

# Байесовский выбор моделей: обоснованность и отбор признаков в линейной и логистической регрессии

Александр Адуенко

10е октября 2018

## Содержание предыдущих лекций

- Формула Байеса:  $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$ ;
- Формула полной вероятности:  $P(B) = P(B|A)P(A) + P(B|\bar{A})P(\bar{A})$ ;
- Определение априорных вероятностей и selection bias;
- (Множественное) тестирование гипотез
- Экспоненциальное семейство распределений. Достаточные статистики.
- Наивный байесовский классификатор. Связь целевой функции и вероятностной модели.
- Линейная регрессия: классический подход, связь МНК и принципа максимума правдоподобия, связь регуляризации и MAP-оценки для вектора параметров  $\mathbf{w}$ .
- Свойство сопряженности априорного распределения правдоподобию.
- Прогноз для одиночной модели:  
$$p(\mathbf{y}_{\text{test}} | \mathbf{X}_{\text{test}}, \mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}) = \int p(\mathbf{y}_{\text{test}} | \mathbf{w}, \mathbf{X}_{\text{test}}) p(\mathbf{w} | \mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}) d\mathbf{w}.$$
- Связь апостериорной вероятности модели и обоснованности  
$$p(M_i | \mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}) \propto p(M_i) p_i(\mathbf{y}_{\text{train}} | \mathbf{X}_{\text{train}}).$$

# Пример выбора модели

a – applicant, r – reviewer

$$a, r = \begin{cases} 0, \text{ нет PhD,} \\ 1, \text{ PhD.} \end{cases}$$

d – decision

$$d = \begin{cases} 1, \text{ принять,} \\ 0, \text{ отвергнуть.} \end{cases}$$

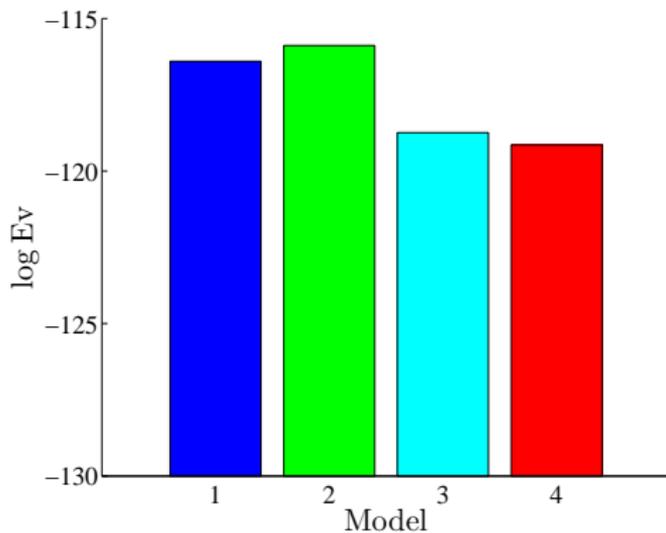
$r = 0$	$d = 0$	$d = 1$
$a = 0$	9	0
$a = 1$	132	19

$r = 1$	$d = 0$	$d = 1$
$a = 0$	97	6
$a = 1$	52	11

Случаи:

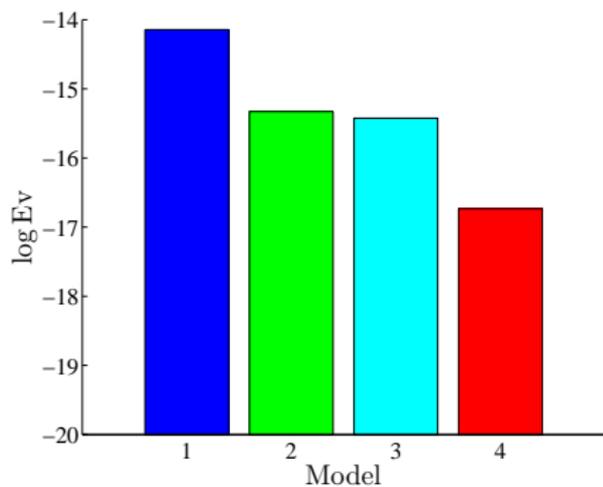
- 1  $p(d|a, r) = p(d)$
- 2  $p(d|a, r) = p(d|a)$
- 3  $p(d|a, r) = p(d|r)$
- 4  $p(d|a, r) = p(d|a, r)$

# Пример выбора модели

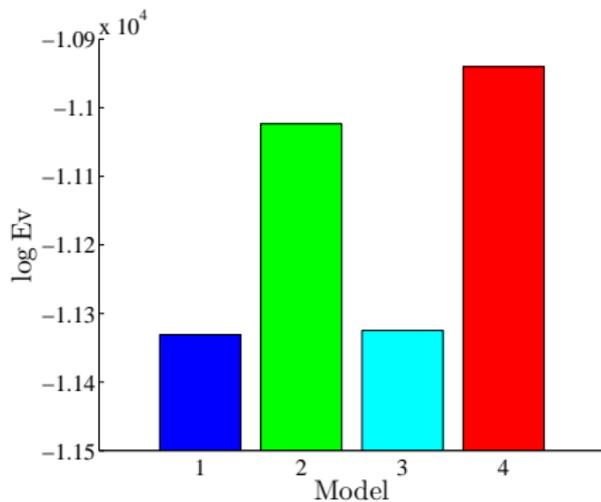


Сравнение обоснованностей, 326 объектов в выборке

# Выбор модели: зависимость от размера выборки



Сравнение обоснованностей, 33  
объекта в выборке



Сравнение обоснованностей, 32600  
объектов в выборке

$$\text{Evidence : } p_i(\mathbf{y}|\mathbf{X}) = \int p_i(\mathbf{y}|\mathbf{X}, \mathbf{w})p_i(\mathbf{w})d\mathbf{w}$$

$$p_i(\mathbf{w}|\mathbf{X}, \mathbf{y}) = \frac{p_i(\mathbf{y}|\mathbf{X}, \mathbf{w})p_i(\mathbf{w})}{p(\mathbf{y}|\mathbf{X})}.$$

## Предположения:

- $w$  одномерный
- Априорное распределение  $p_i(w)$  плоское с шириной  $\Delta w_{\text{prior}}$
- Апостериорное распределение  $p_i(w|\mathbf{X}, \mathbf{y})$  сконцентрировано вокруг  $w_{MP}$  с шириной  $\Delta w_{\text{post}}$

$$\text{Тогда: } \log p_i(\mathbf{y}|\mathbf{X}) \approx \log p_i(\mathbf{y}|\mathbf{X}, w_{MP}) + \log \left( \frac{\Delta w_{\text{post}}}{\Delta w_{\text{prior}}} \right).$$

$$\text{Для } M\text{-мерного } \mathbf{w}: \log p_i(\mathbf{y}|\mathbf{X}) \approx \log p_i(\mathbf{y}|\mathbf{X}, \mathbf{w}_{MP}) + M \log \left( \frac{\Delta w_{\text{post}}}{\Delta w_{\text{prior}}} \right).$$

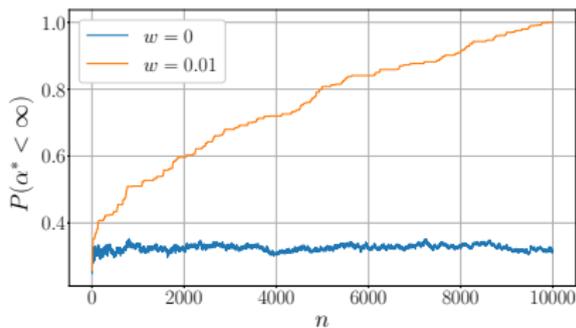
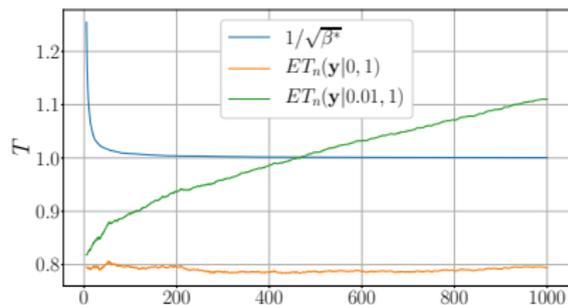
# Пример оптимизации evidence

$$y_i = w + \varepsilon_i, \varepsilon_i \sim N(\varepsilon|0, \beta^{-1})$$

$$y_1|w, \dots, y_n|w \sim N(y_i|w, \beta^{-1}), w \sim N(w|0, \alpha^{-1}).$$

$$p(\mathbf{y}|\alpha, \beta) = \frac{\beta^{n/2} \alpha^{1/2}}{(2\pi)^{n/2} \sqrt{n\beta + \alpha}} \exp \left( -\frac{1}{2} \beta \sum_{i=1}^n y_i^2 + \frac{\beta^2 (\sum_{i=1}^n y_i)^2}{2(n\beta + \alpha)} \right).$$

$$(\alpha^*, \beta^*) = \arg \max_{\alpha, \beta} p(\mathbf{y}|\alpha, \beta).$$



$$\alpha^* = \begin{cases} \frac{n^2 \beta^*}{\beta^* (\sum_{i=1}^n y_i)^2 - n}, & \underbrace{\frac{|\sum_{i=1}^n y_i|}{\sqrt{n}}}_{T_n(\mathbf{y}|w, \beta)} > \frac{1}{\sqrt{\beta^*}}, \\ +\infty, & \text{иначе.} \end{cases} \quad \frac{1}{\beta^*} = \frac{\sum_{i=1}^n (y_i - \bar{\mathbf{y}})^2}{n - 1}.$$

## Обоснованность для линейной регрессии

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}, \mathbf{w} \sim N(\boldsymbol{\theta}|\mathbf{0}, \mathbf{A}^{-1}), \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2\mathbf{I})$$

Совместное правдоподобие:  $p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \mathbf{A}, \sigma^2) = p(\mathbf{y}|\mathbf{X}, \mathbf{w}, \sigma^2)p(\mathbf{w}|\mathbf{A})$ .

Обоснованность:

$$p(\mathbf{y}|\mathbf{X}, \mathbf{A}, \sigma^2) = \int p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \mathbf{A}, \sigma^2)d\mathbf{w} = \int p(\mathbf{y}|\mathbf{X}, \mathbf{w}, \sigma^2)p(\mathbf{w}|\mathbf{A})d\mathbf{w}.$$

$$\mathbf{y}|\mathbf{X}, \mathbf{A}, \sigma^2 \sim N(\mathbf{y}|\mathbf{0}, \sigma^2\mathbf{I} + \mathbf{X}\mathbf{A}^{-1}\mathbf{X}^T)$$

Поэтому:

$$\log p(\mathbf{y}|\mathbf{X}, \mathbf{A}, \sigma^2) \propto -\frac{1}{2} \log \det(\sigma^2\mathbf{I} + \mathbf{X}\mathbf{A}^{-1}\mathbf{X}^T) - \frac{1}{2}\mathbf{y}^T (\sigma^2\mathbf{I} + \mathbf{X}\mathbf{A}^{-1}\mathbf{X}^T)^{-1}\mathbf{y}.$$

### Пример

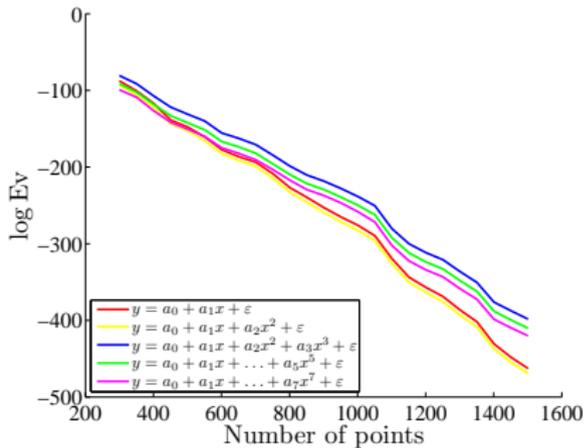
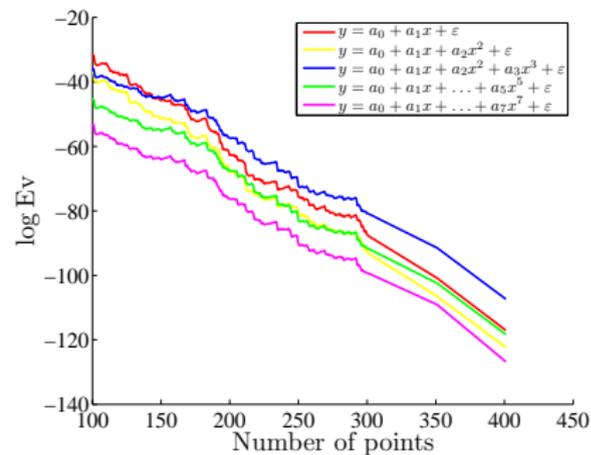
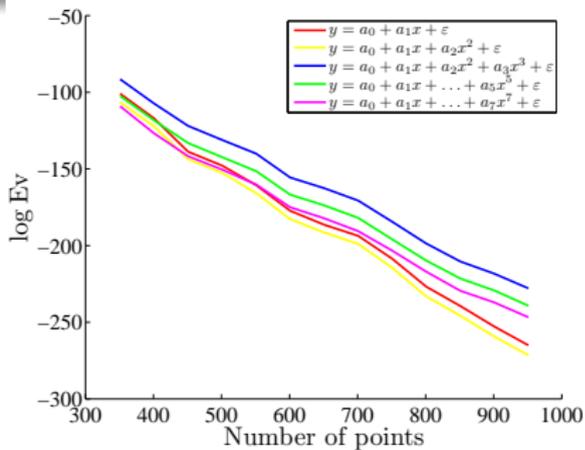
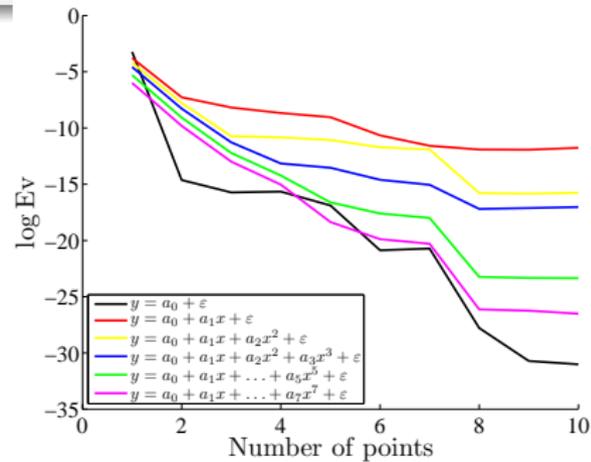
$y_i = \sin x_i + \varepsilon_i$ ,  $x_i$  равномерно выбрано на  $[-\pi/2, \pi/2]$ ,  $\varepsilon_i \sim N(0, \sigma^2)$

$$\mathbf{w} \sim N(\mathbf{w}|\mathbf{0}, \alpha^{-1}\mathbf{I})$$

Значения параметров:  $\alpha = 0.01$ ,  $\sigma^2 = 0.1$ .

Признаки:  $1, x_i, x_i^2, \dots, x_i^k, \dots$

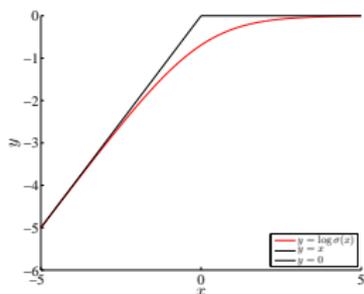
# Пример: сравнение моделей



# Байесовская логистическая регрессия

Пусть  $\mathbf{X} \in \mathbb{R}^{m \times n}$  – признаковая матрица, а  $\mathbf{y} \in \{\pm 1\}^m$  – метки класса.

$$p(\mathbf{y}, \mathbf{w} | \mathbf{X}, \mathbf{A}) = p(\mathbf{y} | \mathbf{X}, \mathbf{w}) p(\mathbf{w} | \mathbf{A}), \text{ где } p(\mathbf{y} | \mathbf{X}, \mathbf{w}) = \prod_{j=1}^m \sigma(y_j \mathbf{w}^\top \mathbf{x}_j).$$



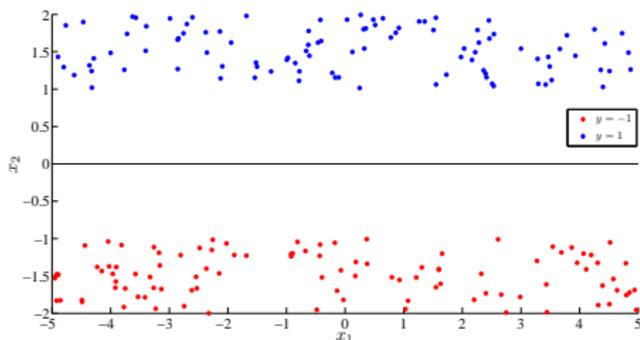
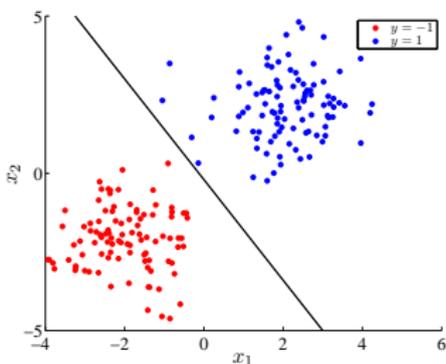
$$p(y_j | \mathbf{w}, \mathbf{x}_j) = \sigma(y_j \mathbf{w}^\top \mathbf{x}_j) = \frac{1}{1 + \exp(-y_j \mathbf{w}^\top \mathbf{x}_j)}.$$

**Вопрос 1:** как выбрать  $p(\mathbf{w} | \mathbf{A})$ ?

**Вопрос 2:** Пусть  $p(\mathbf{w} | \mathbf{A}) = N(\mathbf{0}, \mathbf{A}^{-1})$ ,  $\mathbf{A} = \text{diag}(\boldsymbol{\alpha})$

Что происходит, когда  $\alpha_i \rightarrow \infty$ ?

Примеры неоднозначности выбора разделительной прямой.



**Вопрос 3:** чему равна  $\mathbf{w}_{ML}$  для выборок на рис. выше?

# Обоснованность для логистической регрессии

Пусть  $\mathbf{X} \in \mathbb{R}^{m \times n}$  – признаковая матрица, а  $\mathbf{y} \in \{\pm 1\}^m$  – метки класса.

$$p(\mathbf{y}, \mathbf{w} | \mathbf{X}, \mathbf{A}) = p(\mathbf{y} | \mathbf{X}, \mathbf{w}) p(\mathbf{w} | \mathbf{A}), \text{ где } p(\mathbf{y} | \mathbf{X}, \mathbf{w}) = \prod_{j=1}^m \sigma(y_j \mathbf{w}^T \mathbf{x}_j).$$

**Идея:** выбрать модель с максимальной обоснованностью.

**Вопрос 1:** чем отличаются разные модели байесовской логистической регрессии, описанные выше?

**Вычисление обоснованности.**

Пусть далее  $p(\mathbf{w} | \mathbf{A}) = N(\mathbf{0}, \mathbf{A}^{-1})$ ,  $\mathbf{A} = \text{diag}(\boldsymbol{\alpha})$ .

$$\text{Тогда } \mathbf{A}^* = \arg \max_{\mathbf{A}} p(\mathbf{y} | \mathbf{X}, \mathbf{A}) = \arg \max_{\mathbf{A}} \int \underbrace{p(\mathbf{y} | \mathbf{X}, \mathbf{w}) p(\mathbf{w} | \mathbf{A})}_{Q(\mathbf{w})} d\mathbf{w}.$$

**Проблема:** интеграл аналитически не вычисляется.

**Аппроксимация Лапласа**

$$\log Q(\mathbf{w}) \approx \log Q(\mathbf{w}_{\text{MAP}}) + \frac{1}{2} (\mathbf{w} - \mathbf{w}_{\text{MAP}})^T \overbrace{\nabla \nabla \log Q(\mathbf{w}_{\text{MAP}})}^{-\mathbf{H}^{-1}} (\mathbf{w} - \mathbf{w}_{\text{MAP}}).$$
$$\mathbf{A}^* = \arg \max_{\mathbf{A}} \left( Q(\mathbf{w}_{\text{MAP}}) \int e^{-\frac{1}{2} (\mathbf{w} - \mathbf{w}_{\text{MAP}})^T \mathbf{H}^{-1} (\mathbf{w} - \mathbf{w}_{\text{MAP}})} d\mathbf{w} \right).$$

**Вопрос 2:** Как определяется  $\mathbf{w}_{\text{MAP}}$ ?

# Вариационные нижние оценки

**Определение.**  $g(x, \xi)$  вариационная нижняя оценка для  $f(x) \iff$

1  $f(x) \geq g(x, \xi) \forall x, \xi$

2  $f(\xi) = g(\xi, \xi)$ .

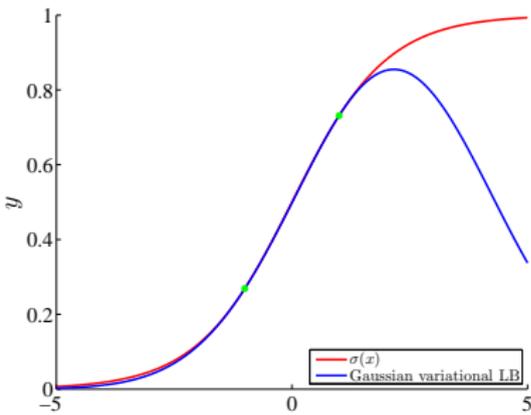
Вместо  $f(x) \rightarrow \max_x$  рассмотрим  $g(x, \xi) \rightarrow \max_{x, \xi}$

1  $\xi^n = \arg \max_{\xi} g(x^{n-1}, \xi)$

2  $x^n = \arg \max_x g(x, \xi^n)$

VLB для сигмоидной функции

$$\sigma(x) \geq \sigma(\xi) \exp \left( -\frac{1}{4\xi} (2\sigma(\xi) - 1)(x^2 - \xi^2) + \frac{x - \xi}{2} \right).$$



**Вопрос:** в чем преимущество использования VLB при максимизации обоснованности в логистической регрессии?

# LB для обоснованности в логистической регрессии

$$p(\mathbf{y}, \mathbf{w} | \mathbf{X}, \mathbf{A}) = \prod_{j=1}^m \sigma(y_j \mathbf{w}^\top \mathbf{x}_j) \frac{\sqrt{\det \mathbf{A}}}{(2\pi)^{n/2}} e^{-\frac{1}{2} \mathbf{w}^\top \mathbf{A} \mathbf{w}} \geq \text{VLB}(\mathbf{w}, \boldsymbol{\xi}, \mathbf{A}) =$$

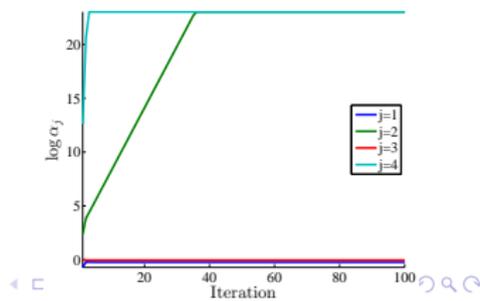
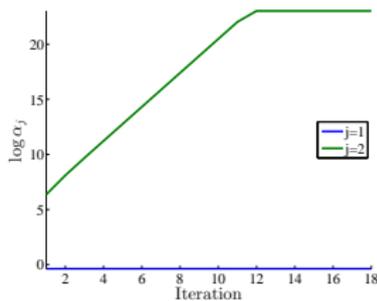
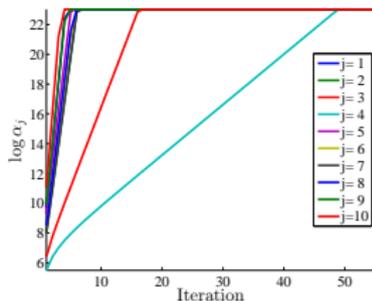
$$\frac{\sqrt{\det \mathbf{A}}}{(2\pi)^{n/2}} e^{-\frac{1}{2} \mathbf{w}^\top \mathbf{A} \mathbf{w}} \prod_{j=1}^m \sigma(\xi_j) \exp \left( -\frac{2\sigma(\xi_j)-1}{4\xi_j} (\mathbf{w}^\top \mathbf{x}_j \mathbf{x}_j^\top \mathbf{w} - \xi_j^2) + \frac{y_j \mathbf{w}^\top \mathbf{x}_j - \xi_j}{2} \right) =$$

$$\frac{\sqrt{\det \mathbf{A}}}{(2\pi)^{n/2}} \prod_{j=1}^m \sigma(\xi_j) e^{\frac{2\sigma(\xi_j)-1}{4\xi_j} \xi_j^2 - \frac{\xi_j}{2}} e^{-\frac{1}{2} \mathbf{w}^\top \mathbf{A}' \mathbf{w} + \mathbf{w}^\top \mathbf{v}}, \text{ где}$$

$$\mathbf{A}' = \mathbf{A} + \sum_{j=1}^m \frac{2\sigma(\xi_j)-1}{2\xi_j} \mathbf{x}_j \mathbf{x}_j^\top, \quad \mathbf{v} = \frac{1}{2} \sum_{j=1}^m y_j \mathbf{x}_j.$$

Тогда  $p(\mathbf{y} | \mathbf{X}, \mathbf{A}) \geq \text{LB}(\mathbf{A}, \boldsymbol{\xi}) = \int \text{VLB}(\mathbf{w}, \boldsymbol{\xi}, \mathbf{A}) d\mathbf{w} \rightarrow \max_{\mathbf{A}, \boldsymbol{\xi}}$ .

Иллюстрация отбора признаков в логистической регрессии



- 1 Bishop, Christopher M. "Pattern recognition and machine learning". Springer, New York (2006). Pp. 113-120, 161-171.
- 2 MacKay, David JC. Bayesian methods for adaptive models. Diss. California Institute of Technology, 1992.
- 3 MacKay, David JC. "The evidence framework applied to classification networks." *Neural computation* 4.5 (1992): 720-736.
- 4 Gelman, Andrew, et al. Bayesian data analysis, 3rd edition. Chapman and Hall/CRC, 2013.
- 5 Agresti, Alan. Analysis of ordinal categorical data. Vol. 656. John Wiley & Sons, 2010.
- 6 Дрейпер, Норман Р. Прикладной регрессионный анализ. Рипол Классик, 2007.
- 7 Chen, Ming-Hui, and Joseph G. Ibrahim. "Conjugate priors for generalized linear models." *Statistica Sinica* (2003): 461-476.