



Лекция 9. Линейные модели. Часть 2.
Логистическая регрессия

Обзор предыдущей лекции





Кривые обучения

- Bias and variance

Expected value of E_{out} w.r.t. \mathcal{D}

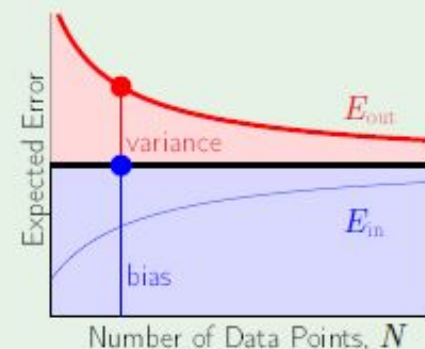
$$= \text{bias} + \text{var}$$



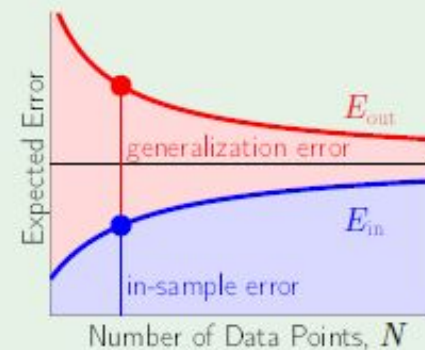
$$g^{(\mathcal{D})}(\mathbf{x}) \rightarrow \bar{g}(\mathbf{x}) \rightarrow f(\mathbf{x})$$

How E_{in} and E_{out} vary with N

B-V:



VC:



- $N \propto$ "VC dimension"

Содержание



- Нелинейное преобразование(обобщение)
- Логистическая регрессия

Нелинейное преобразование



$$\mathbf{x} = (x_0, x_1, \dots, x_d) \xrightarrow{\Phi} \mathbf{z} = (z_0, z_1, \dots, z_{\tilde{d}})$$

$$\text{Each } z_i = \phi_i(\mathbf{x}) \quad \mathbf{z} = \Phi(\mathbf{x})$$

$$\text{Example: } \mathbf{z} = (1, x_1, x_2, x_1x_2, x_1^2, x_2^2)$$

Final hypothesis $g(\mathbf{x})$ in \mathcal{X} space:

$$\text{sign}(\tilde{\mathbf{w}}^\top \Phi(\mathbf{x})) \quad \text{or} \quad \tilde{\mathbf{w}}^\top \Phi(\mathbf{x})$$

Цена, которую мы платим за нелинейное преобразование



$$\mathbf{x} = (x_0, x_1, \dots, x_d) \xrightarrow{\Phi} \mathbf{z} = (z_0, z_1, \dots, z_{\tilde{d}})$$



\mathbf{w}



$$d_{\text{VC}} = d + 1$$



$\tilde{\mathbf{w}}$

$$d_{\text{VC}} \leq \tilde{d} + 1$$

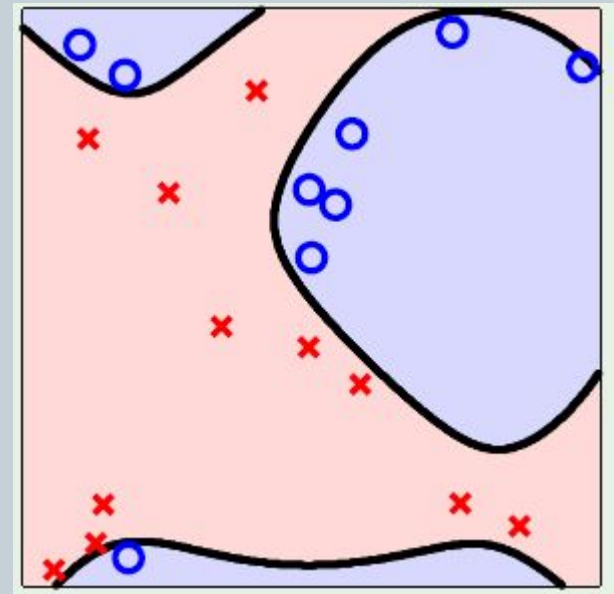
Два линейно неразделимых случая



Первый случай

Два способа решения:

- 1) Использовать линейную модель для $E_{in} > 0$
- 2) Положить $E_{in} = 0$ и использовать нелинейное преобразование в пространстве высокого порядка



Второй случай




- Перейти к преобразованию

$$\mathbf{z} = (1, x_1, x_2, x_1x_2, x_1^2, x_2^2)$$

- Или лучше: $\mathbf{z} = (1, x_1^2, x_2^2)$

- Или: $\mathbf{z} = (1, x_1^2 + x_2^2)$

- Или даже: $\mathbf{z} = (x_1^2 + x_2^2 - 0.6)$



Логистическая регрессия




- 1) Модель
- 2) Мера ошибки
- 3) Алгоритм

Линейные модели

$$s = \sum_{i=0}^d w_i x_i$$


linear classification

$$h(\mathbf{x}) = \text{sign}(s)$$




linear regression

$$h(\mathbf{x}) = s$$



logistic regression

$$h(\mathbf{x}) = \theta(s)$$




Логистическая функция



- «Мягкий порог»

$$\theta(s) = \frac{e^s}{1 + e^s}$$



- Функция θ интерпретируется как вероятность



- Данные (\mathbf{x}, y) , где y бинарная функция, генерируются «шумной» ЦФ

$$P(y | \mathbf{x}) = \begin{cases} f(\mathbf{x}) & \text{for } y = +1; \\ 1 - f(\mathbf{x}) & \text{for } y = -1. \end{cases}$$


- Функция $f : \mathbb{R}^d \rightarrow [0, 1]$ - вероятность

- Изучаем $g(\mathbf{x}) = \theta(\mathbf{w}^\top \mathbf{x}) \approx f(\mathbf{x})$

Мера ошибки. Метод максимального правдоподобия



$$P(y | \mathbf{x}) = \begin{cases} h(\mathbf{x}) & \text{for } y = +1; \\ 1 - h(\mathbf{x}) & \text{for } y = -1. \end{cases}$$



$$P(y | \mathbf{x}) = \theta(y \mathbf{w}^T \mathbf{x})$$

$$\theta(-s) = 1 - \theta(s)$$

Правдоподобие $\mathcal{D} = (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)$ определяется

$$\prod_{n=1}^N P(y_n | \mathbf{x}_n) = \prod_{n=1}^N \theta(y_n \mathbf{w}^T \mathbf{x}_n)$$

Максимизируем правдоподобие



- Минимизируем

$$-\frac{1}{N} \ln \left(\prod_{n=1}^N \theta(y_n \mathbf{w}^\top \mathbf{x}_n) \right)$$

$$= \frac{1}{N} \sum_{n=1}^N \ln \left(\frac{1}{\theta(y_n \mathbf{w}^\top \mathbf{x}_n)} \right)$$

$$E_{\text{in}}(\mathbf{w}) = \frac{1}{N} \sum_{n=1}^N \underbrace{\ln \left(1 + e^{-y_n \mathbf{w}^\top \mathbf{x}_n} \right)}_{e(h(\mathbf{x}_n), y_n)}$$

- «кросс-энтропийная» ошибка


Как минимизировать E_{in} ?



$$E_{in}(\mathbf{w}) = \frac{1}{N} \sum_{n=1}^N \ln \left(1 + e^{-y_n \mathbf{w}^T \mathbf{x}_n} \right)$$

- Метод градиентного спуска

$$\mathbf{w}(1) = \mathbf{w}(0) + \eta \hat{\mathbf{v}}$$




Как выбрать направление $\hat{\mathbf{v}}$



$$\begin{aligned}\Delta E_{\text{in}} &= E_{\text{in}}(\mathbf{w}(0) + \eta \hat{\mathbf{v}}) - E_{\text{in}}(\mathbf{w}(0)) \\ &= \eta \nabla E_{\text{in}}(\mathbf{w}(0))^{\text{T}} \hat{\mathbf{v}} + O(\eta^2) \\ &\geq -\eta \|\nabla E_{\text{in}}(\mathbf{w}(0))\|\end{aligned}$$

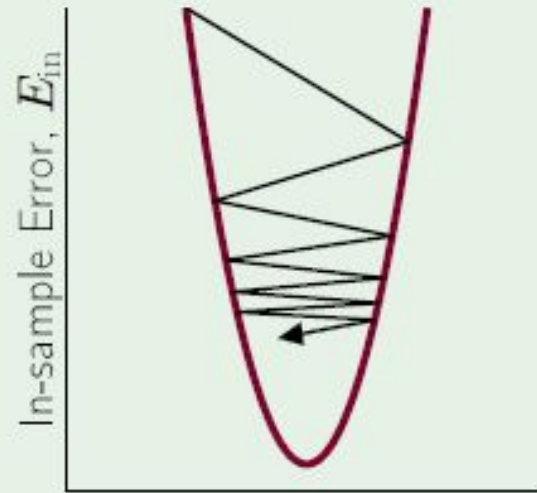
$$\hat{\mathbf{v}} = -\frac{\nabla E_{\text{in}}(\mathbf{w}(0))}{\|\nabla E_{\text{in}}(\mathbf{w}(0))\|}$$

Какая длина шага?



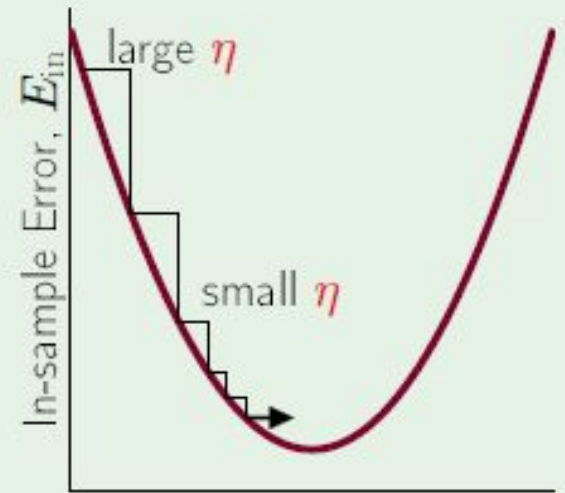
Weights, w

η too small



Weights, w

η too large



Weights, w

variable η – just right

Простое применение



- Вместо

$$\begin{aligned}\Delta \mathbf{w} &= \eta \hat{\mathbf{v}} \\ &= -\eta \frac{\nabla E_{\text{in}}(\mathbf{w}(0))}{\|\nabla E_{\text{in}}(\mathbf{w}(0))\|}\end{aligned}$$

- Используем

$$\Delta \mathbf{w} = -\eta \nabla E_{\text{in}}(\mathbf{w}(0))$$

- С фиксированным η

Алгоритм логистической регрессии

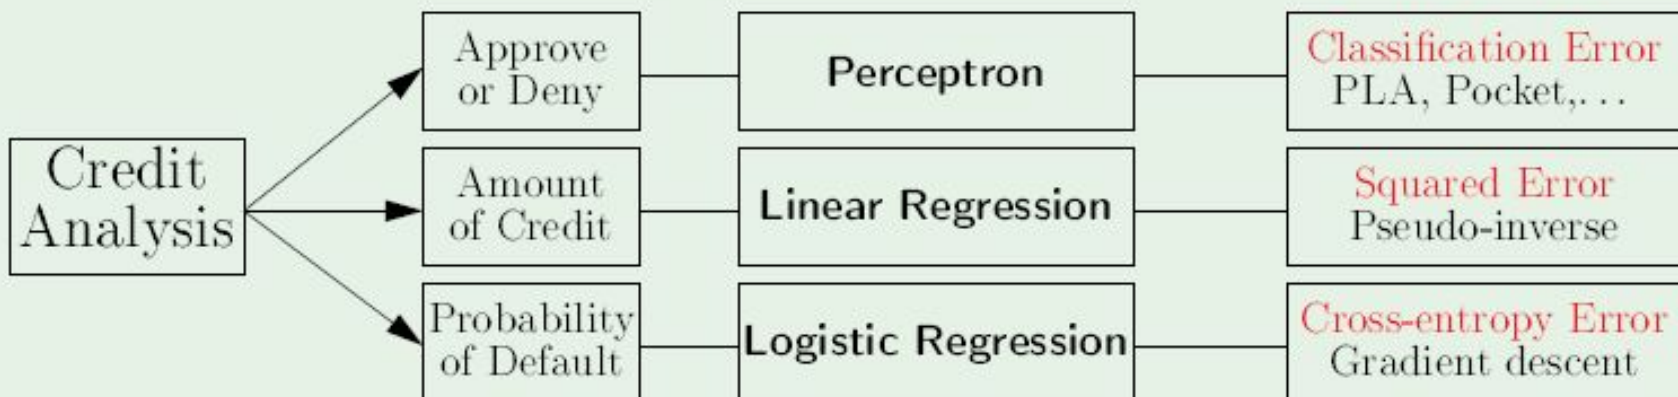


- 1: Initialize the weights at $t = 0$ to $\mathbf{w}(0)$
- 2: **for** $t = 0, 1, 2, \dots$ **do**
- 3: Compute the gradient

$$\nabla E_{\text{in}} = -\frac{1}{N} \sum_{n=1}^N \frac{y_n \mathbf{x}_n}{1 + e^{y_n \mathbf{w}^\top(t) \mathbf{x}_n}}$$

- 4: Update the weights: $\mathbf{w}(t + 1) = \mathbf{w}(t) - \eta \nabla E_{\text{in}}$
- 5: Iterate to the next step until it is time to stop
- 6: Return the final weights \mathbf{w}

Обзор линейных моделей



Использованные источники



- Yaser Abu Mostafa “Learning from Data: Introductory Machine Learning Course”, CalTech University, 2012 . - <https://www.youtube.com/playlist?list=PLnIDYuXHkit4LcWjDeoEwlE57WiGlBs08>