

# Neuronové sítě

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Neuronové sítě

## – Perceptron a lineární separabilita –


Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

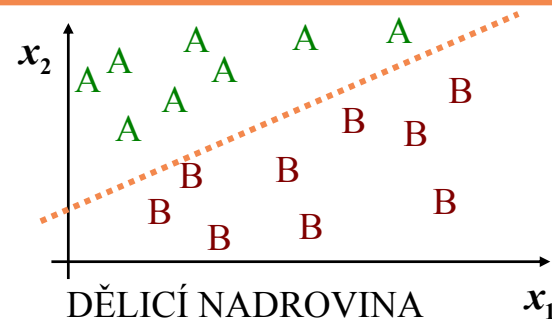
Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

# Formální neuron



$$y = f_h \left( \sum_{i=1}^n w_i x_i + \vartheta \right)$$



$$x_2 = -\frac{w_1}{w_2} x_1 - \frac{\vartheta}{w_2}$$


$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta \geq 0: \text{ TRÍDA A} \\ 0 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta < 0: \text{ TRÍDA B} \end{cases}$$

# Typy přenosových funkcí


## Skoková

$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta \geq 0: \text{ TŘÍDA A} \\ 0 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta < 0: \text{ TŘÍDA B} \end{cases}$$


## Sigmoidální



## Radiální (RBF)



## Waveletová



# Definice formálního neuronu

Neuron s vahami  $(w_1, \dots, w_n) \in R^n$ , prahem  $\vartheta \in R$  a přenosovou funkcí  $f : R^{n+1} \times R^n \rightarrow R$  počítá pro libovolný vstup  $\vec{z} \in R^n$  svůj výstup  $y \in R$  jako hodnotu přenosové funkce v  $\vec{z}$ ,  $f[\vec{w}, \vartheta](\vec{z})$ .

Nejčastěji se uvažuje tzv. sigmoidální přenosová funkce:

$$y = f[\vec{w}, \vartheta](\vec{z}) = f(\xi) = \frac{1}{1 + e^{-\xi}}$$

$\xi = \sum_{i=1}^n z_i w_i + \vartheta$  označuje tzv. potenciál neuronu,  $R$  množinu reálných čísel.

# Definice stavů neuronu

Nechť  $\vec{z}$  označuje vstup neuronu.

– Jestliže  $f[\vec{w}, \vartheta](\vec{z}) = 1$ , říkáme, že je neuron aktivní;

– Jestliže  $f[\vec{w}, \vartheta](\vec{z}) = \frac{1}{2}$ , říkáme, že je neuron tichý;

*Tato skutečnost znamená, že příslušný vstup leží v dělicí nadrovině určené tímto neuronem.*

– Jestliže  $f[\vec{w}, \vartheta](\vec{z}) = 0$ , říkáme, že je neuron pasivní.

# Učení a rozpoznávání

## ◆ Učení:

- **S učitelem - trénovací množina** tvaru [ vstup/požadovaný výstup]
- **Bez učitele (samoorganizace)** - chybí požadovaný výstup

⇒ **Cíl: nastavení (adaptace) synaptických vah**

(např. minimalizací střední kvadratické odchylky)

**Cílová funkce:** např. 
$$\sum_p \sum_j (y_{p,j} - d_{p,j})^2$$

$y$  je skutečný a  $d$  je požadovaný výstup

## ◆ Rozpoznávání:

- **nově předkládaných vstupních vzorů**

⇒ **Cíl: získat odezvu (výstup) neuronové sítě**

# Definice trénovacích vzorů

Pro BP-síť  $B$  s  $n$  vstupními a  $m$  výstupními neurony:

- vstupní vzor označuje vstupní vektor  $\vec{x} \in R^n$  zpracovávaný sítí.
- požadovaný výstup  $\vec{d} = (d_1, \dots, d_m)$  tvoří požadované výstupy neuronů výstupní vrstvy.
- Pro daný vstupní vzor představuje skutečný výstup  $B$  vektor  $\vec{y} = (y_1, \dots, y_m)$  tvořený skutečnými výstupy neuronů výstupní vrstvy.

Trénovací množina  $T$  je množina  $p$  uspořádaných dvojic tvaru vstupní vzor/požadovaný výstup:

$$T = \{ [\vec{x}_1, \vec{d}_1], \dots, [\vec{x}_p, \vec{d}_p] \}.$$



# Perceptron a lineární separabilita (1)

**D:** **Jednoduchý perceptron** je výpočetní jednotka s prahem  $\mathcal{G}$ , která pro  $n$  reálných vstupů  $x_1, x_2, \dots, x_n$  a váhy  $w_1, \dots, w_n$  dává výstup 1, jestliže platí nerovnost

$$\sum_{i=1}^n w_i x_i \geq \mathcal{G} \quad (\text{tzn. pokud } \vec{w} \cdot \vec{x} \geq \mathcal{G}) \text{ a } 0 \text{ jinak.}$$

**Pozn.:** Obdobně pro tzv. **rozšířený váhový a vstupní vektor:**

$$\vec{w} = (w_1, w_2, \dots, w_n, w_{n+1}) \quad ; \quad w_{n+1} = -\mathcal{G}$$

$$\vec{x} = (x_1, x_2, \dots, x_n, 1)$$

$\Rightarrow$  výstup 1, jestliže  $\vec{w} \cdot \vec{x} \geq 0$

# Perceptron a lineární separabilita (2)

## Lineární separabilita:

**D:** Dvě množiny  $A$  a  $B$  se nazývají **lineárně separabilní** v  $n$ -rozměrném prostoru, pokud existuje  $n+1$  reálných čísel  $w_1, \dots, w_n, \vartheta$  takových, že každý bod  $(x_1, x_2, \dots, x_n) \in A$  splňuje  $\sum_{i=1}^n w_i x_i \geq \vartheta$  a každý bod  $(x_1, x_2, \dots, x_n) \in B$  splňuje  $\sum_{i=1}^n w_i x_i < \vartheta$

# Perceptron a lineární separabilita (3)

## Příklad:

- $n=2 \Rightarrow$  14 z 16 možných Boolovských funkcí je „lineárně separabilních“
- $n=3 \Rightarrow$  104 z 256 - '' -
- $n=4 \Rightarrow$  1882 z 65536 - '' -
- Pro obecný případ zatím není znám výraz pro vyjádření odpovídajícího počtu lineárně separabilních funkcí v závislosti na  $n$

# Perceptron a lineární separabilita (4)

## Absolutní lineární separabilita:

**D:** Dvě množiny  $A$  a  $B$  se nazývají **absolutně lineárně separabilní** v  $n$ -rozměrném prostoru, pokud existuje  $n+1$  reálných čísel  $w_1, \dots, w_n, \vartheta$  takových, že každý bod  $(x_1, x_2, \dots, x_n) \in A$  splňuje  $\sum_{i=1}^n w_i x_i > \vartheta$  a každý bod  $(x_1, x_2, \dots, x_n) \in B$  splňuje  $\sum_{i=1}^n w_i x_i < \vartheta$

# Perceptron a lineární separabilita (5)

**V:** Dvě konečné množiny bodů  $A$  a  $B$ , které jsou lineárně separabilní v  $n$ -rozměrném prostoru, jsou také absolutně lineárně separabilní.

Důkaz: Protože jsou množiny  $A$  a  $B$  lineárně separabilní,

existují reálná čísla  $w_1, \dots, w_n, \vartheta$  taková, že platí

$$\sum_{i=1}^n w_i x_i \geq \vartheta \text{ pro všechny body } (x_1, x_2, \dots, x_n) \in A$$

$$\text{a } \sum_{i=1}^n w_i x_i < \vartheta \text{ pro všechny body } (x_1, x_2, \dots, x_n) \in B$$

# Perceptron a lineární separabilita (6)

Dále necht':  $\varepsilon = \max \left\{ \sum_{i=1}^n w_i b_i - \mathcal{G}; (b_1, \dots, b_n) \in B \right\}$   
a zřejmě  $\varepsilon < \varepsilon/2 < 0$

Necht'  $\mathcal{G}' = \mathcal{G} + \frac{\varepsilon}{2}$  (tedy:  $\mathcal{G} = \mathcal{G}' - \frac{\varepsilon}{2}$ )

$\Rightarrow$  Pro všechny body z  $A$  platí, že  $\sum_{i=1}^n w_i a_i - \left( \mathcal{G}' - \frac{1}{2} \varepsilon \right) \geq 0$

To znamená, že  $\sum_{i=1}^n w_i a_i - \mathcal{G}' \geq -\frac{1}{2} \varepsilon > 0$

$\Rightarrow \sum_{i=1}^n w_i a_i > \mathcal{G}' \quad (\forall (a_1, \dots, a_n) \in A) \quad (*)$

# Perceptron a lineární separabilita (6)

Podobně pro všechny body z  $B$

$$\sum_{i=1}^n w_i b_i - \mathcal{G} = \sum_{i=1}^n w_i b_i - \left( \mathcal{G}' - \frac{1}{2} \varepsilon \right) \leq \varepsilon$$

a tedy 
$$\sum_{i=1}^n w_i b_i - \mathcal{G}' \leq \frac{1}{2} \varepsilon < 0 \quad (**)$$

Z (\*) a (\*\*) vyplývá, že množiny  $A$  a  $B$  jsou absolutně lineárně separabilní.

QED

# Dělicí nadrovina – pro rozšířený váhový, resp. příznakový prostor (1)

**D**: Otevřený (uzavřený) pozitivní poloprostor určený  $n$  – rozměrným váhovým vektorem  $\vec{w}$  je množina všech bodů  $\vec{x} \in R^n$ , pro které  $\vec{w} \cdot \vec{x} > 0$  ( $\vec{w} \cdot \vec{x} \geq 0$ )

Otevřený (uzavřený) negativní poloprostor určený  $n$  – rozměrným váhovým vektorem  $\vec{w}$  je množina všech bodů  $\vec{x} \in R^n$ , pro které  $\vec{w} \cdot \vec{x} < 0$  ( $\vec{w} \cdot \vec{x} \leq 0$ )



# Dělicí nadrovina – pro rozšířený váhový, resp. příznakový prostor (2)

**D:** Dělicí nadrovina určená  $n$  – rozměrným váhovým vektorem  $\vec{w}$  je množina všech bodů  $\vec{x} \in R^n$ , pro které  $\vec{w} \cdot \vec{x} = 0$

**Problém:** Nalézt takové váhy, resp. práh, které by umožnily separaci (oddělení) dvou množin vzorů

=> např. **PERCEPTRONOVÝ ALGORITMUS UČENÍ**

**Předpoklad:**

- ♦  $A$  ... množina vstupních vektorů v  $n$  – rozměrném prostoru
- ♦  $B$  ... množina vstupních vektorů v  $n$  – rozměrném prostoru

# Dělicí nadrovina – pro rozšířený váhový, resp. příznakový prostor (3)

## SEPARACE $A$ a $B$ :


⇒ Perceptron by měl realizovat binární funkci  $f_{\vec{w}}$  tak, aby  $f_{\vec{w}}(\vec{x})=1 \quad \forall \vec{x} \in A$  a  $f_{\vec{w}}(\vec{x})=0 \quad \forall \vec{x} \in B$  ( $f_{\vec{w}}$  závisí na vahách, resp. prahu)

- ◆ Chybová funkce odpovídá počtu chybně „zařazených“

vzorů: 
$$E(\vec{w}) = \sum_{\vec{x} \in A} (1 - f_{\vec{w}}(\vec{x})) + \sum_{\vec{x} \in B} f_{\vec{w}}(\vec{x})$$

**Cíl učení:** minimalizace  $E(\vec{w})$  ve váhovém prostoru ( $\Rightarrow$  nejlépe  $E(\vec{w})=0$ )

# Perceptronový algoritmus učení (1)



Hledáme váhový vektor  $\vec{w}$  s pozitivním skalárním součinem pro všechny vektory reprezentované body v  $P$  a se záporným skalárním součinem pro všechny vektory reprezentované body v  $N$

# Perceptronový algoritmus učení (2)

⇒ **OBEZNĚ:** za předpokladu, že  $P$  a  $N$  jsou množiny  $n$  – rozměrných vektorů chceme nalézt takový váhový vektor  $\vec{w}$ , že:

$$\vec{w} \cdot \vec{x} > 0 \quad \forall \vec{x} \in P$$

$$\vec{w} \cdot \vec{x} < 0 \quad \forall \vec{x} \in N$$

- ◆ Perceptronový algoritmus učení začíná s náhodně zvoleným váhovým vektorem  $\vec{w}_0$
- ◆ Pokud existuje vektor  $\vec{x} \in P$  takový, že  $\vec{w} \cdot \vec{x} < 0$ , znamená to, že úhel mezi těmito dvěma vektory je větší než  $90^\circ$ 
  - Váhový vektor je nutné adaptovat ( $\sim$  otočit) ve směru  $\vec{x}$  (tak, aby se tento vektor dostal do „pozitivního“ poloprostoru definovaného  $\vec{w}$ )

# Perceptronový algoritmus učení (3)

- Otočení ve směru  $\vec{x}$  lze provést přičtením  $\vec{x}$  k vektoru  $\vec{w}$
- ◆ Pokud existuje vektor  $\vec{x} \in N$  takový, že  $\vec{w} \cdot \vec{x} > 0$ , znamená to, že úhel mezi těmito dvěma vektory je menší než  $90^\circ$ 
  - Váhový vektor je nutné zadaptovat ( $\sim$  otočit) směrem od  $\vec{x}$  (tak, aby se tento vektor dostal do „negativního“ poloprostoru definovaného  $\vec{w}$ )
  - Otočení směrem od  $\vec{x}$  lze provést odečtením  $\vec{x}$  od vektoru  $\vec{w}$
- ◆ vektory z  $P$  tedy otáčejí váhový vektor opačným směrem než vektory z  $N$
- ◆ Pokud existuje řešení, lze ho nalézt v konečném počtu kroků

# Perceptronový algoritmus učení (4)

**Krok 1:** Inicializace vah malými náhodnými hodnotami  $w_i(0)$   
 $w_i(0)$  ... váha vstupu  $i$  v čase  $0$ ;  $(1 \leq i \leq n+1)$

**Krok 2:** Předložení trénovacího vzoru ve tvaru  
 $(x_1, \dots, x_{n+1})$  ... vstupní vzor a  
 $d(t)$  ..... požadovaný výstup (pro předložený vstup)

**Krok 3:** Výpočet skutečného výstupu (odezvy sítě)

$$y(t) = \operatorname{sgn} \left( \sum_{i=1}^{n+1} w_i(t) x_i(t) \right)$$

**Krok 4:** Adaptace vah podle:

$w_i(t+1) = w_i(t)$	výstup je správný
$w_i(t+1) = w_i(t) + x_i(t)$	výstup je 0 a měl být 1
$w_i(t+1) = w_i(t) - x_i(t)$	výstup je 1 a měl být 0

**Krok 5:** Pokud  $t$  nedosáhl požadované hodnoty, přejdi ke Kroku 2

# Perceptronový algoritmus učení (5)

- ◆ **Heuristika pro počáteční nastavení vah:**

Začít s průměrem „pozitivních“ vstupních vektorů minus průměr „negativních“ vektorů

- ◆ **Modifikace:** parametr učení  $\eta$  ( $0 \leq \eta \leq 1$ )  
(stupeň adaptivity vah ~ plasticita sítě)

- Adaptace vah podle:

$$w_i(t+1) = w_i(t)$$

výstup je správný

$$w_i(t+1) = w_i(t) + \eta x_i(t)$$

výstup je 0 a měl být 1

$$w_i(t+1) = w_i(t) - \eta x_i(t)$$

výstup je 1 a měl být 0

# Konvergence perceptronového algoritmu učení (Rosenblatt, 1959)

**V:** Necht'  $P$  a  $N$  jsou konečné a lineárně separabilní množiny. Potom provede perceptronový algoritmus učení **konečný počet aktualizací** váhového vektoru  $\vec{w}_t$ .

(Pokud se budou cyklicky testovat jeden po druhém vzory z  $P$  a  $N$ , najde perceptronový algoritmus učení po provedení konečného počtu aktualizací váhový vektor, pomocí něhož lze navzájem separovat  $P$  a  $N$ .)

Důkaz: Ukážeme, že perceptronový algoritmus učení přiblíží počáteční váhový vektor  $\vec{w}_0$  dostatečně blízko „hledaného řešení“  $\vec{w}^*$ .



# Konvergence perceptronového algoritmu učení (2)

Tři zjednodušení – bez újmy na obecnosti:

- a) Namísto  $P$  a  $N$  vytvoříme jedinou množinu  
 $P' = P \cup N^-$  ( $N^-$  tvoří „negované“ prvky z  $N$ )
- b) Vektory z  $P'$  budou normalizované  
(Jestliže byl nalezen váhový vektor  $\vec{w}$ , pro který platí  
 $\vec{w} \cdot \vec{x} > 0$ , potom totéž platí i pro každý další vektor  
 $\eta \vec{x}$ ;  $\eta > 0$ .)
- c) Váhový vektor bude také normalizovaný  
(Předpokládané normalizované řešení problému lineární  
separace budeme označovat jako  $\vec{w}^*$ .)

# Konvergence perceptronového algoritmu učení (3)

- ◆ Předpokládejme, že po  $t + 1$  aktualizacích byl vypočten váhový vektor  $\vec{w}_{t+1}$   
→ to znamená, že po  $t$  aktualizacích byl vektor  $\vec{p}_i \in P'$  chybně klasifikován (pomocí váhového vektoru  $\vec{w}_t$ ), a tedy  $\vec{w}_{t+1} = \vec{w}_t + \vec{p}_i$
- ◆ Kosinus úhlu  $\rho$  mezi  $\vec{w}_{t+1}$  a  $\vec{w}^*$  je:

$$\cos \rho = \frac{\vec{w}^* \cdot \vec{w}_{t+1}}{\|\vec{w}_{t+1}\|} \quad (*)$$

# Konvergence perceptronového algoritmu učení (4)

- ◆ Pro výraz v čitateli (\*) víme, že:

$$\vec{w}^* \cdot \vec{w}_{t+1} = \vec{w}^* \cdot (\vec{w}_t + \vec{p}_i) = \vec{w}^* \cdot \vec{w}_t + \vec{w}^* \cdot \vec{p}_i \geq \vec{w}^* \cdot \vec{w}_t + \delta$$

kde  $\delta = \min \{ \vec{w}^* \cdot \vec{p} ; \forall \vec{p} \in P' \}$

- Protože váhový vektor  $\vec{w}^*$  definuje absolutní lineární separaci  $P$  a  $N$ , víme, že  $\delta > 0$

→ indukcí dostáváme:

$$\vec{w}^* \cdot \vec{w}_{t+1} \geq \vec{w}^* \cdot \vec{w}_0 + (t + 1) \delta \quad (**)$$

# Konvergence perceptronového algoritmu učení (5)

- ◆ Zároveň víme, že pro výraz ve jmenovateli (\*) platí:

$$\|\vec{w}_{t+1}\|^2 = (\vec{w}_t + \vec{p}_i) \cdot (\vec{w}_t + \vec{p}_i) = \|\vec{w}_t\|^2 + 2\vec{w}_t \cdot \vec{p}_i + \|\vec{p}_i\|^2$$

- Protože  $\vec{w}_t \cdot \vec{p}_i \leq 0$

( Jinak by nebylo třeba aktualizovat  $\vec{w}_t$  podle  $\vec{p}_i$  . )

- Platí, že:  $\|\vec{w}_{t+1}\|^2 \leq \|\vec{w}_t\|^2 + \|\vec{p}_i\|^2 \leq \|\vec{w}_t\|^2 + 1$

( Protože všechny vektory z  $P'$  byly normalizovány. )

→ indukci dostáváme:

$$\|\vec{w}_{t+1}\|^2 \leq \|\vec{w}_0\|^2 + (t + 1) \quad (***)$$

# Konvergence perceptronového algoritmu učení (6)

- ◆ Z (\*\*\*) a (\*\*\*) dostáváme porovnáním s (\*) nerovnici:

$$\cos \rho \geq \frac{\vec{w}^* \cdot \vec{w}_0 + (t+1)\delta}{\sqrt{\|\vec{w}_0\|^2 + (t+1)}}$$

- pravá strana nerovnice roste proporcionálně k  $\sqrt{t}$ , a protože  $\delta > 0$ , mohla by být libovolně velká
- × protože ale  $\cos \rho \leq 1$ , musí existovat horní mez a počet aktualizací váhového vektoru musí být konečný.

QED

# Příhrádkový algoritmus učení (1)

Gallant, 1990

(aproximuje „ideální lineární separaci“)

## IDEA:

- ◆ Nejlepší váhový vektor nalezený pomocí perceptronového algoritmu učení je „uložen v příhrádce“
- ◆ Současně se pokračuje v aktualizaci váhového vektoru
- ◆ Pokud se najde „lepší“ váhový vektor, nahradí se ním vektor uložený v příhrádce

# Příhrádkový algoritmus učení (2)

## START:

- ◆ Náhodná inicializace váhového vektoru  $\vec{w}$  a uložení váhového vektoru do příhrádky:  $\vec{w}_S = \vec{w}$
- ◆ Nastavení historie uloženého váhového vektoru:  $h_S = 0$

## ITERACE:

- ◆ Aktualizace  $\vec{w}$  pomocí jedné iterace perceptronového algoritmu učení
- ◆ Aktualizace  $h$  podle po sobě jdoucích úspěšně testovaných vektorech
- ◆ Jestliže nastane  $h > h_S$ , nahraď  $\vec{w}_S$  vektorem  $\vec{w}$  a  $h_S$  číslem  $h$
- ◆ Pokračuj v iteraci

# Přihrádkový algoritmus učení (3)

- ◆ Protože se bere v úvahu jen informace o posledně zvolených vzorech, může dojít i k záměně „správného“ váhového vektoru za horší – pravděpodobnost tohoto jevu by však měla klesat s rostoucím počtem iterací
- ◆ Pokud je trénovací množina konečná a složky váhového a příznakových vektorů jsou racionální, lze ukázat, že přihrádkový algoritmus konverguje k optimálnímu řešení s pravděpodobností 1