

# Машина релевантных тегов

Молчанов Д. А.<sup>1</sup>  
Кондрашкин Д. А.<sup>2</sup>  
Ветров Д. П.<sup>2,3</sup>

<sup>1</sup>Московский Государственный Университет им. М. В. Ломоносова

<sup>2</sup> Национальный Исследовательский Университет Высшая Школа Экономики

<sup>3</sup> Сколковский институт науки и технологий

Математические методы распознавания образов,  
19–25 сентября 2015

Модель:

$$p(\mathbf{t}|\mathbf{w}) = \prod_{n=1}^N \sigma(t_n \mathbf{w}^T \phi(\mathbf{x}_n))$$

$$p(\mathbf{w}|\boldsymbol{\alpha}) = \prod_{j=1}^d \mathcal{N}(w_j|0, \alpha_j^{-1})$$

Обучение:

$$p(\mathbf{t}|\boldsymbol{\alpha}) = \int p(\mathbf{t}|\mathbf{w})p(\mathbf{w}|\boldsymbol{\alpha})d\mathbf{w} \rightarrow \max_{\boldsymbol{\alpha}}$$

ARD-эффект: такая процедура обучения осуществляет отбор признаков.

Но будет ли наблюдаться этот эффект на более сложных моделях с другим априорным распределением?

# Постановка задачи

Рассмотрим задачу бинарной классификации данных с бинарными признаками.

- $(\mathbf{x}_i, t_i)_{i=1}^n$  — обучающая выборка
- $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{id})$  — объект
- $t_i \in \{0, 1\}$  — метка класса объекта  $\mathbf{x}_i$
- $x_{ij} = 1 \Leftrightarrow \mathbf{x}_i$  помечен тегом  $j$
- Все теги влияют на метку класса независимо

Вероятностная модель RTM (для одного объекта  $\mathbf{x}$ ):

$$q_j = P(t = 1 | x_j = 1) \quad P(t = 1 | \mathbf{x}, \mathbf{q}) = \frac{\prod_{j=1}^d q_j^{x_j}}{\prod_{j=1}^d q_j^{x_j} + \prod_{j=1}^d (1 - q_j)^{x_j}}$$

Параметры модели — вектор  $\mathbf{q} = (q_1, q_2, \dots, q_d)^T$

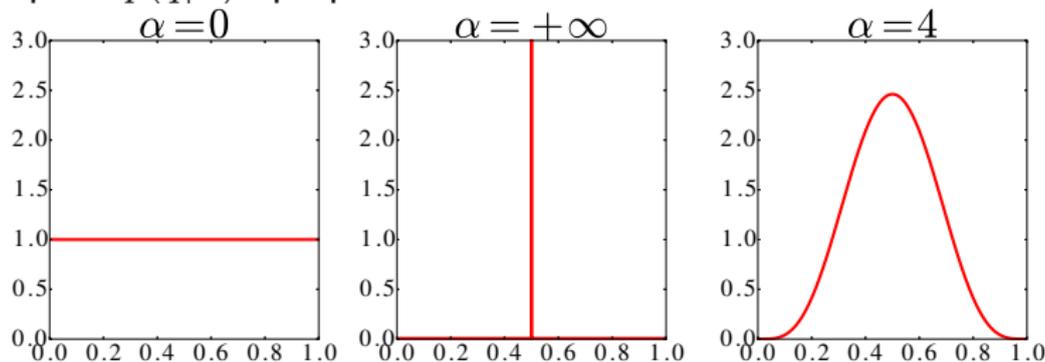
Симметричное бета-распределение:

$$q_j \sim \text{Beta}(\alpha_j + 1, \alpha_j + 1), \alpha_j \in [0, +\infty)$$

Вектор  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_d)^T$  называется вектором гиперпараметров.

- $\alpha_j = 0 \Rightarrow q_j^{MAP} = q_j^{ML}$
- $\alpha_j = +\infty \Rightarrow q_j = p(t = 1 | x_j = 1) = 0.5 \Rightarrow$  тег  $j$  убирается из модели
- $\alpha_j \in (0, +\infty) \Rightarrow$  на  $q_j$  накладывается регуляризация

Графики  $p(q|\alpha)$  при различных значениях  $\alpha$ :



Формула Байеса:

$$p(\mathbf{q}|\mathbf{X}, \mathbf{t}, \alpha) = \frac{P(\mathbf{t}|\mathbf{X}, \mathbf{q})p(\mathbf{q}|\alpha)}{\int P(\mathbf{t}|\mathbf{X}, \mathbf{q})p(\mathbf{q}|\alpha)d\mathbf{q}}$$

- $p(\mathbf{q}|\mathbf{X}, \mathbf{t}, \alpha)$  — апостериорное распределение
- $P(\mathbf{t}|\mathbf{X}, \mathbf{q})$  — функция правдоподобия
- $p(\mathbf{q}|\alpha)$  — априорное распределение
- $E(\alpha) = \int P(\mathbf{t}|\mathbf{X}, \mathbf{q})p(\mathbf{q}|\alpha)d\mathbf{q}$  — обоснованность (evidence)

Обоснованность может быть использована для выбора модели

Максимизация обоснованности дает самую простую модель из тех, что хорошо объясняют данные.

В случае RTM:

Обоснованность  $\rightarrow \max_{\alpha} \Rightarrow \alpha_j \rightarrow +\infty$  для нерелевантных тегов  
 $j \Rightarrow$  нерелевантные теги автоматически убираются из модели.

В случае модели RTM ни значение, ни градиент обоснованности не может быть вычислен, поэтому приходится оптимизировать ее приближенно.

# Вариационные нижние оценки

Рассмотрим функцию  $f(\mathbf{w})$ ,  $\mathbf{w} \in M_1 \subseteq \mathbb{R}^m$

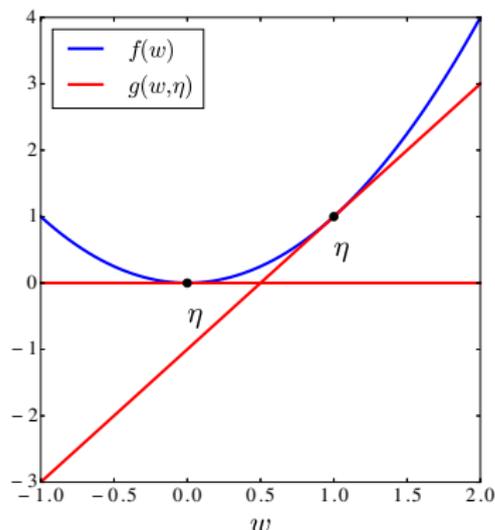
Вариационной нижней оценкой на функцию  $f(\mathbf{w})$  называется функция  $g(\mathbf{w}, \boldsymbol{\eta})$  такая, что:

$$g(\mathbf{w}, \boldsymbol{\eta}) \leq f(\mathbf{w}) \quad \forall \mathbf{w}, \boldsymbol{\eta} \in M_1$$

$$g(\mathbf{w}, \mathbf{w}) = f(\mathbf{w}) \quad \forall \mathbf{w} \in M_1$$

Пример:

$f(\mathbf{w})$  – выпуклая функция,  
 $g(\mathbf{w}, \boldsymbol{\eta})$  – касательная плоскость к функции  $f(\mathbf{w})$ , проведенная через точку касания  $\boldsymbol{\eta}$ .



- Вариационная нижняя оценка на функцию правдоподобия одного объекта:

$$L_i(\mathbf{q}, \boldsymbol{\eta}_i) \leq p(t_i | \mathbf{x}_i, \mathbf{q})$$

- Вариационные параметры:

$$\mathbf{H} = (\eta_{ij})_{i,j=1}^{n,d}$$

- Нижняя оценка на подинтегральную функцию для обоснованности:

$$L(\mathbf{q}, \mathbf{H}, \boldsymbol{\alpha}) = p(\mathbf{q} | \boldsymbol{\alpha}) \prod_{i=1}^n L_i(\mathbf{q}, \boldsymbol{\eta}_i) \leq p(\mathbf{t} | \mathbf{X}, \mathbf{q}) p(\mathbf{q} | \boldsymbol{\alpha})$$

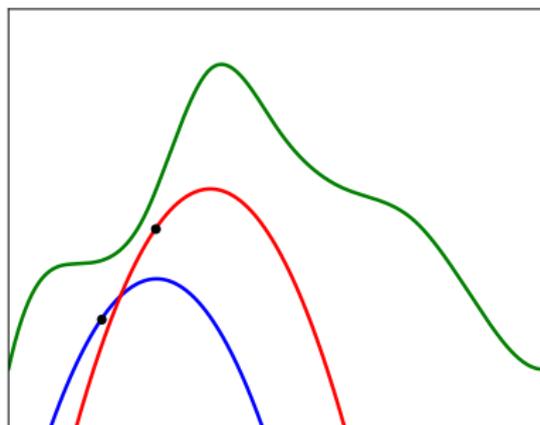
- Семейство нижних оценок на обоснованность:

$$\tilde{E}(\mathbf{H}, \boldsymbol{\alpha}) = \int L(\mathbf{q}, \mathbf{H}, \boldsymbol{\alpha}) d\mathbf{q} \leq E(\boldsymbol{\alpha})$$

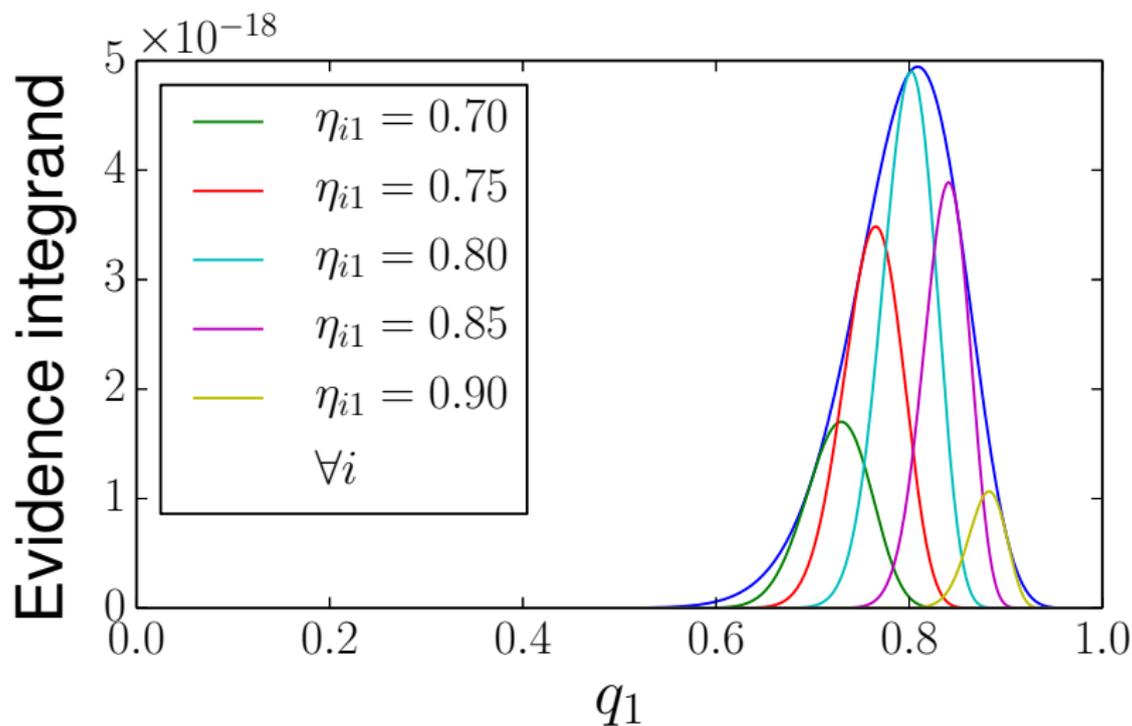
Эти оценки можно использовать для максимизации обоснованности:

$$\begin{aligned}\mathbf{H}^{k+1} &= \arg \max_{\mathbf{H}} \log \tilde{E}(\mathbf{H}, \boldsymbol{\alpha}^k), \\ \boldsymbol{\alpha}^{k+1} &= \arg \max_{\boldsymbol{\alpha}} \log \tilde{E}(\mathbf{H}^{k+1}, \boldsymbol{\alpha})\end{aligned}$$

Здесь не надо вычислять значение оптимизируемой функции!



# Нижняя оценка на подынтегральную функцию для обоснованности



# Нижняя оценка на обоснованность для модели RTM

$$E(\alpha) \geq \tilde{E}(\alpha, \mathbf{H}) = \left( \prod_{i=1}^n c_i(\boldsymbol{\eta}_i) \right) \prod_{j=1}^d \int_0^1 \exp \left( \sum_{i:j \in Q_i} \tilde{c}_{ij}(\boldsymbol{\eta}_i) \left( \frac{1-q_j}{q_j} \right)^{|Q_i|(2t_i-1)} \right) p(q_j | \alpha_j) dq_j$$
$$\forall \mathbf{H} \in (0, 1)^{n \times d}, \forall \alpha \in [0, +\infty)^d,$$

где

$$Q_i = \{j | x_{ij} = 1\},$$

$$c_i(\boldsymbol{\eta}_i) = \frac{\prod_{j \in Q_i} \eta_{ij}^{t_i} (1 - \eta_{ij})^{1-t_i}}{\prod_{j \in Q_i} \eta_{ij} + \prod_{j \in Q_i} (1 - \eta_{ij})} \exp \left( \frac{\prod_{j \in Q_i} \eta_{ij}^{1-t_i} (1 - \eta_{ij})^{t_i}}{\prod_{j \in Q_i} \eta_{ij} + \prod_{j \in Q_i} (1 - \eta_{ij})} \right),$$

$$\tilde{c}_{ij}(\boldsymbol{\eta}_i) = - \frac{\prod_{j \in Q_i} \eta_{ij}^{t_i} (1 - \eta_{ij})^{1-t_i}}{\prod_{j \in Q_i} \eta_{ij} + \prod_{j \in Q_i} (1 - \eta_{ij})} \left( \frac{\eta_{ij}}{1 - \eta_{ij}} \right)^{|Q_i|(2t_i-1)} |Q_i|^{-1}.$$

RTM-full:

$$1 \quad \mathbf{H}^{new} = \arg \max_{\mathbf{H}} \log \tilde{E}(\boldsymbol{\alpha}^{old}, \mathbf{H})$$

$$2 \quad \boldsymbol{\alpha}^{new} = \arg \max_{\boldsymbol{\alpha}} \log \tilde{E}(\boldsymbol{\alpha}, \mathbf{H}^{new})$$

RTM-MAP:

$$1 \quad \boldsymbol{\eta}_i^{new} = \mathbf{q}^{MAP} = \arg \max_{\mathbf{q}} P(\mathbf{t} | \mathbf{X}, \mathbf{q}) p(\mathbf{q} | \boldsymbol{\alpha}^{old}) \quad \forall i.$$

$$2 \quad \boldsymbol{\alpha}^{new} = \arg \max_{\boldsymbol{\alpha}} \log \tilde{E}(\boldsymbol{\alpha}, \mathbf{H}^{new})$$

- $n$  – число объектов
- $\tau$  – среднее число тегов у одного объекта
- $d$  – число возможных тегов
- $k_i$  – число подсчетов градиента оценки обоснованности на  $i$ -м шаге одной итерации,  $i = 1, 2$  (в экспериментах  $k_1 \approx k_2 \approx 10$ )

Сложность одной итерации метода:

Метод	Число операций интегрирования
RTM-full	$O(n\tau k_1 + dk_2)$
RTM-MAP	$O(dk_2)$

- 500 объектов
- 50 тегов
- Усреднение по выборкам с различным уровнем зашумления

Тип шума	Точность отбора признаков:			
	RTM-MAP	RTM-full	RVM	L1-LR
Процент убранных нерелевантных признаков				
Случайный	99.64%	99.46%	99.10%	85.63%
Коррелирующий	84.44%	88.90%	84.65%	100.00%
Процент убранных релевантных признаков				
Случайный	4.50%	4.68%	2.63%	3.54%
Коррелирующий	2.50%	4.34%	1.04%	2.50%

- Классификация предложений по эмоциональной окраске
- Каждый объект задается набором своих слов (теги = слова)

	Точность классификации:				
RTM-MAP	RVM	L1-LR	RF	GBDT	SVM
0.9659	0.9586	0.9708	0.9416	0.9683	0.9683

RVM — машина релевантных векторов

L1-LR — логистическая регрессия с L1-регуляризатором

RF — случайный лес


GBDT — градиентный бустинг решающих пней

SVM — машина опорных векторов

# Задача семантического анализа: отбор признаков

Метод	Число оставленных признаков
RTM-MAP	70
L1-LR	120
RVM	230

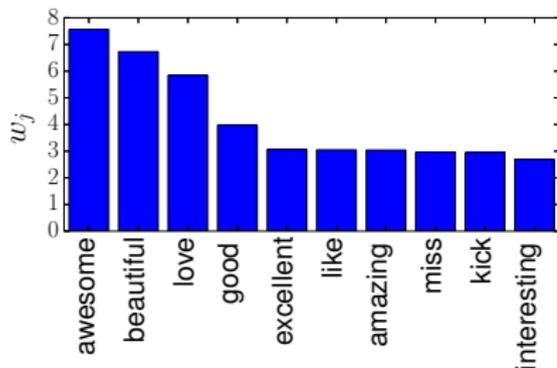
Веса линейной модели, настроенной RVM:



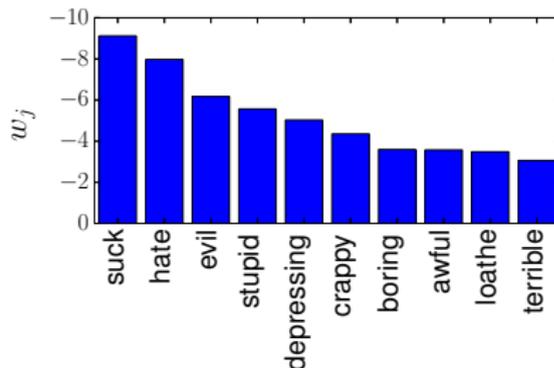
# Задача семантического анализа: отбор признаков

Веса линейной модели, настроенной логистической регрессией:

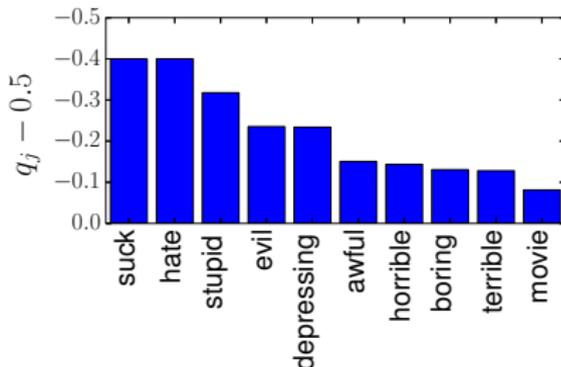
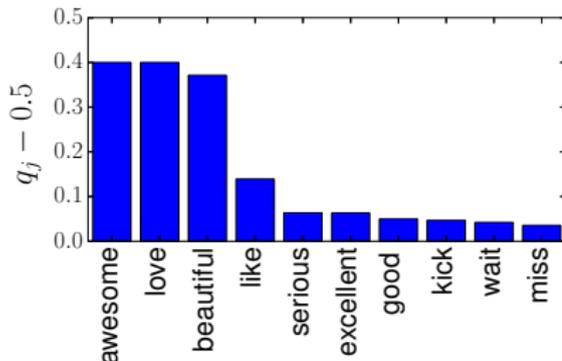
Позитивный класс:



Негативный класс:



$q_j - 0.5$  для самых важных слов у RTM-MAP:



Предложено:

- Модель бинарной классификации для данных с бинарными признаками
- Метод обучения, позволяющий проводить автоматический отбор признаков

Показано:

- Качество классификации и отбора признаков предложенного метода сравнимо с качеством классических моделей
- Модель получается более разреженной
- Эффект ARD наблюдается также и на сложных моделях с априорным распределением, отличным от нормального