

# PV021: Neuronové sítě

**Tomáš Brázdil**

# Cíl předmětu

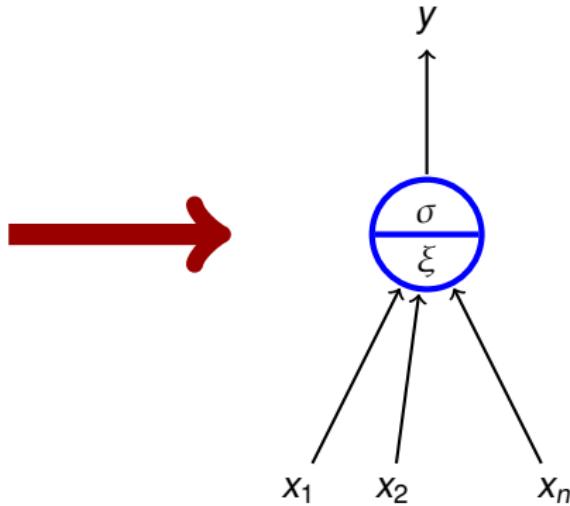
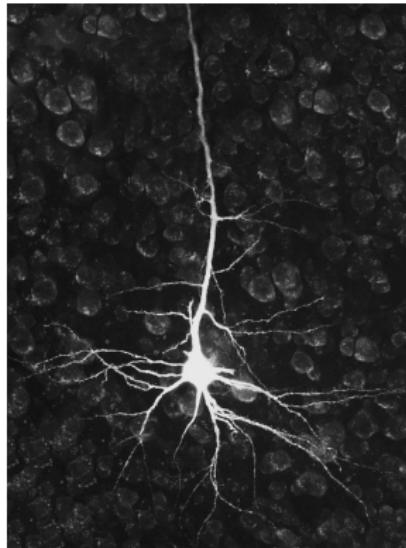
- ▶ Na co se zaměříme
  - ▶ Základní techniky a principy neuronových sítí (NS)
  - ▶ Přehled základních modelů NS a jejich použití
- ▶ Co si (doufám) odnesete
  - ▶ Znalost základních modelů NS (Perceptron, vícevrstvá síť, Hopfieldova síť, Boltzmannův stroj, Kohonenova mapa)
  - ▶ Znalost jednoduchých aplikací těchto modelů
  - ▶ Znalost základních principů učení NS
  - ▶ Přehled elementárních „implementačních“ technik pro učení a aplikaci NS
- ▶ Základní literatura:  
Jiří Šíma a Jan Neruda, Teoretické otázky neuronových sítí  
<http://www2.cs.cas.cz/~sim/a/kniha.pdf>  
(Nás bude zajímat převážně Část I.)

## Základy neuronových sítí

- ▶ Základní přehled a motivace
- ▶ Biologický neuron
- ▶ Formální neuron
- ▶ Neuronové sítě a jejich dynamika

# Co jsou umělé neuronové sítě

- ▶ **Umělý neuron** je *hrubou matematickou approximací* biologického neuronu.
- ▶ **(Umělá) neuronová síť** se skládá ze vzájemně propojených (umělých) neuronů. "Schopnosti" sítě jsou zakódovány v síle spojů mezi neurony.



# Proč umělé neuronové sítě ...

- ▶ Modelování biologických neuronových sítí (computational neuroscience).
  - ▶ zjednodušený matematický model pomáhá identifikovat důležité mechanismy
    - ▶ Jak mozek přijímá a zpracovává informace?
    - ▶ Jak uchovává informace?
    - ▶ Jak se mozek vyvíjí?
    - ▶ ...
  - ▶ neurovědy jsou silně multidisciplinární - precizní (matematický) popis usnadňuje komunikaci mezi odborníky na jednotlivé podoblasti

# Proč umělé neuronové sítě ...

„Inženýrské“ aplikace neuronových sítí.

- ▶ jedinečné vlastnosti biologických sítí vhodně doplňují standardní architekturu počítačů
- ▶ umělé neuronové sítě byly (a jsou) aplikovány v mnoha oblastech.
  - ▶ rozpoznávání vzorů (pattern recognition) - rozpoznávání řeči, psaného textu, sonarových signálů
  - ▶ predikce vývoje časových řad - vývoj cen akcií, měnových kurzů, počasí
  - ▶ další aplikace ve finančnictví - analýza rizik, dělení klientů do specifických skupin
  - ▶ řízení - robotika, řízení výrobních procesů
  - ▶ analýza dat - komprese, dolování znalostí, redukce dimenze dat
  - ▶ redukce šumu - ECG, obraz, zvuk
  - ▶ ...

# Významné vlastnosti neuronových sítí

- ▶ Masivní paralelismus
  - ▶ mnoho pomalých výpočetních prvků zpracovává informace paralelně na mnoha úrovních
- ▶ Adaptace a učení
  - ▶ dítě se naučí poznat králíka poté, co se mu ukáže několik králíků
- ▶ Schopnost generalizace
  - ▶ po shlédnutí několika králíků je dítě schopno poznat další (jiné) králíky
- ▶ Odolnost vůči nepřesnosti vstupu
  - ▶ rozmazaná fotka králíka může být stále klasifikována správně jako obraz králíka
- ▶ Odolnost vůči poškození
  - ▶ mnoho experimentů prokázalo, že i poškozená neuronová síť je stále schopna uspokojivě fungovat
  - ▶ poškozená síť se může přeadaptovat, stávající neurony mohou převzít funkci poškozených

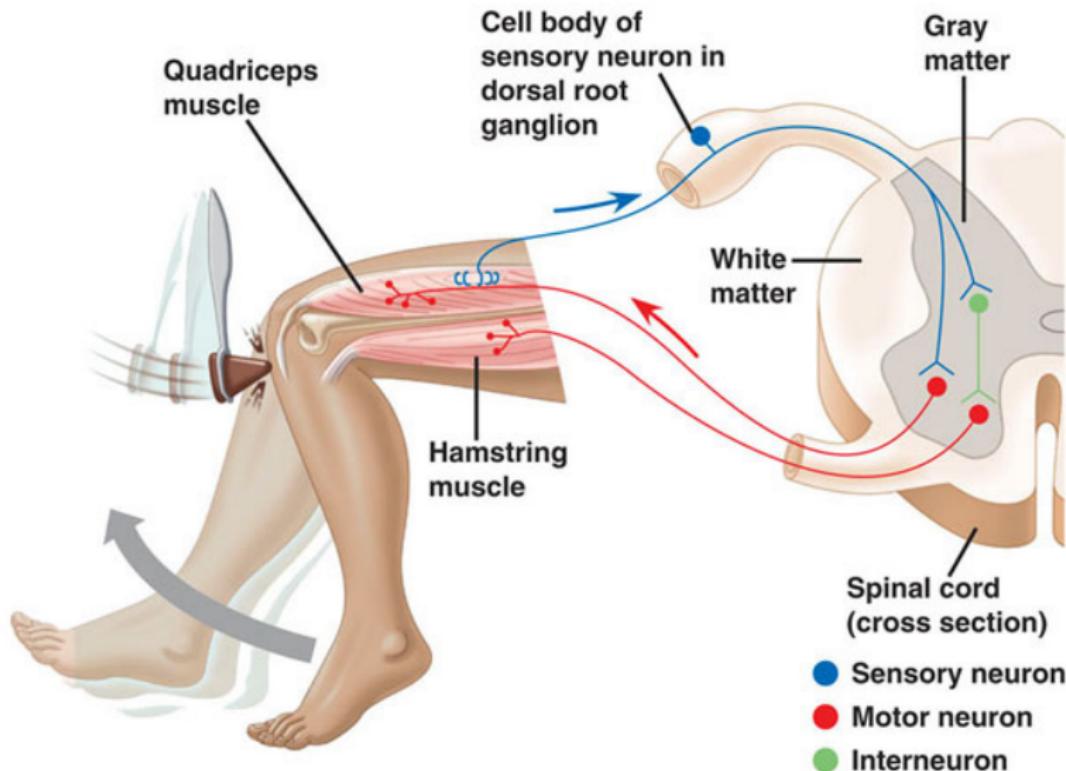
# Biologická neuronová síť

- ▶ Nervová soustava člověka se skládá z přibližně  $10^{11}$  neuronů (centimetr krychlový lidského mozku obsahuje až 50 milionů nervových buňek)
- ▶ Každý neuron je spojen s přibližně  $10^4$  neurony
- ▶ Neurony jsou velmi komplexní systémy

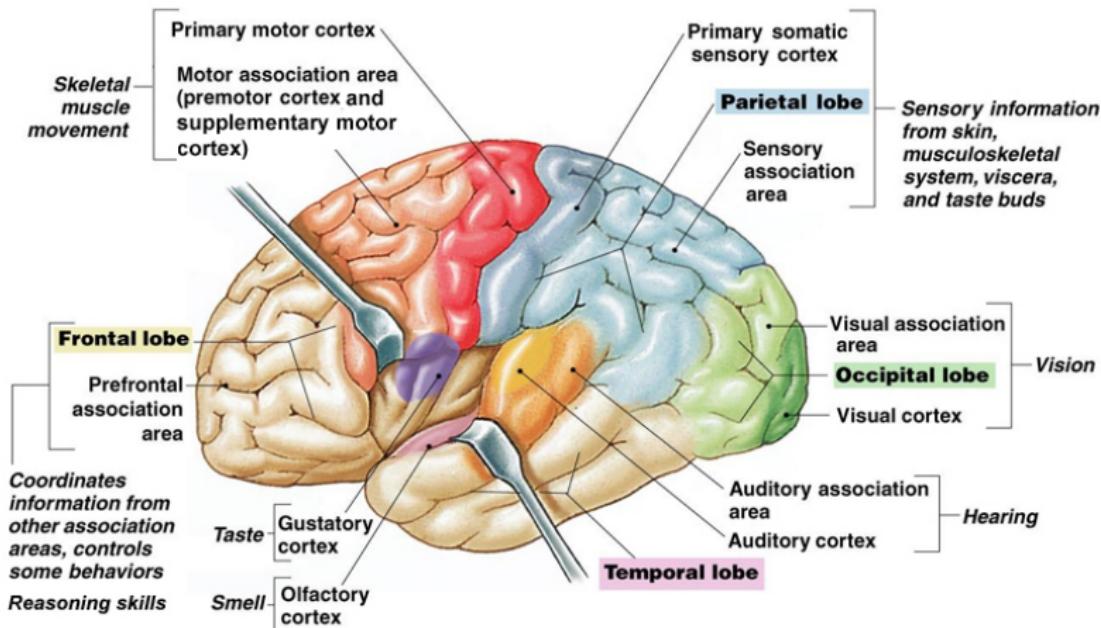
Velmi hrubý popis funkce nervové soustavy:

- ▶ Vnější podněty jsou přijímány *receptory* (např. buňky oka).
- ▶ Informace jsou dále přenášeny pomocí periferní nervové soustavy (PNS) do centrální nervové soustavy (CNS - mícha, mozek) kde jsou zpracovávány (*integrovány*)
- ▶ Po zpracování informace jsou (pomocí PNS) případně aktivovány *efektory* (např. svalové buňky)

# Biologická neuronová síť - příklad



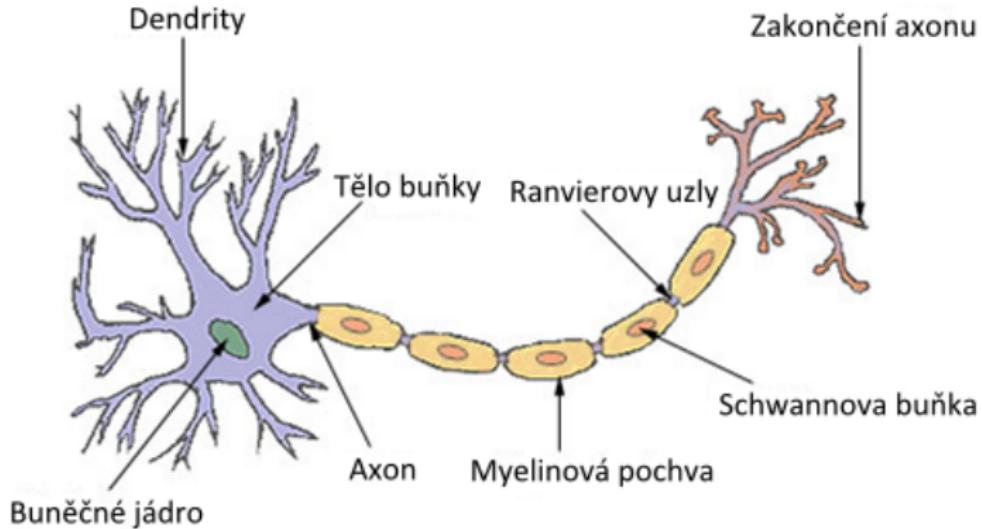
# Mozková kúra



Copyright © 2007 Pearson Education, Inc., publishing as Benjamin Cummings.

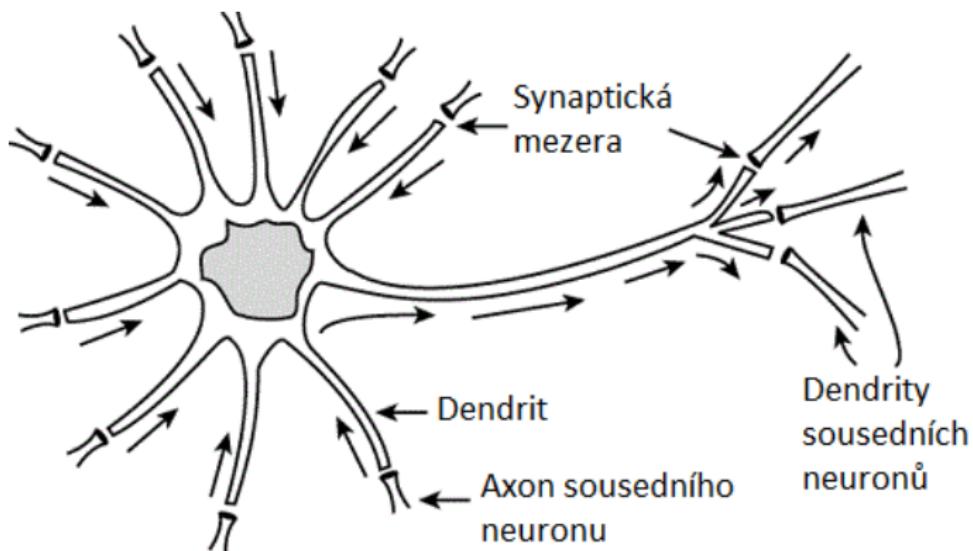
Fig. 9-15

# Biologický neuron



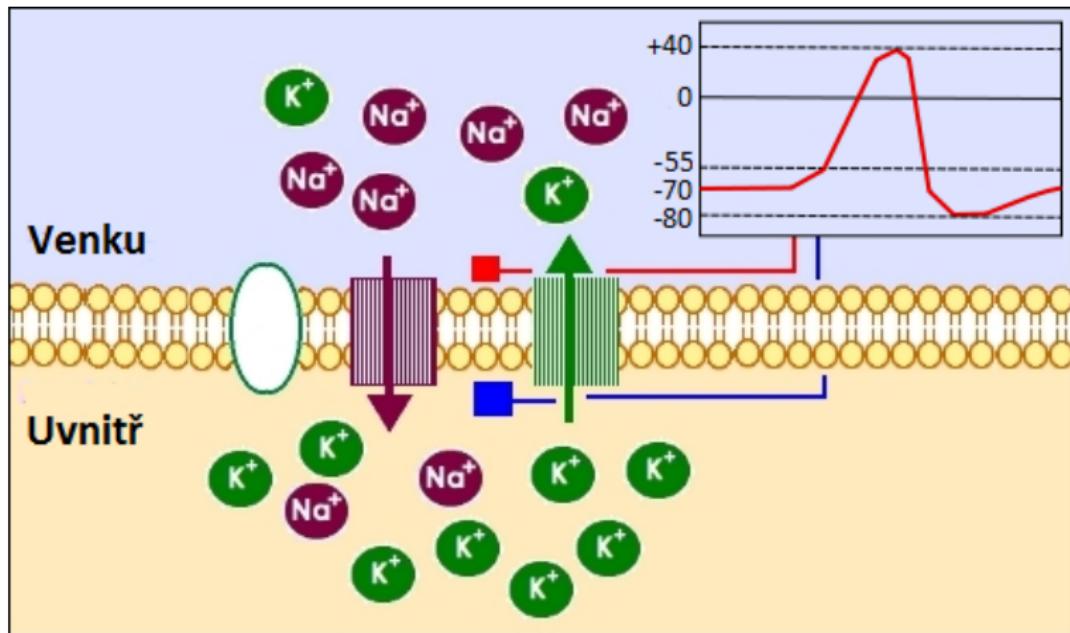
Zdroj: <http://www.web-books.com/eLibrary/Medicine/Physiology/Nervous/Nervous.htm>

# Sumace a akční potenciál



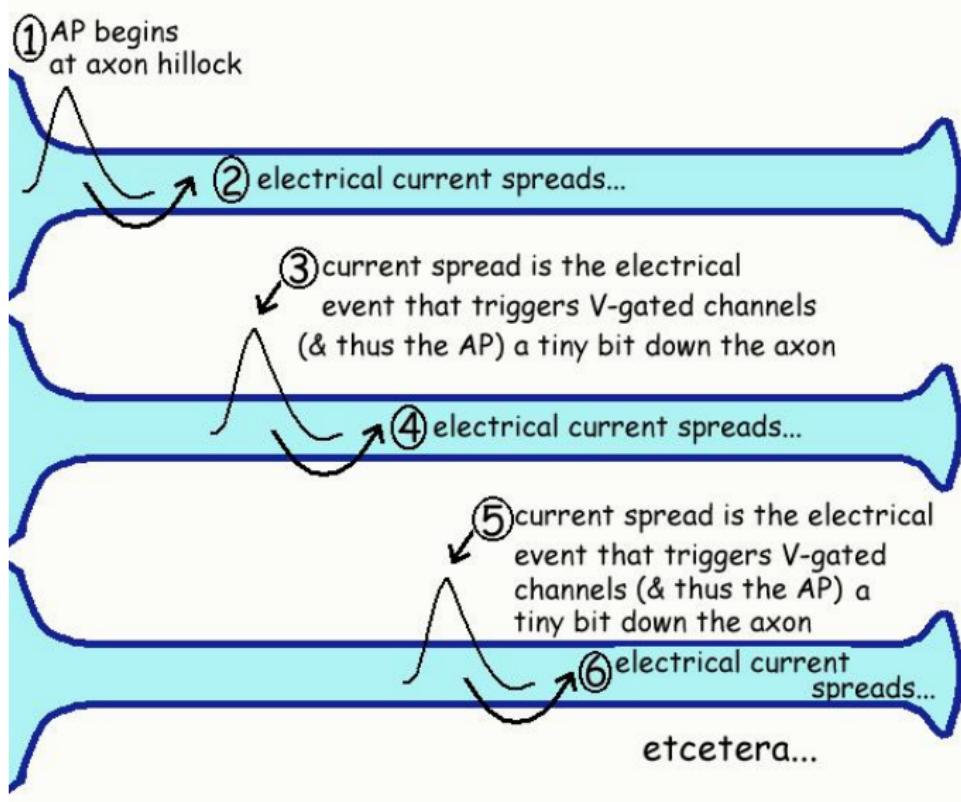
- ▶ Klidový potenciál v těle neuronu  $\approx -70$  mV
- ▶ Vnější podněty mění potenciál v axonovém hrbohlku
- ▶ Po překročení prahu  $\approx -55$  mV je generován **akční potenciál**  $\approx 40$  mV
- ▶ Poté nastane krátká **refrakce**  $\approx -80$  mV
- ▶ akční potenciál se šíří axonem, v axonovém zakončení vyvolá chemický proces, který změní potenciál v sousedním neuronu

# Sumace a akční potenciál - detailněji

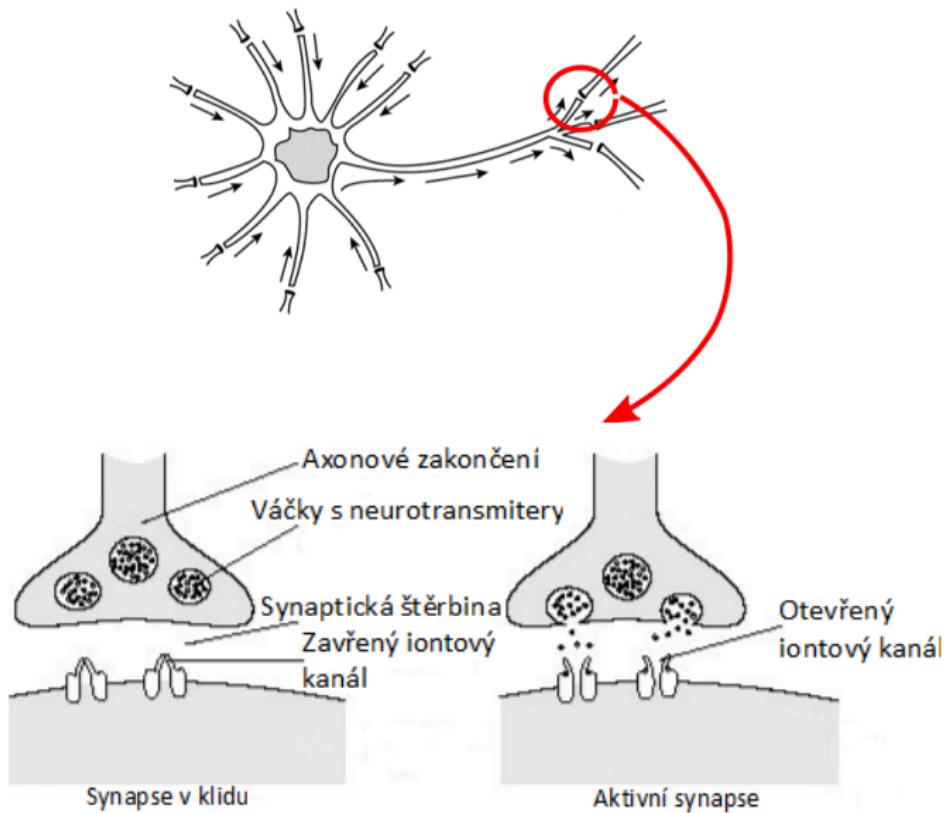


1. Při  $-55mV$  se otevřou kanály pro  $Na^+$ , které se nahrnou dovnitř
2. Při  $+40mV$  se  $Na^+$  kanály uzavřou a  $K^+$  otevřou -  $K^+$  se vyhrnou ven
3. Při  $-80mV$  se  $K^+$  uzavřou, poté iontové pumpy obnoví klidový potenciál

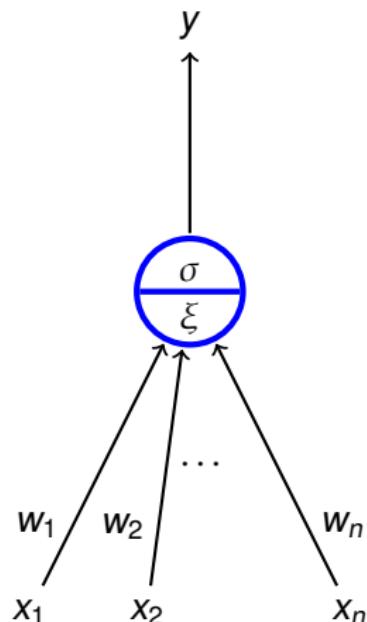
# Šíření akčního potenciálu axonem



# Synaptický přenos



# Formální neuron bez biasu

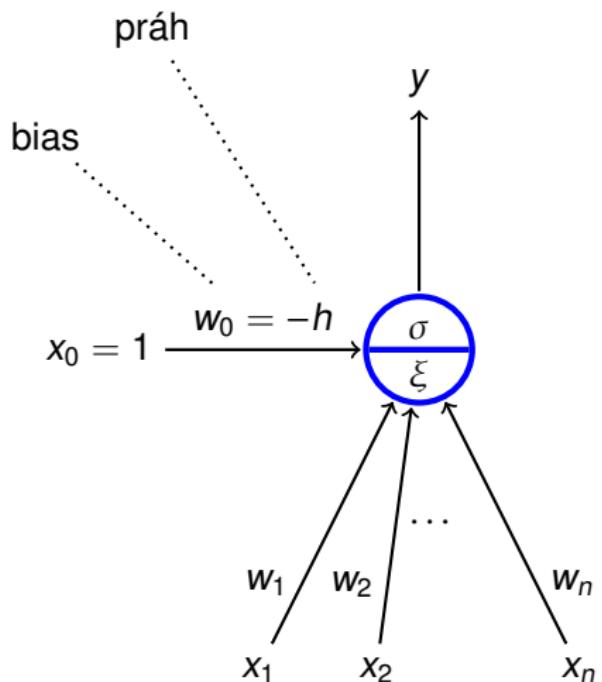


- ▶  $x_1, \dots, x_n$  jsou reálné **vstupy** („dendrity“)
- ▶  $w_1, \dots, w_n$  jsou reálné **váhy** („propustnost synapsí“)
- ▶  $\xi$  je **vnitřní potenciál**; většinou  $\xi = \sum_{i=1}^n w_i x_i$
- ▶ **y je výstup** daný  $y = \sigma(\xi)$  kde  $\sigma$  je **aktivační funkce**;  
např. ostrá *nelinearita*

$$\sigma(\xi) = \begin{cases} 1 & \xi \geq h ; \\ 0 & \xi < h . \end{cases}$$

kde  $h$  je reálný *práh*.

# Formální neuron (s biasem)

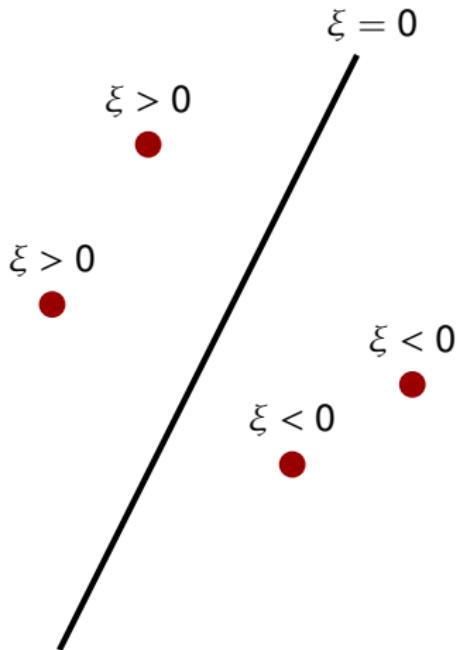


- ▶  $x_1, \dots, x_n$  jsou reálné **vstupy**
- ▶  $x_0$  je speciální vstup, který má vždy hodnotu 1
- ▶  $w_0, w_1, \dots, w_n$  jsou reálné **váhy**
- ▶  $\xi$  je **vnitřní potenciál**; většinou  $\xi = w_0 + \sum_{i=1}^n w_i x_i$
- ▶  $y$  je **výstup** daný  $y = \sigma(\xi)$  kde  $\sigma$  je **aktivační funkce**; např. ostrá nelinearita

$$\sigma(\xi) = \begin{cases} 1 & \xi \geq 0; \\ 0 & \xi < 0. \end{cases}$$

( práh aktivační funkce  $\sigma$  je roven 0;  
reálný práh byl nahrazen vstupem  
 $x_0 = 1$  a váhou  $w_0 = -h$ )

# Neuron a lineární separace



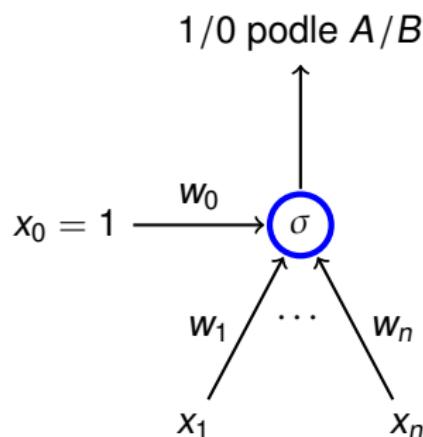
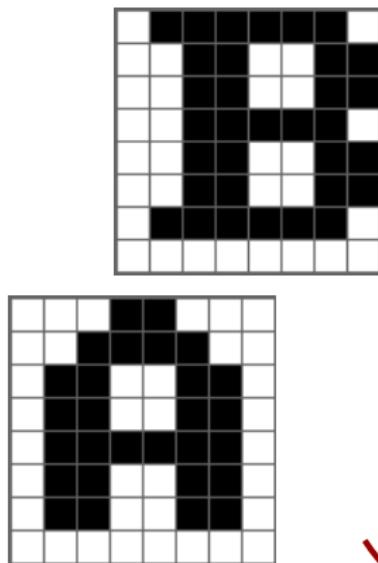
- ▶ vnitřní potenciál

$$\xi = w_0 + \sum_{i=1}^n w_i x_i$$

zadává separační nadrovinu v  
 $n$ -rozměrném **vstupním**  
**prostoru**

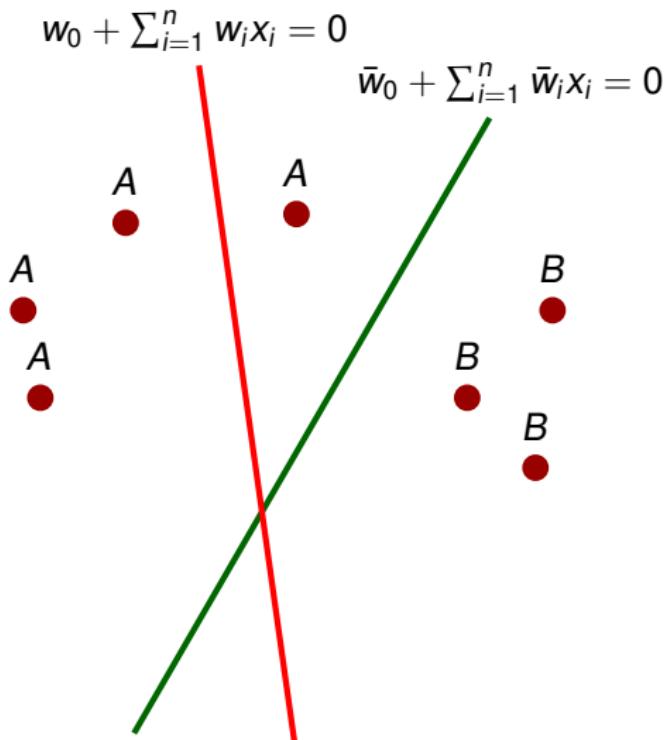
- ▶ v 2d přímka
- ▶ v 3d plocha
- ▶ ...

# Neuron a lineární separace



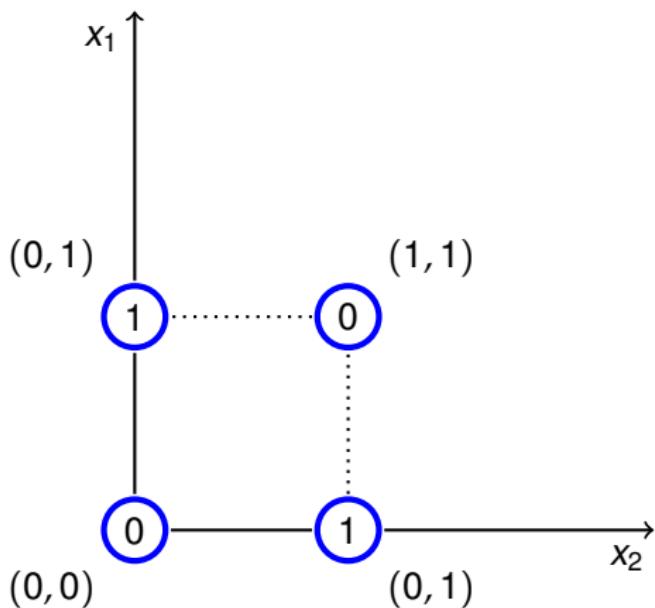
Zde  $n = 8 \cdot 8$  tedy počet pixelů v obrazcích. Vstupy jsou binární vektory dimenze  $n$  (tmavý bod  $\approx 1$ , světlý bod  $\approx 0$ ).

# Neuron a lineární separace



- ▶ Červená přímka nesprávně klasifikuje
- ▶ Zelená klasifikuje správně (může být výsledkem korekce učícího algoritmu)

# Neuron a lineární separace



- ▶ Neexistuje přímka, která by oddělila body 1 od bodů 0.

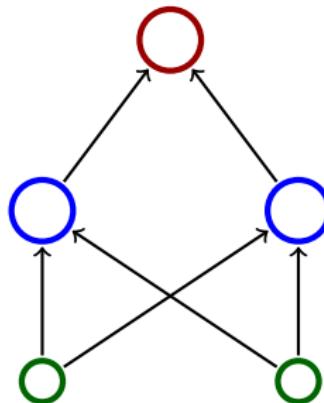
# Neuronové sítě

- ▶ **Neuronová síť** se skládá z formálních neuronů, které jsou vzájemně propojeny tak, že výstup jednoho neuronu je vstupem obecně více neuronů.
- ▶ **Architektura sítě** je určena počtem a vzájemným propojením neuronů.
- ▶ **Stav** sítě je vektor hodnot všech neuronů.  
(Stavy sítě s  $n$  neurony jsou prvky  $\mathbb{R}^n$ )
- ▶ **Stavový prostor** sítě je množina všech stavů.
- ▶ **Konfigurace** sítě je vektor hodnot všech vah v síti.  
(Konfigurace sítě s  $m$  spoji jsou prvky  $\mathbb{R}^m$ )
- ▶ **Váhový prostor** sítě je množina všech konfigurací.

# Neuronové sítě

Neurony rozdělujeme na

- ▶ Výstupní
- ▶ Skryté
- ▶ Vstupní



# Neuronové sítě

Dynamiku sítě dělíme do tří *režimů*

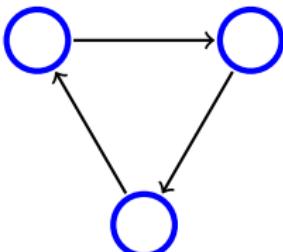
- ▶ **Organizační**
  - ▶ architektura sítě a její případná změna
- ▶ **Aktivní**
  - ▶ počáteční stav sítě (hodnoty neuronů) a jeho změny v čase (při pevné architektuře a konfiguraci)  
(mimo jiné určuje způsob výpočtu vnitřních potenciálů  $\xi$  a aktivační funkce  $\sigma$  všech neuronů)
- ▶ **Adaptivní**
  - ▶ počáteční konfigurace sítě (hodnoty vah) a její změna v čase (učení)

# Organizační dynamika

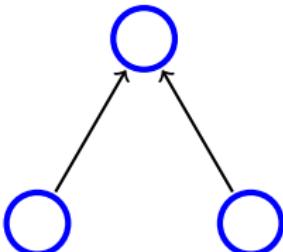
Organizační dynamika určuje strukturu sítě.

Rozlišujeme dva typy architektury:

- ▶ Cyklická (resp. rekurentní), pokud obsahuje orientovaný cyklus.



- ▶ Acyklická (resp. dopředná)

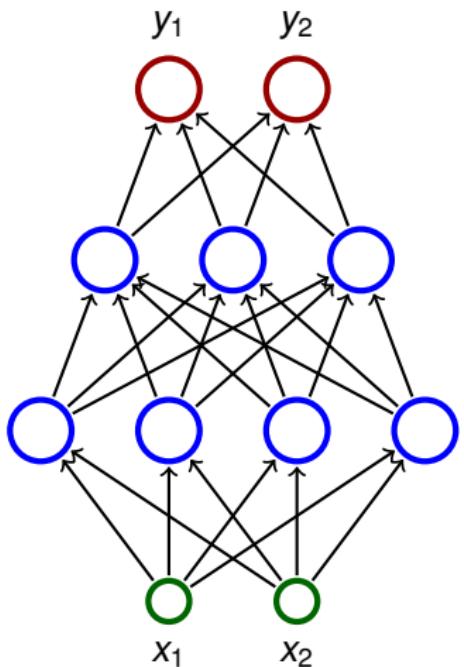


# Organizační dynamika - vícevrstvé sítě

Výstupní

Skryté

Vstupní



- ▶ Neurony jsou rozděleny do **vrstev** (vstupní a výstupní vrstva, obecně několik skrytých vrstev)
- ▶ Vrstvy číslujeme od 0; vstupní vrstva je nultá
  - ▶ Např. třívrstvá síť se skládá z jedné vstupní, dvou skrytých a jedné výstupní vrstvy.
- ▶ Neurony v  $i$ -té vrstvě jsou spojeny se všemi neurony ve vrstvě  $i + 1$ .
- ▶ Vícevrstvou síť lze zadat počty neuronů v jednotlivých vrstvách (např. 2-4-3-2)

Aktivní dynamika určuje, jakým způsobem síť počítá.

Mějme síť s  $n$  neurony z nichž  $k$  je vstupních a  $\ell$  výstupních.

- ▶ **Vstup sítě** je vektor  $k$  reálných čísel, tedy prvek  $\mathbb{R}^k$ .

(někdy se omezíme pouze na jistou podmnožinu  $\mathbb{R}^k$ )

- ▶ **Vstupní prostor** sítě je množina všech vstupů.

- ▶ **Počáteční stav**

Vstupní neurony jsou nastaveny na hodnoty ze vstupu sítě  
(každá složka vstupu má přiřazen příslušný vstupní neuron)

Ostatní neurony jsou iniciálně nastaveny na 0.

# Aktivní dynamika - výpočet

- ▶ **Výpočet** (obvykle) probíhá v diskrétních krocích.  
V každém kroku se provede následující:
  1. Podle **pravidla aktivní dynamiky** je vybrán jeden neuron (sekvenční výpočet) nebo více neuronů (paralelní výpočet).
  2. Vybraný neuron změní svůj stav v závislosti na hodnotách svých vstupů.  
(Hodnota neuronu, který nemá vstupy, zůstává konstantní.)

Výpočet je **konečný** pokud se od jistého kroku dál nemění stav sítě.

- ▶ **Výstup sítě** je vektor hodnot všech výstupních neuronů (tedy prvek  $\mathbb{R}^\ell$ ). Výstup se mění v průběhu výpočtu!

Pro vícevrstvé sítě používáme následující pravidlo aktivní dynamiky:

V  $i$ -tém kroku vyhodnoť právě všechny neurony v  $i$ -té vrstvě.

# Aktivní dynamika - funkce sítě

## Definice

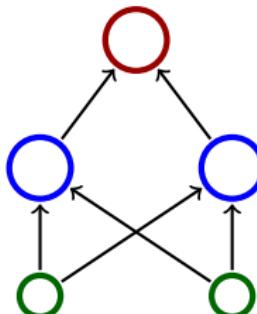
Mějme neuronovou síť s  $n$  neurony z nichž  $k$  je vstupních a  $\ell$  výstupních. Nechť  $A \subseteq \mathbb{R}^k$  a  $B \subseteq \mathbb{R}^\ell$ . Předpokládejme, že výpočet této sítě skončí pro každý vstup z  $A$ .

Řekneme, že tato síť **počítá funkci**  $F : A \rightarrow B$  pokud pro každý vstup  $\vec{v} \in A$  je  $F(\vec{v})$  výstupem sítě po skončení výpočtu.

Podle toho, zda je funkce sítě diskrétní nebo spojitá rozlišujeme **diskrétní** a **analogové** neuronové sítě.

## Příklad 1

Tato síť počítá funkci z  $\mathbb{R}^2$  do  $\mathbb{R}$ .



# Aktivní dynamika - aktivační funkce

Aktivní dynamika určuje aktivační funkci  $\sigma$  pro každý neuron.

- ▶ Ostrá nelinearita

$$\sigma(\xi) = \begin{cases} 1 & \xi \geq 0 \\ 0 & \xi < 0. \end{cases}$$

- ▶ Logistická sigmoida

$$\sigma(\xi) = \frac{1}{1 + e^{-\lambda \cdot \xi}} \quad \text{kde } \lambda \in \mathbb{R} \text{ je prametr strmosti.}$$

- ▶ Hyperbolický tangens

$$\sigma(\xi) = \frac{1 - e^{-\xi}}{1 + e^{-\xi}}$$

## Aktivní dynamika - vnitřní potenciál

Aktivní dynamika určuje způsob výpočtu vnitřního potenciálu  $\xi$  každého neuronu.

Pokud nebude uvedeno jinak, předpokládáme, že

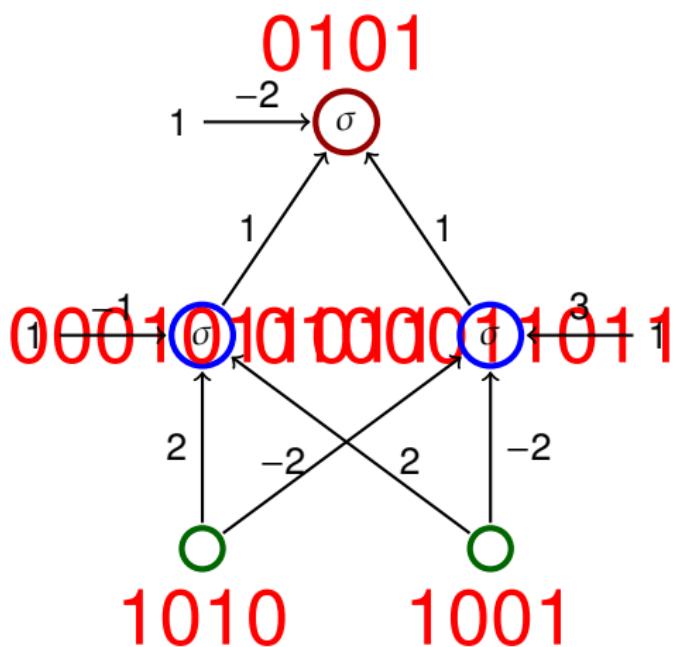
$$\xi = w_0 + \sum_{i=1}^n w_i \cdot x_i$$

Později využijeme další možnosti, např.

$$\xi = \|\vec{x} - \vec{w}\|$$

kde  $\|\cdot\|$  je daná vektorová norma (nejčastěji Euklidovská),  
 $\vec{x} = (x_1, \dots, x_n)$  jsou vstupy neuronu a  $\vec{w} = (w_1, \dots, w_n)$  jsou váhy.

# Aktivní dynamika - XOR



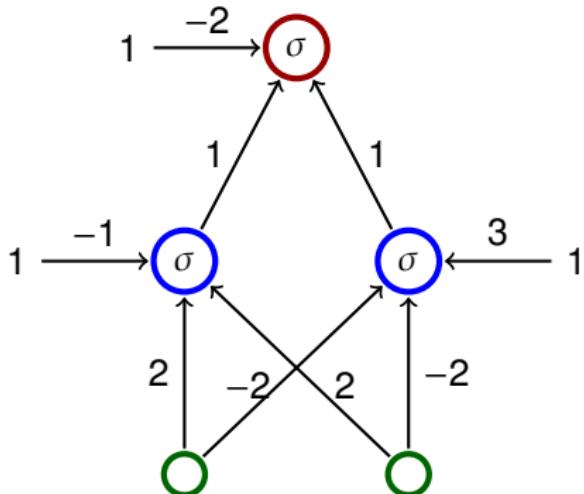
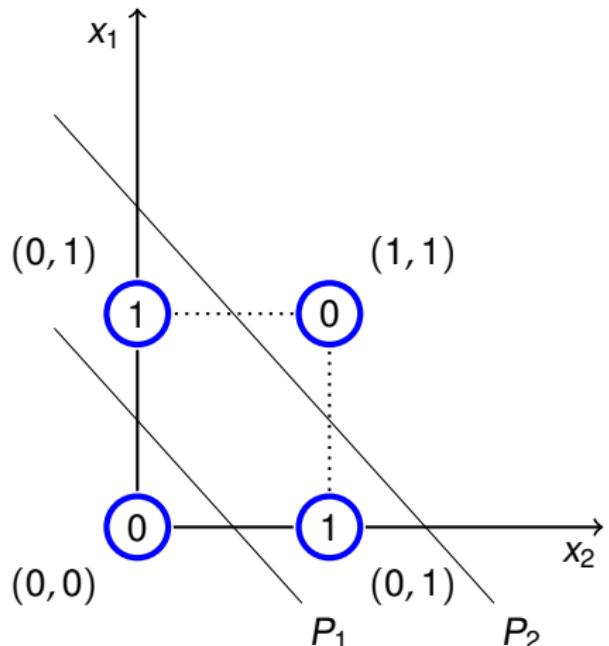
- ▶ Aktivační funkce je ostrá nonlinearita

$$\sigma(\xi) = \begin{cases} 1 & \xi \geq 0 \\ 0 & \xi < 0. \end{cases}$$

- ▶ Síť počítá funkci  $XOR(x_1, x_2)$

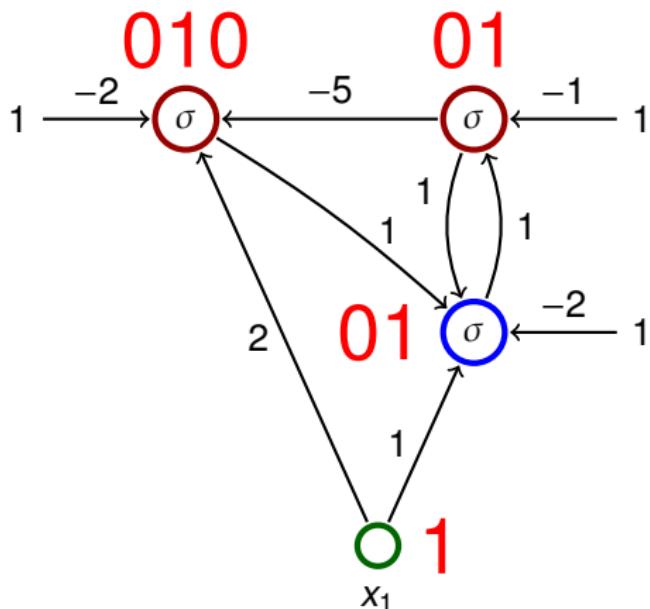
$x_1$	$x_2$	$y$
1	1	0
1	0	1
0	1	1
0	0	0

# Neuron a lineární separace



- ▶ Přímka  $P_1$  má rovnici  $-1 + 2x_1 + 2x_2 = 0$
- ▶ Přímka  $P_3$  má rovnici  $3 - 2x_1 - 2x_2 = 0$

# Aktivní dynamika - příklad



Aktivační funkce ostrá  
nelinearity

$$\sigma(\xi) = \begin{cases} 1 & \xi \geq 0; \\ 0 & \xi < 0. \end{cases}$$

vstup je roven 1

# Adaptivní dynamika

Adaptivní dynamika určuje, jakým způsobem se síť učí.

- ▶ **počáteční konfigurace**

váhy mohou být nastaveny buď náhodně nebo na základě předběžné znalosti vstupů sítě

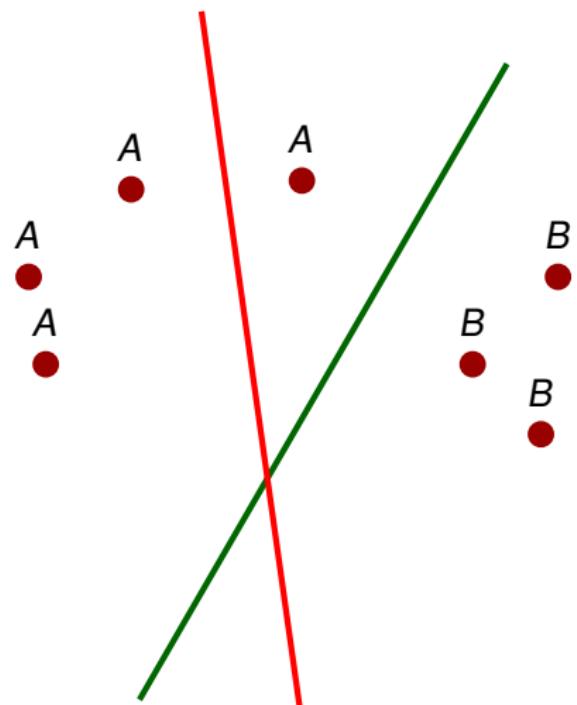
- ▶ **učící pravidlo** pro (postupnou) adaptaci váh

cílem je adaptovat váhy tak, aby síť počítala danou funkci

# Adaptivní dynamika - učící pravidla

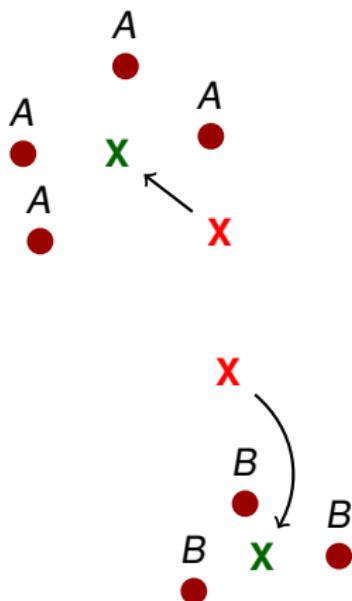
- ▶ učení s učitelem
  - ▶ Požadovaná funkce je zadána množinou *trénninkových* vzorů což jsou dvojice tvaru (vstup, výstup).
  - ▶ Při učení se hledá konfiguraci sítě, která nejlépe odpovídá daným vzorům (vzhledem k danému kvalitativnímu kritériu).
- ▶ učení bez učitele
  - ▶ Tréninková množina obsahuje pouze vstupy sítě.
  - ▶ Cílem je odhalit strukturu v množině vstupů (shlukování, samoorganizace)

# Učení s učitelem - ilustrace



- ▶ klasifikace v rovině pomocí jednoho neuronu
- ▶ tréninkové vzory jsou tvaru (bod, hodnota) kde hodnota je buď 1 nebo 0 podle toho zda je bod ze skupiny A nebo B
- ▶ po předložení nesprávně klasifikovaného vzoru skupiny A (**červená** přímka), učící algoritmus pootočí přímku ve směru nesprávně klasifikovaného bodu (**zelená** přímka).

# Učení bez učitele - ilustrace



- ▶ hledáme dva reprezentanty „shluků“
- ▶ červené křížky odpovídají reprezentantům před aplikací učícího algoritmu, zelené po aplikaci
- ▶ učící algoritmus může např. napočítat množinu bodů, které jsou nejblíže danému reprezentantovi a potom reprezentanta posunout do těžiště této množiny bodů

# Výhody umělých neuronových sítí

- ▶ Masivní paralelismus
  - ▶ neurony mohou být vyhodnocovány současně
- ▶ Adaptace a učení
  - ▶ existuje mnoho učících algoritmů, které „programují“ neuronové sítě na základě příkladů požadovaného chování
- ▶ Schopnost generalizace a odolnost vůči nepřesnosti vstupu
  - ▶ informace jsou v síti kódovány *přibližně* pomocí vah mnoha neuronů
  - ▶ na vstup podobný vstupu tréninkového vzoru, reaguje naučená síť podobným výstupem
  - ▶ takto je schopna extrahovat charakteristické vlastnosti dat
- ▶ Odolnost vůči poškození
  - ▶ poškození se obvykle projevuje postupnou ztrátou přesnosti výsledků