

# Neurónové siete

## 1. prednáška



**Matematický model neurónu a neurónovej siete.  
Postavenie neurónových sietí v informatike.**

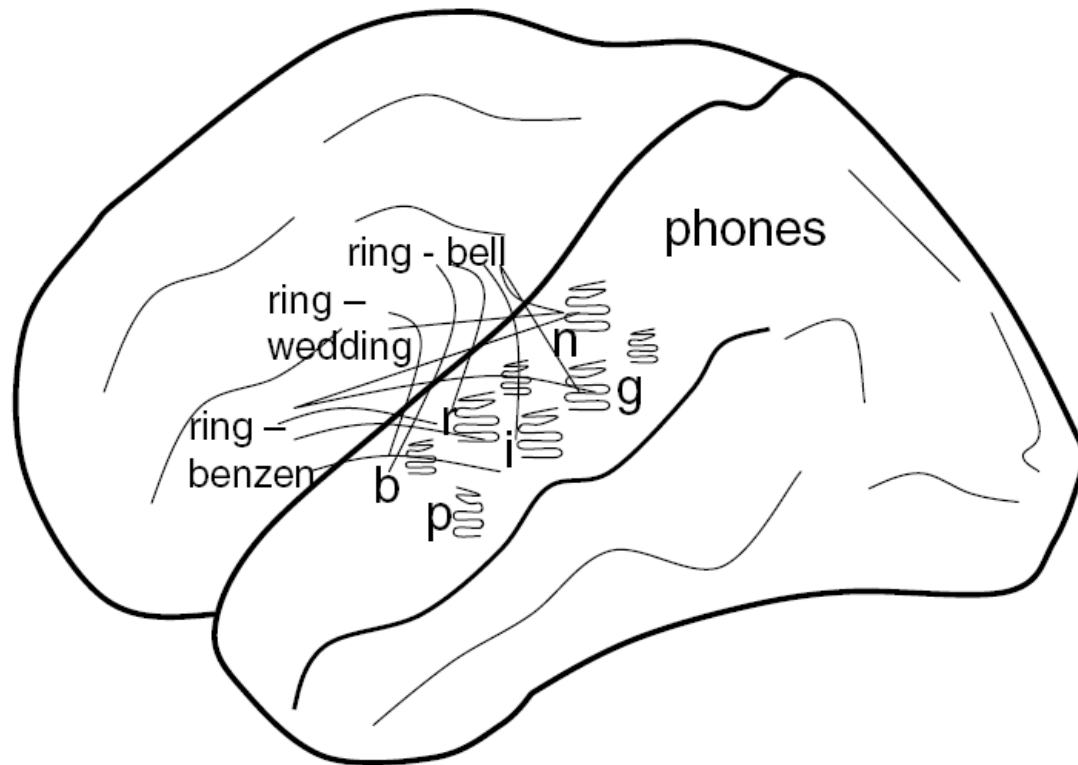
**Prahové jednotky.**

**Perceptróny. Lineárne separovateľné objekty,  
adaptačný proces (učenie), konvergencia  
perceptrónu, perceptróny vyššieho rádu.**

**Typy neurónových sietí.**

# Čo vieme o mozgu?

---



# Fenomén neuronových sietí (NS)

---

- sú inšpirované biologickými neuronovými sieťami
- využívajú distribuované, paralelné spracovanie informácie pri vykonaní výpočtov
- znalosti sú ukladané predovšetkým prostredníctvom sily väzieb medzi jednotlivými neurónmi
- učenie je základná a podstatná vlastnosť neuronových sietí

# História

---

- ❑ Warren Mc Culloch, Walter Pitts, 1943
- ❑ najjednoduchšie typy NS ... ľubovoľná aritmetická alebo logická funkcia
- ❑ Donald Hebb: The Organization of Behavior, 1949
- ❑ učiace pravidlo pre synapsie neurónov
- ❑ prvý neuropočítač Smark, 1951, Marwin Minsky
- ❑ Frank Rosenblatt, 1957... perceptrón, učiaci algoritmus - Principles of Neurodynamics

# História

---

- 1957, 1958 Mark I - Perceptron
- ADALINE
- Nils Nilsson: Learning Machines, 1965 – kritický postoj
- 1967-1982 - ojedinelý výskum, NS zaznávané
- 80. roky
- 1982, 84 John Hopfield – vyznačne sa zaslúžil o pokračovanie vo výskume NS

# Umelé neurónové siete sú vlastne

---

- **paralelné výpočtové modely** - husto poprepájané adaptívne jednotky (procesory)
- **adaptívna povaha - "učenie z príkladov"** - čo je veľmi žiadané v aplikáciách,

# Predpokladáme



---

- sú k dispozícii tréningové údaje
- je neúplné porozumenie riešeného problému (napríklad nevieme tvar funkcie, ktorú potrebujeme nájsť)

Výpočtové modely pre triedy problémov:

- klasifikácia
- syntéza a rozpoznávanie reči
- aproximácia funkcií
- kompresia údajov
- vyhľadávanie klastrov
- predikcia
- kombinatorické optimalizačné úlohy
- modelovanie nelineárnych systémov
- riadenie

# Ako vyzerá biologický neurón?




Prvý obrázok znázorňuje neuróny v mozgu a ich veľkú vzájomnú prepojenosť

Druhý obrázok znázorňuje neurón (nerve cell) zložený z viacerých vstupných spojení (dendrites) a jedného silnejšieho výstupného spojenia (axon). repojenosť.




# Biologický neurón

- Človek  $\rightarrow 1.3 \times 10^{10}$  neurónov
  - $10^{10}$  je v mozgu
  - Každý neurón je pripojený  $\sim 10,000$  inými neurónmi
  - Rozptyl napätia  $\sim 20W$




- Štruktúra neurónu

- Cell Body – **Soma**
- **Axon/prepojenie**
- **Dendrity**
- **Presynaptic Terminal**



# Biologický neurón


## □ Vnútro neurónu:



- **Nucleus** - genetický materiál (chromozómy)
- **Nucleolus** - Produkuje ribozómy : genetická informácia → proteíny
- **Nissl Bodies** - skupiny ribozómov → syntéza proteínov
- **Endoplasmic reticulum (ER)** – systém trubíc → transport materiálu cytoplazme
- **Golgi Apparatus** – membránová ohraničujúca štruktúra
- **Microfilaments/Neurotubules** - transport materiálov v neuróne & štrukturálna podpora.
- **Mitochondria** - Produkujú energiu


# Modelovanie neurónu

---



# Perceptróny, učiace pravidlá

---



# Učiacie 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 a  $d_k \in \{-1, +1\}$ ,  $k=1, 2, \dots, m$  je predpokladaná trieda (cieľ) pre k - tý vstupný vektor (poradie dvojíc - náhodné)

# Učiacie pravidlá pre perceptróny

---

## Správna klasifikácia

- Cieľ - navrhnúť perceptrón, ktorý pre každý vstupný vektor  $\mathbf{x}_k$  tréningovej množiny dá výstup  $y_k$ , ktorý sa zhoduje s cieľom  $d_k$ . 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)**:

- $\mathbf{W}_0 =$  ľubovoľné
- $\mathbf{W}_{k+1} = \mathbf{W}_k + ro (d_{k+1} - y_{k+1})\mathbf{x}_{k+1} \quad k=1,2,\dots$

kde  $ro$  je kladná konštanta - **učiaci pomer**.

# Poznámky

---

- ❑ ak riešenie existuje, potom je dosiahnuté po konečnom počte iterácií;
- ❑ vo všeobecnosti táto metóda poskytuje nekonečný počet riešení;
- ❑ Rosenblattovo učiace pravidlo konverguje k jednému z nich;
- ❑ riešenie je citlivé na hodnotu učiaceho pomeru  $\rho$ , ktorá koriguje prezentáciu dvojice;
- ❑ počet korekcií  $k_0$  závisí od výberu počiatočných hodnôt vektora váh  $\mathbf{W}_0$ ;
- ❑ 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.



# Zovšeobecnenie učiaceho pravidla perceptrónu

---

a)

□  $\mathbf{w}^1$  - ľubovoľné

□  $\mathbf{w}^{k+1} = \mathbf{w}^k + \rho^k \mathbf{z}^k$ , ak  $(\mathbf{z}^k)^T \mathbf{w}^k \leq b$

□  $\mathbf{w}^{k+1} = \mathbf{w}^k$ , inak

# Ďalšie učiace pravidlo

---

b) batch update procedúra

$\mathbf{w}^0$  - ľubovoľné

$$\mathbf{w}^{k+1} = \mathbf{w}^k + \rho \sum \mathbf{z}, \quad \mathbf{z} \in Z(\mathbf{w}^k)$$


kde  $\mathbf{z} \in Z(\mathbf{w}^k)$  je množina nesprávne klasifikovaných vzorov pri váhe  $\mathbf{w}^k$ .

- konverguje rýchlejšie, ale...

# Typy neurónových sietí


## □ Feedforward

- Perceptron
- Multilayer – Error Backpropagation




## □ Competitive

- Hemming
- Maxnet




## □ Variácie pre Competitive

- Adaptive Resonance Theory (ART)
- Kohonen



## □ Hopfield



# Nájsť sieť znamená

---

- určiť počet skrytých vrstiev a počet neurónov v nich
- stanoviť váhy všetkých spojení a prahy všetkých neurónov siete
- ak to určitá metóda hľadania siete vyžaduje, tak aj niektoré ďalšie parametre

# Metódy adaptácie viacvrstvových sietí

---

- **Adaptácia siete** (jej učenie), je charakteristickou vlastnosťou neurónových sietí.
- **Gradientné metódy** - základom je nájsť také hodnoty parametrov siete, ktoré by minimalizovali danú **chybovú funkciu**  $\varepsilon$ .
- **Minimalizácia globálnej chyby**

$$\varepsilon \equiv GE = \frac{1}{2} \sum_T \sum_{i=1}^n (y_i - d_i)^2$$

- kde  $d_i$  je očakávaná odozva siete na daný vstupný vektor v i-tom výstupnom neuróne a  $y_i$  je vypočítaná odozva siete v i-tom výstupnom neuróne