

Neuronové sítě a možnosti jejich využití

Fiala P., Karhan P., Ptáček J.

Oddělení lékařské fyziky a radiační ochrany

Fakultní nemocnice Olomouc

Osnova

1. Biologický neuron

2. Neuronové sítě

- Umělý neuron - Perceptron
- Jednovrstvá neuronová síť
- Vícevrstvá neuronová síť se zpětným šířením (Back-propagation)

3. Aplikace NS - BP v praxi


- ukázky experimentu

Biologický neuron

- živá buňka zaměřená na sběr, zpracování a přenos informací.
- hustota neuronů v lidském mozku je asi 7 až 8 x 10⁴ na 1 mm²
- na jeden neuron připadá asi 10 až 100 tis spojů s jinými neurony.

Skládá se

- tělo (soma)
 - přicházejí informace ze vstupních větví
- vstupní větve (dendridy)
 - až 10 tis na každý neuron
- výstup (axon)
 - na svém konci mnohočetně rozvětven
 - výstupní signál závisí na vstupech
- propojení neuronů je uskutečněno pomocí dendridů s pomocí speciálních výběžků - **synapsí** na dendridy nebo přímo na těla jiných neuronů.



Biologický neuron

Synapse (elektrická, chemická)


- přes synapse se přenášejí vzruchy mezi neurony
- dovolují měnit hodnotu signálu, které přes něj procházejí
- v místě synaptické štěrbině dochází ke změně koncentrace kladných a záporných iontů a tím propustnost membrány vně a uvnitř buňky → **změna membránového potenciálu**

Charakter synaptické vazby

- inhibiční → snižuje membránový potenciál
- excitační → zvyšuje membránový potenciál

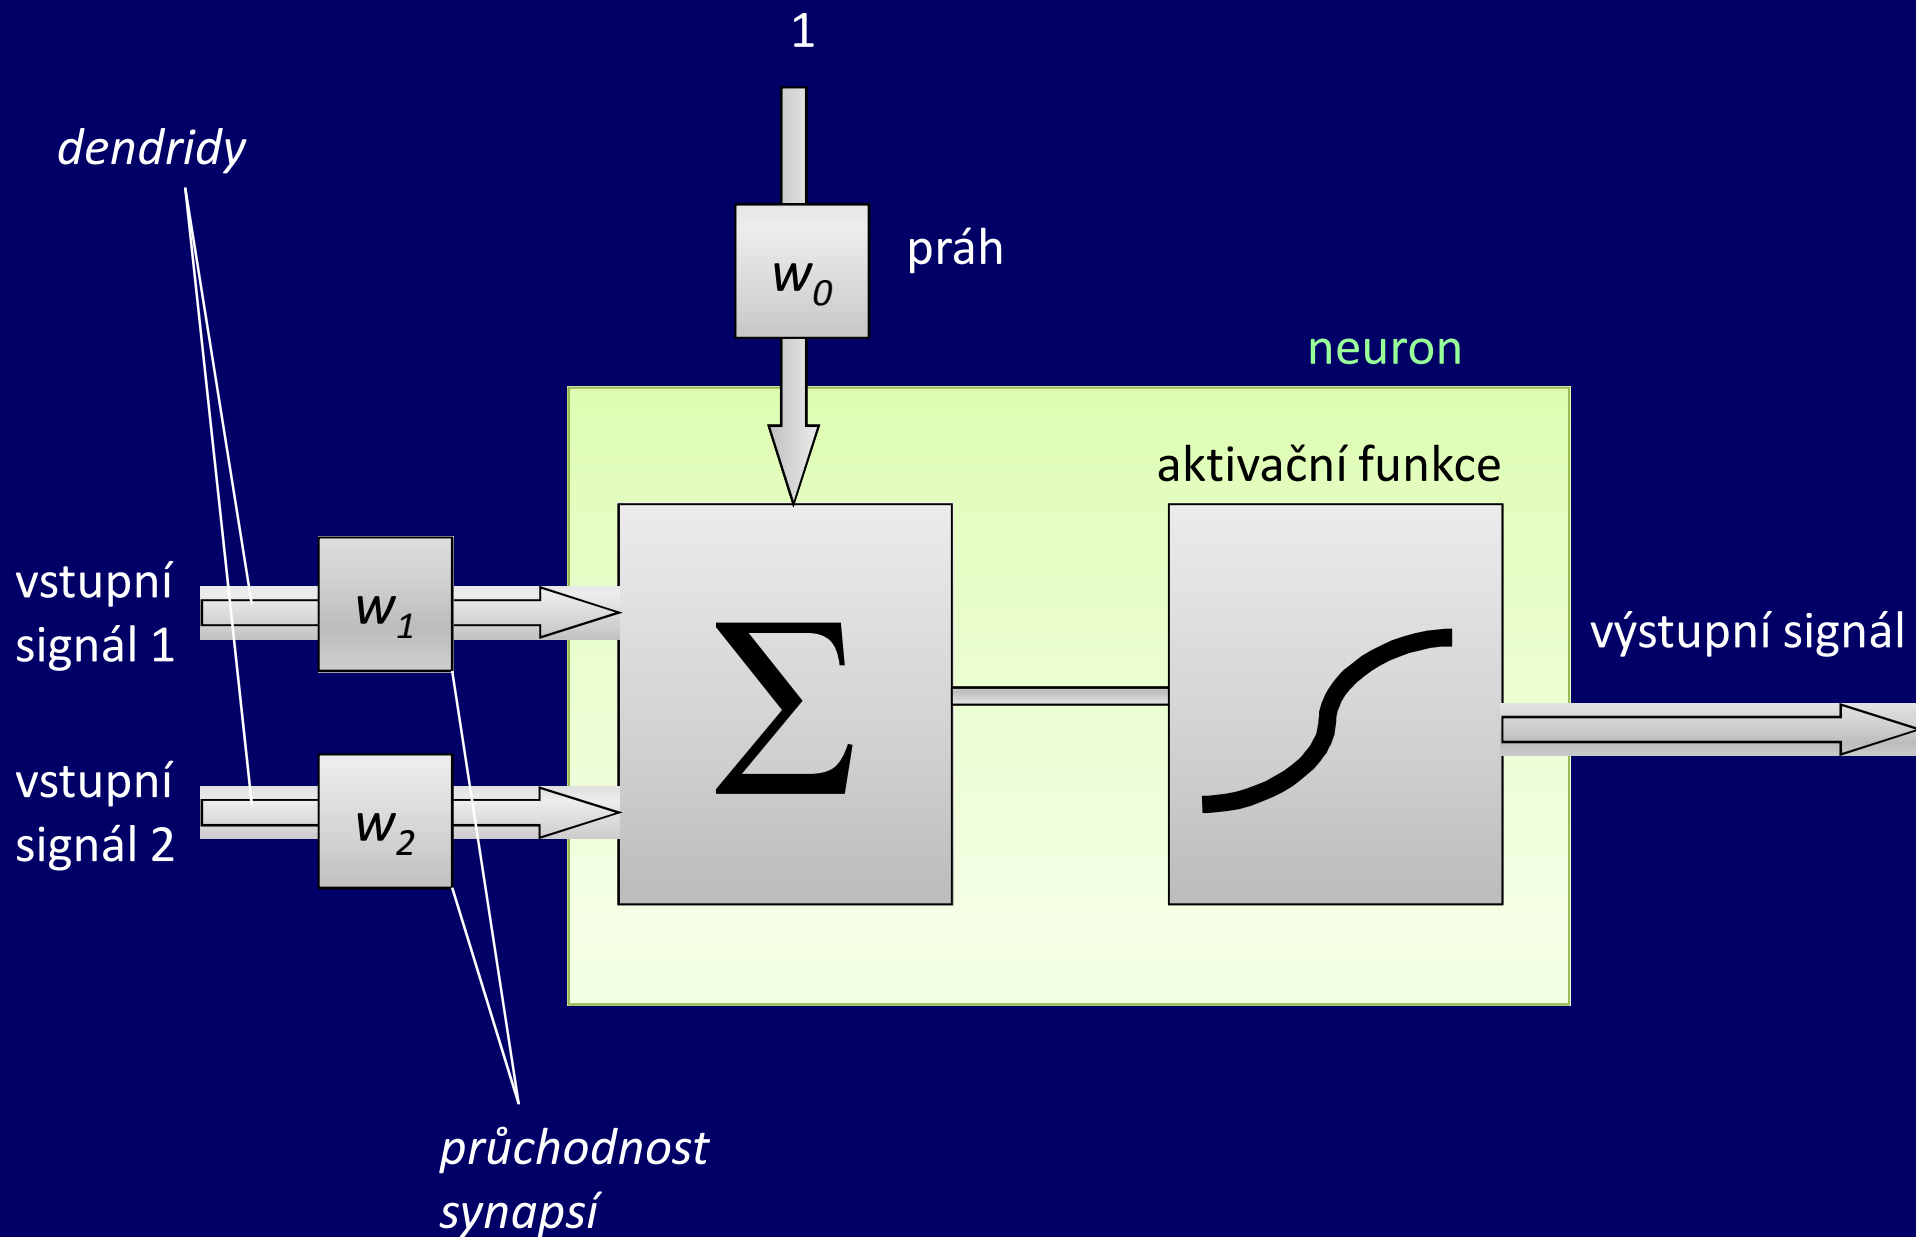
Aktivace neuronu - po překročení daného prahu membránového potenciálu (výstupní signál)

Výstupní signál – nelineární transformace (aktivační funkce) všech vstupních podnětů



Biologický neuron

schéma neuronu



Umělý neuron – Perceptron

(binární klasifikátor)

vstupy $x = [x_1, x_2, x_3, \dots, x_n]$

váhy $w = [w_1, w_2, w_3, \dots, w_n]$

práh w_0 (při fiktivním vstupu $x_0=1$)

vzor

aktivace neuronu

α

charakteristika neuronu

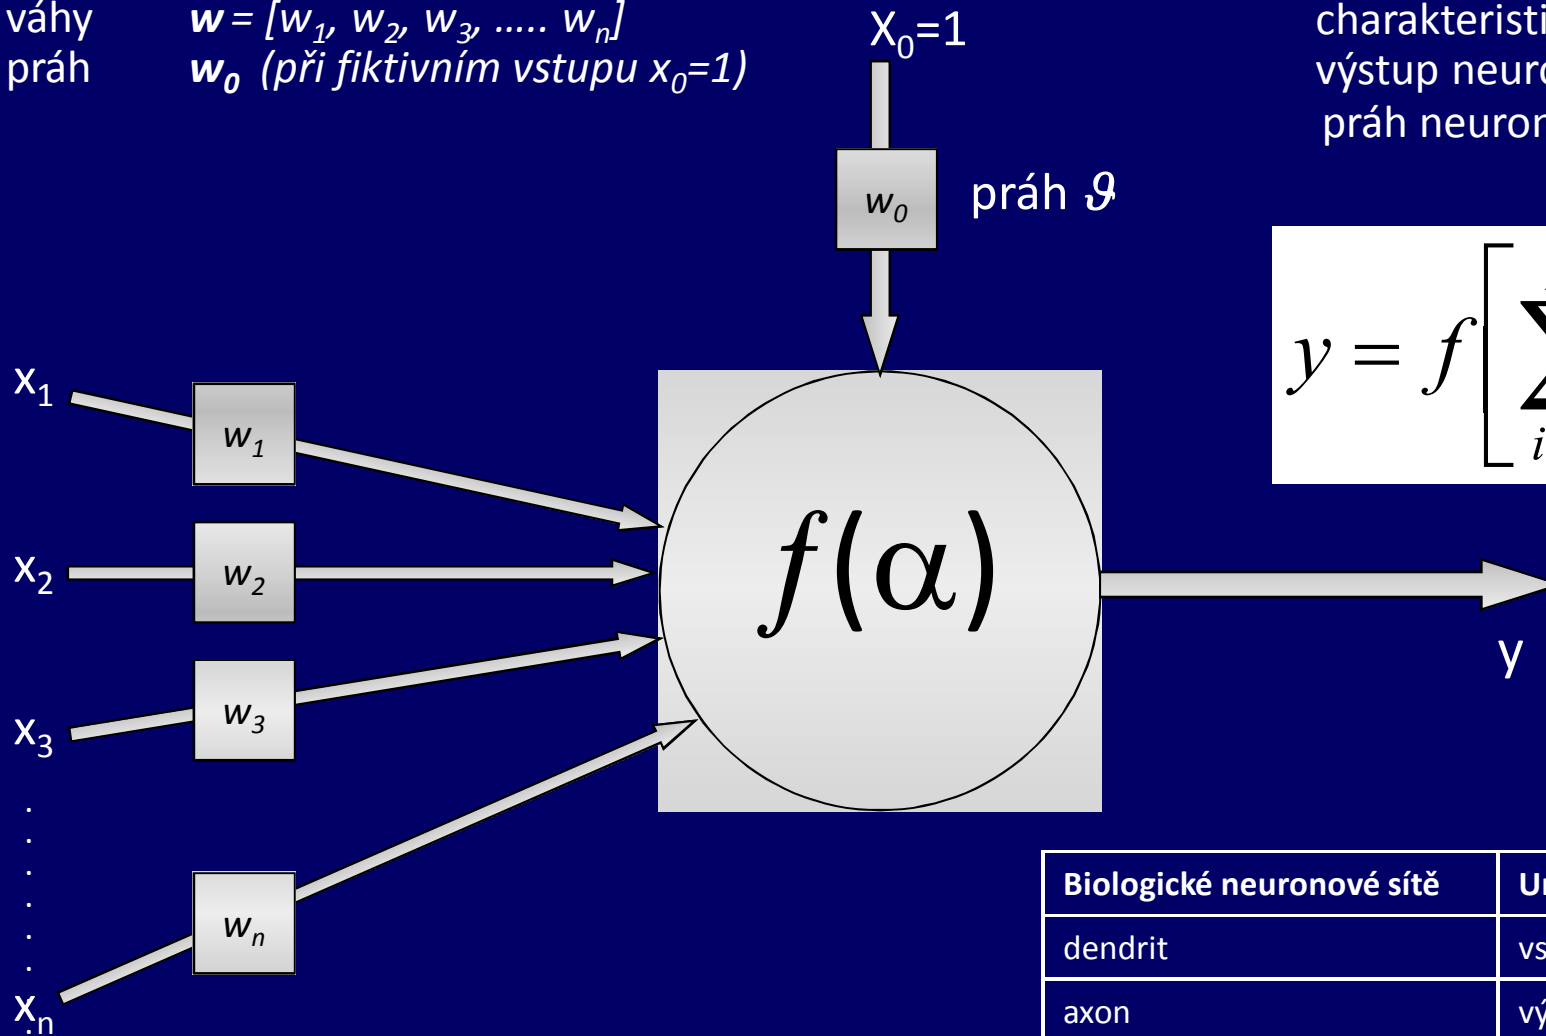
$f(\alpha)$

výstup neuronu

y

práh neuronu

ϑ




$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \vartheta \right]$$

v neuronu pobíhají dva procesy:


- výpočet (post-synaptického) potenciálu
- výpočet hodnoty výstupu pomocí aktivační funkce, (skoková funkce, sigmoida.....)

Biologické neuronové sítě	Umělé neuronové sítě
dendrit	vstupní vedení
axon	výstupní vedení
synapse	paměťové elementy
průchodnost synapsí	synaptické váhy w
soma	příjem signálů, nelin. transformace
neuron	matematický procesor

Aktivační funkce




Skoková funkce (*hardlim*)




Skoková limitní funkce (*hardlims*)


Perceptron –
binární klasifikátor



Lineární přechodová funkce (*pureline*)




Saturační lineární funkce (*satlin*)



Sigmoidální funkce (*logsig*)

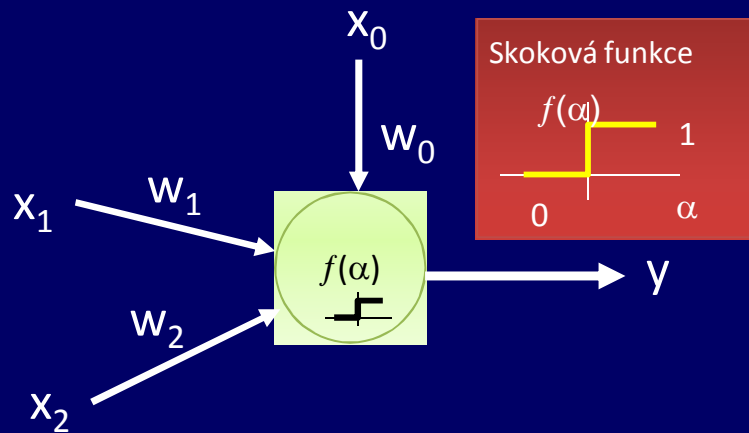
Aproximace
biologického
neuronu



Hyperbolická tangenciální sigmoidální funkce (*tansig*)

Umělý neuron – Perceptron

(binární klasifikátor pro lineárně separovatelné n-dimenzionální prostory)



vstupy $\mathbf{x} = [x_1, x_2, x_3, \dots, x_n]$
 váhy $\mathbf{w} = [w_1, w_2, w_3, \dots, w_n]$
 práh w_0 (při fiktivním vstupu $x_0=1$)
 aktivace neuronu α
 charakteristika neuronu $f(\alpha)$
 výstup neuronu y

$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \vartheta \right]$$

Rovnice hraniční přímky



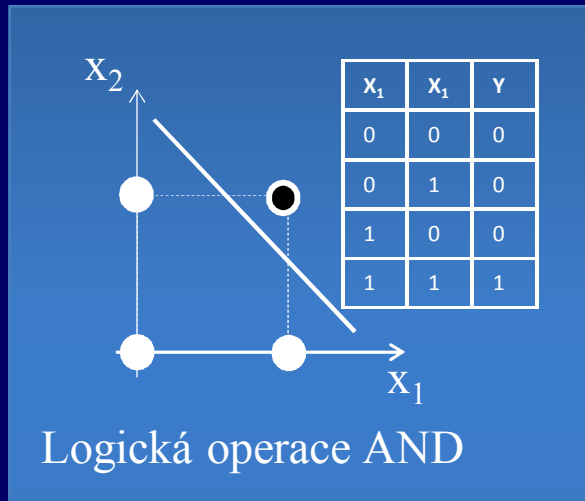

$$y = f(\alpha) = w_1 x_1 + w_2 x_2 - \vartheta = 0$$

Směrnice přímky

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

Posuv přímky na ose x2

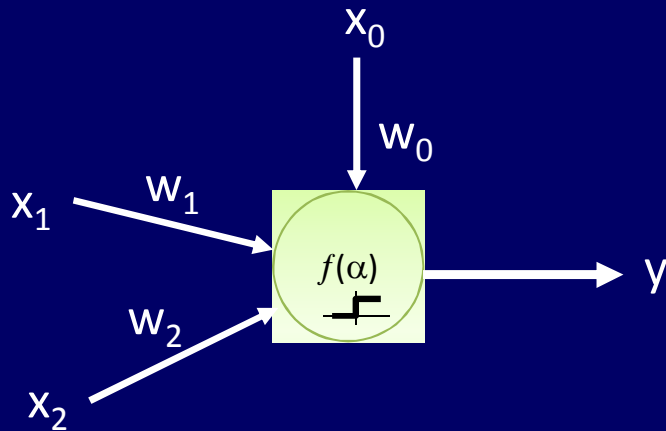
Klasifikace do dvou tříd A a B




Umělý neuron – Perceptron

(binární klasifikátor pro lineárně separovatelné n-dimenzionální prostory)


příklad



Skoková funkce



$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \vartheta \right]$$



Vzor a jeho parametry

vstup	parametr
x_1	výška
x_2	délka vlasů

Klasifikace do dvou tříd A a B

třída	Výstup y
A = ŽENA	1
B = MUŽ	0

Umělý neuron – Perceptron

režim učení (s učitelem)

Učení je proces, při kterém se snažíme nalézt vhodné jednotlivé váhy pro váhový vektor w a minimalizovat chybu mezi skutečným a požadovaným výstupem

Učení probíhá na takových vzorech $(x_1, x_2 \dots x_n)$, u kterých známe do které třídy patří (A, B), tj. známou odezvu d

Pro každou učební dvojici (vzor, známá odezva) provést vhodnou adaptaci vah

fáze režimu učení

1 epocha

krok 1: inicializace vah w a práh θ na malé náhodné hodnoty

krok 2: předložení vstupní trénovací dvojice (vstupní vektor x , požadovaná odezva d)

krok 3: porovnání požadované odezvy d se skutečnou y

krok 4: podle výsledku úprava váhového vektoru w

krok 5: předložení další trénovací dvojice z množiny (krok 2-4)

krok 6: vyhodnotit úspěšnost klasifikace – ukončit učení / zahájit další epochu (krok 2-5)

Umělý neuron – Perceptron

režim učení s binárními vstupy a výstupem

fáze režimu učení

vstupy a výstupy nabývají hodnoty 0 nebo 1

1 epocha

Hebbovo pravidlo

krok 1: inicializace vah w a práh ϑ na malé náhodné hodnoty (v čase $t=0$)

krok 2: předložení vstupní trénovací dvojice (vstupní vektor x , požadovaná odezva d)

krok 3: výpočet skutečné aktuální odezvy y podle a porovnání s požadovanou d

$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \vartheta \right]$$

krok 4: úprava vah

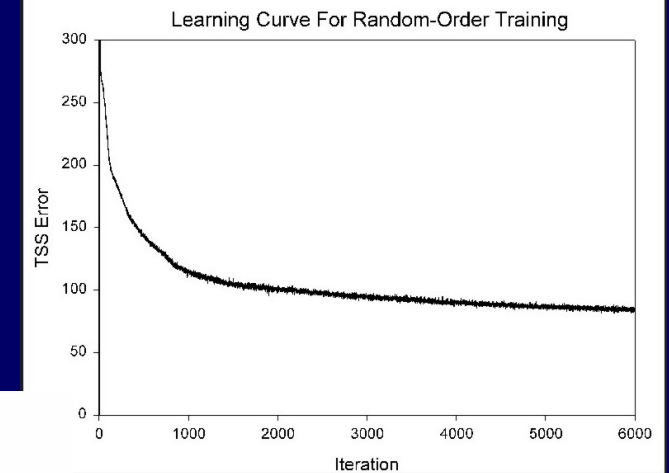
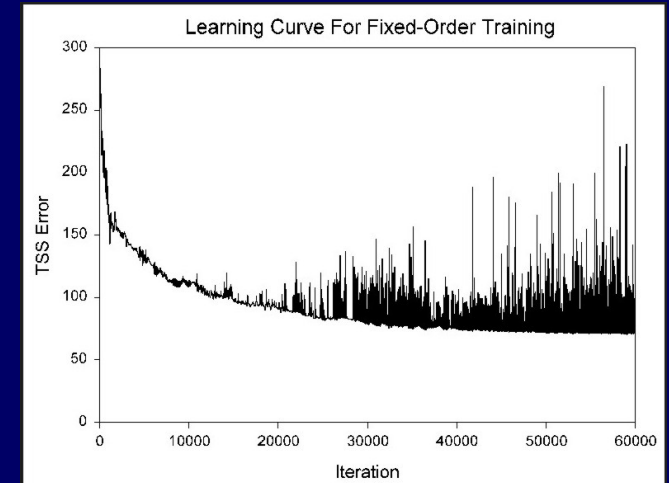
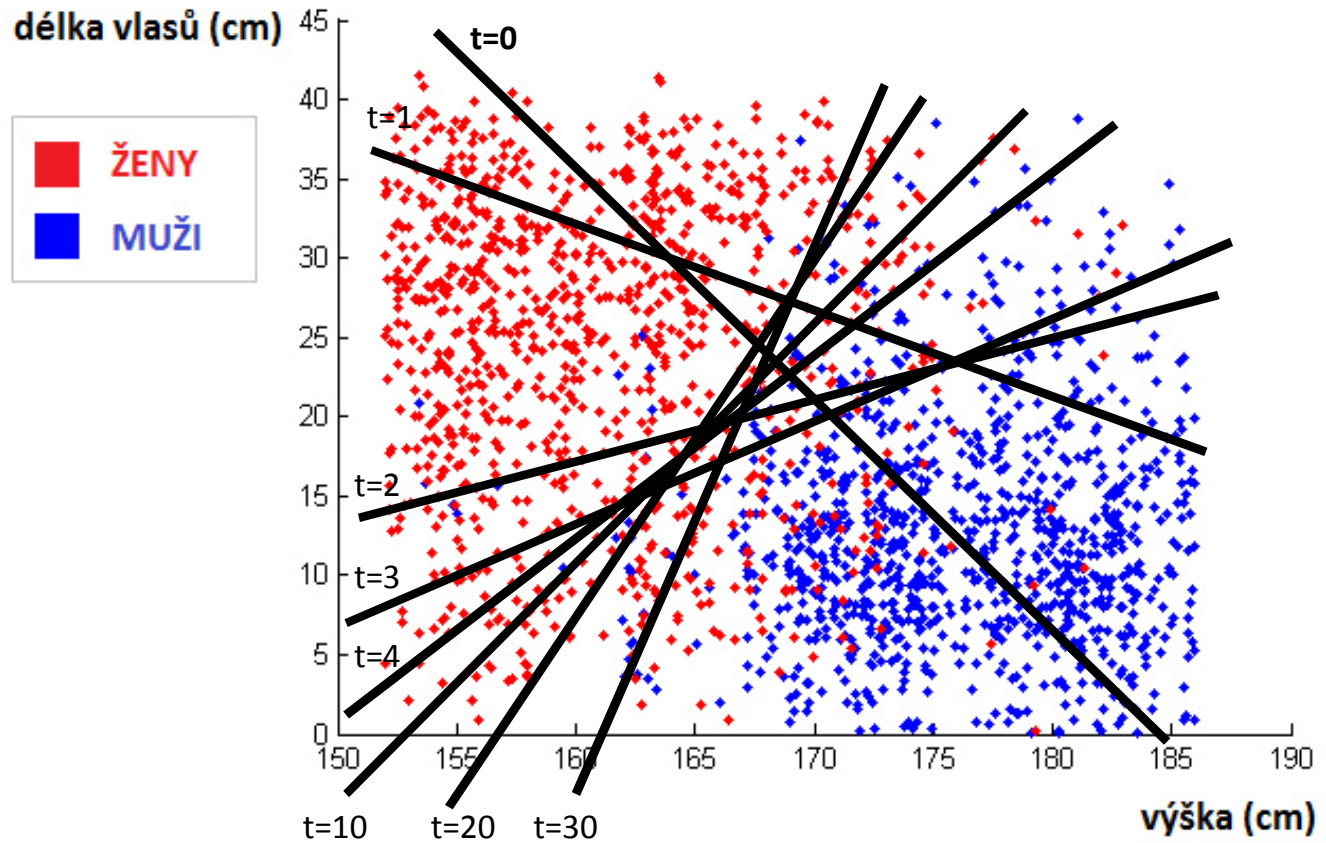
- je-li výstup y správný váhy se nemění
- je-li výstup $y = 0$ a měl by být $d = 1$, pak posílit váhy $w_i(t+1) = w_i(t) + \Delta$
- je-li výstup $y = 1$ a měl by být $d = 0$, pak oslabit váhy $w_i(t+1) = w_i(t) - \Delta$

krok 5: předložení další trénovací dvojice z množiny (krok 2-4)

krok 6: vyhodnotit úspěšnost klasifikace – ukončit učení / zahájit další epochu (krok 2-5)

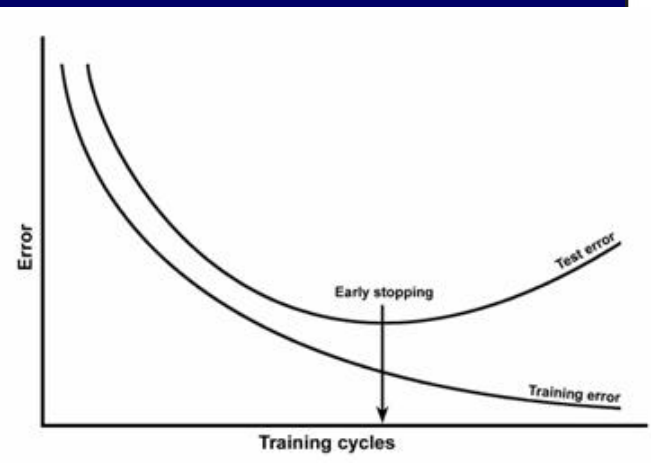
Umělý neuron – Perceptron

Geometrická interpretace procesu učení



Střední kvadratická chyba

$$E_{error} = \frac{1}{n} \cdot \sum_{i=1}^n (y_i - d_i)^2$$



Umělý neuron

režim vybavování neuronu

krok 1: předložení neznámého vzoru (vstupní vektor x)

krok 2: výpočet skutečné aktuální odezvy y

$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \theta \right]$$

krok 3: podle odezvy y zařadit vzor do příslušné třídy (A, B...)

krok 4: pokud jsou další neznámé vzory – opakovat kroky 1-3

Umělý neuron – jednovrstvá neuronová síť

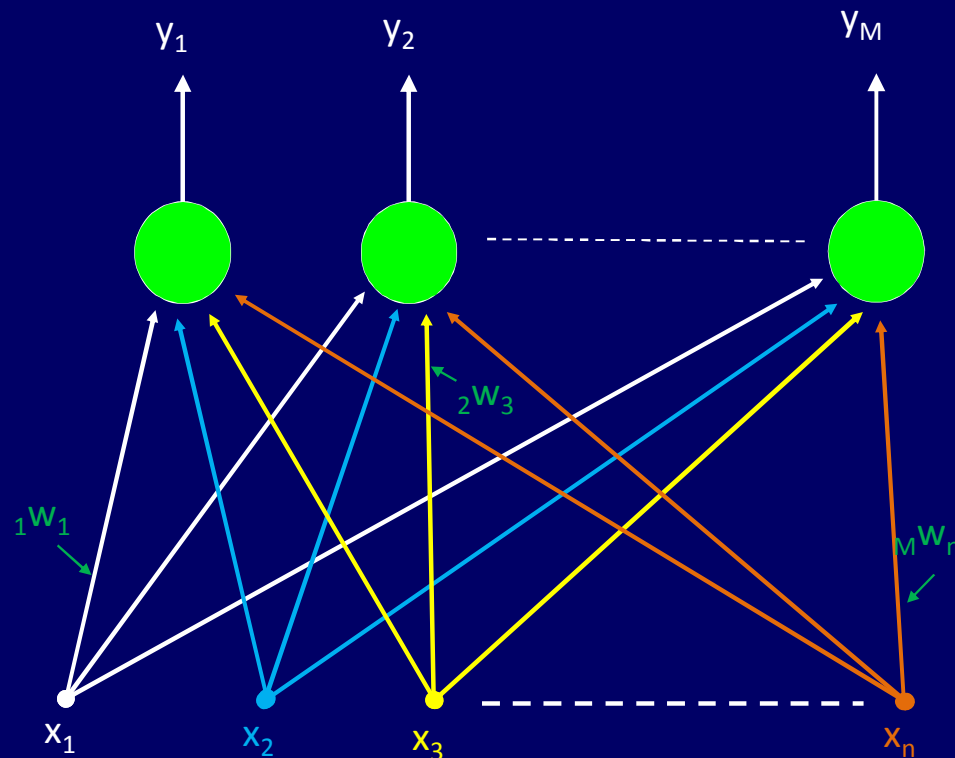
možnosti klasifikace

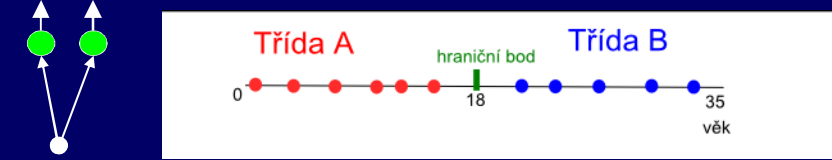
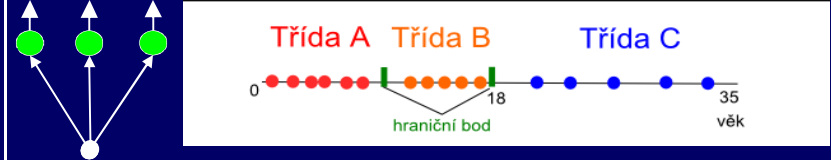
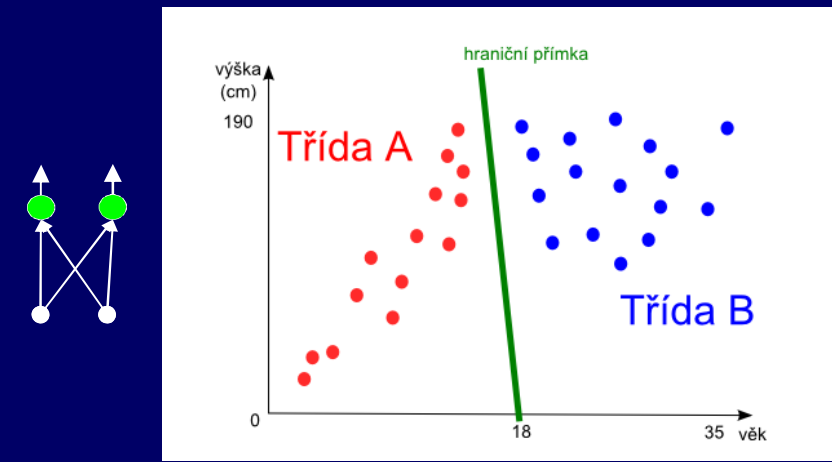
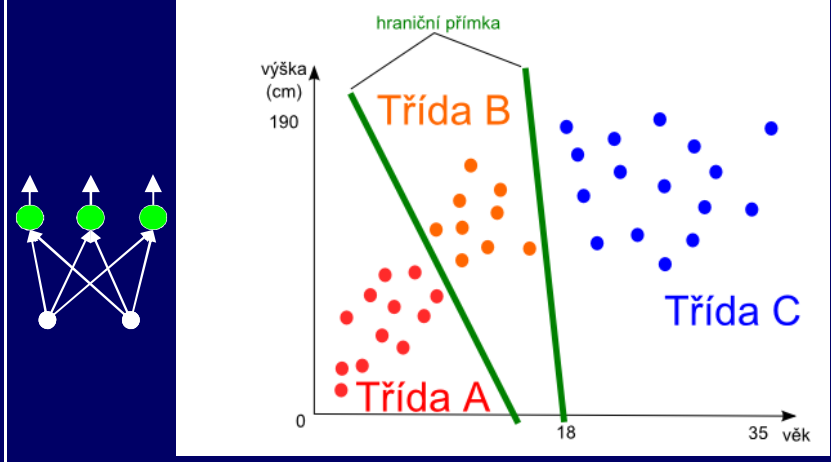
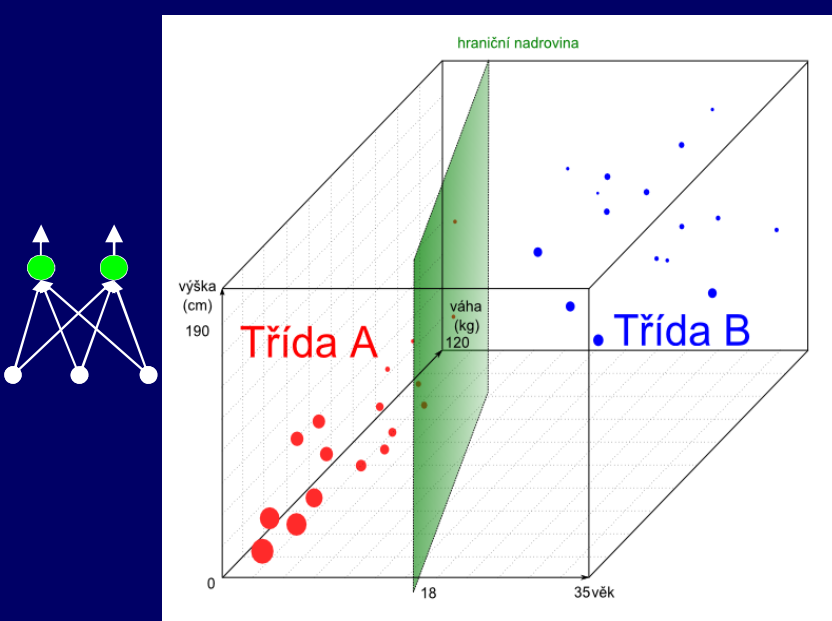
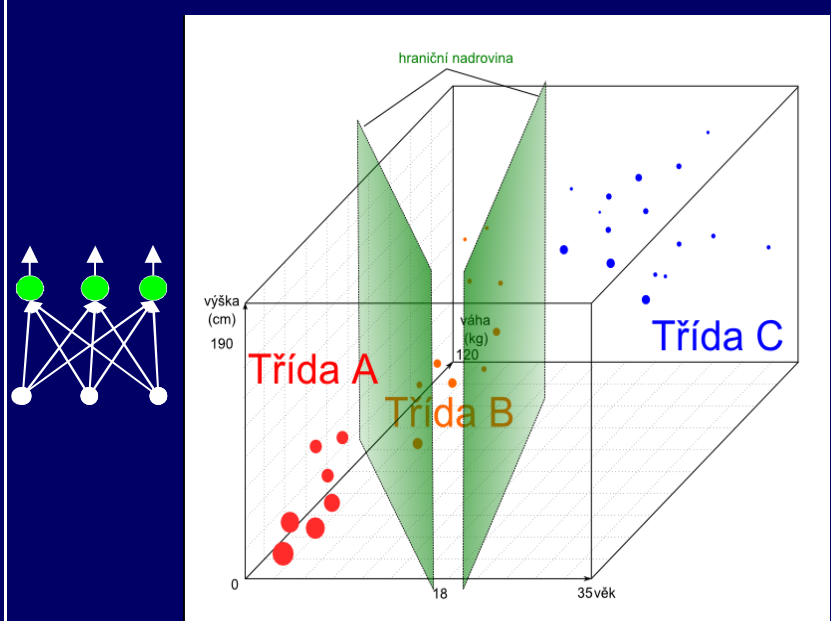
M paralelně pracujících neuronů

počet vstupů x – dimenze prostoru

pro $N=1$ – přímka, pro $N=2$ - rovina, $N=3$ – 3D prostor, $N>3$ těžko představitelný N -dimenzionální prostor

počet neuronů M – počet hraničních přímek resp. počet podprostorů dělících N -dimenzionální prostor = M -počet klasifikačních tříd (A, B, ..., Z)



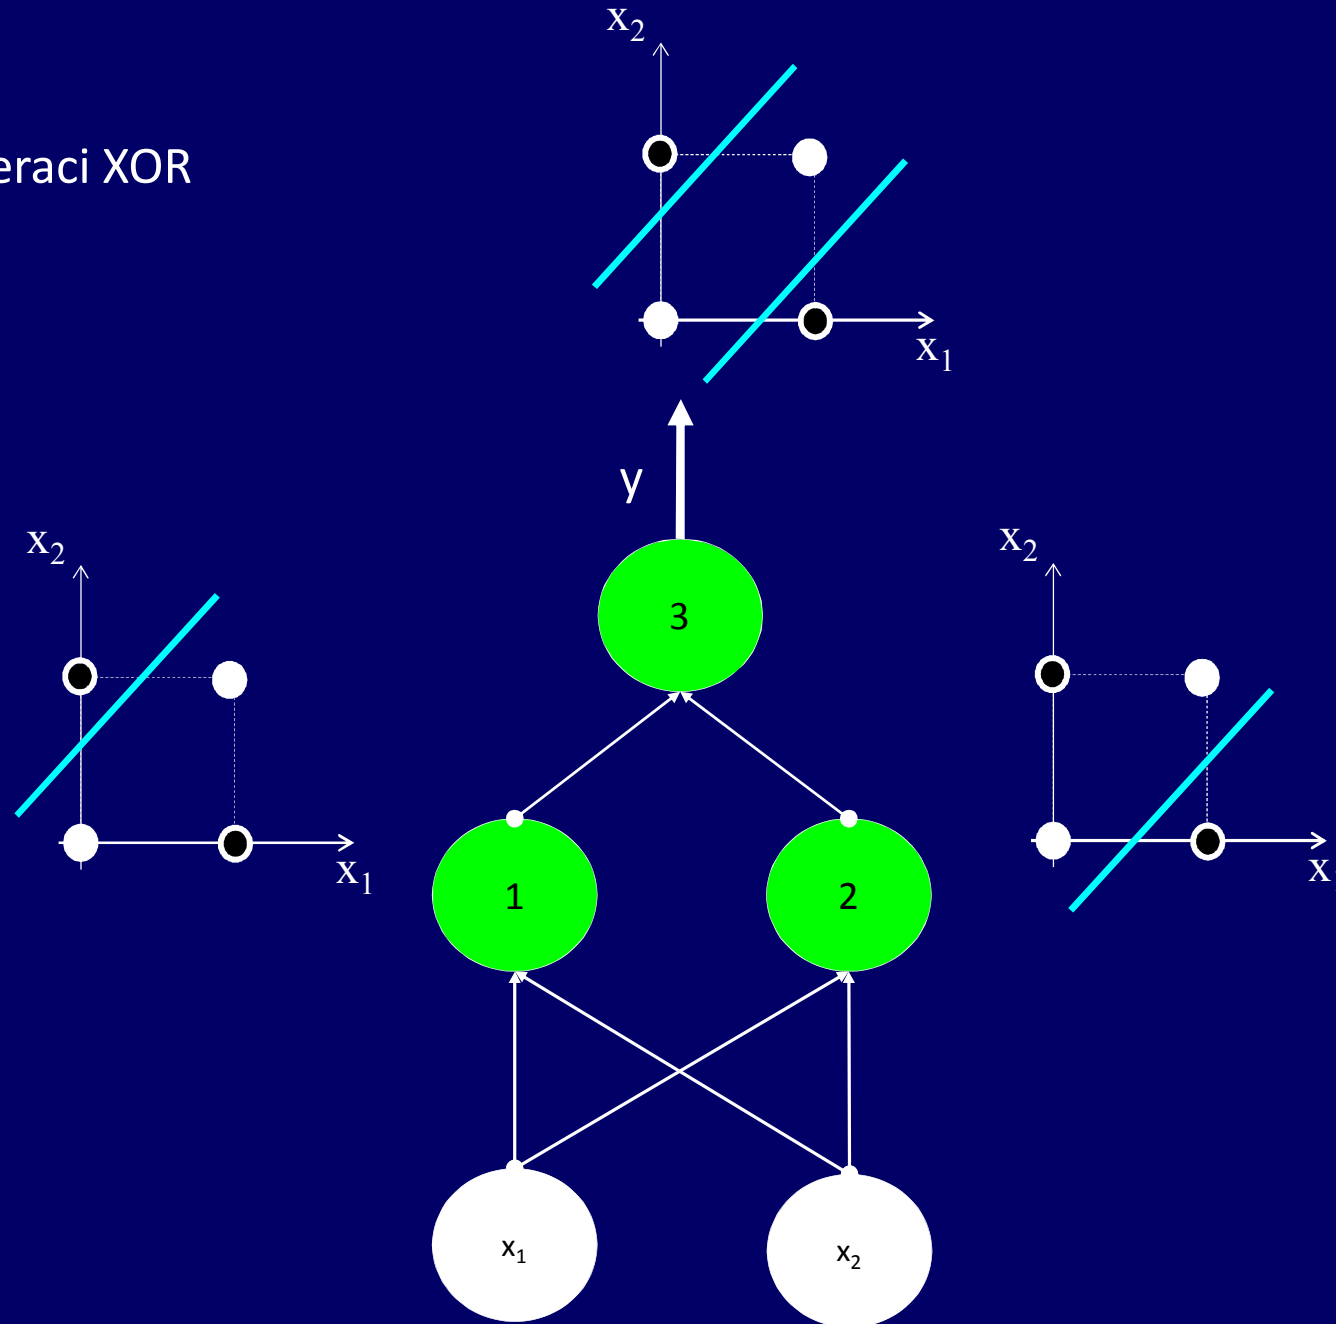
Počet vstupů x	parametr	Počet neuronů	
		2 (1)	3
1 X_1	Věk	 <p>Diagram showing a single neuron with two inputs. The plot shows age (0 to 35) on the x-axis. A vertical green line at 18 is labeled "hraniční bod". Red dots (Třída A) are to the left of 18, and blue dots (Třída B) are to the right.</p>	 <p>Diagram showing a single neuron with three inputs. The plot shows age (0 to 35) on the x-axis. Two vertical green lines are labeled "hraniční bod". Red dots (Třída A) are to the left of the first threshold, orange dots (Třída B) are between the two thresholds, and blue dots (Třída C) are to the right of the second threshold.</p>
2 X_1 X_2	Věk Výška	 <p>Diagram showing a neuron with two inputs. The plot shows height (0 to 190 cm) on the y-axis and age (0 to 35) on the x-axis. A green line labeled "hraniční přímka" separates red dots (Třída A) and blue dots (Třída B).</p>	 <p>Diagram showing a neuron with three inputs. The plot shows height (0 to 190 cm) on the y-axis and age (0 to 35) on the x-axis. Two green lines labeled "hraniční přímka" separate red dots (Třída A), orange dots (Třída B), and blue dots (Třída C).</p>
3 X_1 X_2 X_3	Věk Výška Váha	 <p>Diagram showing a neuron with two inputs. The plot shows height (0 to 190 cm) on the y-axis, age (0 to 35) on the x-axis, and weight (kg) on the z-axis. A green plane labeled "hraniční nadrovina" separates red dots (Třída A) and blue dots (Třída B).</p>	 <p>Diagram showing a neuron with three inputs. The plot shows height (0 to 190 cm) on the y-axis, age (0 to 35) on the x-axis, and weight (kg) on the z-axis. Two green planes labeled "hraniční nadrovina" separate red dots (Třída A), orange dots (Třída B), and blue dots (Třída C).</p>

Vícevrstvá perceptronová neuronová síť

Back-propagation

Schopnost řešit operaci XOR



x_1	x_2	Y
0	0	0
0	1	1
1	0	1
1	1	0



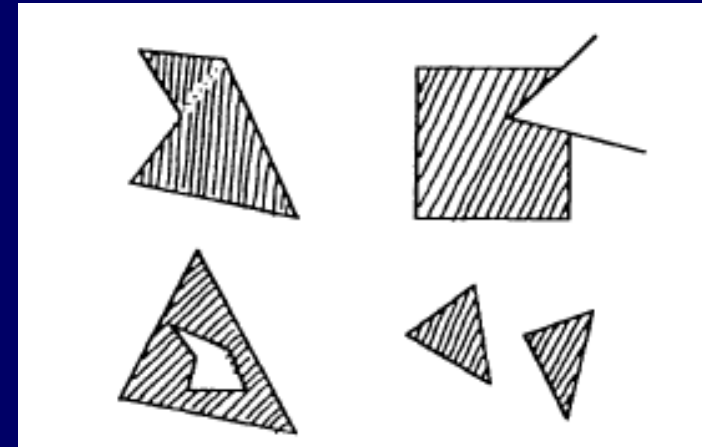
Vícevrstvá perceptronová neuronová síť

Back-propagation


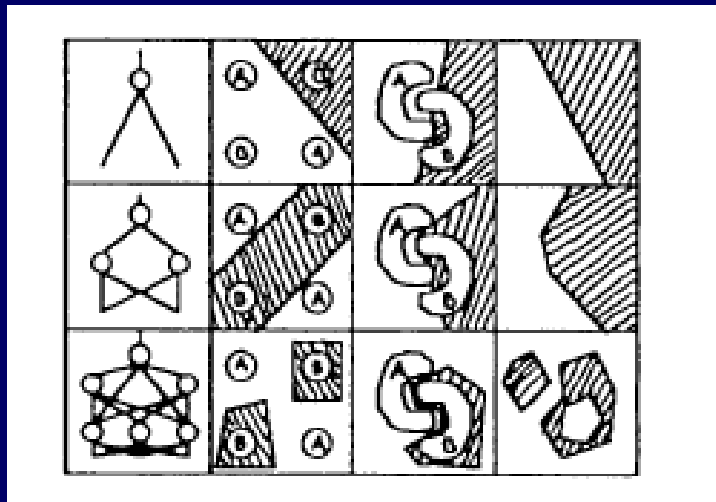
1. vrstva



2,3, 4. vrstva atd.



Princip Kolmogorova teorému: Abychom dokázali vyřešit jakýkoliv problém týkající se klasifikace vzorů, nebudeme nikdy potřebovat více než dvě vrstvy perceptronové sítě (bez vstupní vrstvy), tj. vystačíme si maximálně se dvěma vrstvami.




Přehled problémů řešení BP- sítí


Vícevrstvá perceptronová neuronová síť

Back-propagation

Skoková přenosová funkce

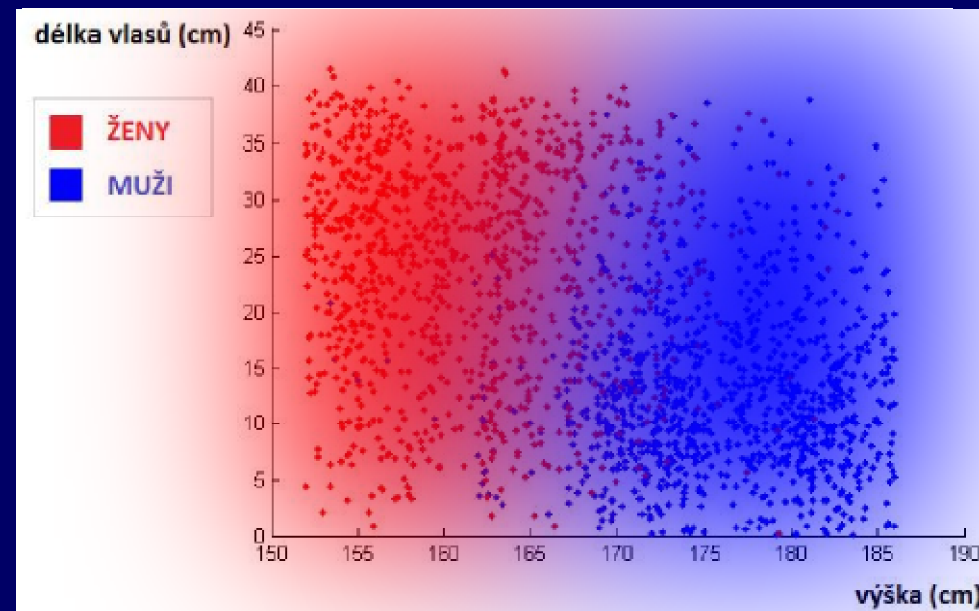



Sigmoidální přenosová funkce



$$f(x) = 0 \text{ pro } x < \Theta \text{ a } f(x) = 1 \text{ pro } x \geq \Theta$$

$$f(x) = \frac{1}{1 + e^{-kx}}$$



Vícevrstvá perceptronová neuronová síť

Back-propagation

1 epocha

fáze režimu učení δ - pravidlo

krok 1: inicializace vah w a práh θ na malé náhodné hodnoty (v čase $t=0$)

krok 2: předložení vstupní trénovací dvojice (vstupní vektor x , požadovaná odezva d)

krok 3: výpočet aktuální odezvy μ každého neuronu v každé vrstvě (M-vrstev)

$$\mu_j^{s+1} = f \left[\sum_{i=1}^{p^s} w_{ij}^s \cdot \mu_i^s - \theta \right]$$

Postupný výpočet výstupů z jednotlivých vrstev.
Výstupy z předchozí vrstvy = vstupy následující vrstvy

$$y_j = \mu_j^{M+1}$$

krok 4: úprava vah

$$w_{ij}^s(t+1) = w_{ij}^s(t) + \eta \cdot \delta_j^{s+1} \cdot \mu_i^s$$

kde $\delta_j^M = y_j(1 - y_j) \cdot (d_j - y_j)$ pro poslední vrstvu

využitím momentového parametru – zlepšení konvergence

$$\delta_j^s = \mu_j^{s+1}(1 - \mu_j^{s+1}) \sum_{k=1}^{p^{s+1}} \delta_k^{s+1} w_{jk}^{s+1}$$
 pro předcházející vrstvy

$$w_{ij}^s(t+1) = w_{ij}^s(t) + \eta \delta_j^{s+1} \mu_i^s + \alpha [w_{ij}^s(t) - w_{ij}^s(t-1)]$$

η - parametr učení ovlivňuje rychlost řízení učení ($\eta \leq 1$)

α - momentový parametr zlepšuje konvergenci ($\alpha \leq 1$)

krok 5: předložení další trénovací dvojice z množiny (krok 2-4)

krok 6: vyhodnotit úspěšnost klasifikace – ukončit učení / zahájit další epochu (krok 2-5)

Vícevrstvá perceptronová neuronová síť

Back-propagation

režim vybavování

krok 1: předložení neznámého vzoru (vstupní vektor x)

krok 2: výpočet skutečné aktuální odezvy y

$$y = f \left[\sum_{i=1}^N w_i \cdot x_i - \theta \right]$$

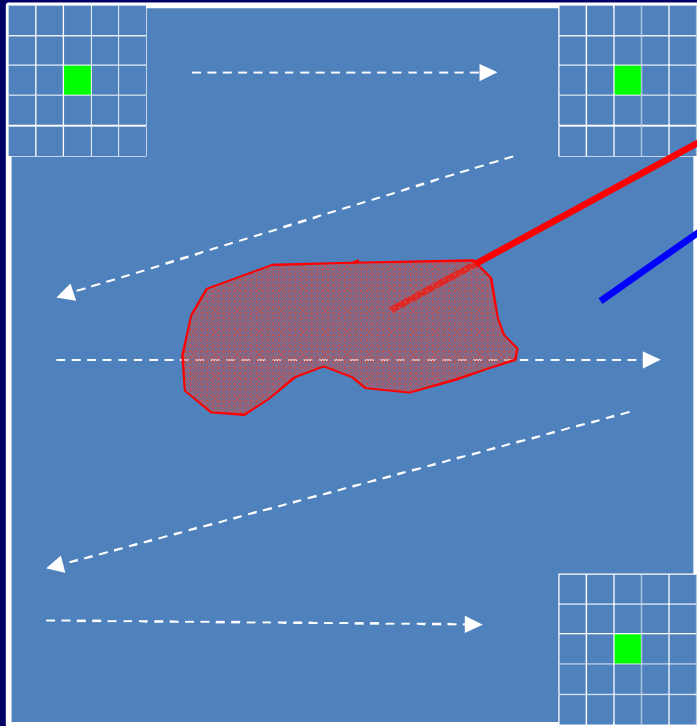
krok 3: podle odezvy y zařadit vzor do příslušné třídy (A, B...)

krok 4: pokud jsou další neznámé vzory – opakovat kroky 1-3

Projekt

Využití NS-BP pro segmentaci obrazu

Výpočet vzorů



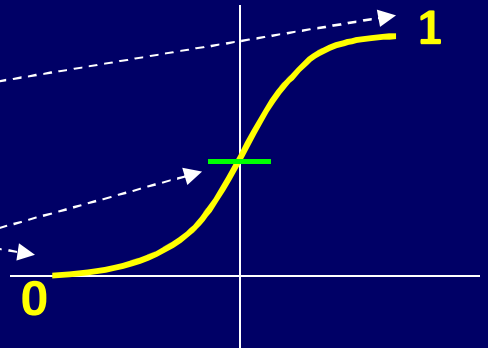
Výstupní vrstva – 1 neuron

klasifikace:

$y = 1$ - zájmová tkáň

$y = 0$ - pozadí+ostatní

$y = 0,5$ - rozhodovací úroveň



vzor: n-okolí (liché) v obraze
(5x5 pix)

Centrální pixel

Vstupy jednoho vzoru:

x_1 : histogram – normovaný

x_2 : unsharp mask

x_3 : intenzita v centrálním pixelu

x_4 : průměr okolí


x_5 : median okolí

x_6 : modus okolí

x_7 : směrodatná odchylka

x_8 : entropie okolí

x_9 : šum jako odmocnina z průměru okolí



Aplikační prostředí (NS - režim učení sítě)

Neuronová síť - režim učení (Back Propagation)

Otevřít obraz
Otevřít obraz
Otevřít adresář (obraz)
Otevřít dicom
Otevřít dicom (multi)

Obraz výřez
Definuj výřez
Obnovit obraz

ROI
 Obdélník
 Ovál
 Polygon
 Volně
ROI
Aktualizace

Rysy
Aktuální počet rysů: 19551
Spočítat rysy Zobraz rysy
Uložit rysy do souboru ...
Načíst rysy ze souboru ...
Nastavení výpočtu rysů
Blok (N x N) 5
Offset (pixel) 1
Rysy (smazat)
 Potvrzení - smazat?
Smazat

Neuronová síť - režim učení
Topologie sítě
 2 vrstvy 3 vrstvy
Počet neuronů
2. vrstva 3. vrstva
10 4
Nastavení parametrů neuronové sítě
 τ - rychlost učení 0.005 počet epoch: 40
 α - moment učení 0.8 strmost přenosové funkce
S = 1.0
Spustit režim učení
START
Uložení nastavení NS
Uložit nastavení ...
Režim vybavování NS
Režim vybavování

Maska

Serie řezů
9

LUT
gray invert

Obraz

W / L - váhování okna
105
0
Střed okna: 52.5
Rozsah: 105

Průběh fáze učení
Epocha č. 40 / 40 - Chyba sítě 208.7903 (1.0679 %) - čas: 128.9994 s

Epocha učení	Chyba sítě
0	1300
5	1280
10	1270
15	1260
20	300
25	250
30	220
35	210
40	208.7903

Aplikační prostředí (NS - režim vybavování sítě)

Neuronová síť - režim vybavování (Back Propagation)

Načtení nastavení NS

Načíst nastavení NS

nebo přejít k

Režim učení NS

Otevřít obraz

Otevřít adresář (obraz)

Otevřít dicom

Otevřít dicom (multi)

Obraz výřez

Definuj výřez

Obnovit obraz

NS - režim vybavování

Smazat předchozí rysy

START

Nastavení neuronové sítě + nastavení rysů

Nastavení neuronové sítě

Topologie neuronové sítě

2 vrstvy

Počet neuronů

2. vrstva: 10

3. vrstva: 4

3 vrstvy

Strmost přenosové funkce

S = 1.0

zobraz

Rysy

Aktuální počet rysů: 7220

Spočítat rysy

Zobraz rysy

Nastavení výpočtu rysů

Blok (N x N): 5

Offset (pixel): 1

Rysy (smazat)

Potvrzení - smazat?

Smazat

Serie řezů

7

W / L - váhování okna

0 82

Střed okna: 41

Rozsah: 82

LUT

gray

invert

Obraz

Výstup neuronové sítě

Práh klasifikace

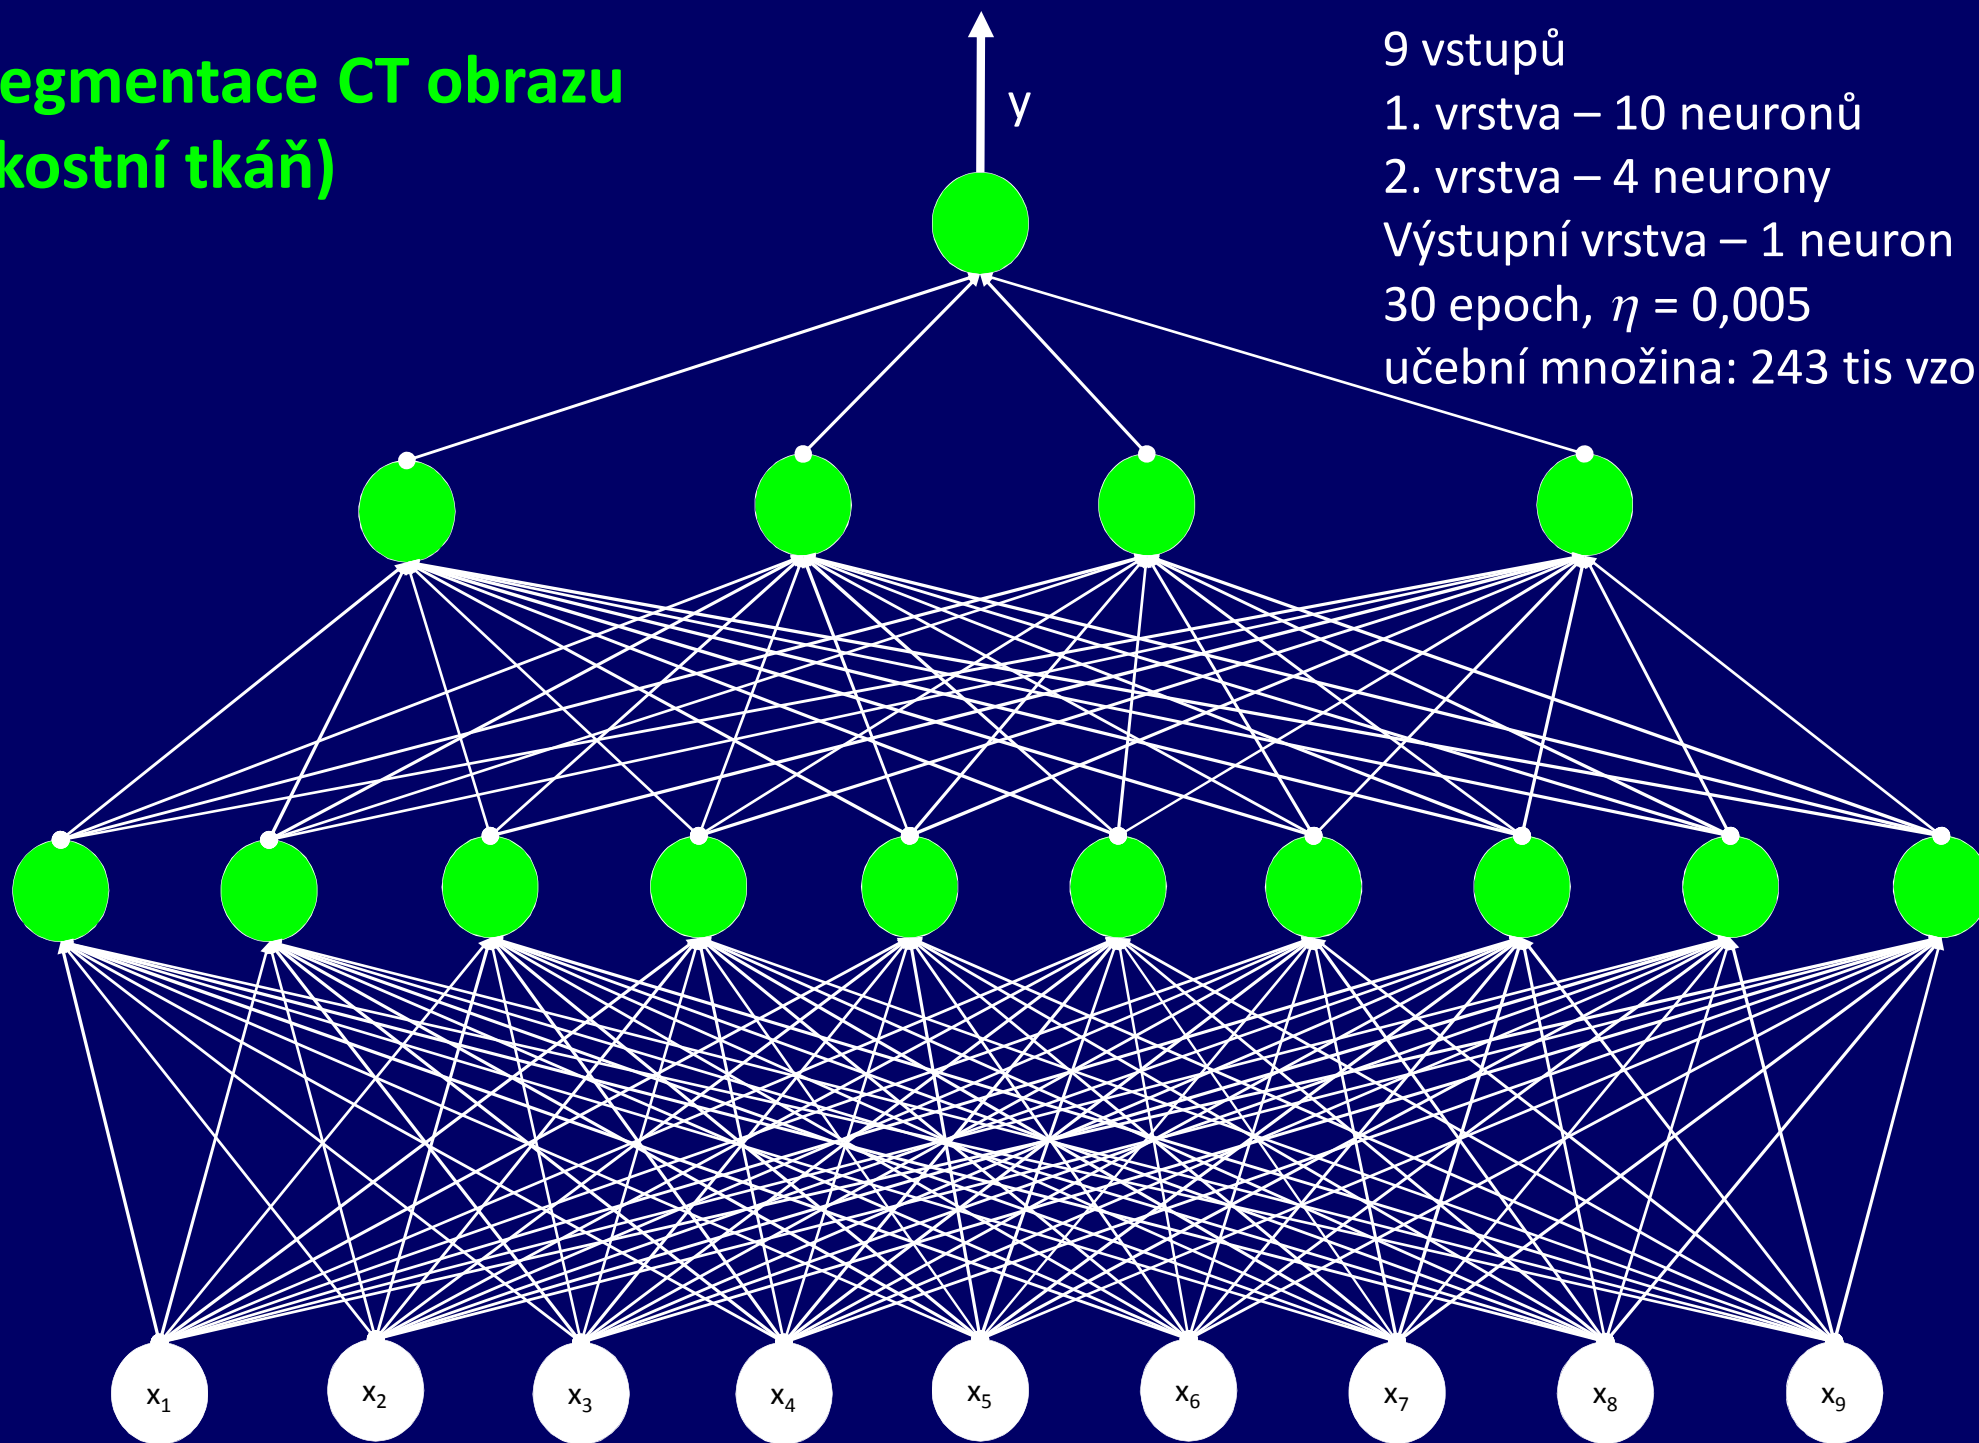
skutečný výstup

Práh: 0.5

Roi - morphologie

Návrh neuronové BP sítě

segmentace CT obrazu
(kostní tkáň)



9 vstupů

1. vrstva – 10 neuronů


2. vrstva – 4 neurony

Výstupní vrstva – 1 neuron


30 epoch, $\eta = 0,005$

učební množina: 243 tis vzorů


vstupní obraz




parametrický obraz – výstup z NS




segmentace




parametrický obraz – binární maska



vstupní obraz



parametrický obraz – výstup z NS




segmentace




parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska



Návrh neuronové BP sítě

segmentace CT obrazu
(plicní tkáň)

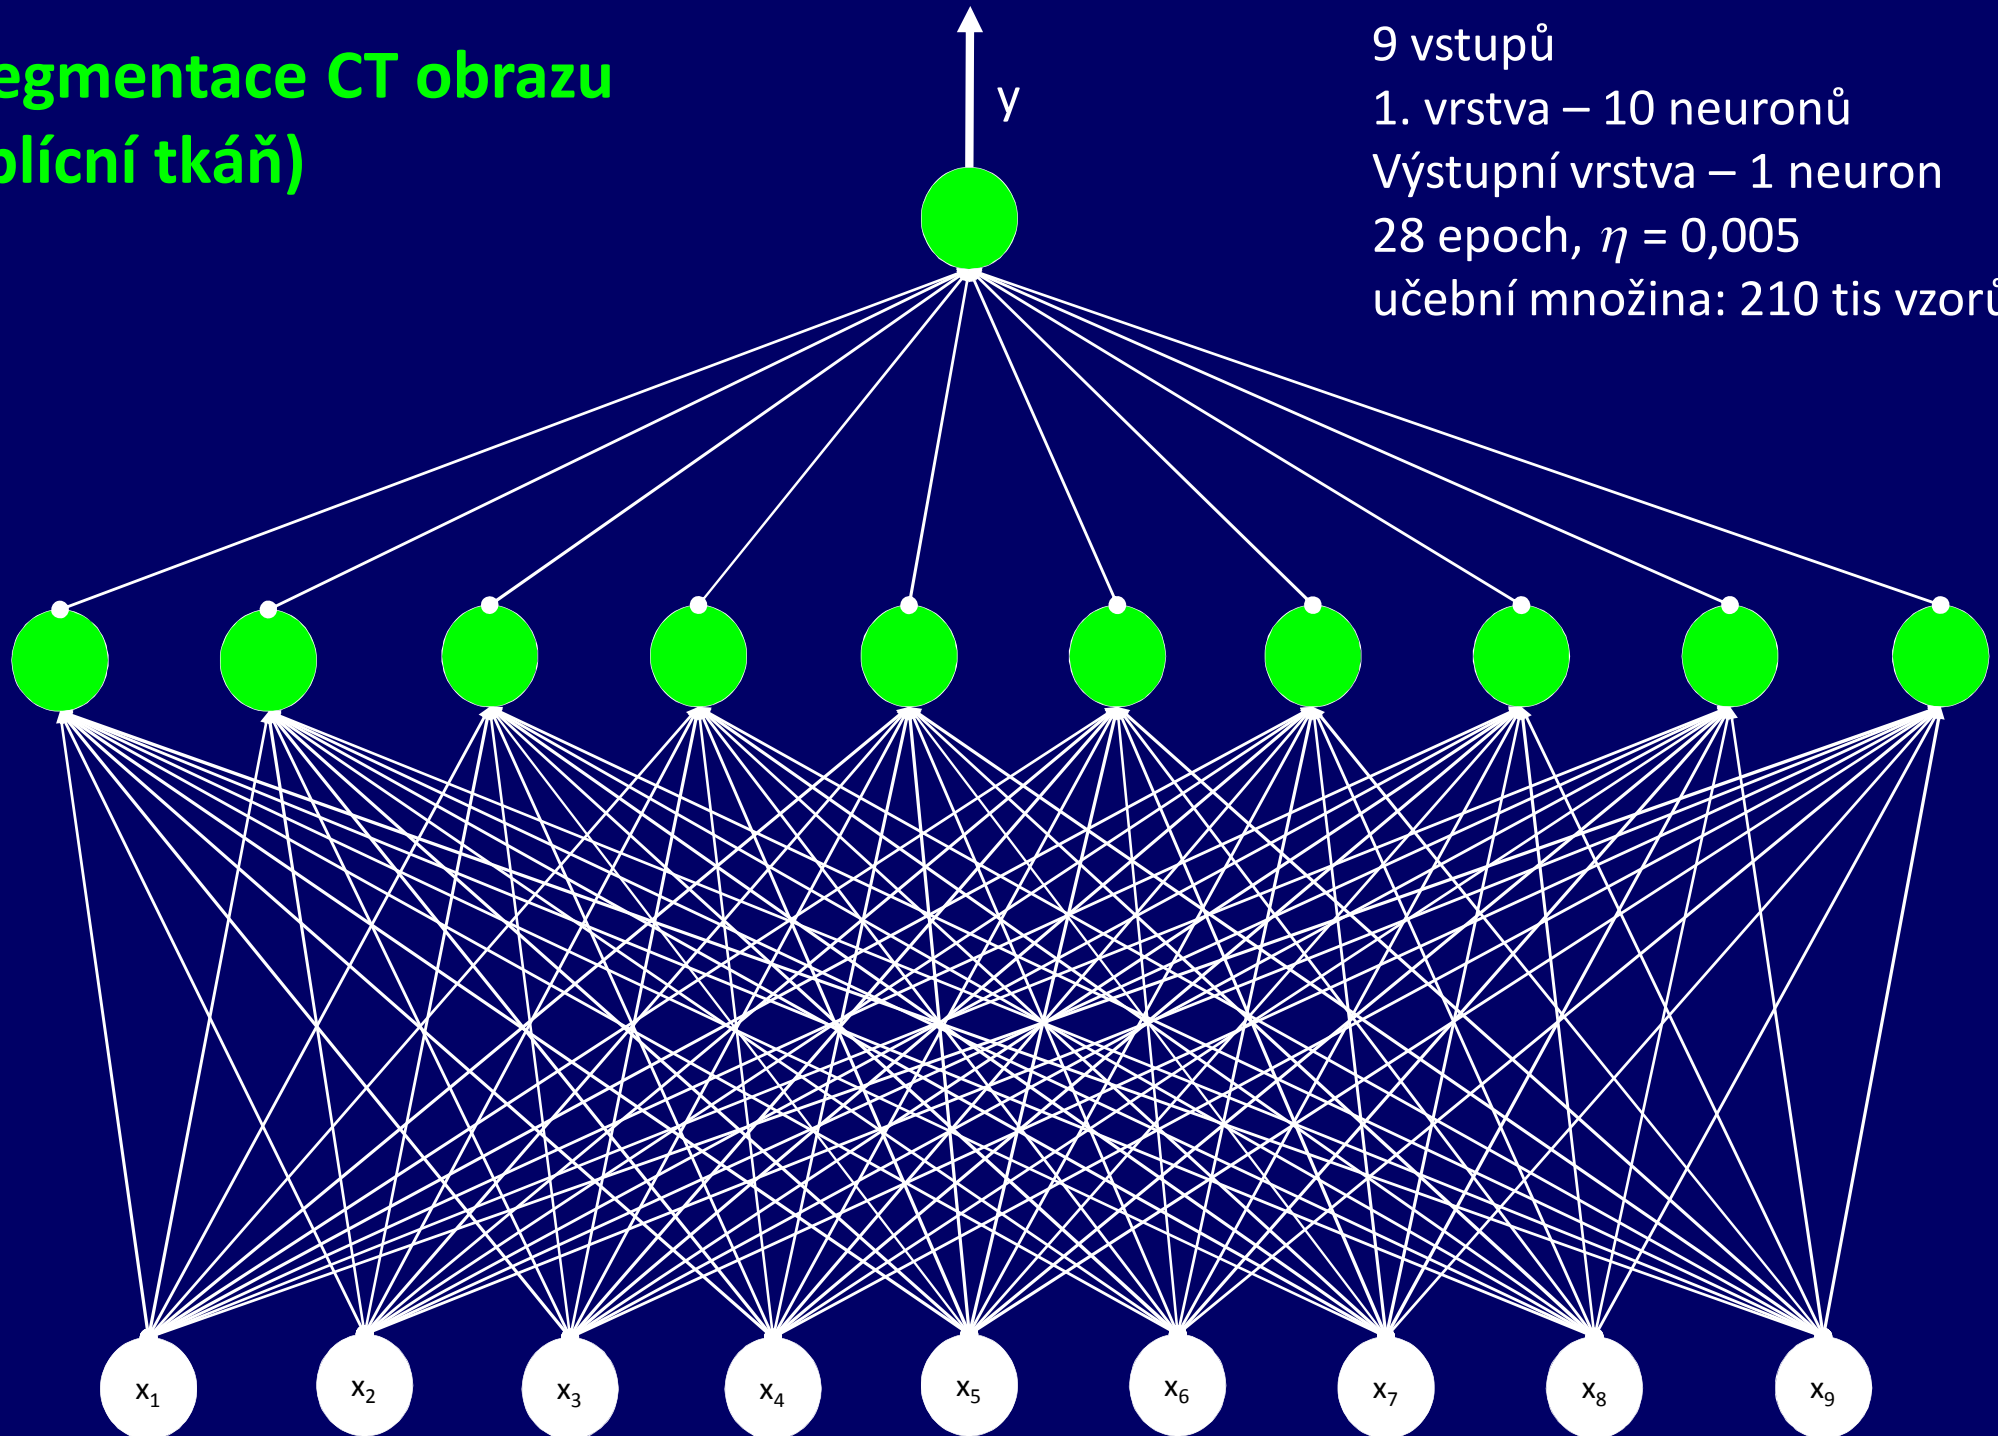
9 vstupů

1. vrstva – 10 neuronů

Výstupní vrstva – 1 neuron

28 epoch, $\eta = 0,005$


učební množina: 210 tis vzorů




vstupní obraz



parametrický obraz – výstup z NS




segmentace



parametrický obraz – binární maska




vstupní obraz




parametrický obraz – binární maska




segmentace




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska



Návrh neuronové BP sítě

segmentace CT obrazu
(kostní + plicní tkáň)

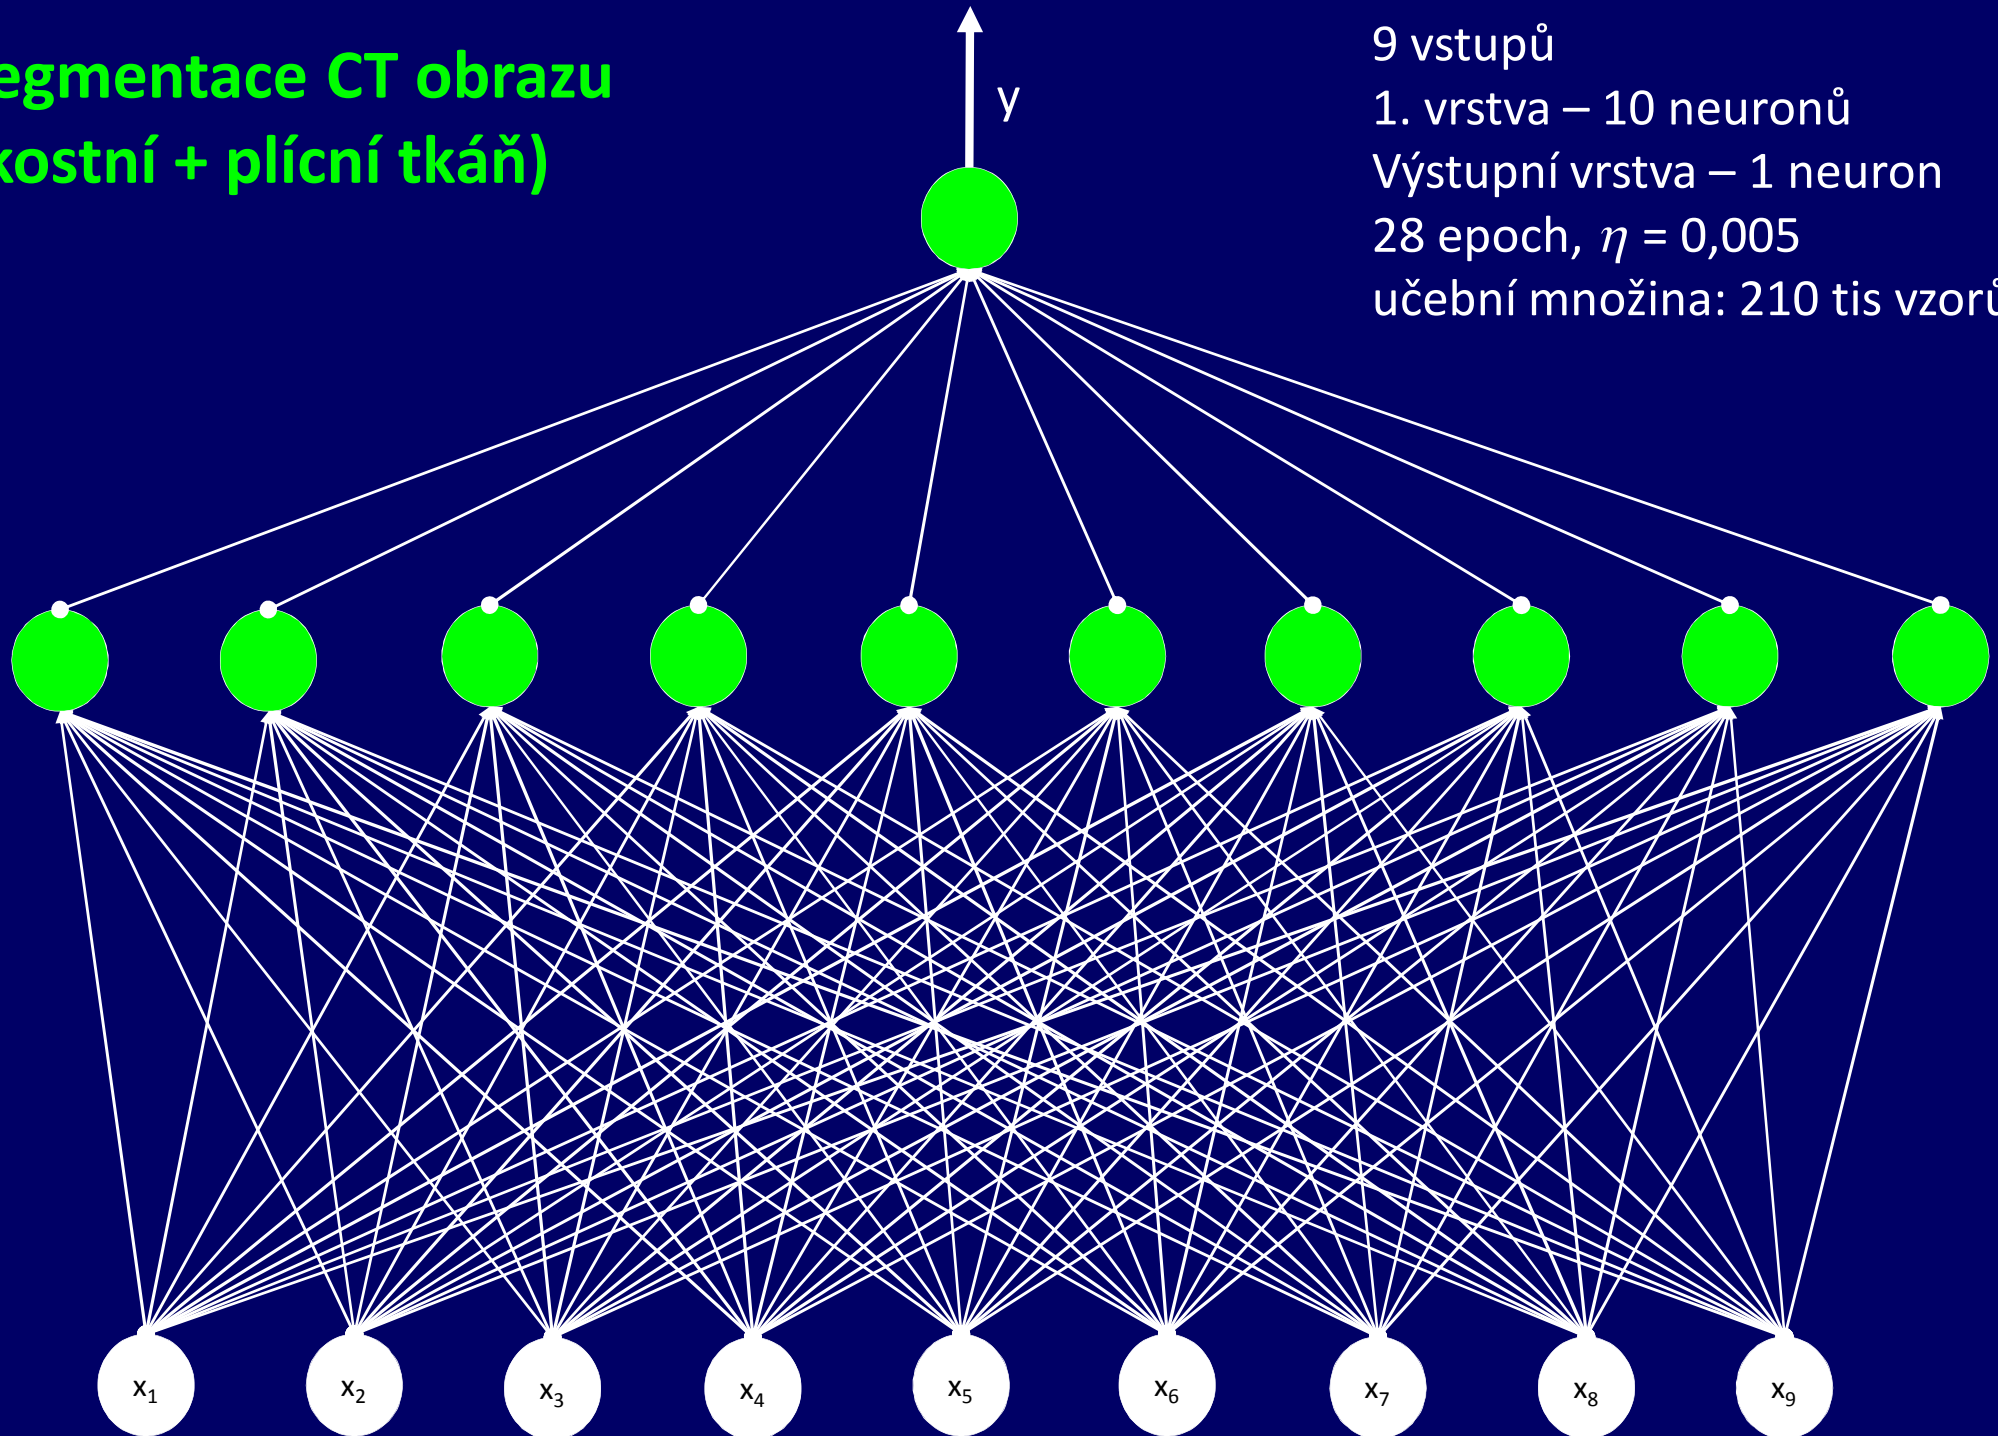
9 vstupů

1. vrstva – 10 neuronů

Výstupní vrstva – 1 neuron

28 epoch, $\eta = 0,005$

učební množina: 210 tis vzorů





Otevřít obraz

- Otevřít obraz
- Otevřít adresář (obraz)
- Otevřít dicom
- Otevřít dicom (multi)

Obraz výřez

- Definuj výřez
- Obnovit obraz

ROI

- Obdélník
- Ovál
- Polygon
- Volně

ROI

Aktualizace

Rysy

Aktuální počet rysů: 0

- Spočítat rysy
- Zobraz rysy

Uložit rysy do souboru ...

Načíst rysy ze souboru ...

Nastavení výpočtu rysů

- Blok (N x N) 5
- Offset (pixel) 1

Rysy (smazat)

- Potvrzení - smazat?
- Smazat

Neuronová síť - režim učení

Topologie sítě

- 2 vrstvy 3 vrstvy
- Počet neuronů
- 2. vrstva 10
- 3. vrstva 4

Nastavení parametrů neuronové sítě

- τ - rychlost učení 0.005
- počet epoch: 28
- α - moment učení 0.8
- strmost přenosové funkce S = 1.0
- zobraz

Spustit režim učení

START

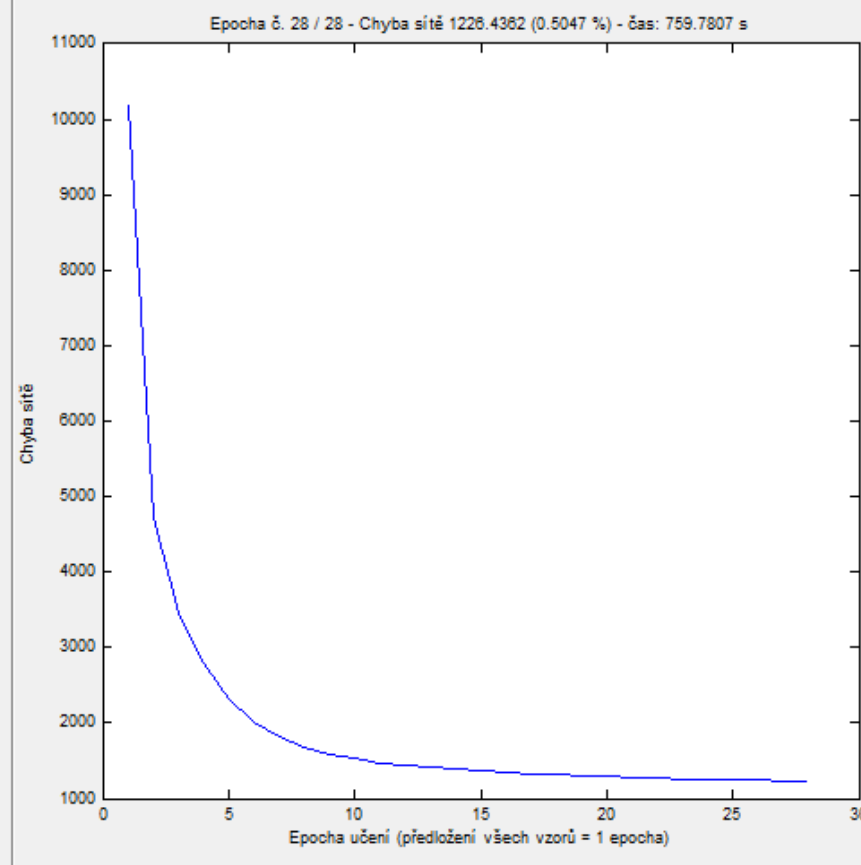
Uložení nastavení NS

Uložit nastavení ...

Režim vybavování NS

Režim vybavování

Průběh fáze učení



Maska



Serie řezů

90

LUT

gray invert

Obraz



W / L - váhování okna

2031


0

Střed okna: 1015.5

Rozsah: 2031

x


vstupní obraz



parametrický obraz – binární maska




segmentace




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska



Návrh neuronové BP sítě

segmentace NM obrazu (štítná žláza)

9 vstupů

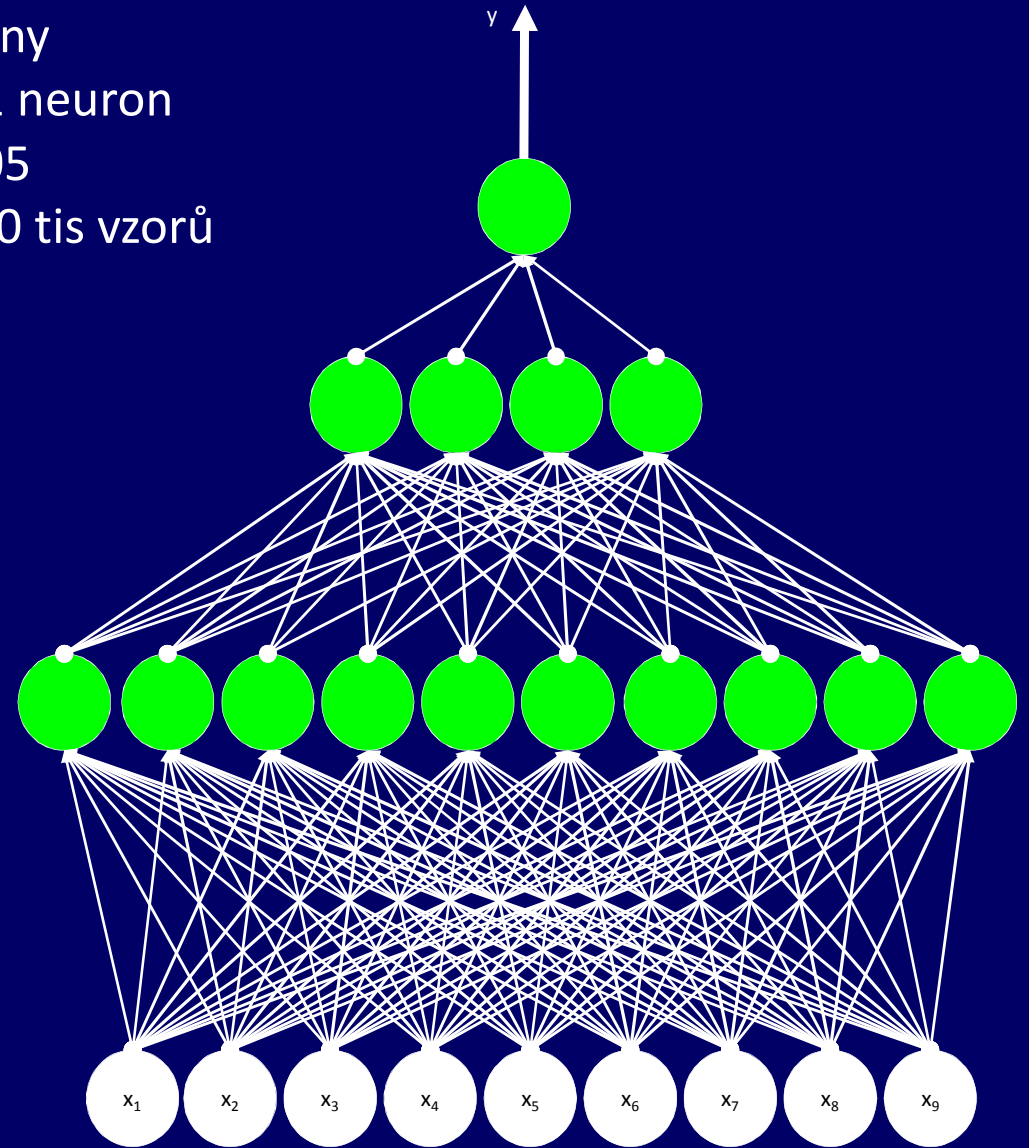
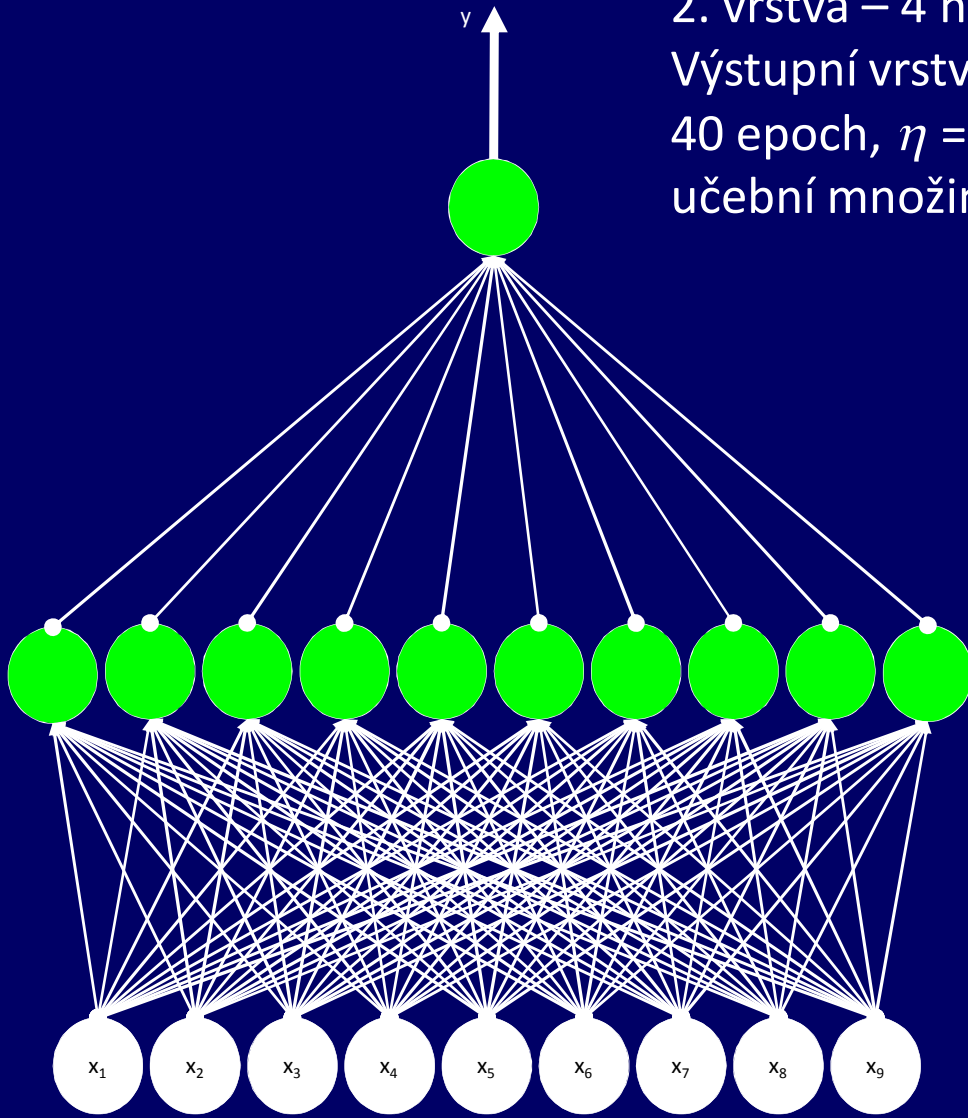
1. vrstva – 10 neuronů

2. vrstva – 4 neurony


Výstupní vrstva – 1 neuron

40 epoch, $\eta = 0,005$

učební množina: 50 tis vzorů




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS



segmentace




parametrický obraz – binární maska




vstupní obraz




parametrický obraz – výstup z NS




segmentace




parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS




segmentace



parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS



segmentace




parametrický obraz – binární maska




vstupní obraz




parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska




vstupní obraz



parametrický obraz – výstup z NS



segmentace



parametrický obraz – binární maska



Projekt

Výhody:

- uložení zkušeností NS v podobě přednastavených vah
- možnost přidávat další vzory (obrazy) k naučení sítě
- časová náročnost naučení NS v řádově desítek sekund až několik minut
- časově rychlé vybavování sítě – zobrazení výsledku

Nevýhody:

- časová náročnost vypočtu vzorů u rozměrných obrazů, nikoliv vybavování sítě
- vhodnější provést výřez obrazu se zájmovou oblastí
- normalizace dat a interpretace výsledku

Další projekt (rozpracován)

- detekce a hodnocení akumulace příštitných tělísek v NM

Typy neuronových sítí

Několik typů neuronových sítí

Každá neuronová síť je vhodná pro jiné třídy úloh.

Podle přítomnosti „učitele“ můžeme neuronové sítě dělit na sítě s učitelem a bez učitele

- Existuje celá řada neuronových sítí, např.
 - Vícevrstvá perceptronová síť
 - Hopfieldova síť
 - Hammingova síť
 - Kohonenovy samoorganizující se mapy
 - Síť RBF
 - ...

- Některé neuronové sítě se mohou vzájemně doplňovat.

Typické úlohy pro neuronové sítě

- Modelování, Identifikace a Analýza systémů
- Optimalizace
- Predikce signálů (časových řad)
- Klasifikace
- Rozpoznávání obrazců
- Detekce poruch

Např.: rozpoznávání písma, rukopisu, některé programy pro rozpoznávání řeči,...

Děkuji za pozornost