

Modele statystyczne, nadzorowane nauczanie i
przybliżenie funkcji

Model statystyczny dla wspólnego rozkładu
 $\Pr(X, Y)$

$$Y = f(X) + \varepsilon$$

$$\mathbf{E}(\varepsilon) = 0$$

$$f(x) = \mathbf{E}(Y | X = x)$$

Uczenie nadzorowane

$$Y = f(X) + \varepsilon$$

$$\mathcal{T} = (x_i, y_i), i = 1, \dots, N$$


Przybliżanie funkcji

- Pary danych $\{x_i, y_i\}$ utożsamiamy jako punkty w $(p + 1)$ -wymiarowej przestrzeni euklidesowej.
- Przyjmujemy dziedzinę \mathbb{R}^p .
- Liniowe rozwinięcia bazowe $f_\theta(x) = \sum_{k=1}^K h_k(x)\theta_k$,
- Transformacja sigmoidalna wspólna dla modeli sieci neuronowych

$$h_k(x) = \frac{1}{1 + \exp(-x^T \beta_k)}$$

- Inne $x_1^2, x_1x_2, \cos(x_1)$

- Metoda najmniejszych kwadratów



$$\text{RSS}(\theta) = \sum_{i=1}^N (y_i - f_{\theta}(x_i))^2$$

- Estymacja największego prawdopodobieństwa

Próba $y_i, i = 1, \dots, N$ o rozkładzie $\Pr_{\theta}(y)$

Prawdopodobieństwo logarytmiczne $L(\theta) = \sum_{i=1}^N \log \Pr_{\theta}(y_i)$

$$\Pr(Y|X, \theta) = N(f_{\theta}(X), \sigma^2)$$

$$L(\theta) = -\frac{N}{2} \log(2\pi) - N \log \sigma - \frac{1}{2\sigma^2} \sum_{i=1}^N (y_i - f_{\theta}(x_i))^2$$

- Wielomianowe prawdopodobieństwo funkcji regresji $\Pr(G|X)$ dla wyjścia jakościowego G

$$\Pr(G = \mathcal{G}_k | X = x) = p_{k,\theta}(x), k = 1, \dots, K$$

$$L(\theta) = \sum_{i=1}^N \log p_{g_i, \theta}(x_i)$$

Modele regresji strukturalnej

Problematyka

$$\text{RSS}(f) = \sum_{i=1}^N (y_i - f(x_i))^2$$

$$x_i, y_{i\ell}, \ell = 1, \dots, N_i$$