


## Organizační dynamika:



$\vec{w} = (w_0, w_1, \dots, w_n)$  a  $\vec{x} = (x_0, x_1, \dots, x_n)$  kde  $x_0 = 1$ .

## Aktivní dynamika:

funkce sítě:  $y[\vec{w}](\vec{x}) = \vec{w} \cdot \vec{x}$

## Adaptivní dynamika:

- ▶ Dána množina **tréninkových vzorů**

$$\mathcal{T} = \left\{ (\vec{x}_1, d_1), (\vec{x}_2, d_2), \dots, (\vec{x}_p, d_p) \right\}$$

Zde  $\vec{x}_k = (x_{k0}, x_{k1}, \dots, x_{kn}) \in \mathbb{R}^{n+1}$ ,  $x_{k0} = 1$ , je vstup  $k$ -tého vzoru a  $d_k \in \mathbb{R}$  je očekávaný výstup.

Intuice: chceme, aby síť počítala afinní aproximaci funkce, jejíž (některé) hodnoty nám předepisuje tréninková množina.

- ▶ **Chybová funkce:**

$$E(\vec{w}) = \frac{1}{2} \sum_{k=1}^p (\vec{w} \cdot \vec{x}_k - d_k)^2 = \frac{1}{2} \sum_{k=1}^p \left( \sum_{i=0}^n w_i x_{ki} - d_k \right)^2$$

- ▶ Cílem je nalézt  $\vec{w}$ , které minimalizuje  $E(\vec{w})$ .

Dále budeme uvažovat pouze  $n = 1$ .

Hodnota sítě pro daný vstup  $(1, x_1)$  bude  $w_0 + w_1 x_1$

Tedy množina **tréninkových vzorů**

$$\mathcal{T} = \{(\vec{x}_1, d_1), (\vec{x}_2, d_2), \dots, (\vec{x}_p, d_p)\}$$

splňuje  $\vec{x}_k = (1, x_{k1}) \in \mathbb{R}^2$  a  $d_k \in \mathbb{R}$

Zjednodušíme si notaci a **budeme předpokládat**

$$\mathcal{T} = \{(x_1, d_1), \dots, (x_p, d_p)\}$$

kde  $x_k \in \mathbb{R}$  a  $d_k \in \mathbb{R}$  pro  $k = 1, \dots, p$ .

Hodnota sítě s váhami  $w_0, w_1$  pro  $k$ -tý vzor bude  $w_0 + w_1 x_k$ .

# Chybová funkce pro $n = 1$

$$E(w_0, w_1) = \frac{1}{2} \sum_{k=1}^p (w_0 + w_1 x_k - d_k)^2$$

Minimalizujeme  $E$  vzhledem k  $w_0$  a  $w_1$ :

$$\frac{\delta E}{\delta w_0} = 0 \quad \Leftrightarrow \quad w_0 = \bar{d} - w_1 \bar{x} \quad \Leftrightarrow \quad \bar{d} = w_0 + w_1 \bar{x}$$

kde  $\bar{x} = \frac{1}{p} \sum_{k=1}^p x_k$  a  $\bar{d} = \frac{1}{p} \sum_{k=1}^p d_k$

$$\frac{\delta E}{\delta w_1} = 0 \quad \Leftrightarrow \quad w_1 = \frac{\frac{1}{p} \sum_{k=1}^p (d_k - \bar{d})(x_k - \bar{x})}{\frac{1}{p} \sum_{k=1}^p (x_k - \bar{x})^2}$$

(tj.  $w_1 = \text{cov}(d, x) / \text{var}(x)$ )

# Normální rozdělení pravděpodobnosti

Rozdělení spojitě náhodné veličiny (tj. s hodnotami v  $\mathbb{R}$ )

Hustota pravděpodobnosti

$$f(x) = \frac{1}{\sigma \sqrt{2\pi}} \exp\left\{-\frac{(x - \mu)^2}{2\sigma^2}\right\} =: N[\mu, \sigma^2](x)$$


$\mu$  je střední hodnota,  $\sigma^2$  rozptyl

Pokud má náhodná veličina  $X$  normální rozdělení, pak

$$P(x_1 \leq X \leq x_2) = \int_{x_1}^{x_2} p(x)$$

Často se používá k vyjádření náhodné chyby, např. chyby měření, způsobené velkým počtem neznámých a vzájemně nezávislých příčin.

# Normální rozdělení pravděpodobnosti



# Věrohodnost (likelihood)

Fixujme  $\mathcal{T} = \{(x_1, d_1), (x_2, d_2), \dots, (x_p, d_p)\}$

Předpokládejme, že  $d_k$  bylo vygenerováno *náhodně* takto

$$d_k = w_0 + w_1 x_k + \epsilon_k$$

Zde

- ▶  $w_0, w_1$  jsou **neznámé konstanty**
- ▶  $\epsilon_k$  jsou generována náhodně s hustotou pravděpodobnosti  $N[0, \sigma^2]$  kde  $\sigma^2$  je **neznámý rozptyl**

Snadno se ukáže, že hustota pravděpodobnosti, se kterou je vygenerováno  $d_k$  splňuje

$$p(d_k | w_0, w_1, \sigma^2) = N[w_0 + w_1 x_k, \sigma^2](d_k)$$

Předpokládejme, že pro fixní  $w_0, w_1, \sigma^2$  jsou  $\epsilon_1, \dots, \epsilon_p$  generována **nezávisle**. Pak hustota pravděpodobnosti, se kterou jsou vygenerována všechna  $d_1, \dots, d_p$  splňuje

$$p(d_1, \dots, d_p | w_0, w_1, \sigma^2) = \prod_{k=1}^p N[w_0 + w_1 x_k, \sigma^2](d_k)$$

# Maximální věrohodnost (maximum likelihood)

Chceme nalézt  $w_0, w_1, \sigma^2$ , která maximalizují

$$L(w_0, w_1, \sigma^2) := p(d_1, \dots, d_p \mid w_0, w_1, \sigma^2)$$

Z technických důvodů budeme raději maximalizovat

$$\log(L(w_0, w_1, \sigma^2))$$

kde  $\log(y)$  je přirozený logaritmus, tedy funkce inverzní k  $e^x$ .

Zřejmě

$$\begin{aligned} w_0, w_1, \sigma^2 \text{ maximalizují } L(w_0, w_1, \sigma^2) \\ \Leftrightarrow \\ w_0, w_1, \sigma^2 \text{ maximalizují } \log(L(w_0, w_1, \sigma^2)) \end{aligned}$$



# Maximální log-věrohodnost (log-likelihood)

Ukážeme, že

$$\log(L(w_0, w_1, \sigma^2)) = -\frac{p}{2} \log 2\pi - p \log \sigma - \frac{1}{2\sigma^2} \sum_{k=1}^p (d_k - w_0 - w_1 x_k)^2$$

a tedy pro každé  $\sigma^2$

$$w_0, w_1 \text{ maximalizují } L(w_0, w_1, \sigma^2)$$

$\Leftrightarrow$

$$w_0, w_1 \text{ maximalizují } \log(L(w_0, w_1, \sigma^2))$$

$\Leftrightarrow$

$$w_0, w_1 \text{ minimalizují } E(w_0, w_1)$$

Tj. maximalizující  $w_0, w_1$  nezávisí na  $\sigma^2$ .

Maximalizujeme-li vzhledem k  $\sigma^2$ , dostaneme

$$\sigma^2 = \frac{1}{p} \sum_{k=1}^p (d_k - w_0 - w_1 x_k)^2$$

(tj. průměrná čtvercová odchylka od žádaných hodnot  $d_k$ , jak se dalo čekat)

# Věrohodnost (likelihood) - libovolná dimenze dat

Fixujme

$$\mathcal{T} = \{(\vec{x}_1, d_1), (\vec{x}_2, d_2), \dots, (\vec{x}_p, d_p)\}$$

kde  $\vec{x}_k \in \mathbb{R}^{n+1}$  a  $d_k \in \mathbb{R}$  pro  $k = 1, \dots, p$ .

Předpokládejme, že  $d_k$  bylo vygenerováno *náhodně* takto

$$d_k = \vec{w} \cdot \vec{x}_k + \epsilon_k = \sum_{i=0}^n w_k x_{ki} + \epsilon_k$$

Zde

- ▶  $\vec{w}$  je vektor **neznámých vah**
- ▶  $\epsilon_k$  jsou generována náhodně s hustotou pravděpodobnosti  $N[0, \sigma^2]$  kde  $\sigma^2$  je **neznámý rozptyl**

Pro fixní  $\vec{w}, \sigma^2$  jsou  $\epsilon_1, \dots, \epsilon_p$  generována **nezávisle**. Pak  $d_1, \dots, d_p$  jsou generována s hustotou

$$p(d_1, \dots, d_p \mid \vec{w}, \sigma^2) = \prod_{k=1}^p N[\vec{w} \cdot \vec{x}_k, \sigma^2](d_k)$$

# Maximální log-věrohodnost (log-likelihood)

Pro

$$L(\vec{w}, \sigma^2) := p(d_1, \dots, d_p \mid \vec{w}, \sigma^2) = \prod_{k=1}^p N[\vec{w} \cdot \vec{x}_k, \sigma^2](d_k)$$

platí

$$\log(L(\vec{w}, \sigma^2)) = -\frac{p}{2} \log 2\pi - p \log \sigma - \frac{1}{2\sigma^2} \sum_{k=1}^p (d_k - \vec{w} \cdot \vec{x}_k)^2$$

a tedy pro každé  $\sigma^2$

$$\vec{w} \text{ maximalizuje } L(\vec{w}, \sigma^2)$$

$\Leftrightarrow$

$$\vec{w} \text{ maximalizuje } \log(L(\vec{w}, \sigma^2))$$

$\Leftrightarrow$

$$\vec{w} \text{ minimalizuje } E(\vec{w})$$

Tj. maximalizující  $\vec{w}$  nezávisí na  $\sigma^2$ .

$$\text{Max. } \sigma^2 \text{ splňuje } \sigma^2 = \frac{1}{p} \sum_{k=1}^p (d_k - \vec{w} \cdot \vec{x}_k)^2$$