


# Perceptróny, model neurónovej siete

# Perceptróny, učiaci algoritmus, konvergencia k riešeniu, klasifikácia do dvoch tried



# Trénujúca množina

## Učiace pravidlá pre perceptróny

Predpokladajme, že trénujeme perceptrón pomocou **tréningovej množiny** – dvojice

$$\{ (\mathbf{x}^1, d^1), (\mathbf{x}^2, d^2), \dots, (\mathbf{x}^m, d^m) \},$$

kde  $\mathbf{x}^k \in \mathbb{R}^{n+1}$  je k-tý vstupný vektor (príklad) a  $d^k \in \{-1, +1\}$ ,  $k=1, 2, \dots, m$ ,

je predpokladaná trieda (cieľ) pre k - tý vstupný vektor (poradie dvojíc - náhodné)

# Rosenblattovo pravidlo

## Správna klasifikácia

Cieľ - navrhnúť perceptrón, ktorý pre každý vstupný vektor  $\mathbf{x}^k$  tréningovej množiny dá výstup  $y^k$ , ktorý sa zhoduje s cieľom  $d^k$ .

$$\text{Teda } y^k = \text{sgn}(\mathbf{w}^T \mathbf{x}^k) = d^k, k=1, 2, \dots, m.$$

Riešenie  $\mathbf{w}^*$  - učiace pravidlo (Rosenblatt, 1962):

$$\begin{cases} \mathbf{w}^1 = \text{náhodne vybraté,} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + r_0 (d^k - y^k) \mathbf{x}^k \quad k=1,2,\dots \end{cases} \quad \text{kde } r_0 \text{ je kladná konštanta - učiaci pomer } (0 < r_0 < 1).$$

# Príklad

- Máme dané trénujúce príklady

$m$	$x^m$	$d^m$
1	(2,6)	1
2	(-1,-4)	-1
3	(2,2)	1
4	(1,-3)	-1
5	(-3,-1)	1

Je potrebné nájsť perceptrón, ktorý bude správne klasifikovať uvedené body v rovine.

# Príklad

Krok\Prem.	m	k	$\rho$	$x^m$	$d^m$	$y^m$	$d^m = x^m$	nehoda	w	$m < M$	nehoda = false
1	1	1	0,5					FALSE	(10, -1, -2)		
2				$x^1 = (2,6)$	$d^1 = 1$	$y^1 = \text{sgn}(10 \cdot (-1) + (-1) \cdot 2 + (-2) \cdot 6) = -1$					
3							-	TRUE	$(10, -1, -2) + 1/2(1 \cdot (-1)) \cdot (-1, 2, 6) = (9, 1, 4)$		
4	2										+
5				$x^2 = (-1, -4)$	$d^2 = -1$	$y^2 = \text{sgn}(9 \cdot (-1) + 1 \cdot (-1) + 4 \cdot (-4)) = -1$					
6							+		(9, 1, 4)		
7	3										+
8				$x^3 = (2,2)$	$d^3 = 1$	$y^3 = \text{sgn}(9 \cdot (-1) + 1 \cdot 2 + 4 \cdot 2) = 1$					
9							+		(9, 1, 4)		
10	4										+
11				$x^4 = (1, -3)$	$d^4 = -1$	$y^4 = \text{sgn}(9 \cdot (-1) + 1 \cdot 1 + 4 \cdot (-3)) = -1$					
12							+		(9, 1, 4)		
13	5										+
14				$x^5 = (-3, -1)$	$d^5 = 1$	$y^5 = \text{sgn}(9 \cdot (-1) + 1 \cdot (-3) + 4 \cdot (-1)) = -1$					
15							-	TRUE	$(9, 1, 4) + 1/2(1 \cdot (-1)) \cdot (-1, -3, -1) = (8, -2, 3)$		
16	6										+
17				$x^6 = (-1, 1)$	$d^6 = 1$	$y^6 = \text{sgn}(8 \cdot (-1) + (-2) \cdot (-1) + 3 \cdot 1) = -1$					
18							-	TRUE	$(8, -2, 4) + 1/2(1 \cdot (-1)) \cdot (-1, -1, 1) = (7, -3, 4)$		
19	7										+
20				$x^7 = (6, 1)$	$d^7 = -1$	$y^7 = \text{sgn}(7 \cdot (-1) + (-3) \cdot 6 + 4 \cdot 1) = -1$					
21							+		(7, -3, 4)		
22											-
23	1	2									-

m	$x^m$	$d^m$
1	(2,6)	1
2	(-1,-4)	-1
3	(2,2)	1
4	(1,-3)	-1
5	(-3,-1)	1

- tréningová množina obsahuje príklady zapísané v Tab.
- počiatočné nastavenie váh je  $w = (-1, -2)$ ; hodnota prahu = 10;
- učiaci pomer = 0,5

# Poznámky

- ak riešenie existuje, potom je dosiahnuté po konečnom počte iterácií;
- vo všeobecnosti táto metóda poskytuje nekonečný počet riešení;
- učiace pravidlo pre perceptróny konverguje k jednému z riešení;
- riešenie je citlivé na hodnotu učiaceho pomeru  $\rho$ , ktorá koriguje prezentáciu dvojice;
- počet korekcií  $k_0$  závisí od výberu počiatočných hodnôt vektora váh  $\mathbf{w}^1$ ;
- ak riešenie neexistuje, perceptrón to neodhalí;
- vektor riešenia existuje, vtedy a len vtedy daná tréningová množina je lineárne separovateľná

# Poznámky

- **Veta:** [Novikoff, 1962; Ridgway, 1962; Nilsson, 1965]}
- Ak tréningová množina je lineárne separovateľná, potom učiace pravidlo pre perceptróny konverguje k riešeniu v konečnom počte iterácií.



# Iné pravidlá

## 2. Zovšeobecnenie učiaceho pravidla perceptrónu

a)

$$\begin{cases} \mathbf{W}^1 & \text{- ľubovoľné} \\ \mathbf{W}^{k+1} = \mathbf{w}^k + \rho^k \mathbf{z}^k, & \text{ak} \\ \mathbf{W}^{k+1} = \mathbf{w}^k, & \text{inak} \end{cases} \quad (\mathbf{z}^k)^T \mathbf{w}^k \leq b$$

**Veta :** Ak trénujúca vzorka je separovateľná a platí

1.  $\rho^k \geq 0$

2.  $\lim_{m \rightarrow \infty} \sum_{k=1}^m \rho^k = \infty$

3.  $\lim_{m \rightarrow \infty} \frac{\sum_{k=1}^m (\rho^k)^2}{\left( \sum_{k=1}^m \rho^k \right)^2} = 0$

potom  $\mathbf{w}^k$  konverguje k riešeniu  $\mathbf{w}^*$ , ktoré spĺňa podmienku

$$(\mathbf{z}^i)^T \mathbf{w}^* > b, \text{ pre } i = 1, 2, \dots, m.$$

Ak  $\rho$  je konštanta v  $\rho^k$ , t.j.  $\rho^k = \rho/k$ ,  $\rho^k = k\rho$ , potom učiace pravidlo konverguje v konečnom čase.

# Čo je to neurónová sieť

- **Neurónová sieť** (angl. neural network - NN) - systém vzájomne poprepájaných základných stavebných prvkov, ktoré nazývame **neuróny**.
- Neurónová sieť môžeme považovať za **orientovaný graf**, ktorého vrcholy reprezentujú neuróny a orientované hrany spojenia medzi neurónmi. Graf prepojenia sa nazýva **topológia siete**.
- Základné stavebné prvky dostali názov neuróny práve preto, lebo svojou činnosťou a približne aj štruktúrou pripomínajú skutočné neuróny centrálnej nervovej sústavy (CNS) živých organizmov.
- Úlohou neurónov v CNS je prijímať stimuly z okolia a podnety od ostatných neurónov, s ktorými sú spojené, spracovať ich a šíriť ich ďalej k ďalším neurónom. A práve túto vlastnosť sa snažia simulovať aj neuróny NN.

# Neurón ako základný stavebný prvok

- **Neurón** ako prvok neurónovej siete môže z okolia, alebo od ďalších neurónov prijímať ľubovoľný (konečný) počet vstupov, ktoré do neho vstupujú po **neurónových spojeniach** (tiež nazývaných **neurónové spoje**).
- Predpokladajme, že neurón má **n** vstupov prichádzajúcich od iných neurónov alebo od okolia.
- Nech na i-tom vstupe prichádza informácia  $x_i$  (vo všeobecnosti  $x_i \in \mathbb{R}$ , pre  $i = 1, 2, \dots, n$ ).
- Vstup do neurónu je potom reprezentovaný n - rozmerným vektorom  $\mathbf{x} = (x_1, x_2, \dots, x_n)$ .

# Ako pracuje neurón

- Avšak nie každá stimulujúca informácia má rovnakú hodnotu - váhu, preto je každé spojenie ohodnotené tzv. **váhou spojenia**, ktorú označujeme  $w_i$  ( $w_i$  je reálne číslo,  $i = 1, 2, \dots, n$ ),
- $\theta \in \mathbb{R}$  označuje **prahovú hodnotu neurónu** alebo jednoducho **prah**. Je to vstup do neurónu z okolitého sveta.
- Vnútorňý potenciál neurónu

$$\xi = \sum_{i=1}^n w_i x_i - \theta$$

# Ako pracuje neurón

## Aktivačná funkcia


Pomocou vstupu a **aktivačnej funkcie**  $f$  vypočítame **stav neurónu**  $V$ . Stav neurónu  $V$  je funkciou vstupu  $\xi$ :

$$V = f(\xi)$$

t.j.:

$$V = f\left(\sum_{i=1}^n w_i x_i - \theta\right)$$

# Neurón bez prahu



Ako **aktivačná funkcia** sa najčastejšie používa nelineárna sigmoidálna funkcia monotónne rastúca medzi dvoma asymptotickými hodnotami 0 a 1 :

$$f(x) = \frac{1}{1 + \exp(-x)}$$

Ďalšie aktivačné funkcie môžu byť :

$$f(x) = \text{sgn}(x)$$

- *funkcia s pevným ohraničením*, napr.
- *funkcia lineárna*, napr.
- *funkcia nelineárna*, napr.

$$f(x) = x$$

$$f(x) = \tanh(x)$$

# Ako pracuje neurón

- **Výstup neurónu  $y$**  vypočítame pomocou výstupnej funkcie  $f$  ako funkciu stavu neurónu  $V$ .
- Funkciou  $f$  je veľmi často identita (ďalej budeme stále uvažovať výstupnú funkciu  $f = \text{id}$ ). Z toho vyplýva, že  $y = V$ , a teda výstup neurónu vypočítame :

$$y = f\left(\sum_{i=1}^n w_i x_i - \theta\right)$$

# Topológia neurónovej siete

- **Topológiou neurónovej siete** rozumieme graf prepojenia danej NN. Ide o orientovaný graf, ktorého vrcholy reprezentujú neuróny a orientované hrany spojenia medzi neurónmi.
- Vlastnosti takýchto všeobecných sietí sa ťažko analyzujú, a preto sa študujú najprv siete s nejakými pravidelnými štruktúrami.
- Jednou z nich (doposiaľ asi najviac preskúmanou) je **viacvrstvová štruktúra**. Vo viacvrstvových sieťach vieme neuróny usporiadať do vrstiev, pričom rozlišujeme vrstvu vstupnú, skrytú a výstupnú



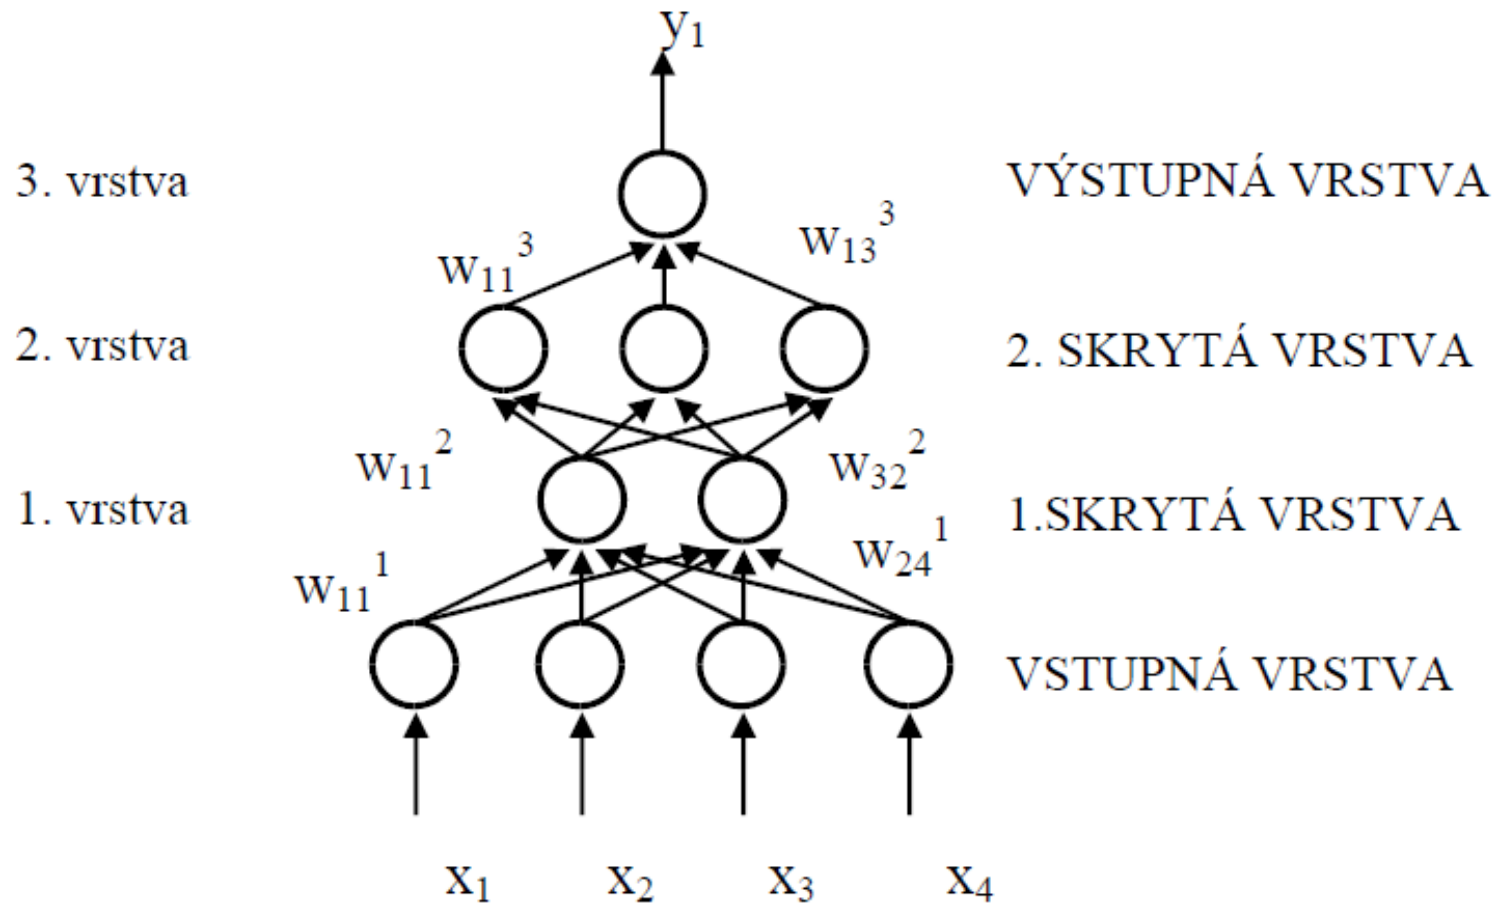
# Topológia neurónovej siete

- Vo všeobecnosti rozdeľujeme topológiu NN do dvoch základných skupín :
- **dopredné NN (angl. feed-forward NN)** - signál sa šíri po orientovaných hranách len jedným smerom - dopredu
- **rekurentné NN (ang. recurrent NN)** - je ťažké rozdeliť neuróny do vrstiev, pretože obsahujú okrem dopredných spojení aj prepojenia, ktoré dovoľujú šíriť signál aj späť - spätné prepojenia, niekedy aj prepojenia samých so sebou.

# Viacvrstvová NS

- Vo **viacvrstvových dopredných sieťach** (angl. feed-forward multilayer networks) sú neuróny v sieti usporiadané do niekoľkých vrstiev (minimálne dvoch), pričom rozoznávame tri typy vrstiev :
  - *vstupná vrstva*
  - *skryté vrstvy*
  - *výstupná vrstva*
- Každá sieť má práve jednu vstupnú, práve jednu výstupnú a ľubovoľný konečný (aj nulový) počet  $r$  skrytých vrstiev. Vstupnú vrstvu označujeme ako 0-tú vrstvu, ďalej sú vrstvy číslované tak, ako za sebou nasledujú. Nech vstupná vrstva je tvorená  $n$  neurónmi, výstupná  $s$  neurónmi a  $s$ -tá skrytá vrstva pozostáva z  $k_s$  neurónov. Hovoríme o **( $r+1$ )-vrstvovej sieti** typu  $n - k_1 - k_2 - \dots - k_r - s$ .
- Každý neurón **vstupnej vrstvy** má práve jeden vstup, ktorý je z vonkajšieho sveta (prah teraz nebudeme započítavať medzi vstupy) a výstup, ktorý pokračuje k ďalším neurónom.

# Štruktúra neurónovej siete



# Činnosť neurónovej siete

- Rozlišujeme dve činnosti neurónovej siete, a to
- **aktívnu prácu** , hovoríme tiež o **aktívnom (pracovnom) móde** a
- o **adaptačnom (učiacom) móde**. Pri *učení* predkladáme sieti vstupy a upravujeme jej parametre za účelom získať na výstupe siete očakávanú odozvu, pri *aktívnej práci* sieť pri danom nastavení parametrov a danom vstupe určí výstupy siete podľa daného algoritmu.

# Aktívny (pracovný) mód

**Sieť pracuje v aktívnom móde**, ak pri danom nastavení parametrov siete, t.j. keď poznáme počet skrytých vrstiev, počet neurónov vo vrstvách a váhy všetkých spojení, hľadá približnú hodnotu celkového výstupu siete,  $f()$ , pričom je daný vstup siete a  $f$  je dané zobrazenie, a to podľa nasledujúceho postupu :

1. **Na vstup siete predložíme  $n$ -rozmerný vektor**, t.j. vstupom  $i$ -teho neurónu ( $i = 1, 2, \dots, n$ ) vstupnej vrstvy je  $x_i$ . Vstupná vrstva nič nepočíta a svoj vstup pošle nezmenený na výstup neurónu a šíri ho po spojeniach do všetkých neurónov nasledujúcej vrstvy.
2. **Každý neurón skrytej vrstvy vypočíta svoj výstup** a pošle ho po svojich spojeniach na vstup každého neurónu nasledujúcej vrstvy.
3. Túto činnosť sieť vykonáva až kým nevypočíta výstupy  $y_i$  ( $i = 1, 2, \dots, s$ ) výstupnej vrstvy. Takto získaný vektor  $(y_1, y_2, \dots, y_s)$  je hľadanou približnou hodnotou výsledku.

# Adaptačný (učiaci) mód

**Adaptačným (učiacim) módom** nazývame takú činnosť siete, pri ktorej sieť nastavuje svoje parametre tak, aby v aktívnom móde pracovala správne, teda aby vypočítaný výstup skutočne odpovedal približnej hodnote zobrazenia  $f$  pre daný vstup.

Neurónové siete vznikli ako zjednodušená abstrakcia CNS živých organizmov, ktoré sa učia na základe príkladov - na určitý druh stimulu formujú určitú odozvu. Množina **príkladov** - dvojíc typu [stimul, žiadaná odozva], je tá množina, na základe ktorej sa učia nielen živé organizmy, ale aj NN.

V terminológii neurónových sietí hovoríme o množine dvojíc

*[vstup, žiadaný výstup]* ako o **tréningovej množine T**.

Keď chceme “naučiť” NN, aby počítala hodnoty zobrazenia  $f$  s ľubovoľnou presnosťou, musíme *určiť zobrazenie  $f$* , a to množinou usporiadaných dvojíc - tréningovou množinou príkladov  $T$ . Na základe príkladov z  $T$  hľadáme sieť tak, aby realizovala zobrazenie  $f$  čo najpresnejšie, a aby čo najviac extrahovala poznatky z množiny  $T$ .

- Spracované na základe knihy prof. Kvasničku a prof. Pospíchala.