

Wzrosty mazyowe

Wzrosty
neuronowe

dane + etykiety

dane: $\begin{bmatrix} 0 \\ 1 \\ 2 \end{bmatrix}$ 28×28

etykiety: 0 1 2 $f: \mathbb{R}^{28 \times 28} \rightarrow \{0, 1, \dots, 9\}$

regresja:

wzrost miedzi, wzrost ojs, wzrost syne

$$f: \mathbb{R}^2 \rightarrow \mathbb{R}$$

cel: znaleźć

$$f: X \rightarrow Y$$

Chociaż będzie modelować jedną ze zmiennych

Wzrosty
nie neuronowe

klasyfikacja



\mathbb{R}^2

- redukcja wymiarowa



(reinforcement
learning)

Wzrosty przez wzmacnianie

W. Szelużyński

MCTS



Regresja liniowa

(nie będziemy negować się w ten sposób statystyczny...)

$$f: \mathbb{R}^m \rightarrow \mathbb{R}$$

$$\text{model: } f_{\theta}(x_i) = [1, x_i] \cdot \theta = \theta_0 + \sum_{j=1}^m x_{ij} \theta_j, \quad i=1, \dots, n$$

$x_i \in \mathbb{R}^m$

np.


$$X = \begin{bmatrix} 163 & 175 \\ 167 & 190 \\ 173 & 172 \\ 150 & 161 \\ 176 & 181 \end{bmatrix}$$

↑ ↑
wzrost wzrost
mężczy góra

$$Y = \begin{bmatrix} 177 \\ 180 \\ 170 \\ 158 \\ 183 \end{bmatrix}$$

↑
wzrost syna

sieć Galton



$$\tilde{X} = \begin{bmatrix} 1 & 163 & 175 \\ 1 & 167 & 190 \\ 1 & 173 & 172 \\ 1 & 150 & 161 \\ 1 & 176 & 181 \end{bmatrix}$$

$$\tilde{X} \cdot \tilde{X}^T = \begin{bmatrix} \dots & \dots & \dots \\ \dots & \dots & \dots \\ \dots & \dots & \dots \end{bmatrix} \cdot \begin{bmatrix} \dots \\ \dots \\ \dots \end{bmatrix} = \begin{bmatrix} \dots \\ \dots \\ \dots \end{bmatrix}$$

~~Stwierdzenie~~ Minimalizujemy następującą funkcję kosztu:

$$L(y, \hat{y}) = \|y - \hat{y}\|_2^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 =$$


\uparrow \uparrow
 prawdziwa modelowa
 wartości wartości

$$= \sum_{i=1}^n (y_i - (\vartheta_0 + x_i(\vartheta_1, \dots, \vartheta_m)))^2$$

Przy założeniu, że $\text{rank} \begin{pmatrix} \bar{x} \\ X \end{pmatrix} = m+1$, istnieje dokładnie jeden $\hat{\vartheta} \in \mathbb{R}^{m+1}$ minimalizujący L ,

$$\hat{\vartheta} = (\tilde{X}^T \tilde{X})^{-1} \tilde{X}^T Y$$

$$\begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix} \begin{bmatrix} \vdots & \vdots & \vdots & \vdots \end{bmatrix} \begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix} = \begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix} \cdot \begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix} = \begin{bmatrix} \vdots \\ \vdots \\ \vdots \end{bmatrix}$$



Numerycznie lepiej jest użyć innej metody.

Regularyzacja

Ridge: regresja liniowa z funkcją kosztu

$$L(y, \hat{y}) = \|y - \hat{y}\|_2^2 + \lambda \|(\alpha_1, \dots, \alpha_m)\|_2^2$$

↑
Współczynnik $\lambda \geq 0$
regularyzacji - ustalony z góry

$\lambda = 0$: zwykła regresja

metoda iteracyjna:

1) $\vartheta = (\text{wzrost})$

partymy } 2) obliczamy $\left(\frac{\partial L(y, \hat{y})}{\partial \vartheta} \right) = \nabla_{\vartheta} L$

3) $\vartheta := \vartheta - \underbrace{c \cdot \nabla_{\vartheta} L}_{\text{krok stoku}}$



numpy

array \leftarrow (wielowymiarowa) macierz złożona z elementów tego samego typu

np. wektor $(1, 3, 5.5) \in \mathbb{R}^3$ shape = (3,)

$\begin{bmatrix} 1 & 2 & 3 & 4 \\ 5 & 6 & 7 & 8 \end{bmatrix} \in \mathbb{R}^{2 \times 4}$ shape = (2, 4)

$((\mathbb{R}^5)^4)^2$ shape = (2, 4, 5)

$a = \text{np.array}([1, 2, 3, 4, 5])$

$a[1:3] (= [2, 3])$

$a[1:3] = [44, 47] \rightsquigarrow$ $a = [1, 44, 47, 4, 5]$

operacje arytmetyczne na obiektach array:

$$[2, 3] + [4, 15] \rightarrow [8, 15]$$

broadcast: pozwala wykonać operację ~~na~~ w przypadku,
gdzie wyznaczniki nie są takie same

$$a: (15, 7, 1)$$

$$b: (1, 14)$$

$$a: (4, 3)$$

$$b: (4, 1)$$

$$a * b$$