^T u_k\right) = F\left(v_i^T u_k\right) / F\left(v_j^T u_k\right) = P_{ik} / P_{jk}$;

- $F\left(v_i^T u_k\right) = P_{ik} = \frac{X_{ik}}{X_i}$

- $F = \exp$
- $v_i^T u_k = \log P_{ik} = \log X_{ik} - \log X_i$
- $v_i^T u_k + b_i + \tilde{b}_k - \log X_{ik} = 0$

- $J(v_i, u_k) = \left(v_i^T u_k + b_i + \tilde{b}_k - \boxed{\log X_{ik}}\right)^2$

GloVe

$$J(v_i, u_k) = \left(v_i^T u_k + b_i + \tilde{b}_k - \log X_{ik}\right)^2$$

- $\log X_{ik}$ не определен при $X_{ik} = 0$

GloVe

$$J(v_i, u_k) = \left(v_i^T u_k + b_i + \tilde{b}_k - \log X_{ik}\right)^2$$

- $\log X_{ik}$ не определен при $X_{ik} = 0$

$$J(v_i, u_k) = \underline{f(X_{ik})}\left(v_i^T u_k + b_i + \tilde{b}_k - \log X_{ik}\right)^2$$

- функция $f(x)$:
  - $f(0) = 0$ (более того $\lim\limits_{x \to 0} f(x) \log^2 x$ конечен)
  - $f(x)$ – неубывающая
  - $f(x)$ – «не слишком высока» для больших x

GloVe

Функция потерь

$$J(\theta) = \sum_{i=1}^{n}\sum_{j=1}^{n} f(X_{ij})\left(v_i^T u_j + b_i + \tilde{b}_j - \log X_{ij}\right)^2,$$

$$f(x) = \begin{cases} (x/x_{max})^{\alpha}, x < x_{max} \\ 1, \quad x \geq x_{max} \end{cases}, \qquad \alpha < 1$$

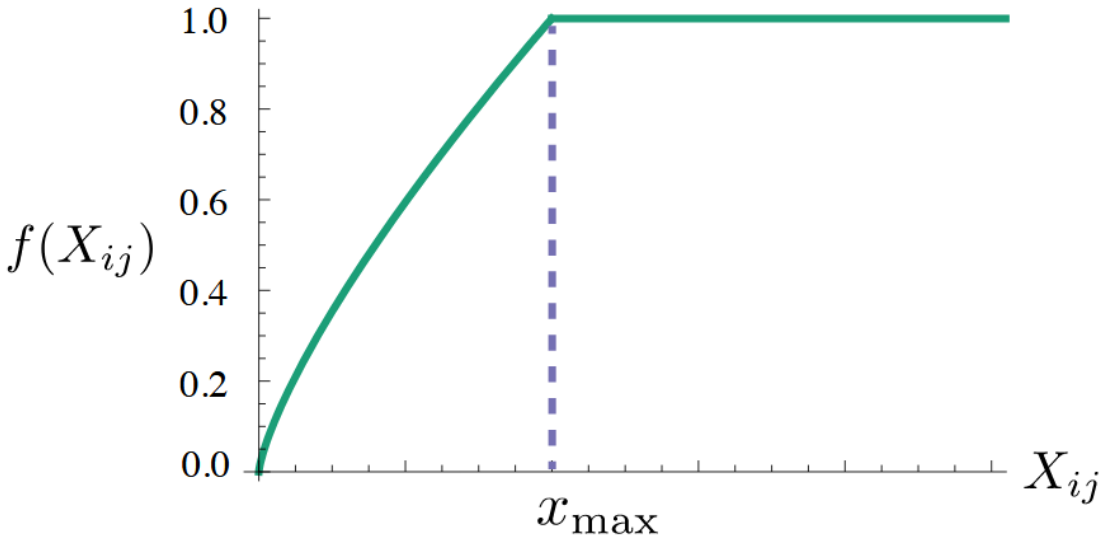

Проблема редких слов

- Для слов, которые встречаются слишком редко, невозможно построить хорошие векторы

- В обучающем корпусе могут отсутствовать редкие слова $\Rightarrow$ такие слова не попадут в словарь V

Проблема редких слов

- Редкие слова заменяются на специальную константу OOV (out of vocabulary)
  - В процессе обучения вычисляется вектор для OOV
  - Этот вектор используется для слов, не вошедших в V

Проблема редких слов

- Редкие слова заменяются на специальную константу OOV (out of vocabulary)
  - В процессе обучения вычисляется вектор для OOV
  - Этот вектор используется для слов, не вошедших в V

- Слова рассматриваются не как атомарные единицы, а как последовательности символов

fasttext

- Каждое слово w представим как мультимножество символьных n-gram

Грозного

n=2 <Гр> <ро> <оз> <зн> <но> <ог> <го>

n=3 <Гро> <роз> <озн> <зно> <ног> <ого>

- Составим словарь слов V и словарь символьных n-gram G

Bojanowski P. et al. Enriching word vectors with subword information – 2017.

fasttext

- В word2vec:

$$p(o|c) = \frac{\exp(u_o^T v_c)}{\sum_{i=1}^{n} \exp(u_i^T v_c)} = \frac{\exp(s(w_o, w_c))}{\sum_{i=1}^{n} \exp(s(w_i, w_c))},$$

$s(w_o, w_c) = u_o^T v_c$ - функция оценки (score)

fasttext

- В word2vec:

$$p(o|c) = \frac{\exp(u_o^T v_c)}{\sum_{i=1}^{n} \exp(u_i^T v_c)} = \frac{\exp(s(w_o, w_c))}{\sum_{i=1}^{n} \exp(s(w_i, w_c))},$$

$s(w_o, w_c) = u_o^T v_c$ - функция оценки (score)

- В fasttext:

$$s(w_o, w_c) = u_o^T v_c + \sum_{g \in \Gamma(w_c)} u_o^T z_g \,,$$

$\Gamma(w_c)$– n-gram’ы слова w_c

Сверточные сети (CNN)

- Архитектура нейронной сети, нацеленная на эффективное распознавание образов

- Состоит из:
  - Слой свертки
  - Слой активации
  - Pooling слой

Сверточные сети (CNN)

- Слой свертки
  - На входе матрица (изображение) $X \in \mathbb{R}^{m \times n}$
  - Задана матрица весов (фильтр, ядро свертки) $K \in \mathbb{R}^{h \times w}$
  - Строим выходное изображение, «двигая» фильтр по матрице

$$Y \in \mathbb{R}^{(m-h+1)\times(n-w+1)}$$

$$y_{i,j} = \sum_{q=1}^{h} \sum_{r=1}^{w} X_{i+q-1,j+r-1} * K_{q,r}\,, i = \overline{1, m-h+1}, j = \overline{1, n-w+1}$$

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$Y \in \mathbb{R}^{?\times?}$

$X \in \mathbb{R}^{4\times5}$

2	1	3	1	2
3	4	2	0	1
2	0	1	2	3
1	3	2	4	0

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$Y \in \mathbb{R}^{2\times3}$

$X \in \mathbb{R}^{4\times5}$

2	1	3	1	2
3	4	2	0	1
2	0	1	2	3
1	3	2	4	0

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$X \in \mathbb{R}^{4\times5}$

2 (2)	1 (-1)	3 (-1)	1	2
3 (-1)	4 (0)	2 (0)	0	1
2 (-1)	0 (0)	1 (2)	2	3
1	3	2	4	0

$Y \in \mathbb{R}^{2\times3}$

-3		

$$y_{1,1} = 2*2 + (-1)*1 + (-1)*3 + (-1)*3 + 0*4 + 0*2 + (-1)*2 + 0*0 + 2*1 = -3$$

Сверточные сети (CNN)

- Слой свертки

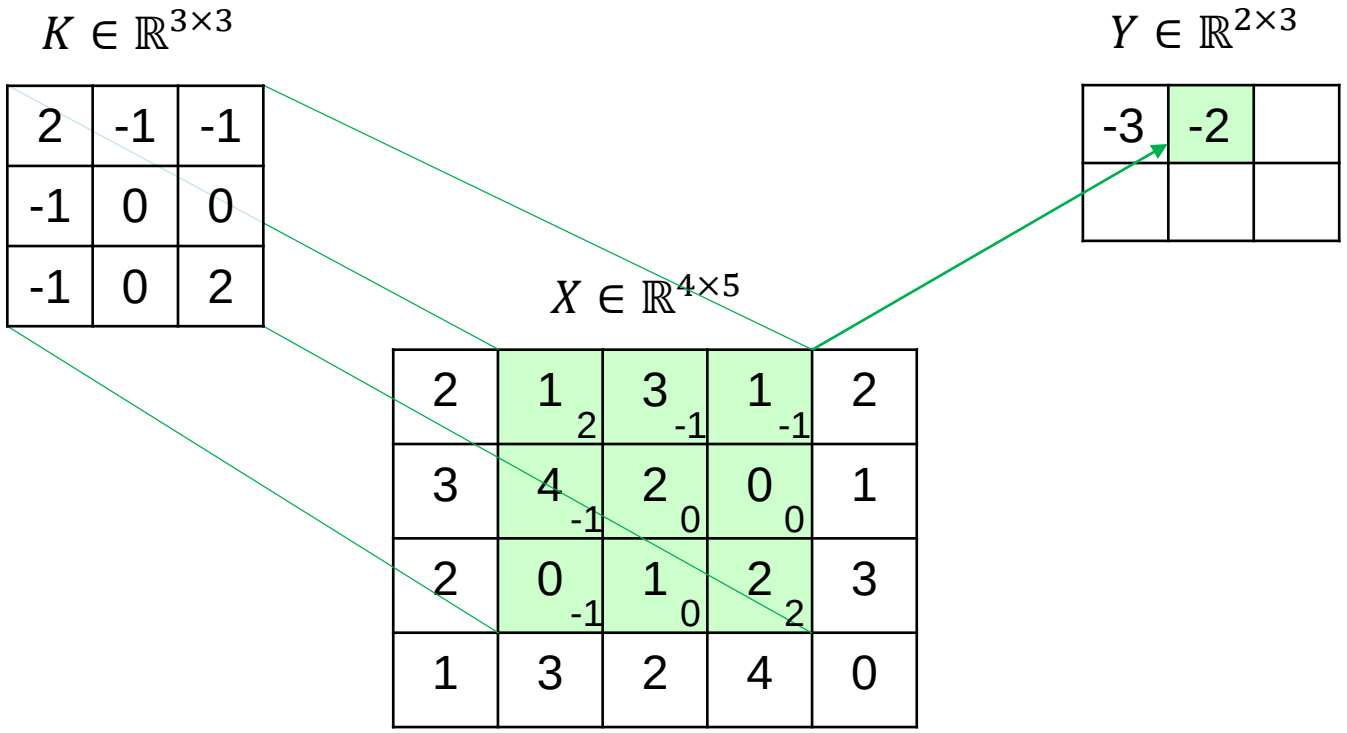

$$y_{1,2} = 2 * 1 + (-1) * 3 + (-1) * 1 + (-1) * 4 + 0 * 2 + 0 * 0 + (-1) * 0 + 0 * 1 + 2 * 2 = -2$$

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$X \in \mathbb{R}^{4\times5}$

2	1	3 $_{2}$	1 $_{-1}$	2 $_{-1}$
3	4	2 $_{-1}$	0 $_{0}$	1 $_{0}$
2	0	1 $_{-1}$	2 $_{0}$	3 $_{2}$
1	3	2	4	0

$Y \in \mathbb{R}^{2\times3}$

-3	-2	6

$$y_{1,3} = 2*3 + (-1)*1 + (-1)*2 + (-1)*2 + 0*0 + 0*1 + (-1)*1 + 0*2 + 2*3 = 6$$

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$X \in \mathbb{R}^{4\times5}$

2	1	3	1	2
3_{2}	4_{-1}	2_{-1}	0	1
2_{-1}	0_{0}	1_{0}	2	3
1_{-1}	3_{0}	2_{2}	4	0

$Y \in \mathbb{R}^{2\times3}$

-3	-2	6
-1		

$$y_{2,1} = 2*3+(-1)*4+(-1)*2+(-1)*2+0*0+0*1+(-1)*1+0*3+2*2=-1$$

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$X \in \mathbb{R}^{4\times5}$

2	1	3	1	2
3	4 2	2 -1	0 -1	1
2	0 -1	1 0	2 0	3
1	3 -1	2 0	4 2	0

$Y \in \mathbb{R}^{2\times3}$

-3	-2	6
-1	11	

$$y_{2,2} = 2*4 + (-1)*2 + (-1)*0 + (-1)*0 + 0*1 + 0*2 + (-1)*3 + 0*2 + 2*4 = 11$$

Сверточные сети (CNN)

- Слой свертки

$K \in \mathbb{R}^{3\times3}$

2	-1	-1
-1	0	0
-1	0	2

$X \in \mathbb{R}^{4\times5}$

2	1	3	1	2
3	4	2_{2}	0_{-1}	1_{-1}
2	0	1_{-1}	2_{0}	3_{0}
1	3	2_{-1}	4_{0}	0_{2}

$Y \in \mathbb{R}^{2\times3}$

-3	-2	6
-1	11	0

$$y_{2,3} = 2*2 + (-1)*0 + (-1)*1 + (-1)*1 + 0*2 + 0*3 + (-1)*2 + 0*4 + 2*0 = 0$$

Сверточные сети (CNN)

- Pooling слой
  - Агрегирует выходы группы нейронов в один выход
  - На входе матрица (признаки) $X \in \mathbb{R}^{m \times n}$
  - Задан размер окна $(h \times w)$
  - Строим выходное признаки, «двигая» окно по матрице и выполняя операцию агрегации

$$Y \in \mathbb{R}^{\frac{m}{h} \times \frac{n}{w}};$$

$$y_{i,j} = f\left(X_{(i-1)*h:i*h,(j-1)*w:j*w}\right)$$

  - В качестве f обычно используется функция max

Сверточные сети (CNN)

- Pooling слой

Окно $(h \times w)$: $h = 2; w = 1$

$X \in \mathbb{R}^{2\times 3}$

-3	-2	6
-1	11	0

$Y \in \mathbb{R}^{?\times ?}$

Сверточные сети (CNN)

- Pooling слой

Окно $(h \times w)$: $h = 2; w = 1$

$X \in \mathbb{R}^{2\times 3}$

-3	-2	6
-1	11	0

$Y \in \mathbb{R}^{1\times 3}$

Сверточные сети (CNN)

- Pooling слой

Окно $(h \times w)$: $h = 2; w = 1$

$X \in \mathbb{R}^{2\times 3}$

-3	-2	6
-1	11	0

$Y \in \mathbb{R}^{1\times 3}$

-1		

Сверточные сети (CNN)

- Pooling слой

Окно $(h \times w)$: $h = 2; w = 1$

$X \in \mathbb{R}^{2\times 3}$

-3	-2	6
-1	11	0

$Y \in \mathbb{R}^{1\times 3}$

-1	11	

Сверточные сети (CNN)

- Pooling слой

Окно $(h \times w)$: $h = 2; w = 1$

$X \in \mathbb{R}^{2\times 3}$

-3	-2	6
-1	11	0

$Y \in \mathbb{R}^{1\times 3}$

-1	11	6

CharCNN

- Собираем словарь символов C по обучающему корпусу
- Каждому символу $c \in C$ ставим в соответствие вектор $v_c \in \mathbb{R}^d$
- Слово w рассматриваем как последовательность символов $[c_1, c_2, \dots, c_n]$
- Подставляя для каждого символа c_i вектор v_{c_i} получаем матрицу $X \in \mathbb{R}^{n \times d}$
- Задаем m фильтров $K_i \in \mathbb{R}^{k_i \times d}$

- Применяем к X свертки с фильтрами K_i с max pooling и получаем вектор $y \in \mathbb{R}^m$ для слова w

CharCNN

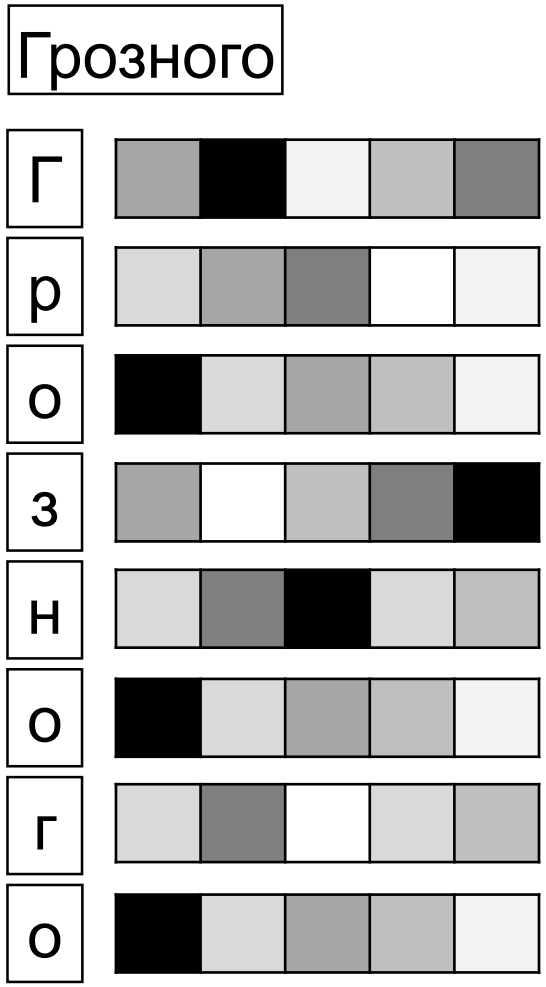

CharCNN

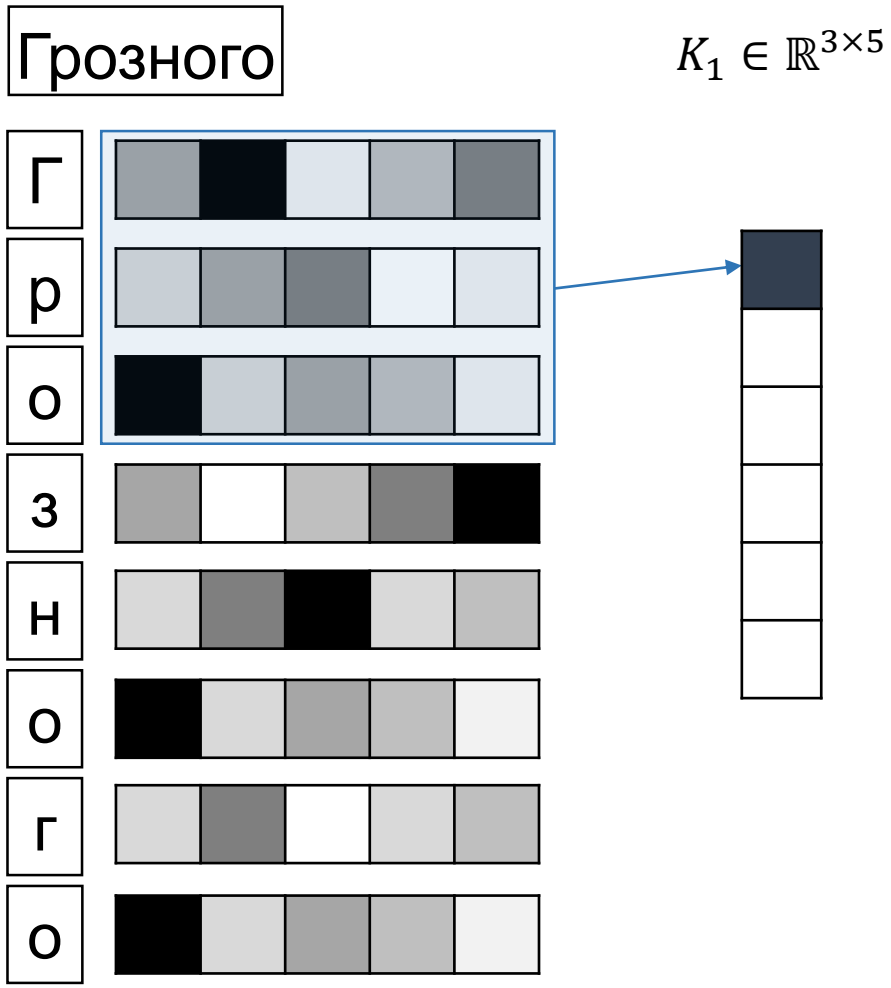

CharCNN

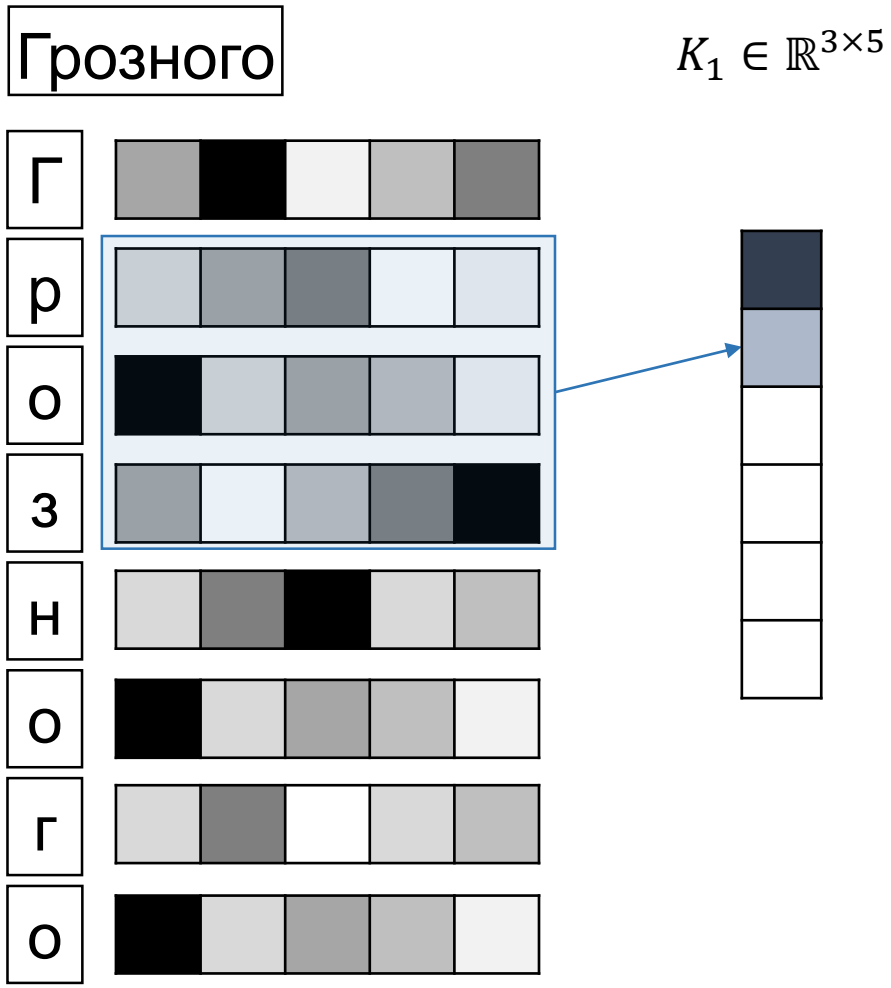

CharCNN

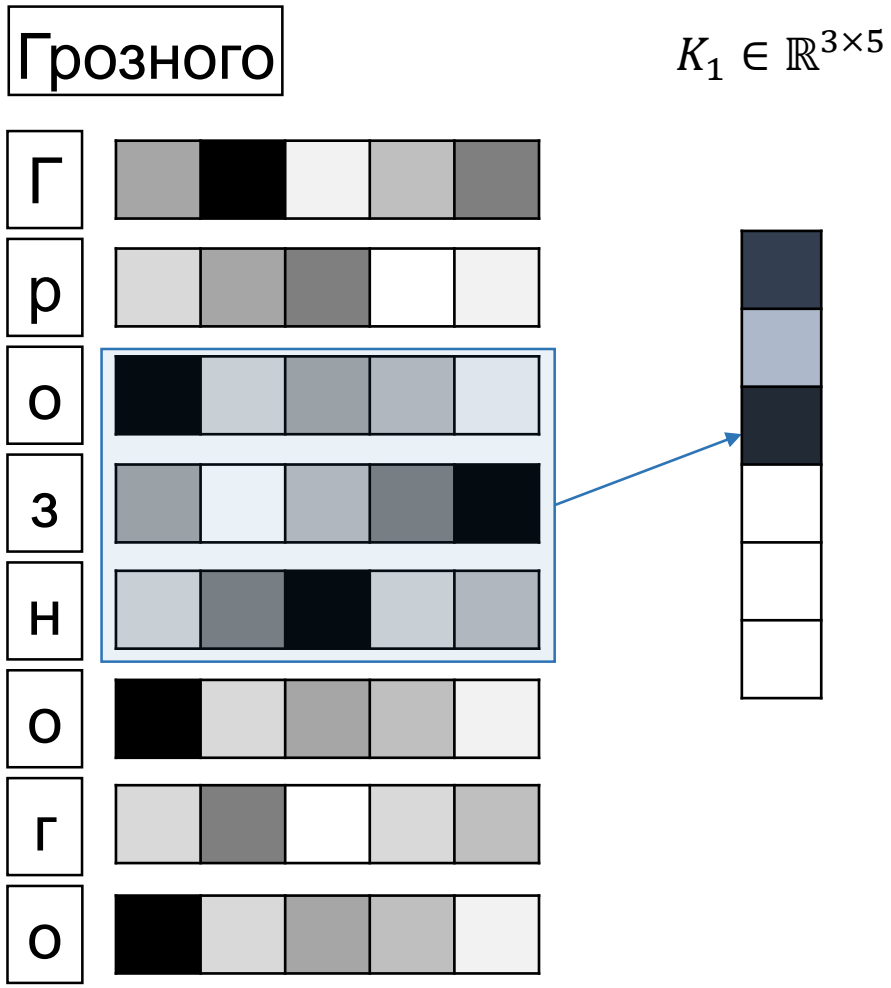

CharCNN

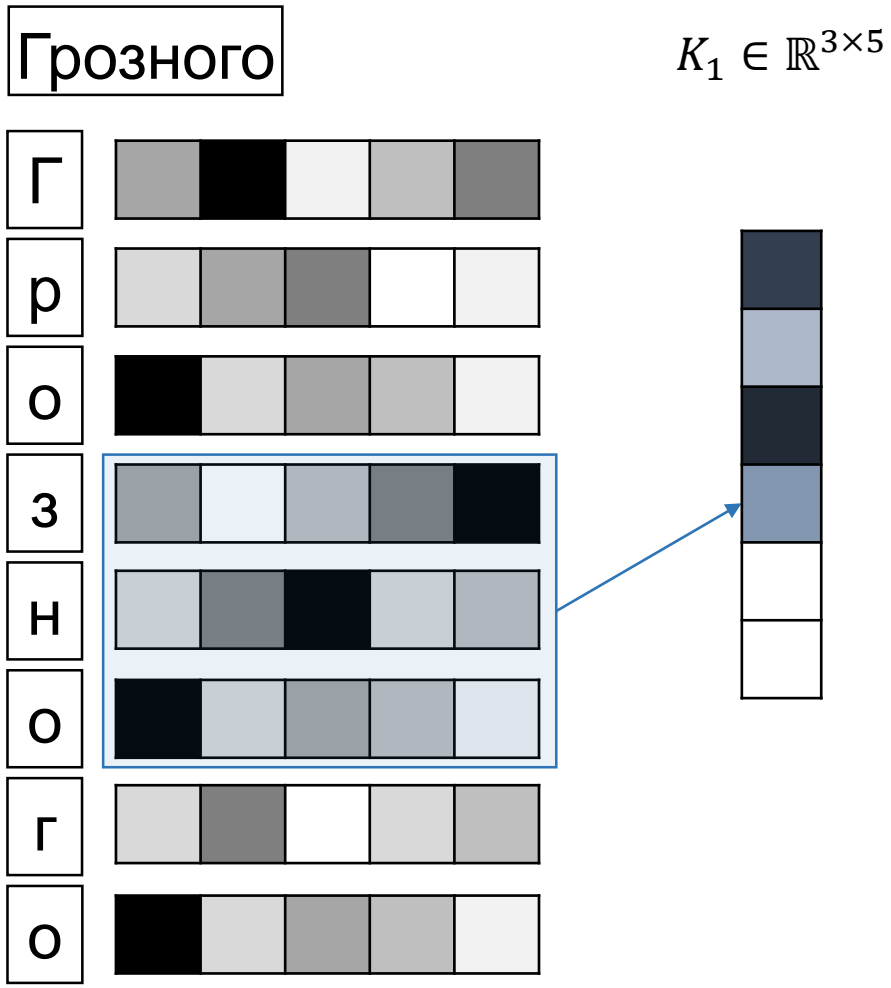

CharCNN

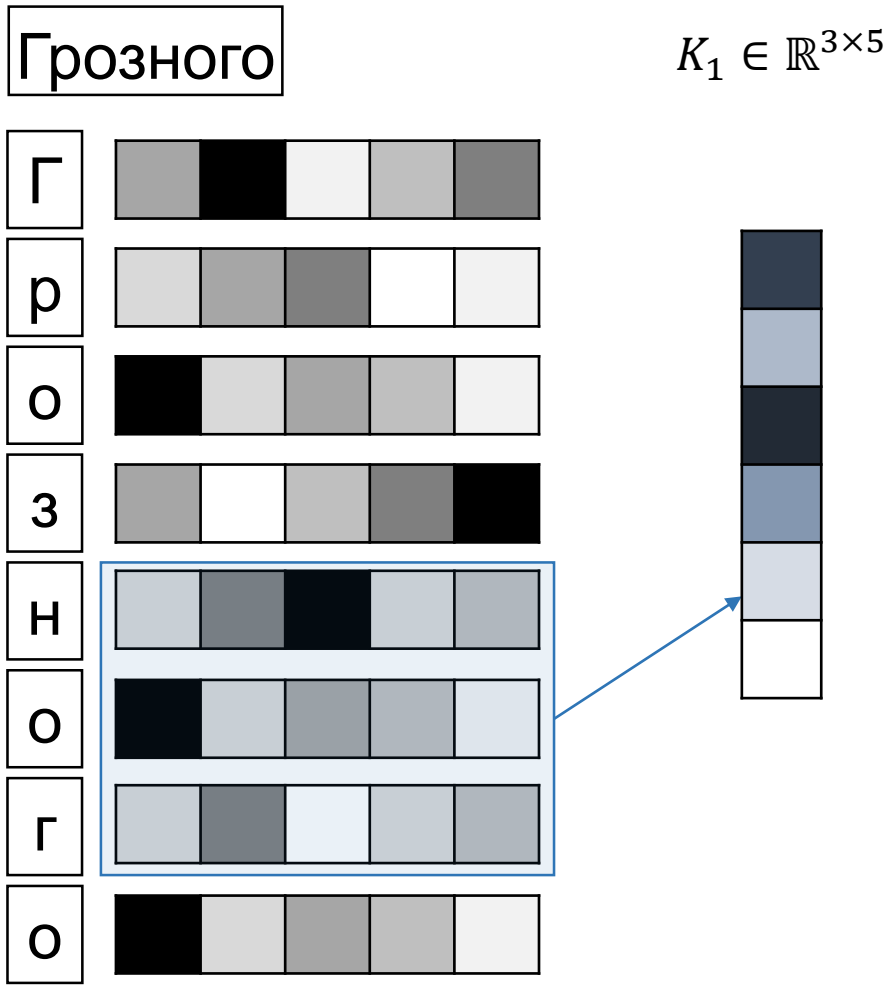

CharCNN

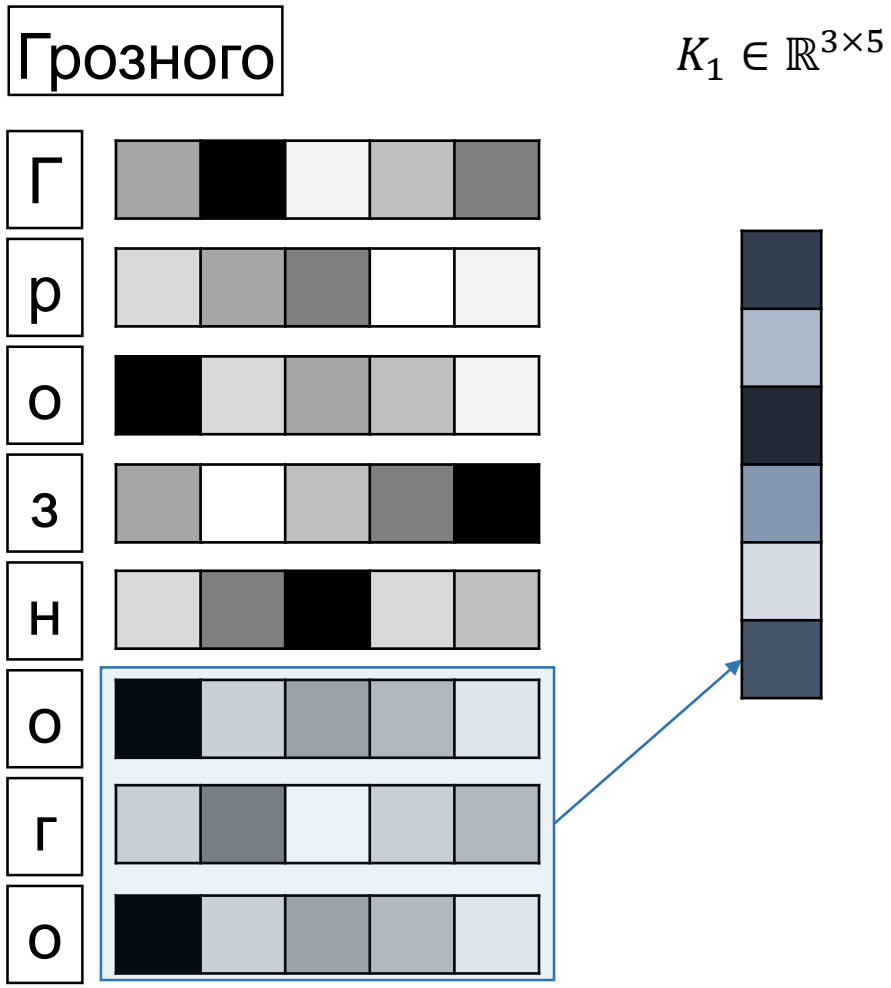

CharCNN

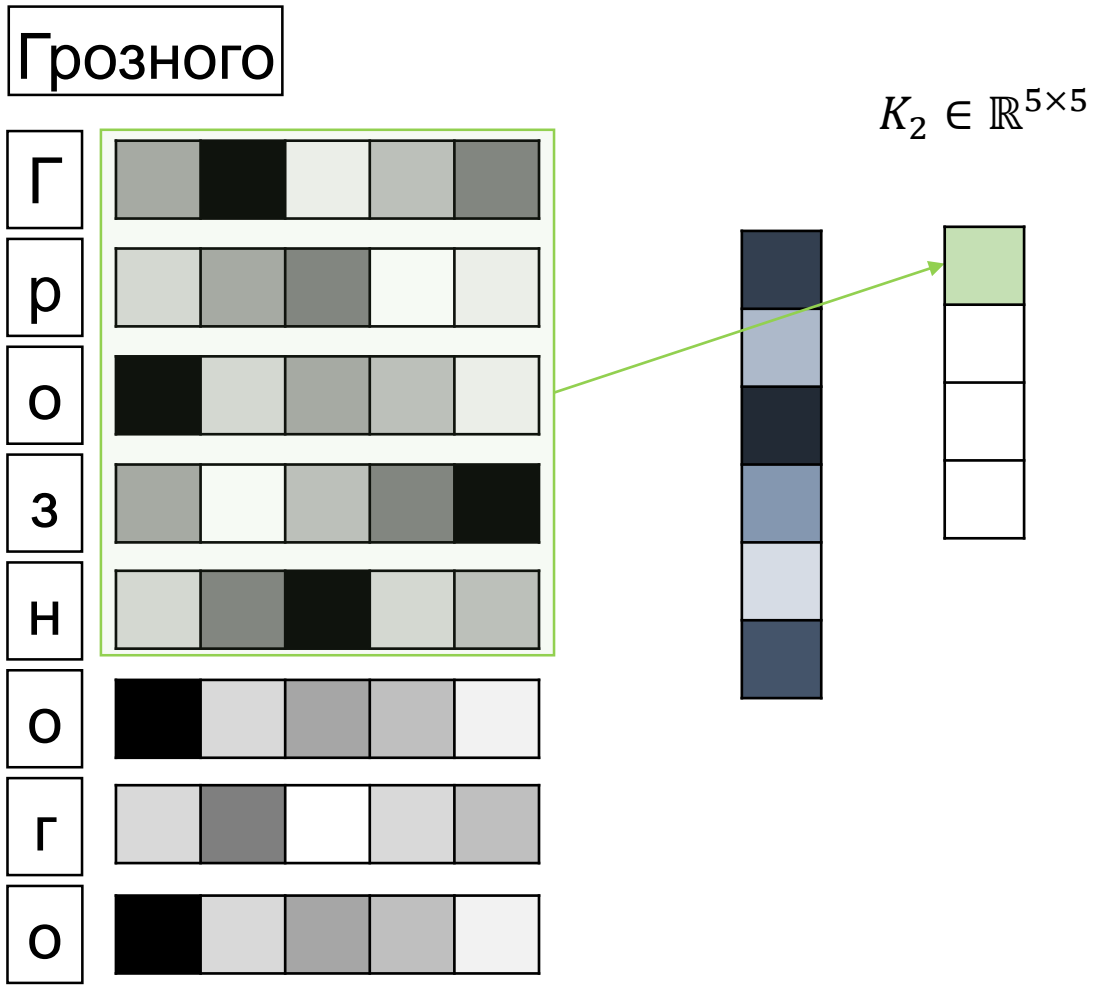

CharCNN

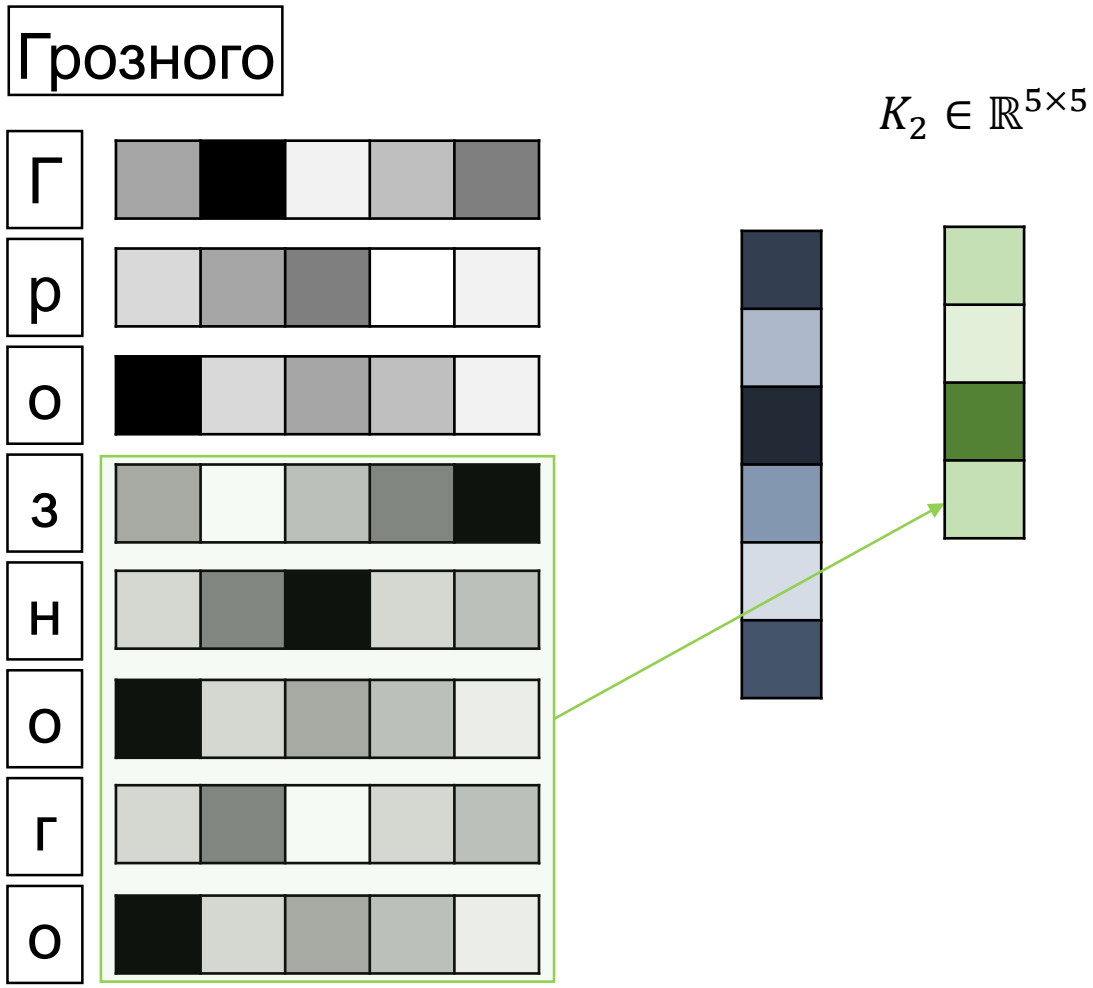

CharCNN

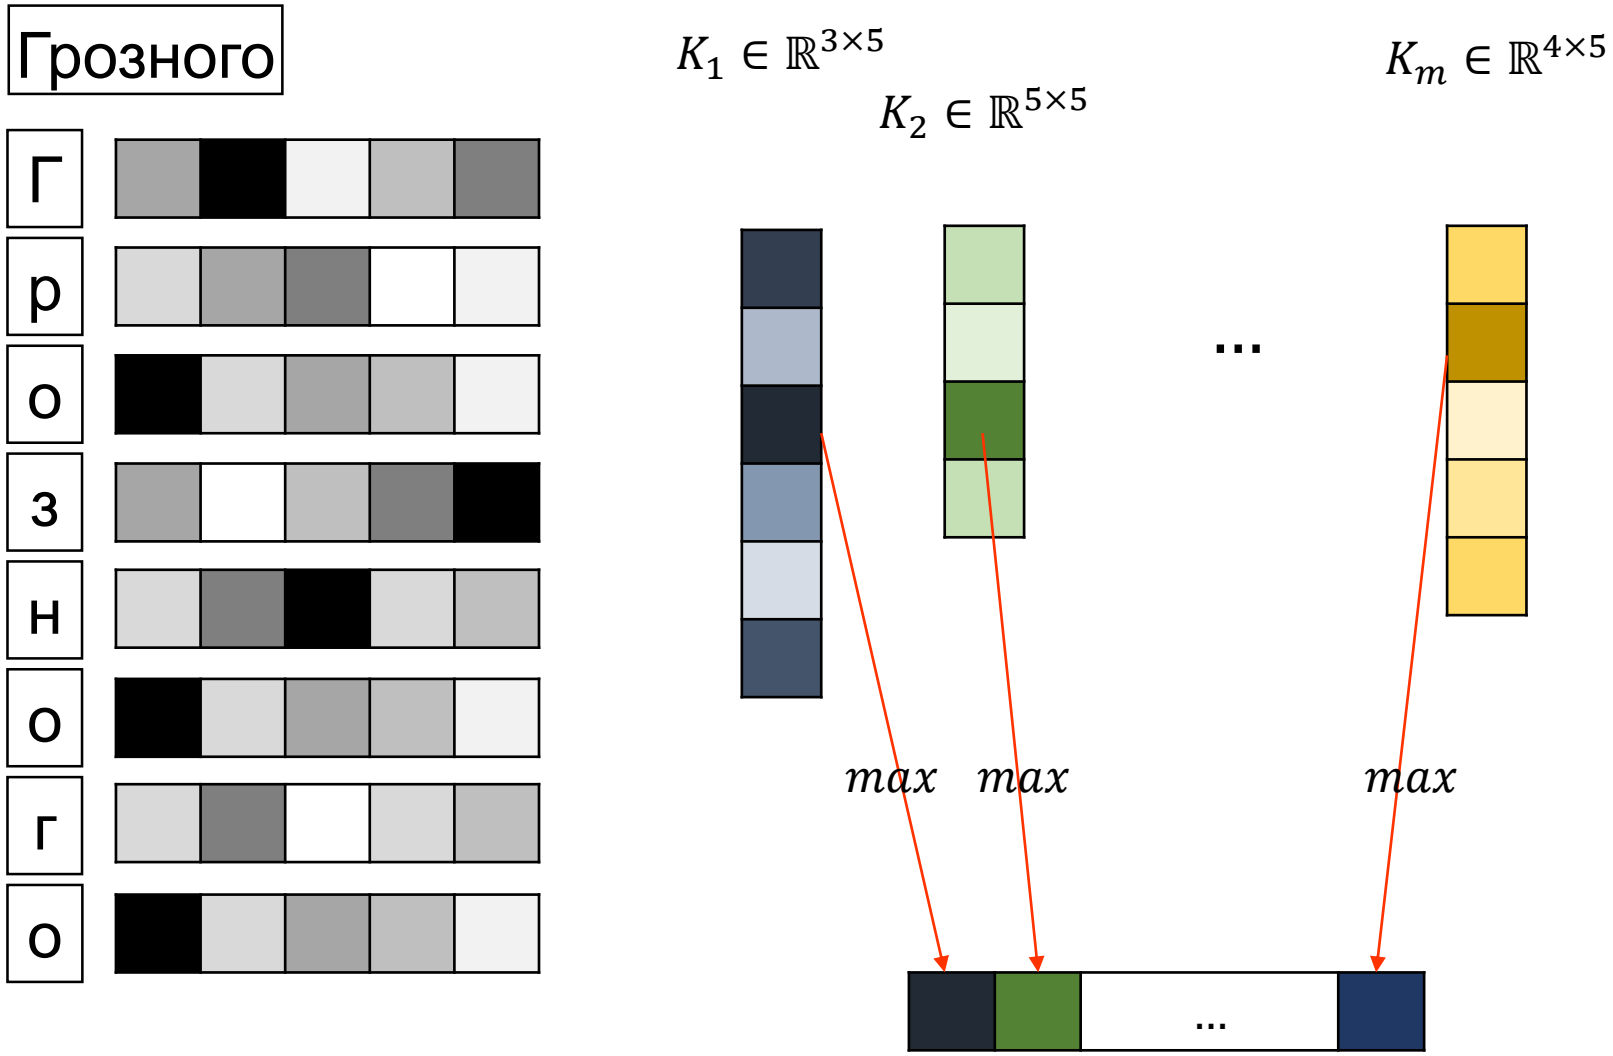
Грозного
Г
р
о
з
н
о
г
о
$K_1 \in \mathbb{R}^{3\times5}$
$K_2 \in \mathbb{R}^{5\times5}$
$K_m \in \mathbb{R}^{4\times5}$
...
max
max
max
...

Следующая лекция

Базовые задачи обработки текстов