

Лингвистические аспекты
новых информационных технологий
Энграммные языковые модели.

Алексей Андреевич Сорокин

ОТИПЛ МГУ,
осенний семестр 2017–2018 учебного года

Вероятность текста

- Часто требуется оценивать вероятность текста:
- Автоматическая генерация текста (чатботы),

Вероятность текста

- Часто требуется оценивать вероятность текста:
- Автоматическая генерация текста (чатботы),
- Модель канала связи: $\hat{t} = \operatorname{argmax} p(t|s) = \operatorname{argmax} p(s|t)p(t)$.
 - Например, s — предложение на исходном языке, t — на целевом.

Вероятность текста

- Часто требуется оценивать вероятность текста:
- Автоматическая генерация текста (чатботы),
- Модель канала связи: $\hat{t} = \operatorname{argmax} p(t|s) = \operatorname{argmax} p(s|t)p(t)$.
 - Например, s — предложение на исходном языке, t — на целевом.
 - Или s — последовательность графем, t — последовательность фонем.

Вероятность текста

- Часто требуется оценивать вероятность текста:
- Автоматическая генерация текста (чатботы),
- Модель канала связи: $\hat{t} = \operatorname{argmax} p(t|s) = \operatorname{argmax} p(s|t)p(t)$.
 - Например, s — предложение на исходном языке, t — на целевом.
 - Или s — последовательность графем, t — последовательность фонем.
 - s — последовательность слов, t — последовательность морфологических меток
- Везде нужно считать $p(t)$.

Вероятность текста

- Часто требуется оценивать вероятность текста:
- Автоматическая генерация текста (чатботы),
- Модель канала связи: $\hat{t} = \operatorname{argmax} p(t|s) = \operatorname{argmax} p(s|t)p(t)$.
 - Например, s — предложение на исходном языке, t — на целевом.
 - Или s — последовательность графем, t — последовательность фонем.
 - s — последовательность слов, t — последовательность морфологических меток
- Везде нужно считать $p(t)$.
- Формула условной вероятности:
$$p(w_1 \dots w_N) = p(w_1)p(w_2|w_1)p(w_3|w_1w_2)\dots p(w_N|w_1 \dots w_{N-1})$$
.

Базовая энграммная модель

- Предположение энграммной модели: каждое слово зависит только от $n - 1$ предыдущего.

$$p(w_N | w_1 \dots w_{N-1}) = p(w_N | w_{N-n+1} \dots w_{N-1})$$

Базовая энграммная модель

- Предположение энграммной модели: каждое слово зависит только от $n - 1$ предыдущего.

$$p(w_N | w_1 \dots w_{N-1}) = p(w_N | w_{N-n+1} \dots w_{N-1})$$

- Чаще всего берут $n \leq 3$ ($n = 1$ — унigramsмы, $n = 2$ — биграммы, $n = 3$ — триграммы).
- Как считать энграммные вероятности?

Базовая энграммная модель

- Предположение энграммной модели: каждое слово зависит только от $n - 1$ предыдущего.

$$p(w_N | w_1 \dots w_{N-1}) = p(w_N | w_{N-n+1} \dots w_{N-1})$$

- Чаще всего берут $n \leq 3$ ($n = 1$ — унigramsмы, $n = 2$ — биграммы, $n = 3$ — триграммы).
- Как считать энграммные вероятности?
- Наивный подход: $p(w_n | \mathbf{w}_{1,n-1}) = \frac{c(\mathbf{w}_{1,n})}{c(\mathbf{w}_{1,n-1})}$.
- Здесь и далее $\mathbf{w}_{1,n} = w_1 \dots w_n$.

Базовая энграммная модель

- Предположение энграммной модели: каждое слово зависит только от $n - 1$ предыдущего.

$$p(w_N | w_1 \dots w_{N-1}) = p(w_N | w_{N-n+1} \dots w_{N-1})$$

- Чаще всего берут $n \leq 3$ ($n = 1$ — унigramsмы, $n = 2$ — биграммы, $n = 3$ — триграммы).
- Как считать энграммные вероятности?
- Наивный подход: $p(w_n | w_{1,n-1}) = \frac{c(w_{1,n})}{c(w_{1,n-1})}$.
- Здесь и далее $w_{1,n} = w_1 \dots w_n$.
- Недостаток: нулевые вероятности.**

Пример

я читал	1864	
я читал книгу	19	$\frac{19}{1864} \approx 0.010$
я читал газету	3	$\frac{3}{1864} \approx 0.002$
я читал лекцию	11	$\frac{11}{1864} \approx 0.006$
я читал доклад	0	$\frac{0}{1864} = 0?$
я читал инструкцию	0	$\frac{0}{1864} = 0?$

Аддитивное сглаживание

- Можно применить аддитивное сглаживание:

$$p(t_n | t_1 \dots t_{n-1}) = \frac{c(t_1 \dots t_{n-1} t_n) + \alpha}{c(t_1 \dots t_{n-1} \bullet) + \alpha |D|},$$

где D — словарь (множество возможных униграмм),
 $\alpha > 0$ — сглаживающее слагаемое

Аддитивное сглаживание

- Можно применить аддитивное сглаживание:

$$p(t_n | t_1 \dots t_{n-1}) = \frac{c(t_1 \dots t_{n-1} t_n) + \alpha}{c(t_1 \dots t_{n-1} \bullet) + \alpha |D|},$$

где D — словарь (множество возможных униграмм),
 $\alpha > 0$ — сглаживающее слагаемое

- Теперь уже нет нулевых вероятностей. Но как выбирать значение α ?

Аддитивное сглаживание

- Можно применить аддитивное сглаживание:

$$p(t_n | t_1 \dots t_{n-1}) = \frac{c(t_1 \dots t_{n-1} t_n) + \alpha}{c(t_1 \dots t_{n-1} \bullet) + \alpha |D|},$$

где D — словарь (множество возможных униграмм),
 $\alpha > 0$ — сглаживающее слагаемое

- Теперь уже нет нулевых вероятностей. Но как выбирать значение α ?
- Маленькая α — риск переподгонки под обучающую выборку.
- Большая α — не учитываем наблюдаемые вероятности.

Аддитивное сглаживание

- Можно применить аддитивное сглаживание:

$$p(t_n | t_1 \dots t_{n-1}) = \frac{c(t_1 \dots t_{n-1} t_n) + \alpha}{c(t_1 \dots t_{n-1} \bullet) + \alpha |D|},$$

где D — словарь (множество возможных униграмм),
 $\alpha > 0$ — сглаживающее слагаемое

- Теперь уже нет нулевых вероятностей. Но как выбирать значение α ?
- Маленькая α — риск переподгонки под обучающую выборку.
- Большая α — не учитываем наблюдаемые вероятности.
- Нужно что-то среднее, на чём достигается наилучшее качество.
- Кстати, а как мерить качество?

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.
 - Посчитать перплексию на контрольной.

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.
 - Посчитать перплексию на контрольной.
- Перплексия модели M на выборке $W = [w_1, \dots, w_N]$:
$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}}$$

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.
 - Посчитать перплексию на контрольной.
- Перплексия модели M на выборке $W = [w_1, \dots, w_N]$:

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}}$$
- Для униграммной модели

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}} = \left(\prod_i^N p(w_i)\right)^{-\frac{1}{N}} = \left(\prod_{j=1}^{|D|} p(w_{(j)})^{n_j}\right)^{-\frac{1}{N}}$$

$$\log_2 PP_M(W) = -\frac{1}{N} \sum_{j=1}^N n_j \log_2 p(w_{(j)})$$

$w_{(j)}$ — j -ое слово в словаре

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.
 - Посчитать перплексию на контрольной.
- Перплексия модели M на выборке $W = [w_1, \dots, w_N]$:

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}}$$

- Для униграммной модели

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}} = \left(\prod_i p(w_i) \right)^{-\frac{1}{N}} = \left(\prod_{j=1}^{|D|} p(w_{(j)})^{n_j} \right)^{-\frac{1}{N}}$$

$$\log_2 PP_M(W) = -\frac{1}{N} \sum_{j=1}^{|D|} n_j \log_2 p(w_{(j)})$$

$w_{(j)}$ — j -ое слово в словаре

- То есть для униграммной модели $\log_2 PP_M(W)$ — это среднее значение отрицательного логарифма вероятности слова в тексте.

Перплексия

- Алгоритм определения качества языковой модели:
 - Разбить данные на обучающую и контрольную выборку.
 - Построить модель по обучающей выборке.
 - Посчитать перплексию на контрольной.
- Перплексия модели M на выборке $W = [w_1, \dots, w_N]$:

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}}$$
- Для униграммной модели

$$PP_M(W) = p(w_1 \dots w_N)^{-\frac{1}{N}} = \left(\prod_i p(w_i)\right)^{-\frac{1}{N}} = \left(\prod_{j=1}^{|D|} p(w_{(j)})^{n_j}\right)^{-\frac{1}{N}}$$

$$\log_2 PP_M(W) = -\frac{1}{N} \sum_{j=1}^N n_j \log_2 p(w_{(j)})$$

$w_{(j)}$ — j -ое слово в словаре

- То есть для униграммной модели $\log_2 PP_M(W)$ — это среднее значение отрицательного логарифма вероятности слова в тексте.
- В терминах теории информации — среднее количество битов, нужное на описание одного элемента текста.
- Чем меньше перплексия, тем лучше (точнее описание).

Интерполяция и откат

- Недостатки аддитивного сглаживания:
 - непонятно, как подбирать α (зависит от размера корпуса, размера словаря, порядка энграмм и т. д.)

Интерполяция и откат

- Недостатки аддитивного сглаживания:
 - непонятно, как подбирать α (зависит от размера корпуса, размера словаря, порядка энграмм и т. д.)
 - метод негибкий, не учитывает историю $t_1 \dots t_{n-1}$.

Интерполяция и откат

- Недостатки аддитивного сглаживания:
 - непонятно, как подбирать α (зависит от размера корпуса, размера словаря, порядка энграмм и т. д.)
 - метод негибкий, не учитывает историю $t_1 \dots t_{n-1}$.
- Основная идея: будем использовать $p(t_n | t_2 \dots t_{n-1})$ для вычисления $p(t_n | t_1 \dots t_{n-1})$, если $c(t_n | t_1 \dots t_{n-1}) = 0$.

Интерполяция и откат

- Недостатки аддитивного сглаживания:
 - непонятно, как подбирать α (зависит от размера корпуса, размера словаря, порядка энграмм и т. д.)
 - метод негибкий, не учитывает историю $t_1 \dots t_{n-1}$.
- Основная идея: будем использовать $p(t_n | t_2 \dots t_{n-1})$ для вычисления $p(t_n | t_1 \dots t_{n-1})$, если $c(t_n | t_1 \dots t_{n-1}) = 0$.
- Общая интерполяционная формула:

$$p_I(t_n | t_1 \dots t_{n-1}) = \lambda p_C(t_n | t_{1,n-1}) + (1 - \lambda) p_I(t_n | t_{2,n-1})$$

Интерполяция и откат

- Недостатки аддитивного сглаживания:
 - непонятно, как подбирать α (зависит от размера корпуса, размера словаря, порядка энграмм и т. д.)
 - метод негибкий, не учитывает историю $t_1 \dots t_{n-1}$.
- Основная идея: будем использовать $p(t_n|t_2 \dots t_{n-1})$ для вычисления $p(t_n|t_1 \dots t_{n-1})$, если $c(t_n|t_1 \dots t_{n-1}) = 0$.
- Общая интерполяционная формула:

$$p_I(t_n|t_1 \dots t_{n-1}) = \lambda p_C(t_n|\mathbf{t}_{1,n-1}) + (1 - \lambda)p_I(t_n|\mathbf{t}_{2,n-1})$$

$p_C(t_n|t_1 \dots t_{n-1}) = \frac{c(t_1 \dots t_{n-1} t_n)}{c(t_1 \dots t_{n-1} \bullet)}$ — “корпусная” вероятность,
 λ — коэффициент, вообще говоря, зависящий от $t_1 \dots t_{n-1}$.

Пример

$w_1 w_2$	w_3	$c(w_1 w_2 w_3)$	$p(w_3 w_1 w_2)$	w_2	w_3	$c(w_2 w_3)$	$p(w_3 w_2)$
я читал		1832		читал		18149	
я читал газету	3	0.0016		читал газету	149	0.0082	
я читал книгу	19	0.0103		читал книгу	138	0.0076	
я читал лекцию	11	0.0060		читал лекцию	81	0.0045	
я читал доклад	0	0		читал доклад	22	0.0012	

Пример

$w_1 w_2$	w_3	$c(w_1 w_2 w_3)$	$p(w_3 w_1 w_2)$	w_2	w_3	$c(w_2 w_3)$	$p(w_3 w_2)$
я читал		1832		читал		18149	
я читал газету	3	0.0016		читал газету	149	0.0082	
я читал книгу	19	0.0103		читал книгу	138	0.0076	
я читал лекцию	11	0.0060		читал лекцию	81	0.0045	
я читал доклад	0	0		читал доклад	22	0.0012	

При $\lambda = 0.5$ получаем

$$p(\text{газету} | \text{я читал}) = 0.5 * 0.0016 + 0.5 * 0.0082 = 0.0049$$

$$p(\text{доклад} | \text{я читал}) = 0.5 * 0.0000 + 0.5 * 0.0012 = 0.0006$$

Интерполяция и откат

- Обозначим $\mathbf{t}_{i,j} = t_i \dots t_j$.
- Общая интерполяционная формула:

$$p_I(t_n | \mathbf{t}_{1,n-1}) = \lambda p_C(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1})$$

Интерполяция и откат

- Обозначим $\mathbf{t}_{i,j} = t_i \dots t_j$.
- Общая интерполяционная формула:

$$p_I(t_n | \mathbf{t}_{1,n-1}) = \lambda p_C(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1})$$

- Формула отката (backoff):

$$p_I(t_n | t_1 \dots t_{n-1}) = \begin{cases} \alpha(\mathbf{t}_{1,n-1}) p_C(t_n | \mathbf{t}_{1,n-1}), & c(\mathbf{t}_{1,n-1} t_n) > 0, \\ \beta(\mathbf{t}_{1,n-1}) p_I(t_n | \mathbf{t}_{2,n-1}), & c(\mathbf{t}_{1,n-1} t_n) = 0 \end{cases}$$

Интерполяция и откат

- Обозначим $\mathbf{t}_{i,j} = t_i \dots t_j$.
- Общая интерполяционная формула:

$$p_I(t_n | \mathbf{t}_{1,n-1}) = \lambda p_C(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1})$$

- Формула отката (backoff):

$$p_I(t_n | t_1 \dots t_{n-1}) = \begin{cases} \alpha(\mathbf{t}_{1,n-1}) p_C(t_n | \mathbf{t}_{1,n-1}), & c(\mathbf{t}_{1,n-1} t_n) > 0, \\ \beta(\mathbf{t}_{1,n-1}) p_I(t_n | \mathbf{t}_{2,n-1}), & c(\mathbf{t}_{1,n-1} t_n) = 0 \end{cases}$$

- Чем больше λ (в формуле отката), тем больше мы доверяем истории $\mathbf{t}_{1,n-1}$.

Интерполяция и откат

- Обозначим $\mathbf{t}_{i,j} = t_i \dots t_j$.
- Общая интерполяционная формула:

$$p_I(t_n | \mathbf{t}_{1,n-1}) = \lambda p_C(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1})$$

- Формула отката (backoff):

$$p_I(t_n | t_1 \dots t_{n-1}) = \begin{cases} \alpha(\mathbf{t}_{1,n-1}) p_C(t_n | \mathbf{t}_{1,n-1}), & c(\mathbf{t}_{1,n-1} t_n) > 0, \\ \beta(\mathbf{t}_{1,n-1}) p_I(t_n | \mathbf{t}_{2,n-1}), & c(\mathbf{t}_{1,n-1} t_n) = 0 \end{cases}$$

- Чем больше λ (в формуле отката), тем больше мы доверяем истории $\mathbf{t}_{1,n-1}$.
- Много случайных продолжений у $\mathbf{t}_{1,n-1}$ — λ мало.
- Продолжений мало и они частотные — $\lambda \approx 1$

Интерполяция и откат

- Обозначим $\mathbf{t}_{i,j} = t_i \dots t_j$.
- Общая интерполяционная формула:

$$p_I(t_n | \mathbf{t}_{1,n-1}) = \lambda p_C(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1})$$

- Формула отката (backoff):

$$p_I(t_n | t_1 \dots t_{n-1}) = \begin{cases} \alpha(\mathbf{t}_{1,n-1}) p_C(t_n | \mathbf{t}_{1,n-1}), & c(\mathbf{t}_{1,n-1} t_n) > 0, \\ \beta(\mathbf{t}_{1,n-1}) p_I(t_n | \mathbf{t}_{2,n-1}), & c(\mathbf{t}_{1,n-1} t_n) = 0 \end{cases}$$

- Чем больше λ (в формуле отката), тем больше мы доверяем истории $\mathbf{t}_{1,n-1}$.
- Много случайных продолжений у $\mathbf{t}_{1,n-1}$ — λ мало.
- Продолжений мало и они частотные — $\lambda \approx 1$
- β подбирают, чтобы сумма вероятностей получилась 1.

Метод Уиттена-Белла

- Метод Уиттена-Белла:

$$\begin{aligned} p_I(t_n | \mathbf{t}_{1,n-1}) &= \lambda p_c(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1}) \\ \lambda &= \frac{c(t_1 \dots t_{n-1} \odot)}{c(t_1 \dots t_{n-1} \odot) + N_{1+}(t_1 \dots t_{n-1})} \\ N_{1+}(t_1 \dots t_{n-1}) &= |\{t | c(t_1 \dots t_{n-1} t) > 0\}| \\ N_{1+}(t_1 \dots t_{n-1}) &\text{ — “число продолжений”} \end{aligned}$$

Метод Уиттена-Белла

- Метод Уиттена-Белла:

$$\begin{aligned}
 p_I(t_n | \mathbf{t}_{1,n-1}) &= \lambda p_c(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1}) \\
 \lambda &= \frac{c(t_1 \dots t_{n-1} \odot)}{c(t_1 \dots t_{n-1} \odot) + N_{1+}(t_1 \dots t_{n-1})} \\
 N_{1+}(t_1 \dots t_{n-1}) &= |\{t | c(t_1 \dots t_{n-1} t) > 0\}| \\
 N_{1+}(t_1 \dots t_{n-1}) &\text{ — "число продолжений"}
 \end{aligned}$$

- Пример (британский национальный корпус):

w_1	$c(w_1 \odot)$	$N_{1+}(w_1)$	$N_{3+}(w_1)$	$\lambda(w_1)$	$1 - \lambda(w_1)$
<i>spite</i>	2899	59	15	$\frac{2899}{2899 + 59} = 0.980$	0.02
<i>stupid</i>	2898	602	117	$\frac{2898}{2898 + 602} = 0.828$	0.172

Метод Уиттена-Белла

- Метод Уиттена-Белла:

$$\begin{aligned}
 p_I(t_n | \mathbf{t}_{1,n-1}) &= \lambda p_c(t_n | \mathbf{t}_{1,n-1}) + (1 - \lambda) p_I(t_n | \mathbf{t}_{2,n-1}) \\
 \lambda &= \frac{c(t_1 \dots t_{n-1} \odot)}{c(t_1 \dots t_{n-1} \odot) + N_{1+}(t_1 \dots t_{n-1})} \\
 N_{1+}(t_1 \dots t_{n-1}) &= |\{t | c(t_1 \dots t_{n-1} t) > 0\}| \\
 N_{1+}(t_1 \dots t_{n-1}) &\text{ — "число продолжений"}
 \end{aligned}$$

- Пример (британский национальный корпус):

w_1	$c(w_1 \odot)$	$N_{1+}(w_1)$	$N_{3+}(w_1)$	$\lambda(w_1)$	$1 - \lambda(w_1)$
<i>sprite</i>	2899	59	15	$\frac{2899}{2899 + 59} = 0.980$	0.02
<i>stupid</i>	2898	602	117	$\frac{2898}{2898 + 602} = 0.828$	0.172

- Униграммная модель для *stupid* в 86 раз более значима, чем для *sprite*.

Метод Кнезера-Нея

- Метод Уиттена-Белла учитывает количество возможных правых продолжений.

Метод Кнезера-Нея

- Метод Уиттена-Белла учитывает количество возможных правых продолжений.
- Можно учитывать и левые:

Метод Кнезера-Нея

- Метод Уиттена-Белла учитывает количество возможных правых продолжений.
- Можно учитывать и левые:
 - предшественником слова *York* практически всегда будет слово *New*.

Метод Кнезера-Нея

- Метод Уиттена-Белла учитывает количество возможных правых продолжений.
- Можно учитывать и левые:
 - предшественником слова *York* практически всегда будет слово *New*.
 - соответственно, $p(\text{York}|w) \approx 0$ при $w \neq \text{new}$.
 - при этом $p_{UNI}(\text{York}) = \frac{c(\text{York})}{N}$ достаточно велика.

Метод Кнезера-Нея

- Метод Уиттена-Белла учитывает количество возможных правых продолжений.
- Можно учитывать и левые:
 - предшественником слова *York* практически всегда будет слово *New*.
 - соответственно, $p(\text{York}|w) \approx 0$ при $w \neq \text{new}$.
 - при этом $p_{UNI}(\text{York}) = \frac{c(\text{York})}{N}$ достаточно велика.
- В методе Кнезера-Нея униграммная вероятность считается по формуле

$$p_{KN}(w) = \frac{N_{1+}(\bullet w)}{\sum_{w'} N_{1+}(\bullet w')}$$

$$N_{1+}(\bullet w) = |\{w_1 | c(w_1 w) > 0\}| \quad \text{— число левых продолжений}$$

Метод Кнезера-Нея

- Для перераспределения вероятностей на новые слова используется дисконтирование (из всех счётчиков вычитается δ).

$$p_0(t_n | \mathbf{t}_{1,n-1}) = \frac{c(\mathbf{t}_{1,n-1} t_n) - \delta}{c(\mathbf{t}_{1,n-1} \bullet)}, \quad c(\mathbf{t}_{1,n-1} t_n) > 0$$

Метод Кнезера-Нея

- Для перераспределения вероятностей на новые слова используется дисконтирование (из всех счётчиков вычитается δ).

$$p_0(t_n | \mathbf{t}_{1,n-1}) = \frac{c(\mathbf{t}_{1,n-1} t_n) - \delta}{c(\mathbf{t}_{1,n-1} \bullet)}, \quad c(\mathbf{t}_{1,n-1} t_n) > 0$$

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{2,n-1})$$

получаем $\beta = \frac{\delta N_{1+}(\mathbf{t}_{1,n-1})}{c(\mathbf{t}_{1,n-1} \bullet)}$ (выведите эту формулу).

- Для униграммных вероятностей — формула с предыдущего слайда.

Метод Кнезера-Нея

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{1,n-2})$$

Метод Кнезера-Нея

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{1,n-2})$$

- Основная проблема: поиск оптимальной δ . В стандартной реализации

$$\begin{aligned}\delta_1 &= 1 - 2Y \frac{N_2}{N_1} & \delta_2 &= 1 - 3Y \frac{N_3}{N_2} \\ \delta_{\geq 3} &= 1 - 4Y \frac{N_4}{N_3} & Y &= \frac{N_1}{N_1 + 2N_2}\end{aligned}$$

Метод Кнезера-Нея

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{1,n-2})$$

- Основная проблема: поиск оптимальной δ . В стандартной реализации

$$\begin{aligned} \delta_1 &= 1 - 2Y \frac{N_2}{N_1} & \delta_2 &= 1 - 3Y \frac{N_3}{N_2} \\ \delta_{\geq 3} &= 1 - 4Y \frac{N_4}{N_3} & Y &= \frac{N_1}{N_1 + 2N_2} \end{aligned}$$

- Здесь δ_i — дисконт для счётчиков, равных i , N_i — число энграмм частоты i .

Метод Кнезера-Нея

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{1,n-2})$$

- Основная проблема: поиск оптимальной δ . В стандартной реализации

$$\begin{aligned}\delta_1 &= 1 - 2Y \frac{N_2}{N_1} & \delta_2 &= 1 - 3Y \frac{N_3}{N_2} \\ \delta_{\geq 3} &= 1 - 4Y \frac{N_4}{N_3} & Y &= \frac{N_1}{N_1 + 2N_2}\end{aligned}$$

- Здесь δ_i — дисконт для счётчиков, равных i , N_i — число энграмм частоты i .
- В случае лексических энграмм метод Кнезера-Нея наиболее мощный.

Метод Кнезера-Нея

- В интерполяционной формуле

$$p_{KN}(t_n | \mathbf{t}_{1,n-1}) = p_0(t_n | \mathbf{t}_{1,n-1}) + \beta(\mathbf{t}_{1,n-1}) p_{KN}(t_n | \mathbf{t}_{1,n-2})$$

- Основная проблема: поиск оптимальной δ . В стандартной реализации

$$\begin{aligned}\delta_1 &= 1 - 2Y \frac{N_2}{N_1} & \delta_2 &= 1 - 3Y \frac{N_3}{N_2} \\ \delta_{\geq 3} &= 1 - 4Y \frac{N_4}{N_3} & Y &= \frac{N_1}{N_1 + 2N_2}\end{aligned}$$

- Здесь δ_i — дисконт для счётчиков, равных i , N_i — число энграмм частоты i .
- В случае лексических энграмм метод Кнезера-Нея наиболее мощный.
- Недостаток: работает только в случае $N_1 \geq N_2 \geq N_3 \dots$, поэтому плохо применим к символальным и морфологическим энграммам.

Интерполяция через удаление

- В морфологическом анализаторе TnT используется триграммная модель для морфологических меток, основанная на интерполяции через удаление:

$$p(t_3|t_1 t_2) = \mu_3 p_C(t_3|t_1 t_2) + \mu_2 p_C(t_3|t_2) + \mu_1 p(t_3)$$

Интерполяция через удаление

- В морфологическом анализаторе TnT используется триграммная модель для морфологических меток, основанная на интерполяции через удаление:

$$p(t_3|t_1 t_2) = \mu_3 p_C(t_3|t_1 t_2) + \mu_2 p_C(t_3|t_2) + \mu_1 p(t_3)$$

- Метод вычисления μ_1, μ_2, μ_3 :

- Для каждой триграммы $t_1 t_2 t_3$ в корпусе вычислить величины

$$f_3 = \frac{c(t_1 t_2 t_3) - 1}{c(t_1 t_2 \bullet)}, \quad f_2 = \frac{c(t_2 t_3) - 1}{c(t_2 \bullet)}, \quad f_1 = \frac{c(t_3) - 1}{c(\bullet)}.$$

Интерполяция через удаление

- В морфологическом анализаторе TnT используется триграммная модель для морфологических меток, основанная на интерполяции через удаление:

$$p(t_3|t_1 t_2) = \mu_3 p_C(t_3|t_1 t_2) + \mu_2 p_C(t_3|t_2) + \mu_1 p(t_3)$$

- Метод вычисления μ_1, μ_2, μ_3 :

- Для каждой триграммы $t_1 t_2 t_3$ в корпусе вычислить величины

$$f_3 = \frac{c(t_1 t_2 t_3) - 1}{c(t_1 t_2 \bullet)}, f_2 = \frac{c(t_2 t_3) - 1}{c(t_2 \bullet)}, f_1 = \frac{c(t_3) - 1}{c(\bullet)}.$$

- Увеличить μ_k , где $k = \operatorname{argmax}_j f_j$.

Интерполяция через удаление

- В морфологическом анализаторе TnT используется триграммная модель для морфологических меток, основанная на интерполяции через удаление:

$$p(t_3|t_1 t_2) = \mu_3 p_C(t_3|t_1 t_2) + \mu_2 p_C(t_3|t_2) + \mu_1 p(t_3)$$

- Метод вычисления μ_1, μ_2, μ_3 :
 - Для каждой триграммы $t_1 t_2 t_3$ в корпусе вычислить величины
 $f_3 = \frac{c(t_1 t_2 t_3) - 1}{c(t_1 t_2 \bullet)}$, $f_2 = \frac{c(t_2 t_3) - 1}{c(t_2 \bullet)}$, $f_1 = \frac{c(t_3) - 1}{c(\bullet)}$.
 - Увеличить μ_k , где $k = \operatorname{argmax}_j f_j$.
- Если не вычитать 1, метод переобучается (слишком большой вес у триграмм).
- Этот метод не позволяет учитывать метки, не встречавшиеся в корпусе, можно добавить к $p(t_3|t_1 t_2)$ слагаемое $\mu_0 \frac{1}{|D|}$.

Интерполяция через удаление

- В морфологическом анализаторе TnT используется триграммная модель для морфологических меток, основанная на интерполяции через удаление:

$$p(t_3|t_1 t_2) = \mu_3 p_C(t_3|t_1 t_2) + \mu_2 p_C(t_3|t_2) + \mu_1 p(t_3)$$

- Метод вычисления μ_1, μ_2, μ_3 :
 - Для каждой триграммы $t_1 t_2 t_3$ в корпусе вычислить величины

$$f_3 = \frac{c(t_1 t_2 t_3) - 1}{c(t_1 t_2 \bullet)}, f_2 = \frac{c(t_2 t_3) - 1}{c(t_2 \bullet)}, f_1 = \frac{c(t_3) - 1}{c(\bullet)}.$$
 - Увеличить μ_k , где $k = \operatorname{argmax}_j f_j$.
- Если не вычитать 1, метод переобучается (слишком большой вес у триграмм).
- Этот метод не позволяет учитывать метки, не встречавшиеся в корпусе, можно добавить к $p(t_3|t_1 t_2)$ слагаемое $\mu_0 \frac{1}{|D|}$.
- μ_0 увеличиваем, если $\max_j f_j = 0$.

Применения языковых моделей

- Применение языковых моделей:
 - Автоматический перевод
 $(p(s) \text{ в формуле } \hat{t} = \operatorname{argmax}_t p(s|t)p(t)),$

Применения языковых моделей

- Применение языковых моделей:
 - Автоматический перевод
 $(p(s)$ в формуле $\hat{t} = \operatorname{argmax}_t p(s|t)p(t))$,
 - Вычислительная фонология (распознавание речи и т. д.),

Применения языковых моделей

- Применение языковых моделей:

- Автоматический перевод
 $(p(s)$ в формуле $\hat{t} = \operatorname{argmax}_t p(s|t)p(t))$,
- Вычислительная фонология (распознавание речи и т. д.),
- Вычислительная морфология (вычисление вероятности последовательности состояний).

Применения языковых моделей

- Применение языковых моделей:
 - Автоматический перевод
 $(p(s) \text{ в формуле } \hat{t} = \operatorname{argmax}_t p(s|t)p(t))$,
 - Вычислительная фонология (распознавание речи и т. д.),
 - Вычислительная морфология (вычисление вероятности последовательности состояний).
- Свойства языковых моделей:
 - Большое количество параметров (для моделей глубины n — порядка $|D|^n$).

Применения языковых моделей

- Применение языковых моделей:
 - Автоматический перевод
 $(p(s)$ в формуле $\hat{t} = \operatorname{argmax}_t p(s|t)p(t))$,
 - Вычислительная фонология (распознавание речи и т. д.),
 - Вычислительная морфология (вычисление вероятности последовательности состояний).
- Свойства языковых моделей:
 - Большое количество параметров (для моделей глубины n — порядка $|D|^n$).
 - Большое количество редких или неизвестных слов (для лексических энграмм).

Применения языковых моделей

- Применение языковых моделей:
 - Автоматический перевод
 $(p(s)$ в формуле $\hat{t} = \operatorname{argmax}_t p(s|t)p(t))$,
 - Вычислительная фонология (распознавание речи и т. д.),
 - Вычислительная морфология (вычисление вероятности последовательности состояний).
- Свойства языковых моделей:
 - Большое количество параметров (для моделей глубины n — порядка $|D|^n$).
 - Большое количество редких или неизвестных слов (для лексических энграмм).
 - Большая глубина модели (в морфологии/фонологии, $n = 8$).

Недостатки энграммных моделей

- Трудности использования языковых моделей:
 - Большие затраты памяти, необходимы эффективные структуры данных.

Недостатки энграммных моделей

- Трудности использования языковых моделей:
 - Большие затраты памяти, необходимы эффективные структуры данных.
 - В лексических моделях много редких слов (закон Ципфа), которые не влияют на свойства модели, но занимают много памяти.

Недостатки энграммных моделей

- Трудности использования языковых моделей:
 - Большие затраты памяти, необходимы эффективные структуры данных.
 - В лексических моделях много редких слов (закон Ципфа), которые не влияют на свойства модели, но занимают много памяти.
- Недостатки энграммного метода:
 - Нельзя учесть историю большой глубины (лексические модели).

Недостатки энграммных моделей

- Трудности использования языковых моделей:
 - Большие затраты памяти, необходимы эффективные структуры данных.
 - В лексических моделях много редких слов (закон Ципфа), которые не влияют на свойства модели, но занимают много памяти.
- Недостатки энграммного метода:
 - Нельзя учесть историю большой глубины (лексические модели).
 - Не учитываются дистантные и разрывные зависимости (в триграмме PREP ADJ N не учитывается зависимость существительного от предлога).

Недостатки энграммных моделей

- Трудности использования языковых моделей:
 - Большие затраты памяти, необходимы эффективные структуры данных.
 - В лексических моделях много редких слов (закон Ципфа), которые не влияют на свойства модели, но занимают много памяти.
- Недостатки энграммного метода:
 - Нельзя учесть историю большой глубины (лексические модели).
 - Не учитываются дистантные и разрывные зависимости (в триграмме PREP ADJ N не учитывается зависимость существительного от предлога).
 - Элементы энграмммы представляются как единое целое (не учитываются граммемы внутри морфологической метки).

Модификации энграммных моделей

Недостатки энграммного метода:

- В лексических моделях много редких слов.
- **Решение:** разбивать слова на классы (например, все слова частоты 1 попадут в 1 класс, Brown et al., 1992).

Модификации энграммных моделей

Недостатки энграммного метода:

- В лексических моделях много редких слов.
- **Решение:** разбивать слова на классы (например, все слова частоты 1 попадут в 1 класс, Brown et al., 1992).
- Не учитываются дистантные и разрывные зависимости.
- **Решение:** скипграммы (при $c(w_1 w_2 w) = 0$ для вычисления $p(w|w_1 w_2)$ используют $c(w_1 w)$ и $c(w_2 w)$).

Модификации энграммных моделей

Недостатки энграммного метода:

- В лексических моделях много редких слов.
- **Решение:** разбивать слова на классы (например, все слова частоты 1 попадут в 1 класс, Brown et al., 1992).
- Не учитываются дистантные и разрывные зависимости.
- **Решение:** скрипграммы (при $c(w_1 w_2 w) = 0$ для вычисления $p(w|w_1 w_2)$ используют $c(w_1 w)$ и $c(w_2 w)$).
- Элементы энграмм представляются как единое целое.
- **Решение:** факторные модели (каждое слово w представляется как совокупность факторов $f_1(w), \dots, f_m(w)$, Kirchhoff, Blimes, 2003).

Модификации энграммных моделей

Недостатки энграммного метода:

- В лексических моделях много редких слов.
- **Решение:** разбивать слова на классы (например, все слова частоты 1 попадут в 1 класс, Brown et al., 1992).
- Не учитываются дистантные и разрывные зависимости.
- **Решение:** скипграммы (при $c(w_1 w_2 w) = 0$ для вычисления $p(w|w_1 w_2)$ используют $c(w_1 w)$ и $c(w_2 w)$).
- Элементы энграмммы представляются как единое целое.
- **Решение:** факторные модели (каждое слово w представляется как совокупность факторов $f_1(w), \dots, f_m(w)$, Kirchhoff, Blimes, 2003).
- Условные вероятности оцениваются “наивно”.
- **Решение:** использовать при оценке вероятностей в факторных моделях машинное обучение.

Модификации энграммных моделей

Недостатки энграммного метода:

- В лексических моделях много редких слов.
- **Решение:** разбивать слова на классы (например, все слова частоты 1 попадут в 1 класс, Brown et al., 1992).
- Не учитываются дистантные и разрывные зависимости.
- **Решение:** скипграммы (при $c(w_1 w_2 w) = 0$ для вычисления $p(w|w_1 w_2)$ используют $c(w_1 w)$ и $c(w_2 w)$).
- Элементы энграмммы представляются как единое целое.
- **Решение:** факторные модели (каждое слово w представляется как совокупность факторов $f_1(w), \dots, f_m(w)$, Kirchhoff, Blimes, 2003).
- Условные вероятности оцениваются “наивно”.
- **Решение:** использовать при оценке вероятностей в факторных моделях машинное обучение.
- **Решение для всех проблем:** модели, основанные на нейронных сетях (Mikolov, 2013; Ling et al., 2016; Bojanowski et al., 2016, etc.)

Энграммные модели, основанные на классах

- Зачастую из одного семантического класса имеют близкую контекстную вероятность.

$$p(\text{пятницу} | \text{я уезжаю в}) \approx p(\text{четверг} | \text{я уезжаю в})$$

Энграммные модели, основанные на классах

- Зачастую из одного семантического класса имеют близкую контекстную вероятность.

$$p(\text{пятницу} | \text{я уезжаю в}) \approx p(\text{четверг} | \text{я уезжаю в})$$

- Будем считать, что каждое слово жёстко относится к своему классу.

Энграммные модели, основанные на классах

- Зачастую из одного семантического класса имеют близкую контекстную вероятность.

$$p(\text{пятницу} | \text{я уезжаю в}) \approx p(\text{четверг} | \text{я уезжаю в})$$

- Будем считать, что каждое слово жёстко относится к своему классу.
- Дополнительно будем считать, что энграммные вероятности зависят только от классов предыдущих слов.

$$p(w_n | w_{1:n-1}) = p(w_n | c_n, \mathbf{c}_{1:n-1}) = p(w_n | c_n) p(c_n | \mathbf{c}_{1:n-1})$$

Энграммные модели, основанные на классах

- Зачастую из одного семантического класса имеют близкую контекстную вероятность.

$$p(\text{пятницу} | \text{я уезжаю в}) \approx p(\text{четверг} | \text{я уезжаю в})$$

- Будем считать, что каждое слово жёстко относится к своему классу.
- Дополнительно будем считать, что энграммные вероятности зависят только от классов предыдущих слов.

$$p(w_n | w_{1,n-1}) = p(w_n | c_n, c_{1,n-1}) = p(w_n | c_n) p(c_n | c_{1,n-1})$$

- $p(c_n | c_{1,n-1})$ — энграммные вероятности для классов (считываются стандартным образом).
- $p(w_n | c_n)$ — вероятность слова в своём классе.

Энграммные модели, основанные на классах

- Зачастую из одного семантического класса имеют близкую контекстную вероятность.

$$p(\text{пятницу} | \text{я уезжаю в}) \approx p(\text{четверг} | \text{я уезжаю в})$$

- Будем считать, что каждое слово жёстко относится к своему классу.
- Дополнительно будем считать, что энграммные вероятности зависят только от классов предыдущих слов.

$$p(w_n | w_{1:n-1}) = p(w_n | c_n, c_{1:n-1}) = p(w_n | c_n) p(c_n | c_{1:n-1})$$

- $p(c_n | c_{1:n-1})$ — энграммные вероятности для классов (считываются стандартным образом).
- $p(w_n | c_n)$ — вероятность слова в своём классе.
- Основная проблема: как делить на классы.

Энграммные модели, основанные на классах

- Можно использовать заранее известное разделение на семантические классы.
- Можно провести кластеризацию дистрибутивных векторов и использовать получившиеся кластеры.

Энграммные модели, основанные на классах

- Можно использовать заранее известное разделение на семантические классы.
- Можно провести кластеризацию дистрибутивных векторов и использовать получившиеся кластеры.
- Однако чаще всего классы вычисляются параллельно с обучением модели.

Энграммные модели, основанные на классах

- Можно использовать заранее известное разделение на семантические классы.
- Можно провести кластеризацию дистрибутивных векторов и использовать получившиеся кластеры.
- Однако чаще всего классы вычисляются параллельно с обучением модели.
- Алгоритм Брауна для разделения на k кластеров:
 - Вначале отнести каждое из k наиболее частотных слов к своему кластеру.

Энграммные модели, основанные на классах

- Можно использовать заранее известное разделение на семантические классы.
- Можно провести кластеризацию дистрибутивных векторов и использовать получившиеся кластеры.
- Однако чаще всего классы вычисляются параллельно с обучением модели.
- Алгоритм Брауна для разделения на k кластеров:
 - Вначале отнести каждое из k наиболее частотных слов к своему кластеру.
 - На каждом шаге рассматривать следующее слово из словаря в качестве одноэлементного кластера.

Энграммные модели, основанные на классах

- Можно использовать заранее известное разделение на семантические классы.
- Можно провести кластеризацию дистрибутивных векторов и использовать получившиеся кластеры.
- Однако чаще всего классы вычисляются параллельно с обучением модели.
- Алгоритм Брауна для разделения на k кластеров:
 - Вначале отнести каждое из k наиболее частотных слов к своему кластеру.
 - На каждом шаге рассматривать следующее слово из словаря в качестве одноэлементного кластера.
 - После этого объединить какие-то два кластера оптимальным образом.
- Оптимально значит так, чтобы вероятность обучающего корпуса была максимальной.

Факторные энграммные модели

- Общая формула отката:

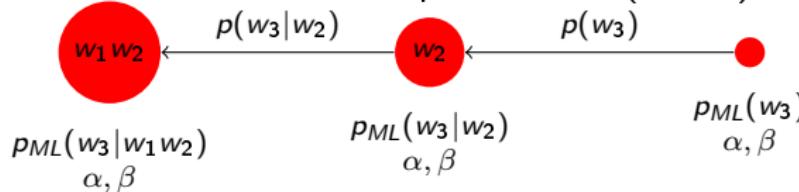
$$p_{BO}(w_n | \mathbf{w}_{1,n-1}) = \begin{cases} \alpha(\mathbf{w}_{1,n-1}) \frac{c(\mathbf{w}_{1,n-1} w_n)}{c(\mathbf{w}_{1,n-1} \bullet)}, & c(\mathbf{w}_{1,n-1} w_n) > 0, \\ \beta(\mathbf{w}_{1,n-1}) p_{BO}(w_n | \mathbf{w}_{2,n-1}), & c(\mathbf{w}_{1,n-1} w_n) = 0 \end{cases}$$

Факторные энграммные модели

- Общая формула отката:

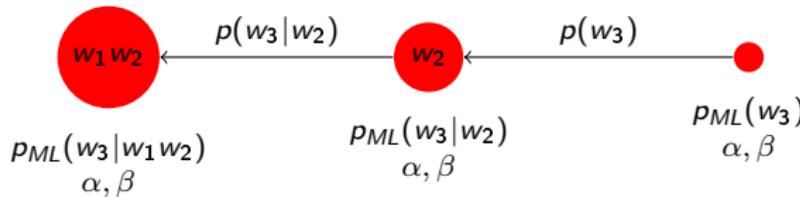
$$p_{BO}(w_n | \mathbf{w}_{1,n-1}) = \begin{cases} \alpha(\mathbf{w}_{1,n-1}) \frac{c(\mathbf{w}_{1,n-1} w_n)}{c(\mathbf{w}_{1,n-1} \bullet)}, & c(\mathbf{w}_{1,n-1} w_n) > 0, \\ \beta(\mathbf{w}_{1,n-1}) p_{BO}(w_n | \mathbf{w}_{2,n-1}), & c(\mathbf{w}_{1,n-1} w_n) = 0 \end{cases}$$

- Схематически это можно изобразить как ($n = 2$)



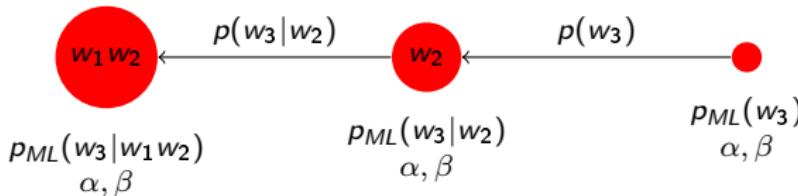
Факторные энграммные модели

Обычная энграммная модель ($n = 2$):

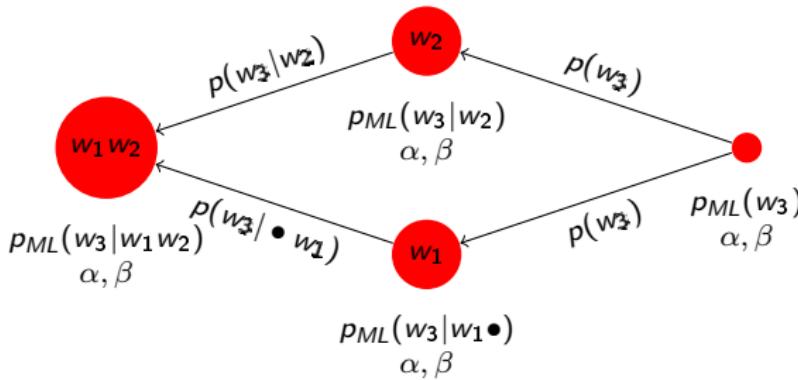


Факторные энграммные модели

Обычная энграммная модель ($n = 2$):

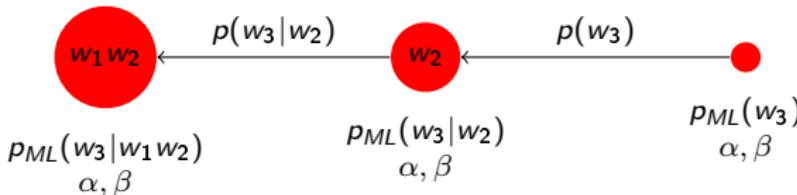


Разрешим вершине иметь несколько предков

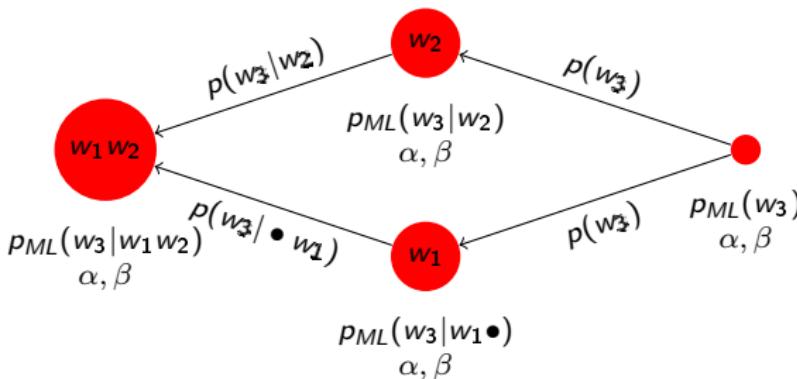


Факторные энграммные модели

Обычная энграммная модель ($n = 2$):

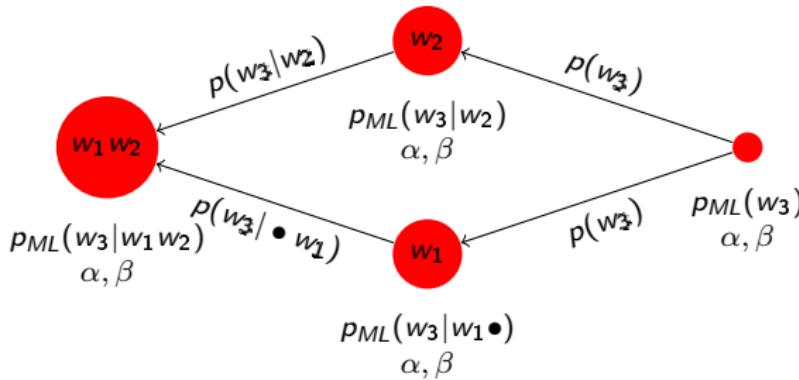


Разрешим вершине иметь несколько предков



Как описать математически?

Факторные энграммные модели



В этом случае $p(w_3|w_1 w_2)$ задаётся формулой

$$p(w_3|w_1 w_2) = \begin{cases} \alpha(\mathbf{w}_{1,2}) \frac{c(\mathbf{w}_{1,2} w_3)}{c(\mathbf{w}_{1,2} \bullet)}, & c(\mathbf{w}_{1,2} w_n) > 0, \\ \beta(w_1, w_2) g(p_{BO}(w_3|w_2), p_{BO}(w_3|w_1 \bullet)), & \text{иначе} \end{cases}$$

Факторные энграммные модели

- Общая формула:

$$p(w_3|w_1 w_2) = \begin{cases} \alpha(\mathbf{w}_{1,2}) \frac{c(\mathbf{w}_{1,2} w_3)}{c(\mathbf{w}_{1,2} \bullet)}, & c(\mathbf{w}_{1,2} w_n) > 0, \\ \beta(w_1, w_2) g(p_{BO}(w_3|w_2), p_{BO}(w_3|w_1 \bullet)), & \text{иначе} \end{cases}$$

Факторные энграммные модели

- Общая формула:

$$p(w_3|w_1 w_2) = \begin{cases} \alpha(\mathbf{w}_{1,2}) \frac{c(\mathbf{w}_{1,2} w_3)}{c(\mathbf{w}_{1,2} \bullet)}, & c(\mathbf{w}_{1,2} w_n) > 0, \\ \beta(w_1, w_2) g(p_{BO}(w_3|w_2), p_{BO}(w_3|w_1 \bullet)), & \text{иначе} \end{cases}$$

- $\alpha(\mathbf{w}_{1,2})$ — сглаживающий множитель (как в обычных методах),

Факторные энграммные модели

- Общая формула:

$$p(w_3|w_1 w_2) = \begin{cases} \alpha(\mathbf{w}_{1,2}) \frac{c(\mathbf{w}_{1,2} w_3)}{c(\mathbf{w}_{1,2} \bullet)}, & c(\mathbf{w}_{1,2} w_n) > 0, \\ \beta(w_1, w_2) g(p_{BO}(w_3|w_2), p_{BO}(w_3|w_1 \bullet)), & \text{иначе} \end{cases}$$

- $\alpha(\mathbf{w}_{1,2})$ — сглаживающий множитель (как в обычных методах),
- $\beta(w_1, w_2)$ — поправочный множитель (чтобы сумма вероятностей равнялась 1)

Факторные энграммные модели

- Общая формула:

$$p(w_3|w_1 w_2) = \begin{cases} \alpha(\mathbf{w}_{1,2}) \frac{c(\mathbf{w}_{1,2} w_3)}{c(\mathbf{w}_{1,2} \bullet)}, & c(\mathbf{w}_{1,2} w_n) > 0, \\ \beta(w_1, w_2) g(p_{BO}(w_3|w_2), p_{BO}(w_3|w_1 \bullet)), & \text{иначе} \end{cases}$$

- $\alpha(\mathbf{w}_{1,2})$ — сглаживающий множитель (как в обычных методах),
- $\beta(w_1, w_2)$ — поправочный множитель (чтобы сумма вероятностей равнялась 1)
- g — агрегирующая функция (максимум, произведение, взвешенная сумма...)

Факторные энграммные модели

- С помощью факторов можно задавать зависимость от произвольного из последних k слов.

Факторные энграммные модели

- С помощью факторов можно задавать зависимость от произвольного из последних k слов.
- Однако факторы необязательно соответствуют отдельным словам.

Факторные энграммные модели

- С помощью факторов можно задавать зависимость от произвольного из последних k слов.
- Однако факторы необязательно соответствуют отдельным словам.
- Ими можно задавать морфологические категории или основы (для случая слов), фонетические классы (для фонем), часть речи или отдельные граммемы (для морфологических меток).

Факторные энграммные модели

- С помощью факторов можно задавать зависимость от произвольного из последних k слов.
- Однако факторы не обязательно соответствуют отдельным словам.
- Ими можно задавать морфологические категории или основы (для случая слов), фонетические классы (для фонем), часть речи или отдельные граммемы (для морфологических меток).
- Например, следующая биграммная модель сначала смотрит на слово w_1 , потом на метку t_1 , потом на часть речи c_1 .

