

Evidence: байесовский подход к выбору моделей

Адуенко Александр

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

Научный руководитель:
д.ф.-м.н., н.с. ВЦ РАН В. В. Стрижов

22 октября 2015 года

- Линейная и логистическая регрессия
- Регуляризаторы: влияние на переобучение и разрешимость
- Априорное распределение, поощряющее разреженность
- Evidence (обоснованность)
- Принцип максимума evidence (обоснованности)
- Evidence для линейной регрессии
- Evidence для логистической регрессии

Линейная и логистическая регрессия

Линейная регрессия

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

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

$$p(\mathbf{y}|\mathbf{X}, \mathbf{w}) = N(\mathbf{y}|\mathbf{X}\mathbf{w}, \beta^{-1}\mathbf{I}).$$

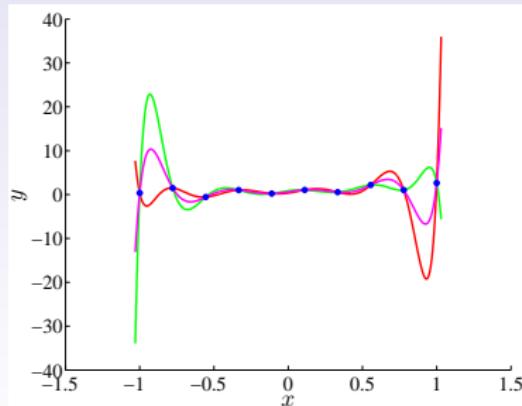
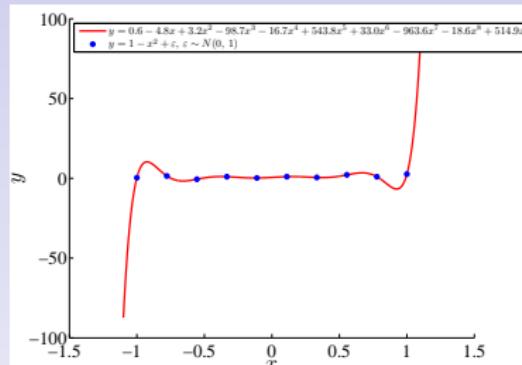
Логистическая регрессия

Два класса: $\{-1, 1\}$.

Для объекта \mathbf{x}_i вероятность принадлежать классу y_i есть

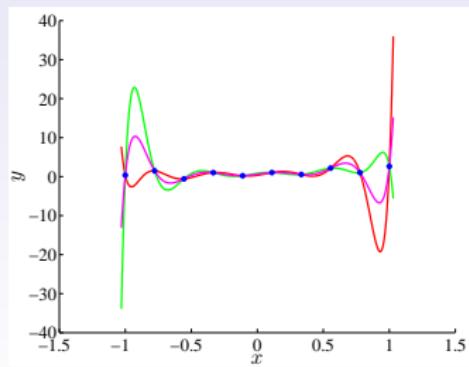
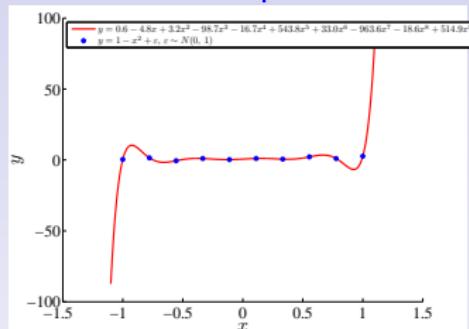
$$p(y_i|\mathbf{x}_i, \mathbf{w}) = \frac{1}{1 + \exp(-y_i \mathbf{w}^\top \mathbf{x}_i)}.$$

$$p(\mathbf{y}|\mathbf{X}, \mathbf{w}) = \prod_{i=1}^n \sigma(y_i \mathbf{w}^\top \mathbf{x}_i).$$



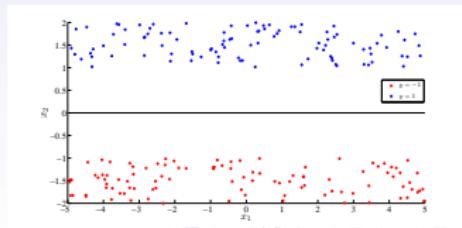
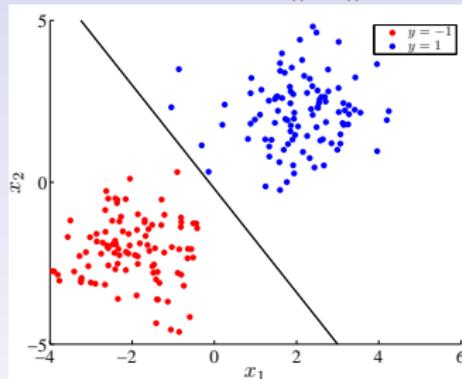
Переобучение и разрешимость

Линейная регрессия и избыточные признаки



Два линейно-разделимых класса для логистической регрессии

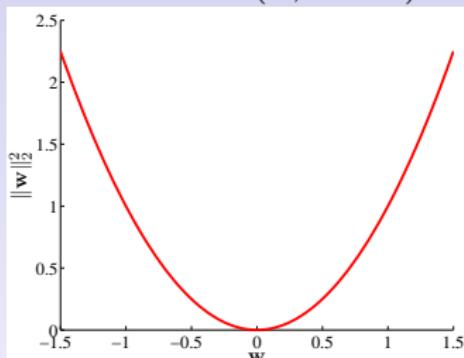
Проблема: оптимальное решение имеет $\|\mathbf{w}\|_2 = \infty$



Регуляризация

Квадратичная регуляризация

Prior: $\mathbf{w} \sim N(\mathbf{0}, \tau^{-1} \mathbf{I})$

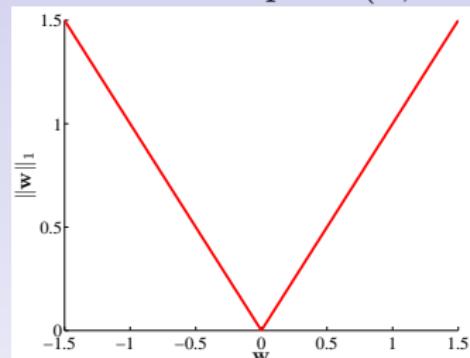


Свойства:

- + Обе задачи становятся разрешимы
- + Для линейной регрессии есть аналитическое решение
- Слабо поощряет разреженность

l_1 -regularization

Prior: $\mathbf{w} \sim Laplace(\mathbf{0}, \tau^{-1})$



Свойства:

- + Обе задачи становятся разрешимы
- Для линейной регрессии нет аналитического решения
- Недифференцируемая целевая функция
- + Поощряет разреженность

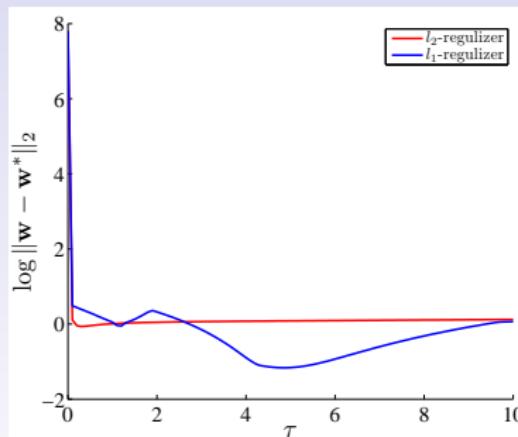
Пример с регрессией на полиномы

Данные

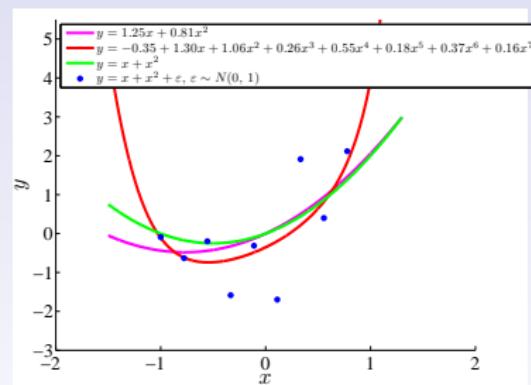
$$y = x + x^2 + \varepsilon, \varepsilon \sim N(0, 1),$$

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

выбраны равномерно на $[-1, 1]$.



Зависимость точности от
параметра регуляризации τ



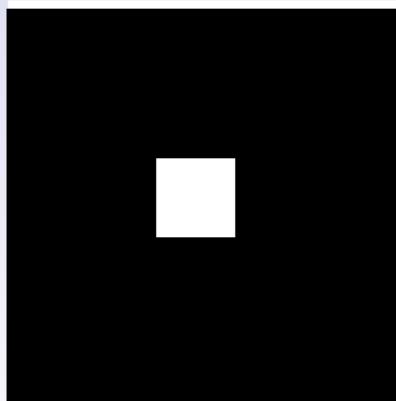
Наилучшие полиномы

Пример "томография"

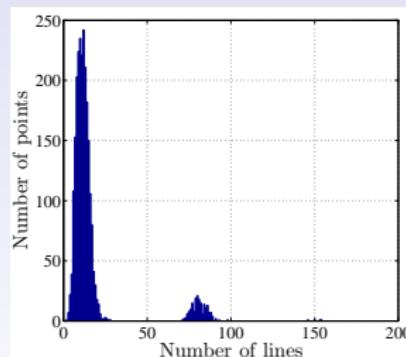
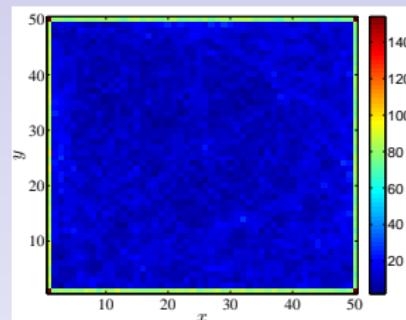
Постановка задачи

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \beta^{-1}\mathbf{I}),$$
$$\mathbf{y} \in \mathbb{R}^m, \mathbf{X} \in \mathbb{R}^{m \times n^2}, m < n^2,$$
$$\mathbf{w} \in [0, 1]^{n^2}.$$

Параметры: $m = 1000, n = 50$.



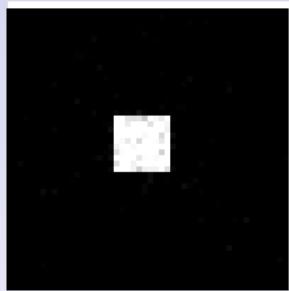
Настоящий \mathbf{w}



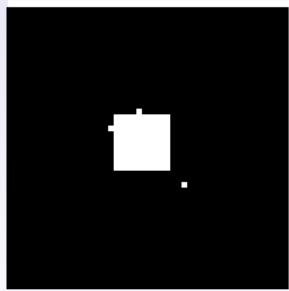
Распределение точек по числу линий

Пример "томография $\beta = 100$

l_1 -регуляризация

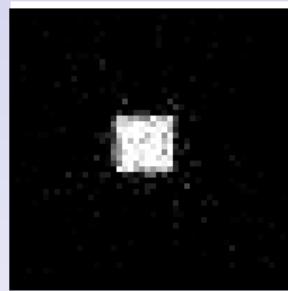


\hat{w}

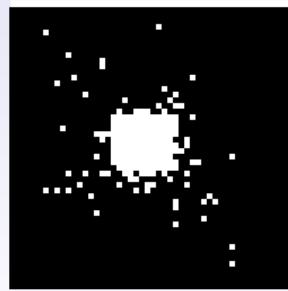


$[\hat{w} > 0.05]$

Квадратическая регуляризация



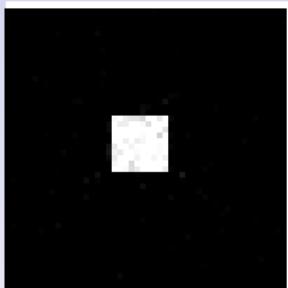
\hat{w}



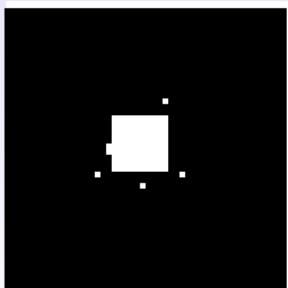
$[\hat{w} > 0.05]$

Пример "томография $\beta = 4$

l_1 -регуляризация



\hat{w}

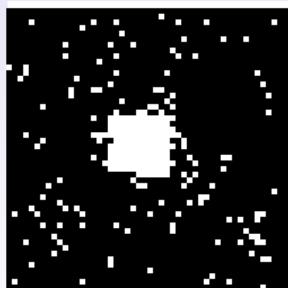


$[\hat{w} > 0.05]$

Квадратическая регуляризация



\hat{w}



$[\hat{w} > 0.05]$

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

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

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

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

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 θ^* из априорного распределения $p_{i^*}(\theta)$
- Имея i^* , θ^* природа выбирает X_{train} и сэмплирует T_{train} из $p_{i^*}(T | X_{\text{train}}, \theta^*)$
- $(X_{\text{train}}, T_{\text{train}})$ даны наблюдателю.
- Природа выбирает X_{test} и сэмплирует T_{test} из $p_{i^*}(T | X_{\text{test}}, \theta^*)$

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

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

Пример выбора модели

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

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

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

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

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

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

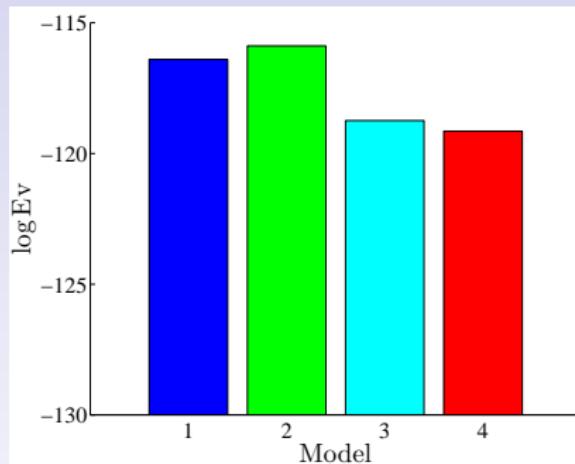
$p(d|a = 1, r = 0) = \text{Be}(\theta_3)$, $p(d|a = 1, r = 1) = \text{Be}(\theta_4)$.

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

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

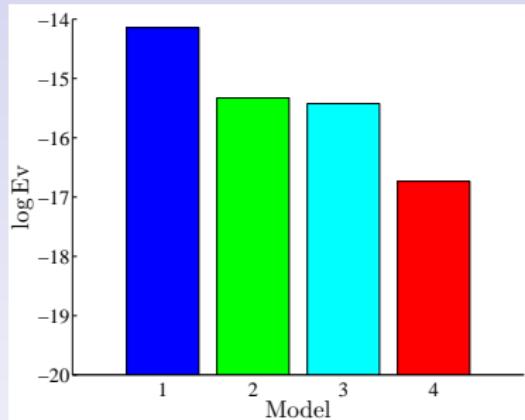
$$p(T|X) = 0.18 \cdot 10^{-51} CCCC$$

Пример выбора модели

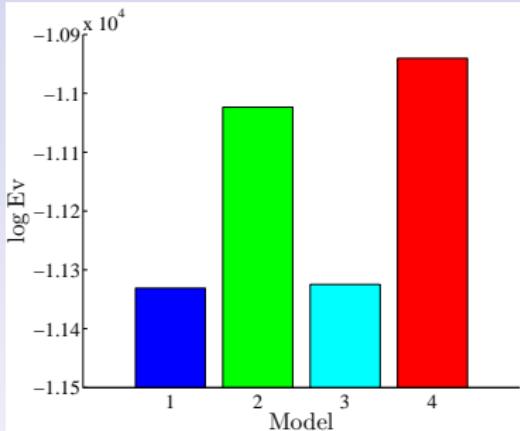


Сравнение обоснованностей, 326 объектов в выборке

Model selection example



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:

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

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

$$T = X\theta + \varepsilon, \quad \theta \sim N(\theta | \mathbf{0}, \alpha^{-1} \mathbf{I}), \quad \varepsilon \sim N(\mathbf{0}, \beta^{-1} \mathbf{I})$$

Совместное правдоподобие:

$$p(T, \theta | X, \alpha, \beta) = p(T | X, \theta, \beta)p(\theta | \alpha).$$

Evidence: $p(T | X, \alpha, \beta)$

$$T | X, \alpha, \beta \sim N(T | \mathbf{0}, \beta^{-1} \mathbf{I} + \alpha^{-1} X X^T)$$

Поэтому: $\log p(T | X, \alpha, \beta) \propto$

$$-\frac{1}{2} \log \det(\beta^{-1} \mathbf{I} + \alpha^{-1} X X^T) - \frac{1}{2} T^T (\beta^{-1} \mathbf{I} + \alpha^{-1} X X^T)^{-1} T.$$

Пример

$y_i = \sin x_i + \varepsilon_i$, x_i равномерно выбрано на $[-\pi/2, \pi/2]$,

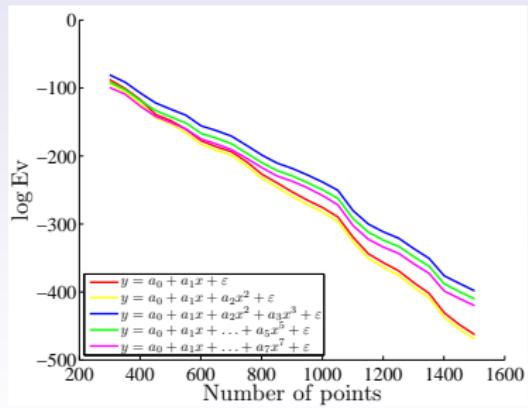
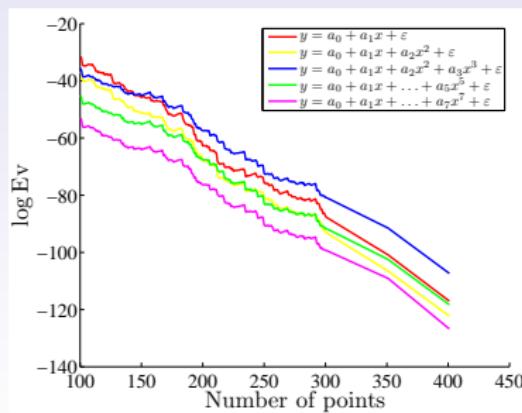
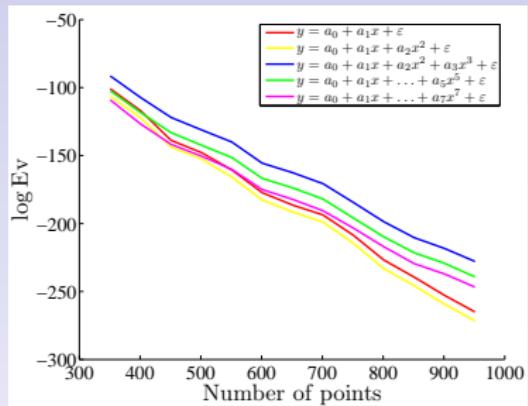
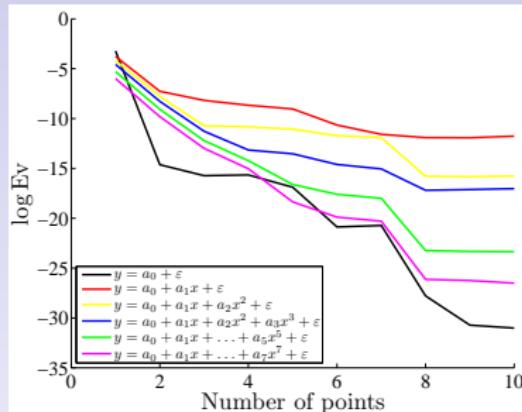
$$\varepsilon_i \sim N(0, \beta^{-1})$$

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

Значения параметров: $\alpha = 0.01$, $\beta = 10$.

Признаки: 1, x_i , x_i^2 , ..., x_i^k , ...

Пример: сравнение моделей



Пример оптимизации evidence

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

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

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

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

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

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

Отбор признаков с помощью evidence для линейной регрессии

$$p(T, \theta | X, A, \beta) = p(T | X, \theta, \beta)p(\theta | A) = N(T | X\theta, \beta^{-1}\mathbf{I})N(\theta | \mathbf{0}, A^{-1}).$$

Максимизация evidence: $p(T_{\text{train}} | X_{\text{train}}, A, \beta) \rightarrow \max_{A, \beta}$.

$$\log p(T_{\text{train}} | X_{\text{train}}, A, \beta) \propto$$

$$-\frac{1}{2} \log \det(\beta^{-1}\mathbf{I} + XA^{-1}X^T) - \frac{1}{2} T^T (\beta^{-1}\mathbf{I} + XA^{-1}X^T)^{-1} T \rightarrow \max_{A, \beta}.$$

Введем $\mu = \beta \Sigma X^T T$, где $\Sigma = (\beta X^T X + A)^{-1}$.

$$\frac{1}{2} \log \det \Sigma + \frac{n}{2} \log \beta + \frac{1}{2} \log \det A - \frac{1}{2} \beta \|T - X\mu\|^2 - \frac{1}{2} \mu^T A \mu \rightarrow \max_{A, \beta}.$$

Итеративный алгоритм максимизации evidence

$$\frac{1}{2} \log \det \Sigma + \frac{n}{2} \log \beta + \frac{1}{2} \log \det A - \frac{1}{2} \beta \|T - X\mu\|^2 - \frac{1}{2} \mu^\top A \mu \rightarrow \max_{A, \beta}.$$

Рассмотрим $f(x, g(x)) \rightarrow \max_x$. Предположим

$\frac{\partial f}{\partial x} = 0$, $\frac{\partial f}{\partial g} = 0$ легко решаются, а $\frac{df}{dx} = 0$ сложно.

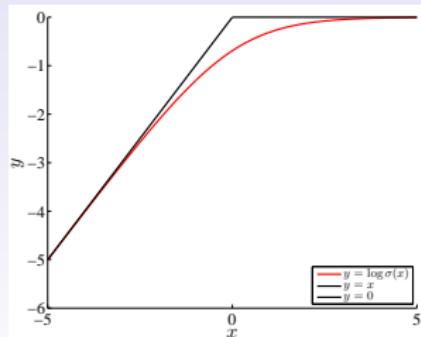
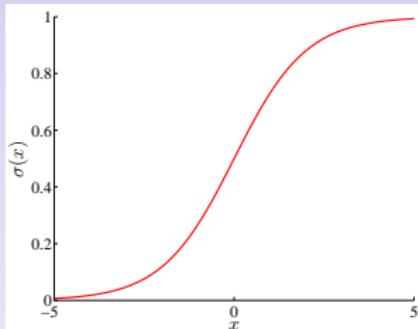
Итерационный процесс: $\begin{cases} x_n = \arg \max_x f(x, g_{n-1}), \\ g_n = \arg \max_g f(x_n, g). \end{cases}$

$$1 \quad \alpha_j^n = \frac{1 - \alpha_j^{n-1} \Sigma_{jj}^{n-1}}{\mu_j^2}$$

$$2 \quad \beta^n = \frac{n}{\|T - X\mu^{n-1}\|^2 + \text{tr}(\Sigma^\top X^\top X)}$$

$$3 \quad \mu^n = \beta^n (\beta^n X^\top X + A^n)^{-1} X^\top T.$$

Evidence для логистической регрессии



$$p(t_i|x_i, \theta) = \frac{1}{1 + \exp(-t\theta^\top x)} = \sigma(t\theta^\top x).$$
$$p(T|X, \theta) = \prod_{i=1}^n p(t_i|x_i, \theta),$$
$$p(\theta|A) = N(\theta|\mathbf{0}, A^{-1})$$

$$A^* = \arg \max_A p(T|X, A) =$$
$$\arg \max_A \int p(T, \theta|X, A) d\theta =$$
$$\arg \max_A \int \underbrace{p(T|X, \theta)p(\theta|A)}_{Q(\theta)} d\theta.$$

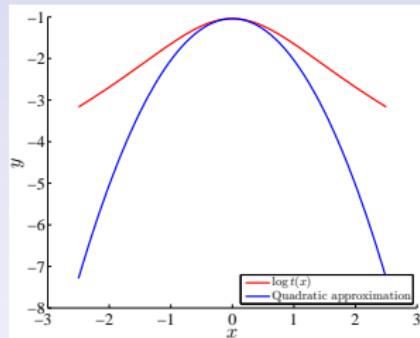
Аппроксимация

$$\log Q(\theta) \approx \log Q(\theta_{MP}) + \frac{1}{2}(\theta - \theta_{MP})^T \nabla \nabla \log Q(\theta_{MP})(\theta - \theta_{MP})$$

$\log p(T|X, A) \approx \log p(T|X, \theta_{MP}) - \frac{d}{2} \log(2\pi) + \frac{1}{2} \log \det(A) + \frac{1}{2} \log \det \Sigma - \frac{1}{2} \theta_{MP}^T A \theta_{MP}$, где $\Sigma^{-1} = X^T R X + A$.

1 $\alpha_j^n = \frac{1 - \alpha_j^{n-1} \Sigma_{jj}^{n-1}}{\theta_{MPj}^2}$

2 $\theta_{MP}^n \leftarrow \text{IRLS}$



Вариационные нижние оценки

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

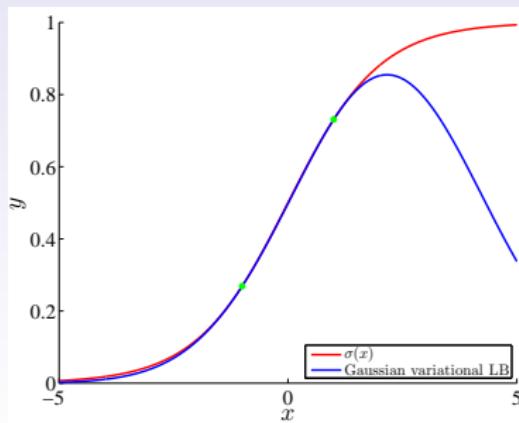
1 $f(x) \geq g(x, \xi) \forall x, \xi$

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

Вместо $f(x) \rightarrow \max$ рассмотрим:

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

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



VLB для сигмоидной функции

$$\begin{aligned}\sigma(x) &\geq \\ \sigma(\eta) \exp \left(\frac{1}{4\eta} (1 - 2\sigma(\eta)) \right. \\ &\quad \left. (x^2 - \eta^2) + \frac{x - \eta}{2} \right)\end{aligned}$$

$$p(T|X, A) \geq LB(A, \eta) \rightarrow \max_{A, \eta}$$

Список литературы

- 1 Mackay, David. The evidence framework applied to classification networks. Neural computation 4.5 (1992): 720-736.
- 2 Bishop, Christopher M. Pattern recognition and machine learning. Vol. 1. New York: Springer, 2006.
- 3 MacKay, David JC. Bayesian methods for adaptive models. Diss. California Institute of Technology, 1992.
- 4 Yuksel, Seniha Esen, Joseph N. Wilson, and Paul D. Gader. Twenty years of mixture of experts. Neural Networks and Learning Systems, IEEE Transactions on 23.8 (2012): 1177-1193.