

# Байесовский выбор моделей: байесовская линейная регрессия и понятие обоснованности (evidence)

Александр Адуенко

23е сентября 2020

## Содержание предыдущих лекций

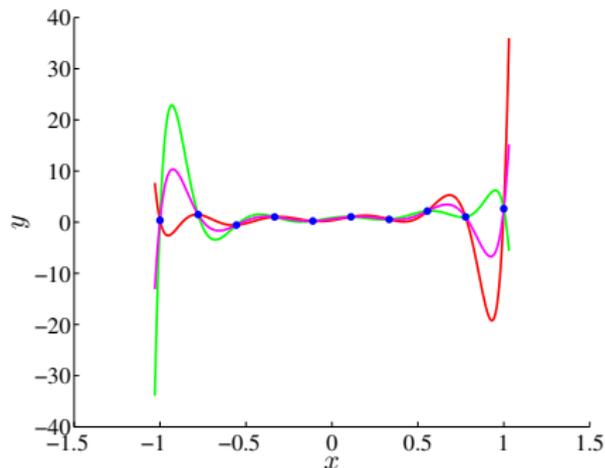
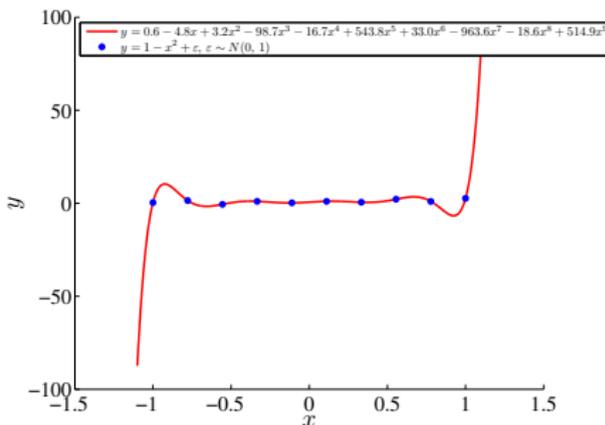
- Формула Байеса:  $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$ ;
- Формула полной вероятности:  $P(B) = P(B|A)P(A) + P(B|\bar{A})P(\bar{A})$ ;
- Определение априорных вероятностей и selection bias;
- Тестирование гипотез
  - Ошибка первого рода и мощность критерия;
  - Критическая область и как ее определить;
- Проблема множественного тестирования гипотез
  - Проблема ложных открытий при независимом одновременном тестировании множества гипотез;
  - FWER и FDR как обобщения вероятности ошибки первого рода;
  - Поправка Бонферрони как консервативное средство контроля FWER;
  - Поправка Бенджамини-Хохберга для контроля FDR для положительно регрессионно зависимых гипотез.
- Экспоненциальное семейство распределений. Достаточные статистики.
- Наивный байесовский классификатор. Связь целевой функции и вероятностной модели.

# Линейная регрессия: классический подход

$y = \mathbf{X}\mathbf{w} + \epsilon$ , где  $y \in \mathbb{R}^n$ ,  $\mathbf{X} \in \mathbb{R}^{n \times d}$ ,  $\mathbf{w} \in \mathbb{R}^d$ .

МНК (формула Гаусса):  $\hat{\mathbf{w}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T y$ .

Оптимизационная задача:  $\|y - \mathbf{X}\mathbf{w}\|^2 \rightarrow \min_{\mathbf{w}}$ .



$n = d$

$n < d$

Вопросы:

- Что делать, если  $n < d$  ( $\mathbf{X}^T \mathbf{X}$  вырождена)?
- Почему именно такая оптимизационная задача? Как связана с вероятностной моделью генерации данных?

# Линейная регрессия: классический подход

Оптимизационная задача:  $\|y - \mathbf{X}\mathbf{w}\|^2 \rightarrow \min_{\mathbf{w}}$ .

**Пример.** Пусть измеряется температура  $y_i$  в серверной комнате в момент времени  $x_i$  после включения отопления и считается, что нагрев происходит линейно, то есть  $\mathbf{X} = [\mathbf{1}, \mathbf{x}]$ .

Предположим, что  $\varepsilon_i = N(0, 1)^\circ\text{C} / -500 + N(0, 1)^\circ\text{C}$  с  $p = 1/2$ .

**Замечание.** Пусть  $w = 1^\circ\text{C}/\text{час}$ , а  $w_0 = 20^\circ\text{C}$ .

Выборка:  $(0, 20.3)$ ,  $(1, -480.5)$ ,  $(2, 20.8)$ ,  $(3, -476.3)$ .

МНК-оценка:  $w_0 = -80.44$ ;  $w_1 = -98.85$ .

**Вопрос:** почему МНК не сработал?

## Вероятностная модель линейной регрессии

$y = \mathbf{X}\mathbf{w} + \varepsilon$ ,  $\varepsilon \sim N(\mathbf{0}, \sigma^2\mathbf{I})$ , где  $\mathbf{y} \in \mathbb{R}^n$ ,  $\mathbf{X} \in \mathbb{R}^{n \times d}$ ,  $\mathbf{w} \in \mathbb{R}^d$ .

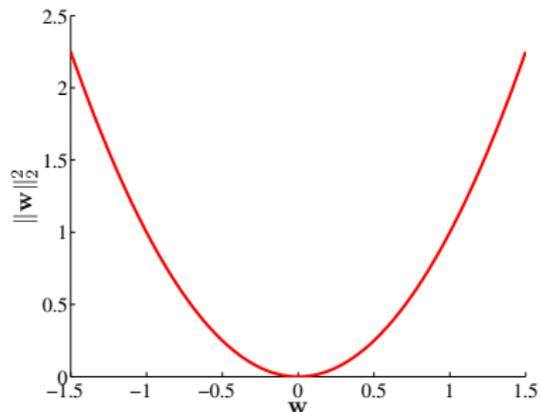
$$p(\mathbf{y}|\mathbf{X}, \mathbf{w}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(y_i - \mathbf{w}^\top \mathbf{x}_i)^2} = \frac{1}{(2\pi)^{n/2}\sigma^n} e^{-\frac{1}{2\sigma^2}\|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2}.$$

**Принцип максимума правдоподобия:**  $\hat{\mathbf{w}}_{ML} = \arg \max_{\mathbf{w}} p(\mathbf{y}|\mathbf{X}, \mathbf{w})$

$$\hat{\mathbf{w}}_{ML} = \arg \min_{\mathbf{w}} -\log p(\mathbf{y}|\mathbf{X}, \mathbf{w}) = \arg \min_{\mathbf{w}} \frac{1}{2\sigma^2}\|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2.$$

## Квадратическая регуляризация

$$\|y - Xw\|^2 + \tau \|w\|_2^2 \rightarrow \min_w$$

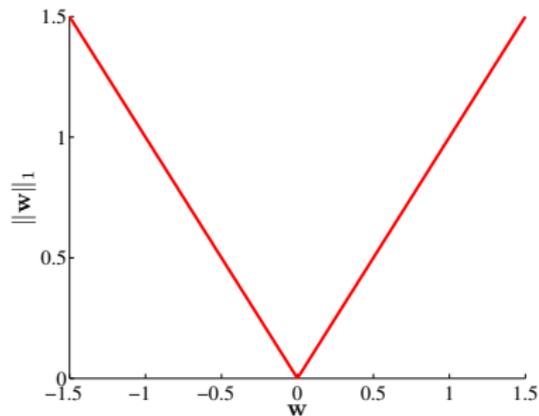


### Свойства:

- + Разрешимость
- + Есть аналитическое решение
- Слабо поощряет разреженность

## $l_1$ -regularization

$$\|y - Xw\|^2 + \tau \|w\|_1 \rightarrow \min_w$$



### Свойства:

- + Разрешимость
- Нет аналитического решения
- Недифференцируемая целевая функция
- + Поощряет разреженность

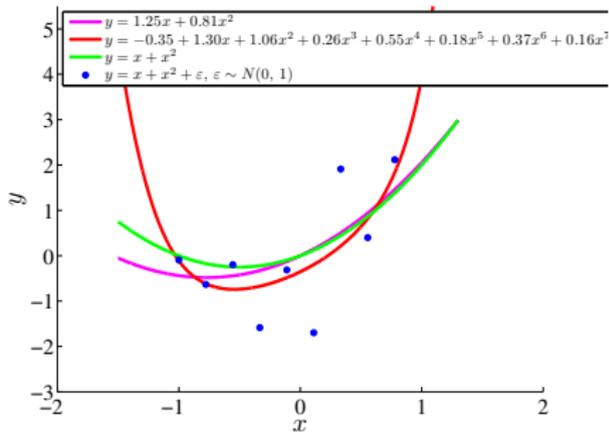
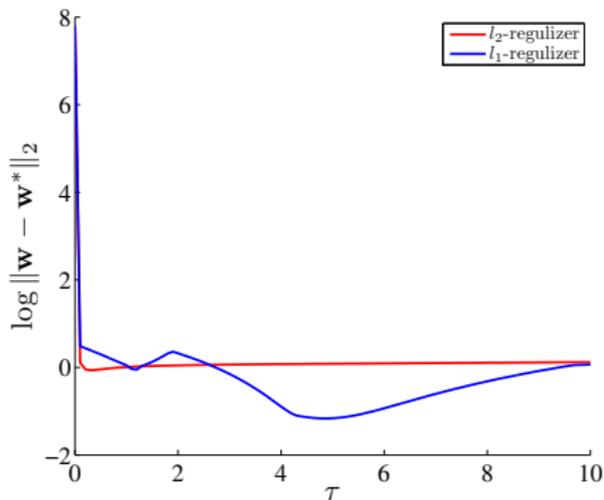
# Пример с регрессией на полиномы

## Данные

$$y = x + x^2 + \varepsilon, \varepsilon \sim N(0, 1),$$

$y_i \sim p(y|x_i)$ ,  $i = 1, \dots, 10$ , где  $x_1, \dots, x_{10}$

выбраны равномерно на  $[-1, 1]$ .



Зависимость точности от параметра регуляризации  $\tau$  Наилучшие полиномы

# Пример "томография"

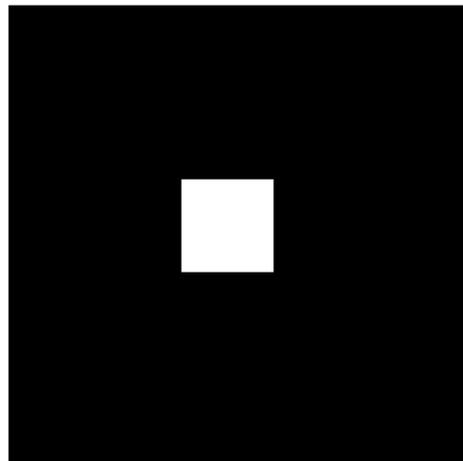
## Постановка задачи

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \beta^{-1}\mathbf{I}),$$

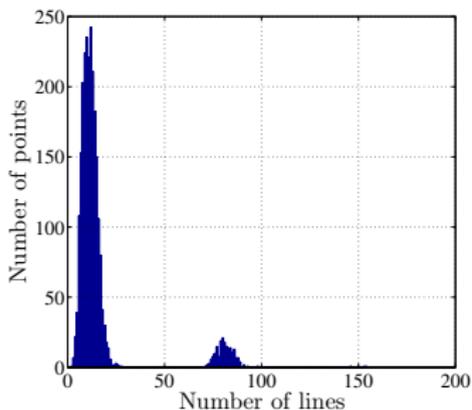
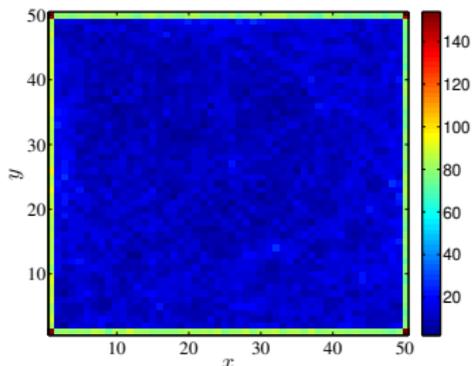
$$\mathbf{y} \in \mathbb{R}^m, \mathbf{X} \in \mathbb{R}^{m \times n^2}, m < n^2.$$

$$\mathbf{w} \in [0, 1]^{n^2}.$$

Параметры:  $m = 1000$ ,  $n = 50$ .

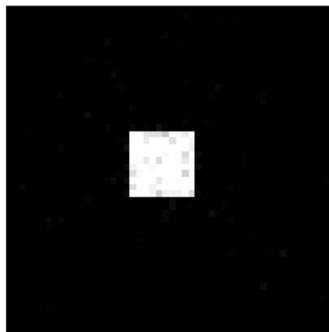


Настоящий  $\mathbf{w}$

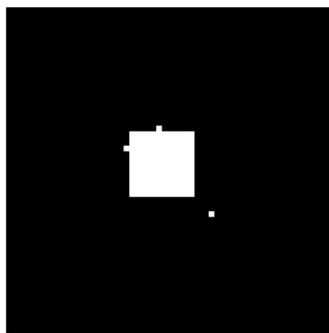


Распределение точек по числу линий

$l_1$ -регуляризация

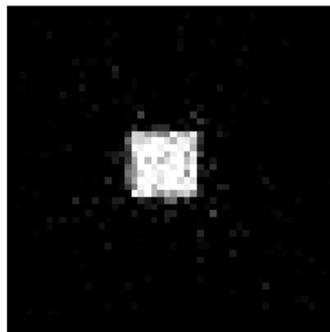


$\hat{w}$

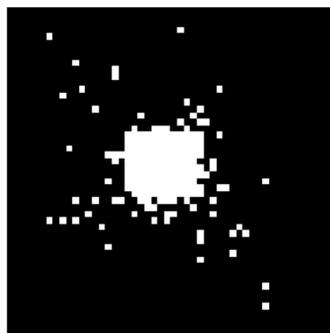


$[\hat{w} > 0.05]$

Квадратическая регуляризация

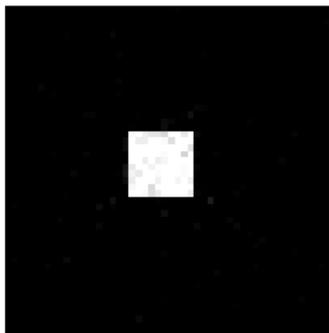


$\hat{w}$

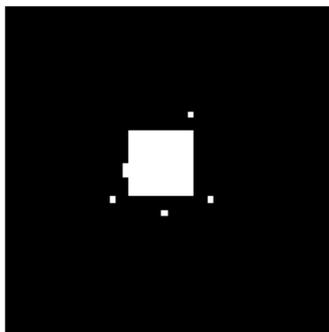


$[\hat{w} > 0.05]$

$l_1$ -регуляризация

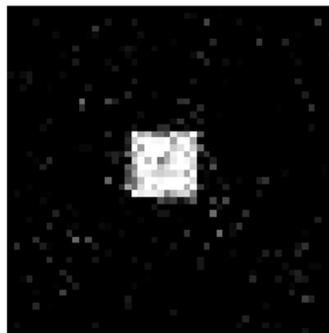


$\hat{w}$

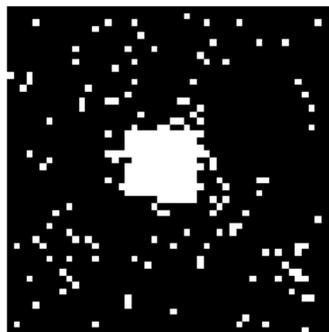


$[\hat{w} > 0.05]$

Квадратическая регуляризация



$\hat{w}$



$[\hat{w} > 0.05]$

# Линейная регрессия: байесовский подход

## Вероятностная модель линейной регрессии

$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}$ ,  $\boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2\mathbf{I})$ , где  $\mathbf{y} \in \mathbb{R}^n$ ,  $\mathbf{X} \in \mathbb{R}^{n \times d}$ ,  $\mathbf{w} \in \mathbb{R}^d$ .

$$p(\mathbf{y}|\mathbf{X}, \mathbf{w}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(y_i - \mathbf{w}^\top \mathbf{x}_i)^2} = \frac{1}{(2\pi)^{n/2}\sigma^n} e^{-\frac{1}{2\sigma^2}\|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2}.$$

## Байесовский подход.

Пусть теперь еще  $\mathbf{w} \sim p(\mathbf{w}|\alpha)$ , тогда  $p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \alpha) = p(\mathbf{y}|\mathbf{X}, \mathbf{w})p(\mathbf{w}|\alpha)$ .

$$p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha) = \frac{p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \alpha)}{p(\mathbf{y}|\mathbf{X}, \alpha)}$$
 – апостериорное распределение.

$$\mathbf{w}_{MAP} = \arg \max_{\mathbf{w}} p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha) = \arg \min_{\mathbf{w}} (-\log p(\mathbf{y}|\mathbf{X}, \mathbf{w}) - \log p(\mathbf{w}|\alpha)).$$

## Примеры:

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

$$\mathbf{w}_{MAP} = \arg \min_{\mathbf{w}} \left( \frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2 + \frac{\tau}{2} \|\mathbf{w}\|^2 \right).$$

- $p(\mathbf{w}|\alpha) = \text{Laplace}(\mathbf{0}, \tau^{-1}\mathbf{I})$

$$\mathbf{w}_{MAP} = \arg \min_{\mathbf{w}} \left( \frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2 + \tau \|\mathbf{w}\|_1 \right).$$

**Вопрос 1:** А как получить ML оценку  $\mathbf{w}_{ML} = \arg \min_{\mathbf{w}} (-\log p(\mathbf{y}|\mathbf{X}, \mathbf{w}))$ ?

**Вопрос 2:** Получили ли мы что-то новое?

# Апостериорное распределение

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

Тогда  $\log p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha) \propto \log p(\mathbf{y}|\mathbf{X}, \mathbf{w}) + \log p(\mathbf{w}|\alpha)$ .

**Нормальное априорное распределение.**

Рассмотрим  $p(\mathbf{w}|\alpha) = N(\mathbf{0}, \tau^{-1}\mathbf{I})$ , тогда

$$-\log p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha) \propto \frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|^2 + \frac{\tau}{2} \|\mathbf{w}\|^2 = \frac{1}{2\sigma^2} \mathbf{y}^\top \mathbf{y} - \frac{1}{\sigma^2} \mathbf{y}^\top \mathbf{X}\mathbf{w} +$$

$$\frac{1}{2\sigma^2} \mathbf{w}^\top \mathbf{X}^\top \mathbf{X}\mathbf{w} + \frac{\tau}{2} \mathbf{w}^\top \mathbf{w} \propto \frac{1}{2} \left( \mathbf{w}^\top (\tau\mathbf{I} + \frac{1}{\sigma^2} \mathbf{X}^\top \mathbf{X}) \mathbf{w} - \frac{2}{\sigma^2} \mathbf{y}^\top \mathbf{X}\mathbf{w} \right) \propto$$

$$\frac{1}{2} (\mathbf{w} - \mathbf{m})^\top \Sigma^{-1} (\mathbf{w} - \mathbf{m}), \text{ где}$$

$$\mathbf{m} = \left( \mathbf{X}^\top \mathbf{X} + \tau\sigma^2\mathbf{I} \right)^{-1} \mathbf{X}^\top \mathbf{y}, \quad \Sigma = \left( \tau\mathbf{I} + \frac{1}{\sigma^2} \mathbf{X}^\top \mathbf{X} \right)^{-1}.$$

Таким образом,  $p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha) \propto e^{-\frac{1}{2}(\mathbf{w}-\mathbf{m})^\top \Sigma^{-1}(\mathbf{w}-\mathbf{m})}$ .

**Вопрос 1:** Что мы можем сказать про распределение  $p(\mathbf{w}|\mathbf{X}, \mathbf{y}, \alpha)$ ?

**Вопрос 2:** Что получилось бы, если бы в качестве  $p(\mathbf{w}|\alpha)$  было взято  $\text{Laplace}(\mathbf{0}, \tau\mathbf{I})$ ?

**Вопрос 3:** Что получилось бы, если бы в качестве  $p(\mathbf{w}|\alpha)$  была взята смесь нормальных распределений  $\sum_k \pi_k N(\mathbf{m}_k, \Sigma_k)$ ?

# Экспоненциальное семейство распределений

Распределение  $p(\mathbf{x})$  в экспоненциальном семействе, если плотность вероятности (функция вероятности) представима в виде

$$p(\mathbf{x}|\Theta) = \frac{1}{Z(\Theta)} h(\mathbf{x}) \exp(\Theta^\top \mathbf{u}(\mathbf{x})).$$

**Вопрос 1:** как выбрать априорное распределение  $p(\Theta)$ , чтобы апостериорное распределение осталось в том же экспоненциальном семействе? (свойство сопряженности правдоподобия  $p(\mathbf{x}|\Theta)$  и априорного распределения  $p(\Theta)$ )

Пусть  $p(\Theta) = \frac{H(\alpha, \mathbf{v})}{Z(\Theta)^\alpha} \exp(\Theta^\top \mathbf{v})$ . Тогда  $p(\Theta|\mathbf{x}) = \frac{p(\mathbf{x}|\Theta)p(\Theta)}{p(\mathbf{x})} =$

$$\frac{1}{Z(\Theta)^n p(\mathbf{x})} \prod_{i=1}^n h(x_i) \exp(\Theta^\top \sum_{i=1}^n \mathbf{u}(x_i)) \cdot \frac{H(\alpha, \mathbf{v})}{Z(\Theta)^\alpha} \exp(\Theta^\top \mathbf{v}) =$$
$$\frac{1}{Z(\Theta)^{n+\alpha}} \left( H(\alpha, \mathbf{v}) \prod_{i=1}^n h(x_i) / p(\mathbf{x}) \right) \exp \left( \Theta^\top \left( \mathbf{v} + \sum_{i=1}^n \mathbf{u}(x_i) \right) \right).$$

**Вопрос 2:** Зачем нам свойство сопряженности?

# Обоснованность (evidence)

Модель  $M_i$ :  $p_i(T, \theta|X) = p_i(T|X, \theta)p(\theta)$

Шаг	Наблюдаемые	Скрытые	Результат
Обучение	$(X_{\text{train}}, T_{\text{train}})$	$\theta$	$p(\theta X_{\text{train}}, T_{\text{train}})$
Контроль	$X_{\text{test}}$	$T_{\text{test}}$	$p(T_{\text{test}} X_{\text{test}}, X_{\text{train}}, T_{\text{train}})$

$$p(\theta|X_{\text{train}}, T_{\text{train}}) = \frac{p(T_{\text{train}}, \theta|X_{\text{train}})}{\int p(T_{\text{train}}, \theta^*|X_{\text{train}})d\theta^*}$$

$$\begin{aligned} p(T_{\text{test}}|X_{\text{test}}, X_{\text{train}}, T_{\text{train}}) &= \int p(T_{\text{test}}, \theta|X_{\text{test}}, X_{\text{train}}, T_{\text{train}})d\theta = \\ &= \int p(T_{\text{test}}|\theta, X_{\text{test}}, X_{\text{train}}, T_{\text{train}})p(\theta|X_{\text{test}}, X_{\text{train}}, T_{\text{train}})d\theta = \\ &= \int p(T_{\text{test}}|\theta, X_{\text{test}})p(\theta|X_{\text{train}}, T_{\text{train}})d\theta \end{aligned}$$

Модель  $M_i$ :  $p_i(T, \theta|X) = p_i(T|X, \theta)p_i(\theta)$

Пусть имеется  $K > 1$  моделей.

**Процесс порождения выборки:**

- Природа выбирает модель из  $K$  доступных моделей с априорными вероятностями  $p(M_i)$ ,  $i = 1, \dots, K$ .
- Для выбранной модели  $i^*$  природа сэмплирует вектор параметров  $\theta^*$  из априорного распределения  $p_{i^*}(\theta)$
- Имея  $i^*$ ,  $\theta^*$  природа выбирает  $X_{\text{train}}$  и сэмплирует  $T_{\text{train}}$  из  $p_{i^*}(T|X_{\text{train}}, \theta^*)$
- $(X_{\text{train}}, T_{\text{train}})$  даны наблюдателю.
- Природа выбирает  $X_{\text{test}}$  и сэмплирует  $T_{\text{test}}$  из  $p_{i^*}(T|X_{\text{test}}, \theta^*)$

## Обоснованность (evidence)

Модель  $M_i$ :  $p_i(T, \theta|X) = p_i(T|X, \theta)p_i(\theta)$

Общая модель  $M$ :  $p(T, \theta, M_i|X) = p(M_i)p_i(\theta)p_i(T|X, \theta)$

$$p(T_{\text{test}}|X_{\text{test}}, X_{\text{train}}, T_{\text{train}}) =$$

$$\sum_{i=1}^K p_i(T_{\text{test}}|X_{\text{test}}, X_{\text{train}}, T_{\text{train}})p(M_i|X_{\text{test}}, X_{\text{train}}, T_{\text{train}}) =$$

$$\sum_{i=1}^K p_i(T_{\text{test}}|X_{\text{test}}, X_{\text{train}}, T_{\text{train}})p(M_i|X_{\text{train}}, T_{\text{train}})$$

$$p(M_i|X_{\text{train}}, T_{\text{train}}) = \frac{p(T_{\text{train}}, M_i|X_{\text{train}})}{P(T_{\text{train}}|X_{\text{train}})} \propto p(T_{\text{train}}, M_i|X_{\text{train}}) =$$

$$\int p(T_{\text{train}}, \theta, M_i|X_{\text{train}})d\theta = p(M_i)p_i(T_{\text{train}}|X_{\text{train}})$$

# 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

$$1) p(d|a, r) = p(d)$$

Поэтому  $p(d|\theta) = \text{Be}(\theta)$ . **Prior** :  $p(\theta) = U[0, 1]$

$$p(T|X) = \int p(T|X, \theta)p(\theta)d\theta = \int_0^1 C_9^0(1-\theta)^9 C_{103}^{97}\theta^6(1-\theta)^{97} C_{151}^{132}\theta^{19}(1-\theta)^{132} C_{63}^{52}\theta^{11}(1-\theta)^{52}d\theta = 2.8 \cdot 10^{-51} CCCC$$

$$2) p(d|a, r) = p(d|a)$$

Поэтому  $p(d|a=0) = \text{Be}(\theta_1)$ ,  $p(d|a=1) = \text{Be}(\theta_2)$ .

**Prior** :  $p(\theta_1) = U[0, 1]$ ,  $p(\theta_2) = U[0, 1]$

$$p(T|X) = \int p(T|X, \theta_1, \theta_2)p(\theta_1)p(\theta_2)d\theta_1d\theta_2 = \int_0^1 \int_0^1 C_9^0(1-\theta_1)^9 C_{103}^{97}\theta_1^6(1-\theta_1)^{97} C_{151}^{132}\theta_2^{19}(1-\theta_2)^{132} C_{63}^{52}\theta_2^{11}(1-\theta_2)^{52}d\theta_1d\theta_2 = 4.7 \cdot 10^{-51} CCCC$$

$$3) p(d|a, r) = p(d|r)$$

Поэтому  $p(d|r = 0) = \text{Be}(\theta_1)$ ,  $p(d|r = 1) = \text{Be}(\theta_2)$ .

**Prior** :  $p(\theta_1) = U[0, 1]$ ,  $p(\theta_2) = U[0, 1]$

$$p(T|X) = 0.27 \cdot 10^{-51} CCCCC$$

$$4) p(d|a, r) = p(d|a, r)$$

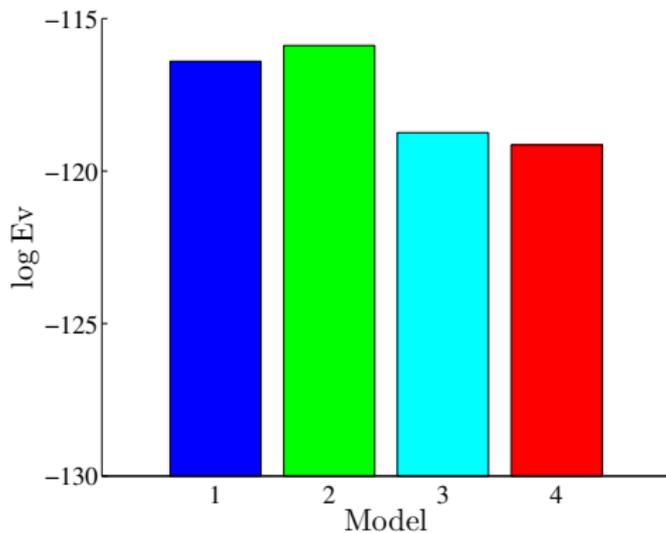
Поэтому  $p(d|a = 0, r = 0) = \text{Be}(\theta_1)$ ,  $p(d|a = 0, r = 1) = \text{Be}(\theta_2)$ ,

$p(d|a = 1, r = 0) = \text{Be}(\theta_3)$ ,  $p(d|a = 1, r = 1) = \text{Be}(\theta_4)$ .

**Prior** :  $p(\theta_1) = U[0, 1]$ ,  $p(\theta_2) = U[0, 1]$ ,

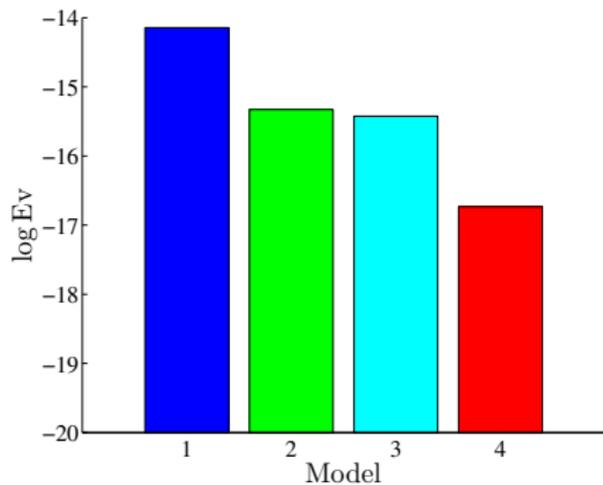
$p(\theta_3) = U[0, 1]$ ,  $p(\theta_4) = U[0, 1]$

$$p(T|X) = 0.18 \cdot 10^{-51} CCCCC$$

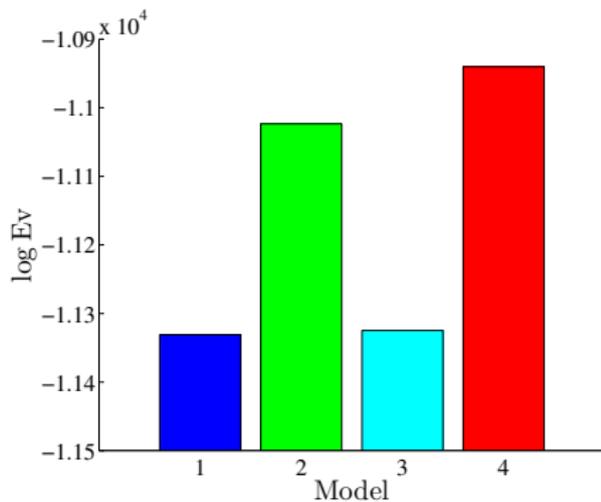


Сравнение обоснованностей, 326 объектов в выборке

# Выбор модели: зависимость от размера выборки



Сравнение обоснованностей, 33  
объекта в выборке



Сравнение обоснованностей, 32600  
объектов в выборке

$$\text{Evidence} : p_i(T|X) = \int p_i(T|X, \theta)p_i(\theta)d\theta$$

$$p_i(\theta|X, T) = \frac{p_i(T|X, \theta)p_i(\theta)}{p(T|X)}.$$

**Предположения:**

- $\theta$  одномерный
- Априорное распределение  $p_i(\theta)$  плоское с шириной  $\Delta\theta_{\text{prior}}$
- Апостериорное распределение  $p_i(\theta|X, T)$  сконцентрировано вокруг  $\theta_{MP}$  с шириной  $\Delta\theta_{\text{post}}$

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

Для  $M$ -мерного  $\theta$ :  $\log p_i(T|X) \approx \log p_i(T|X, \theta_{MP}) + M \log \left( \frac{\Delta\theta_{\text{post}}}{\Delta\theta_{\text{prior}}} \right)$ .

## Пример оптимизации evidence

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

$$t_1, \dots, t_n \sim N(t|\theta, \beta^{-1}), \theta \sim N(\theta|0, \alpha^{-1}).$$

Evidence:  $p(t|\alpha, \beta)$

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

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

$$\alpha^* = \begin{cases} \frac{n^2 \beta}{\beta (\sum_{i=1}^n t_i)^2 - n}, & \beta \left( \sum_{i=1}^n t_i \right)^2 > n, \\ +\infty, & \text{иначе.} \end{cases} \quad \beta^* = \frac{n-1}{\sum_{i=1}^n (t_i - \bar{t})^2}.$$

- 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 Conjugate priors: <https://people.eecs.berkeley.edu/jordan/courses/260-spring10/other-readings/chapter9.pdf>