



### 3. UMELÉ NEURÓNOVÉ SIETE

# **3.1 Úvod**

## **biologické neuróny, história vývoja**

# Biologické neuróny a motivácia vzniku umelých neurónových sietí (UNS)

## Ľudský mozog :

- 50-100 miliárd neurónov, každý neurón je spojený s asi 10 000 ďalšími neurónmi
- paralelné spracovanie informácií (vnemov, myšlienok, akcií ...)
- funkcia mozgu ? (ako mozog myslí, čo je to vedomie, ...)
- schopnosť sa učiť, modifikovať znalosti, zovšeobecňovať, konkretizovať, autoasociácia / heteroasociácia

- **klasická výpoč. tech. - vopred daný algoritmus (program), pomocou ktorého sa sekvenčne spracovávajú informácie, centrálné riadenie výpočtu**
- **mozog - veľký počet rôznych druhov spracovaní informácií súčasne (nezávisle ?) bez centrálného programu:**
  - vyhodnocovanie obrazu, zvuku, hmatu, teploty ...
  - spracovanie informácií z týchto vnemov, vyhodnocovanie situácie, klasifikácia objektov a javov
  - uvažovanie, učenie sa, rozhodnutie o adekvátnych akciách
  - realizácia akcie, hrubá motorika, jemná motorika
  - súčasné vykonávanie viacerých nezávislých činností
  - popritom riadenie (zložitých) funkcií organizmu

- **Spracovanie znalostí:**
  - *fáza učenia*: získavanie informácií, vytváranie znalostí, prispôsobovanie sa, korigovanie znalostí
  - *fáza vybavovania*: využitie získaných znalostí a schopností
- **biologické neuróny pracujú o 5-6 rádov pomalšie než kremíkové hradlá (ms - ns)**
- **napriek tomu v mnohých ohľadoch je ľudský mozog neporovnateľne výkonnejší než súčasné najvýkonnejšie počítače**

# Príklady činností mozgu človeka


- **vyhodnotenie scény (tváre človeka na neznámom pozadí, priestorová scéna ...) je mozog schopný uskutočniť v zlomku sekundy - počítaču to môže trvať hodiny**
- **hranie basketbalu, riadenie auta v dopravnej špičke, ...**
- **vypočutie, vyhodnotenie a zapamätanie si podstatných informácií z prednášky**
- **podľa odhadov najvýkonnejší počítač v r. 2000 svojim integrovaným výkonom zodpovedal výkonnosti mozgu malého hlodavca**

# Cieľ nášho snaženia

**napodobenie architektúry / funkcií biologických neurónových systémov a ich využitie pre rôzne praktické (technické, výpočtové) účely →**

**"umelé neurónové siete" a im príbuzné systémy**

# Biologický neurón






# Činnosť jedného neurónu

- ak suma všetkých vstupných potenciálov v danom okamžiku presiahne prahovú hodnotu - aktivácia neurónu, jadro po axone vyšle impulz, ktorý je distribuovaný do všetkých synáps
- na výstupe n. sa generujú v priebehu času zhluky impulzov, doba prenosu impulzov medzi neurónmi je 20-40 ms



*zhluky impulzov s frekvenciou 250-1000 impulzov / s,  
frekvencia zhlukov 1-10 zhlukov za sekundu  
(frekvenčná modulácia)*

# Synaptické spojenie dvoch neurónov



## U človeka

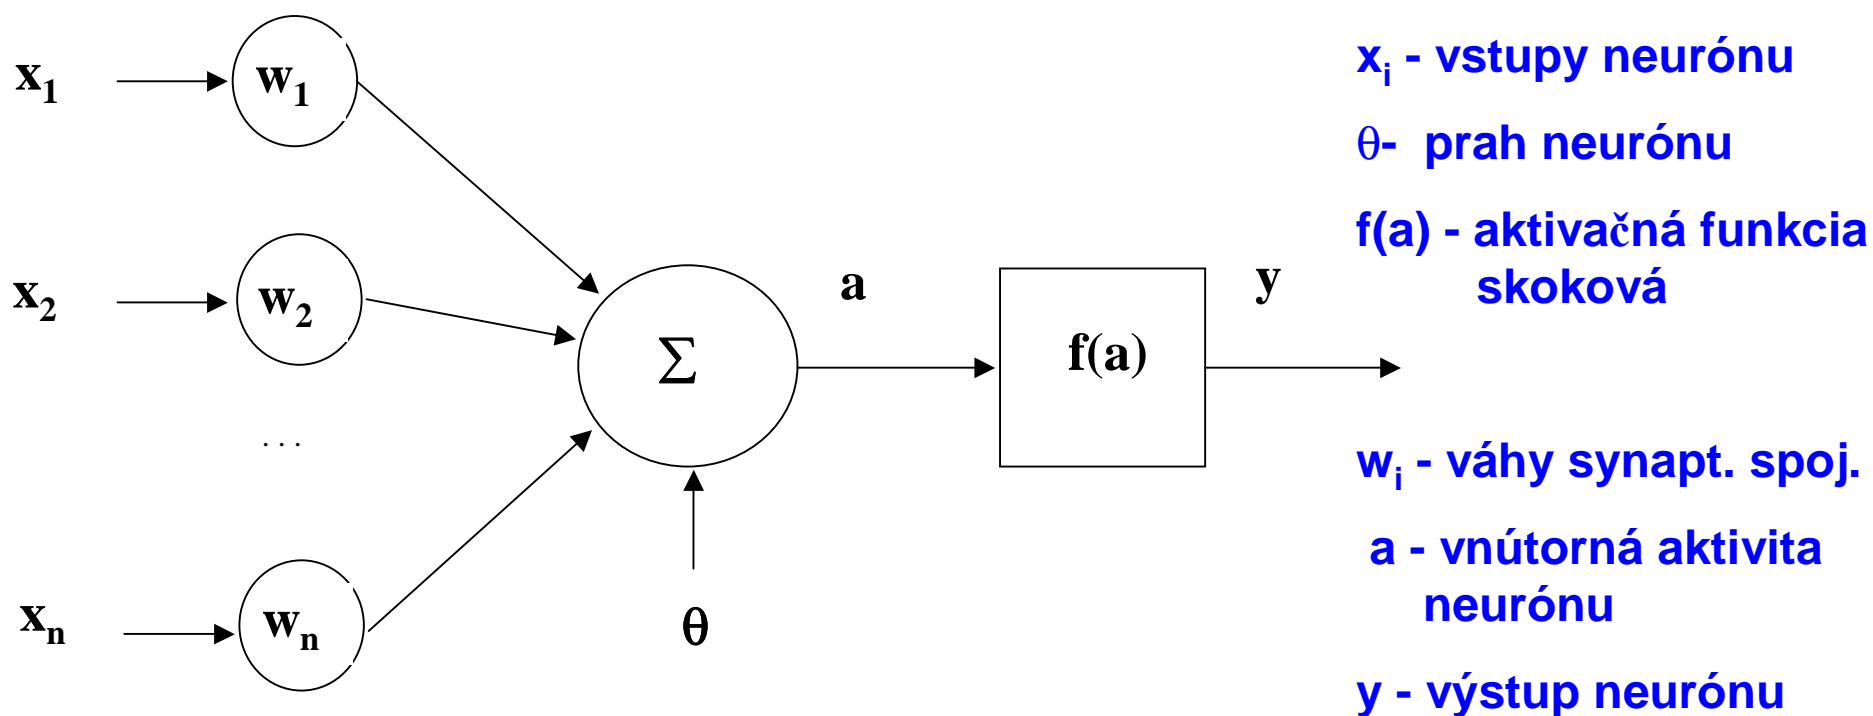
- priemerne okolo 50-100 miliárd neurónov (asi  $7 \cdot 10^4$  neurónov /  $\text{mm}^3$ )
- neuróny vznikajú počas vývoja organizmu v detstve
- denne odumrie okolo 10 000 neurónov - strata informácie (za 75 rokov je to asi 0,2-0,5 % z ich celkového počtu)
- vytvárajú sa nové synaptické spojenia medzi neurónmi, synapsy môžu byť excitačné (vybudzujú n.) alebo inhibičné (utlmujú n.)
- stav na výstupe neurónu (v axone) je závislý od stavu (sumy) jednotlivých vstupov (dendridov), ale aj od stavu prostredia (hormóny, kyslosť, obsah  $\text{O}_2$ , obsah glukózy, drogy, lieky ...)
- činnosť mozgu pozostáva zo súčinnosti všetkých neurónov

## **Ekvivalent hustoty väzieb v mozgu**


**„každý človek na zemi súčasne telefonuje s 18 inými ľuďmi, s každým na inú tému“**

## Stručná história vývoja UNS

- 1.pol. 20. stor. - W.S McCulloch, 1. významná práca o modeli neurónu
- 40. roky, W.S McCulloch, W.Pits - model neurónu v podstate používaný dodnes




- **Rosenblatt (1958) neurónová sieť – „perceptrón“**



- **otázky, aké využitie nájdú neurónové siete, ako realizovať zložité transformácie a proces učenia**
- **Minsky a Papert (1969) – „ohraničenosť použitia n.s. iba na lineárne separovateľné problémy“, tento záver zovšeobecnil na všetky typy n.s.**

## Lineárne separovateľné a neseparovateľné problémy



*Triedy A a B sú lineárne separovateľné,  
triedy C a D nie sú lineárne separovateľné*

<b>AND</b>	<b>0</b>	<b>1</b>
<b>0</b>	<b>0</b>	<b>1</b>
<b>1</b>	<b>1</b>	<b>1</b>

AND - lineárne  
separovateľný  
problém

<b>XOR</b>	<b>0</b>	<b>1</b>
<b>0</b>	<b>0</b>	<b>1</b>
<b>1</b>	<b>1</b>	<b>0</b>

XOR- lineárne  
neseparovateľný  
problém




- "Ak sa nedá riešiť tento jednoduchý problém (XOR), tak sa nedajú riešiť ani oveľa zložitejšie nelineárne problémy" - Minsky a Papert vplyvom sily svojich osobností utlmili iniciatívy v oblasti vývoja n.s. až do 80. rokov 20. Storočia ...
- Až návrh algoritmu "Error Back-Propagation" (algoritmus spätného šírenia chyby, BP) priniesol univerzálne riešenie návrhu parametrov viacvrstvových n.s. Toto spôsobilo renesanciu UNS, použitie aj pre riešenie lineárne neseparovateľných problémov.
- Dnes sú UNS neodmysliteľnou súčasťou riešenia mnohých problémov: nelineárneho modelovania, klasifikácie, rozpoznávania obrazu, signálov ...
- Pri UNS sa využívajú vlastnosti ako: schopnosť sa učiť/adaptovať, odolnosť voči poruchám, schopnosť zovšeobecňovať ...

## Niektoré aplikácie UNS

- Rozpoznávanie, identifikácia obrazu, zvuku, signálov ...
- Hľadanie spoločných charakterisík v rozsiahlych dátových štruktúrach
- Modelovanie a predpovedanie (*predikcia*) výsledkov na základe existujúcich dát (emisie škodlivín, záplavy, erózia, predpoveď zaťaženia el. energie, modelovanie chem., biol. procesov ...).
- Modelovanie a predpovedanie stavu a porúch strojov, diagnostika porúch ...
- Modelovanie a predpovedanie ekonomických a finančných procesov a javov ...
- Modelovanie a predpovedanie bio-medicínskch javov .

## 3.2 Matematický (počítačový) neurón



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

$x_i$  - vstupy neurónu

$\theta$  - prah (citlivosti) neurónu


$\varphi$  - aktivačná funkcia neurónu

$w_i$  - váhy synaptických spojení

$a$  - vnútorná aktivita neurónu


$y$  - výstup neurónu

# Aktivačné funkcie neurónov




$$\begin{aligned}\varphi(a) &= -1 && \text{pre } a < 0 \\ \varphi(a) &= 1 && \text{pre } a \geq 0\end{aligned}$$

**skoková funkcia  $\langle -1; 1 \rangle$**




$$\begin{aligned}\varphi(a) &= 0 && \text{pre } a < 0 \\ \varphi(a) &= 1 && \text{pre } a \geq 0\end{aligned}$$

**skoková funkcia  $\langle 0; 1 \rangle$**




$$\varphi(a) = a$$

**lineárna funkcia**



$$\varphi(a) = \frac{1}{1 + e^{-\beta a}}$$

**sigmoida - logistická f.**




$$\varphi(a) = \operatorname{tgh}(a / 2) = \frac{1 - e^{-a}}{1 + e^{-a}}$$

**hyperbolický tangens**

## 3.3 Rozdelenie neurónových sietí podľa architektúry


### a) Vrstvové štruktúry

#### Jednovrstvové (resp. dvojvrstvové) siete



(napr. sieť štruktúry 2-3) úplné prepojenie, obyčajne - perceptrónové siete so skokovými aktivačnými funkciami za účelom klasifikácie do tried (iba lin. separovateľné problémy)


## Viacvrstvové siete



Viacvrstvové siete obsahujú aspoň jednu skrytú vrstvu. Na obr. je trojvrstvová sieť štruktúry 2-3-1. Vstupná vrstva iba distribuuje vstupné signály, výkonnú funkciu majú len skrytá a výstupná vrstva.

## b) Dopredné a rekurentné vrstvové štruktúry


### Dopredné siete



Dopredné siete obsahujú iba väzby v smere od vstupov k výstupom. Na obr. je dopredná sieť veľkosti 3-2-3.




## Rekurentné siete




Rekurentné siete sú podobné ako dopredné, ale obsahujú aspoň jednu spätnú väzbu v rámci tej istej vrstvy alebo v rámci rôznych vrstiev.

## c) Iné štruktúry sietí



Mriežková štruktúra siete (Kohonenova sieť)



Hopfieldova sieť

## 3.4 Spôsoby učenia (trénovania) neurónových sietí

### 1. Hľadisko rozdelenia podľa miery vplyvu (nadradeného) učiteľa

**1.1 Učenie s učiteľom** - danému vstupu zodpovedá známy výstup (odozva). Parametre siete sa korigujú, aby sa správanie siete približovalo reálnym výstupom modelovaného systému (od učiteľa).

**1.2 Učenie známkované** - učiteľ namiesto správnej odpovede iba ohodnotí adekvátnosť správania sa siete známkou.

**1.3 Samoorganizácia** - sieť sa modifikuje sama reakciou na vstupné dáta bez akéhokoľvek učiteľa.

### 2. Podľa typu učenia

**2.1 Učenie korigujúce chybu** (napr. *Back-propagation*)

**2.2 Súťažné učenie**

**2.3 Hebbovo učenie**

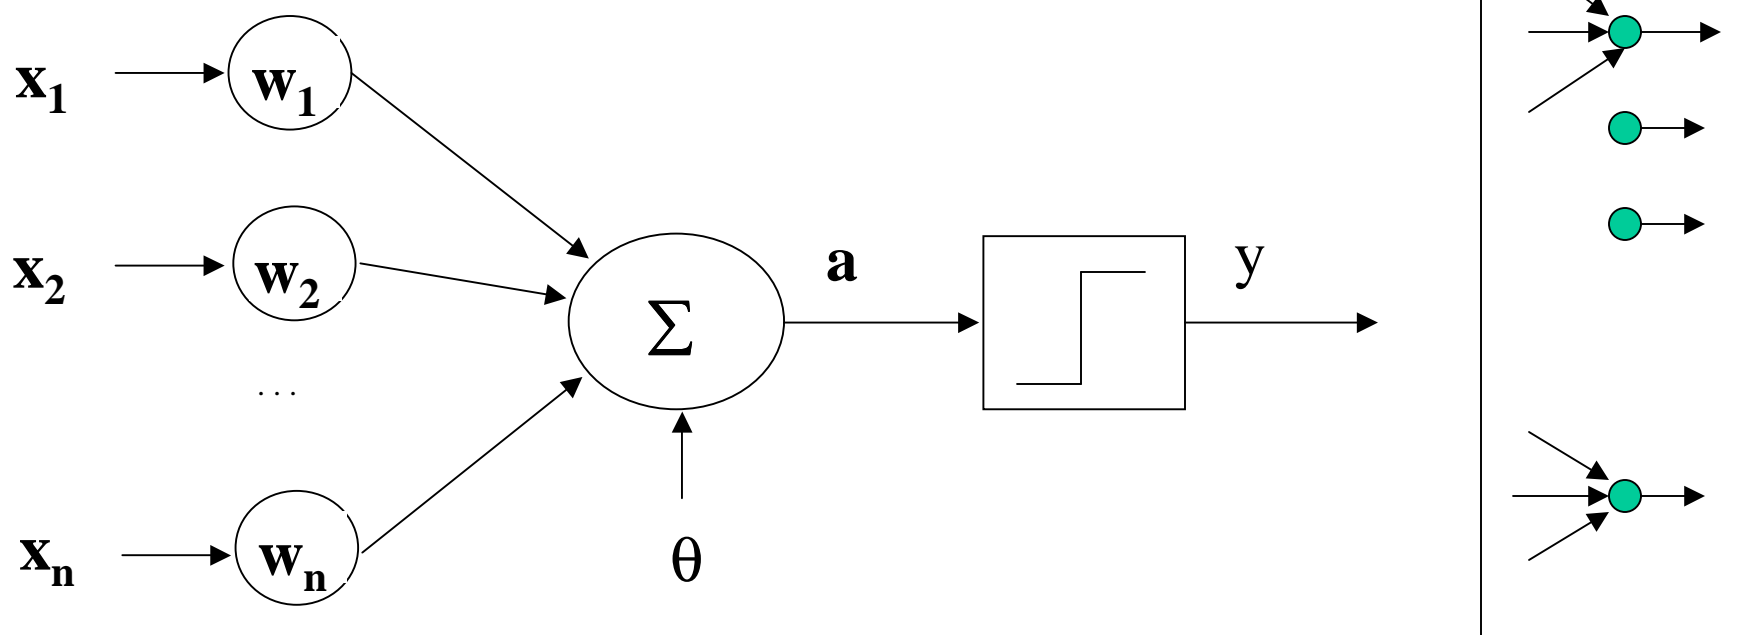
**2.4 *Iné ...***

## **3.5 Vybrané typy sietí, spôsoby ich učenia (trénovania) a ich použite**

9-30

## 3.5.1. Jednovrstvové perceptrónové siete

Tieto siete sa tiež nazývajú "perceptrón". Predstavujú ich neuróny so skokovou aktivačnou funkciou usporiadané do jednej vrstvy.




Táto sieť dokáže iba klasifikovať (kódovať) vstupné objekty (vzorky, vektory) - priradovať ich do tried. Ak výstup  $i$ -teho neurónu  $y_i$  je 1, potom vstupný objekt, charakterizovaný vektorom  $x_i$  patrí do triedy  $C_i$ . Ak výstup je rovný 0 (alebo -1), potom do tejto triedy nepatrí.

## Proces učenia pre 1 neurón

Pre  $n$ -rozmerný priestor ( $n$ -vstupov) sú definované 2 rozhodovacie triedy  $C_1$  a  $C_2$ , ktoré sú reprezentované regiónmi oddelenými hyperrovinou podľa rovnice

$$\sum_{i=1}^n w_i x_i - \theta = 0$$

Cieľom tréningu je naparametrizovať váhy  $w_i$  a prah  $\theta$  aby perceptrón priradil výstup 1 vstupnému objektu z triedy  $C_1$  a výstup -1 pre objekt z triedy  $C_2$ .



## Postup tréovania

1. inicializácia :  $w(0)=0$
2. aktivácia: v kroku  $k$  prived' na vstupy neurónu vektor  $x(k)$
3. výpočet výstupu :  $y(k)= f [ w(k), x(k) ]$  ; kde  $f$  je skoková aktivačná funkcia
4. adaptácia váh :  $w(k+1) = w(k) + \alpha [ d(k) - y(k) ] x(k)$
5. inkrementácia kroku a skok na bod 2

*Kde:  $x(k)=\{x_1, x_2, \dots, x_n, -1\}$  - vstupný tréovací vzor*

*$w(k)=\{w_1, w_2, \dots, w_n, \theta\}$  - parametre neurónu*

*$y$  -aktuálny výstup neurónu*

*$d$  - požadovaná odpoveď neurónu*

*$\alpha$  - parameter rýchlosti učenia,  $0 < \alpha \leq 1$*

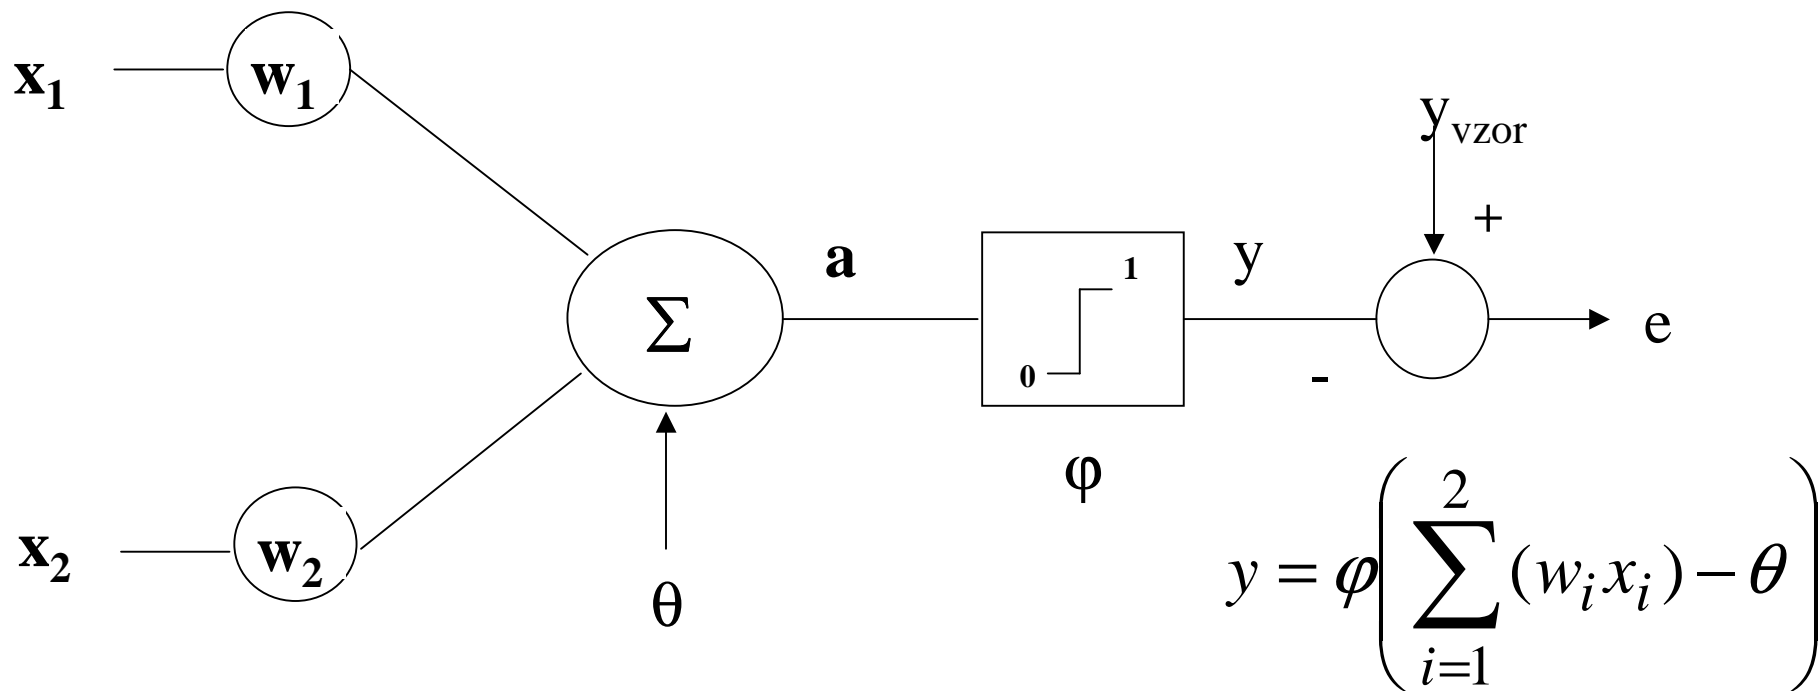


## **Príklad**

### ***učenia 1-vrstvového perceptrónu***

**Úloha: modelovanie logickej funkcie AND**

**Model: 1neurón, 2 vstupy / 1 výstup**



**Logická funkcia AND**  
(trénovacie vzory)

<b>VZOR</b>	<b><math>x_1</math></b>	<b><math>x_2</math></b>	<b><math>y_{\text{vzor}}</math></b>
<b><math>v_1</math></b>	<i>0</i>	<i>0</i>	<i>0</i>
<b><math>v_2</math></b>	<i>0</i>	<i>1</i>	<i>0</i>
<b><math>v_3</math></b>	<i>1</i>	<i>0</i>	<i>0</i>
<b><math>v_4</math></b>	<i>1</i>	<i>1</i>	<i>1</i>

# Postup tréovania

1. Inicializácia: nastavíme váhy  $w_1$  a  $w_2$  na náhodné hodnoty z rozsahu  $(-0,5 ; 0,5)$ .
2. Výpočet výstupu  $y(v)$  pri vstupe vzoru  $v_1$  ( $v_j$ )
3. Výpočet chyby  $e = y_{\text{vzor}} - y$ .
4. Korekcia váh:  $w_{j,\text{new}} = w_j + \Delta w_j$   
 $\Delta w_j = \alpha \cdot x_j \cdot e ; j=1, 2$
5. Chod' na ďalší vzor ( $v_2, v_3, v_4$ )
6. Cyklus krokov 2-5 („epocha“) opakuj, kým chyba modelu nebude dostatočne malá.

Epocha	$x_1$	$x_2$	Požad. $y_v$	Staré $w_1$	Staré $w_2$	Aktual. $y$	Chyba $e$	Nové $w_1$	Nové $w_2$
1	0	0	0	0,3	-0,1	0	0	0,3	-0,1
	0	1	0	0,3	-0,1	0	0	0,3	-0,1
	1	0	0	0,3	-0,1	1	-1	0,2	-0,1
	1	1	1	0,2	-0,1	0	1	0,3	0
2	0	0	0	0,3	0	0	0	0,3	0
	0	1	0	0,3	0	0	0	0,3	0
	1	0	0	0,3	0	1	-1	0,2	0
	1	1	1	0,2	0	1	0	0,2	0
3	0	0	0	0,2	0	0	0	0,2	0
	0	1	0	0,2	0	0	0	0,2	0
	1	0	0	0,2	0	1	-1	0,1	0
	1	1	1	0,1	0	0	1	0,2	0,1
4	0	0	0	0,2	0,1	0	0	0,2	0,1
	0	1	0	0,2	0,1	0	0	0,2	0,1
	1	0	0	0,2	0,1	1	-1	0,1	0,1
	1	1	1	0,1	0,1	1	0	0,1	0,1
5	0	0	0	0,1	0,1	0	0	0,1	0,1
	0	1	0	0,1	0,1	0	0	0,1	0,1
	1	0	0	0,1	0,1	0	0	0,1	0,1
	1	1	1	0,1	0,1	1	0	0,1	0,1

$\alpha=0,1$


$\theta=0,2$

**Príklad:**

***klasifikácia objektov do dvoch tried***

**Jednovrstvová perceptrónová sieť, bez ohľadu na použitý typ aktivačnej funkcie dokáže klasifikovať iba lineárne separovateľné problémy.**

## 3.5.2 Viacvrstvové perceptrónové siete (MLP)



- Obsahujú aspoň jednu skrytú vrstvu neurónov.
- Väčšinou obsahujú spojitú nelineárnu aktivačnú funkciu, (obyčajne sigmoidu alebo hyperbolický tangens).
- Sú schopné aproximovať ľubovoľnú nelineárnu transformáciu.
- Parametrizácia takýchto sietí sa realizuje tréňovaním neurónovej siete algoritmom "spätneho šírenia chyby".


# Laboratórne cvičenie

**1. Klasifikácia objektov do tried**

**2. Použitie viacvrstvovej perceptrónovej siete na rozpoznávanie znakov**



# Rozpoznávanie znakov



## 3-vrstvová MLP sieť

