

Umělé neuronové sítě

Úvod do problematiky

- výpočetní model
- vychází z biologických principů – fungování lidského mozku:
 - rychlosť zpracování informací
 - způsob zpracování informací – paralelně
 - způsob ukládání informací
 - redundancy, řízení

Umělé neuronové sítě – Stručná historie

- 1943 – formální neuron (W. McCulloch, W. Pitts)
- 1949 – matematický pojem učení (D. Hebb)
- 1951 – první neuropočítač Snark (M. Minsky)
- 1958 – perceptron (F. Rosenblatt)
- 1958 – první úspěšný neuropočítač *Mark I Perceptron* (F. Rosenblatt, C. Wightman)
- 1962 – Adaline a sigmoidální přenosová funkce (B. Widrow, M. Hoff)
- 60. léta - velký rozvoj neurovýpočtů a neuropočítačů, ale problémy
- 1969 – Perceptrony (M. Minsky, S. Papert)

Umělé neuronové sítě – Stručná historie

od 80. let — další rozvoj (Darpa, J. Hopfield)

- 1986 Algoritmus zpětného šíření (P. Werbos, D. Rumelhart, G. Hinton, Y. LeCun)
- Kohonenovy mapy (T. Kohonen)
- RBF-sítě (Radial Basis Function, J. Moody, C. Darken)
- GNG-model (Growing Neural Gas, B. Fritzke)
- Konvoluční neuronové sítě (Y. LeCun)
- SVM-stroje (Support Vector Machines, V. Vapnik)
- ELM-sítě (Extreme Learning Machines, G.-B. Huang)

Umělé neuronové sítě – Stručná historie

od 80. let — další rozvoj

- 1987 IEEE International Conference on Neural Networks
- 1987 založena INNS (International Neural Network Society), časopis *Neural Networks*
- mezinárodní časopisy: *Neural Computation* (1989), *IEEE Transactions on Neural Networks* (1990), *Neural Network World* (1991) aj.

Umělé neuronové sítě – Stručná historie

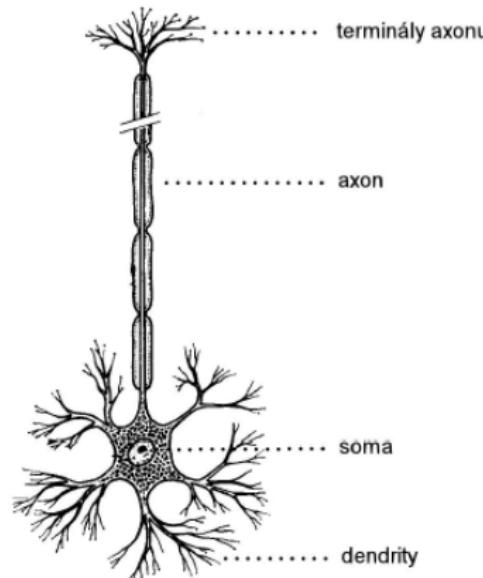
Současné problémy

- Strategie učení – paralelizace a efektivita
- Architektura — generalizace a robustnost
- Přeúčení

Použití

- Dobývání znalostí, shlukování, klasifikace
- Optimalizační úlohy
- Zpracování signálů (řeč, obraz, motorika apod.)
- Komprese dat
- Multimediální data
- ...

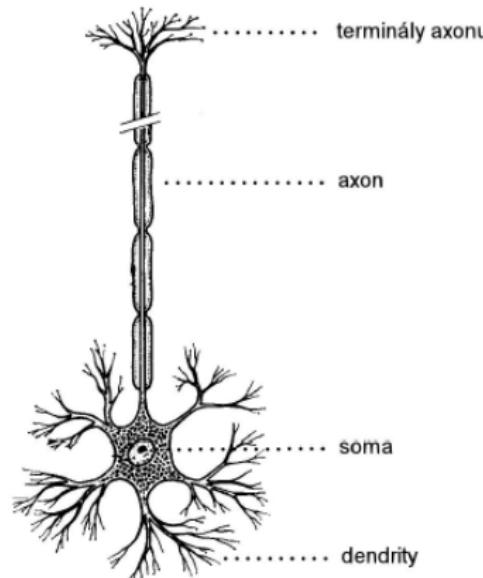
Model biologického neuronu



Biologický neuron

- základní stavební jednotka neuronové sítě
- výstup závisí na vstupech neuronu a jejich zpracování uvnitř těla neuronu

Model biologického neuronu



Biologická neuronová síť

- neurony jsou vzájemně propojeny do sítí
 - axony se pomocí synapsí napojují na dendryty dalších neuronů
 - synapse se vytvářejí během celého života – učení, paměť

Paměť

- **Krátkodobý paměťový mechanismus**

- založen na cyklickém oběhu vzruchů v neuronových sítích
- fixace informace za cca 30 s

- **Střednědobý paměťový mechanismus**

- založen na změnách vah neuronů
- uchování informace v řádu hodin až dnů

- **Dlouhodobý paměťový mechanismus**

- uchování informace do bílkovin v jádřech neuronů
- uchování informace až celý život

Adaptace a učení

Adaptace

- schopnost přizpůsobit se změnám okolního prostředí
- znamená pro organismus vždy ztrátu (materiál, energie,...)

Učení

- minimalizace ztrát vynaložených na adaptaci
- výsledek mnohonásobného opakování adaptace

Strojové učení

Princip

- vychází z biologických principů, model se "vytvoří sám"
- výpočetní model se učí na základě předložených příkladů a sám provádí predikci

Výpočetní modely založené na znalostech

- ① expertní - model vytvoří expert
- ② sehnat data a naučit model z dat – strojové učení
- ③ spolupráce strojového učení a experta – expert kritizuje či opravuje model vytvořený z dat

Strojové učení

Příklady modelů strojového učení

- uložená data
- lineární či nelineární funkce (lineární regrese, logistická regrese apod.)
- rozhodovací strom, množina pravidel
- bayesovská síť
- neuronová síť
- fuzzy systémy
- ...

Strojové učení

Úloha strojového učení

- je dána množina trénovacích dat: vstupní a výstupní vzory (požadované výstupy)
- chceme, aby model co nejlépe approximoval neznámou funkci
→ aby pro každý předložený vstupní správně predikoval hodnotu výstupu
- generalizace = zobecňování – model by měl dát správný výstup i pro data, která nejsou v trénovací množině

Základní způsoby učení

Typy úloh

- regrese – predikujeme numerickou hodnotu
- klasifikace – predikujeme diskrétní hodnotu

Metody učení

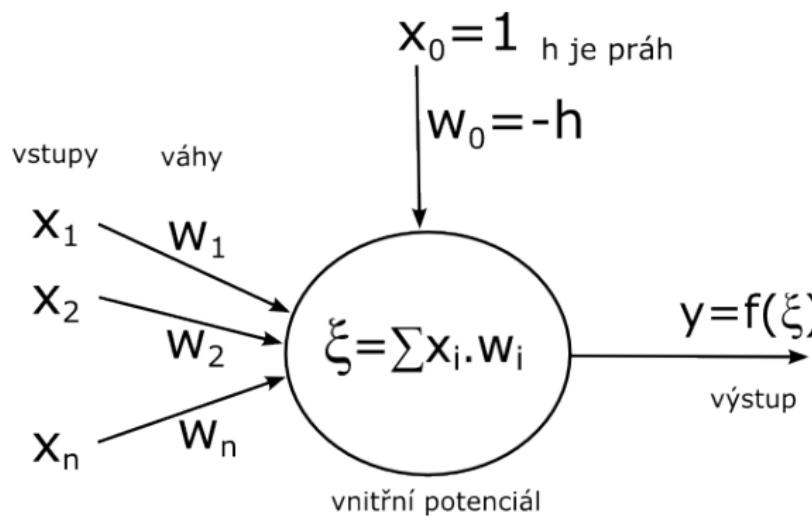
- Učení s učitelem (supervised learning)
- Učení bez učitele (unsupervised learning)
- Zpětnovazebné učení (reinforcement learning)

Strojové učení

Postup řešení úlohy

- připravit data – např. vybrat příznaky
- naučit model
 - jaký typ modelu? (záleží na problému)
 - jaký model daného typu? (volba vhodných parametrů)
- otestovat model – nejlépe na nových datech

Formální (matematický) model neuronu



- vnitřní potenciál $\xi = \sum_{i=1}^n w_i \cdot x_i - h = \sum_{i=0}^n w_i \cdot x_i = \vec{w} \cdot \vec{x}$

Formální (matematický) model neuronu

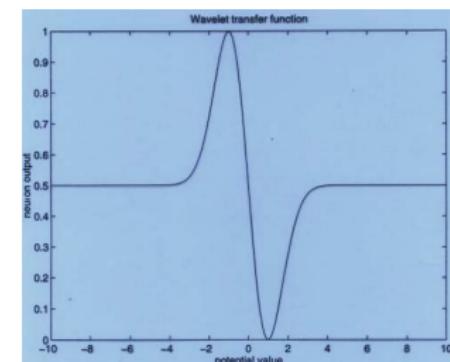
Definice

- parametry neuronu:
 - vektor vah $\vec{w} = (w_1, \dots, w_n) \in \Re^n$,
 - práh h
 - přenosová funkce $f : \Re^{n+1} \rightarrow \Re$
- neuron pro vstup $x \in \Re^n$ spočte výstup $y \in \Re$ jako hodnotu přenosové funkce $f_{\vec{w}, h}(x)$

Přenosové funkce

- Diskrétní
 - Skoková (hard-limit) ... *hardlim*
 - Kvantovaná
- Spojitá
 - Lineární ... *purelin*
 - Lineárně saturovaná ... *satlin*
 - Sigmoidální ... *logsig*
 - Radiální (RBF) ... *radbas*
 - Waveletová
- Lokální
- Globální
- Pologlobální

Waveletová funkce



Přenosové funkce

Typické požadavky

- $f(y)$ definovaná na $(-\infty, \infty)$
- $\lim_{y \rightarrow -\infty} f(y) = m < M = \lim_{y \rightarrow \infty} f(y)$
- $f(y) \approx m$... neuron je inhibován (pasivní)
- $f(y) \approx M$... neuron je excitován (aktivní)

Typické modely

- $(m, M) = (0, 1)$... binární model ... *hardlim, logsig*
- $(m, M) = (-1, 1)$... bipolární model ... *hardlims, tansig*

Skoková přenosová funkce

hardlim, hardlims

- $f(\xi) = 1$ pro $\xi \geq 0$... třída A ... neuron je aktivní
- $f(\xi) = 0$ pro $\xi < 0$... třída B ... neuron je pasivní
- popř. varianta $f(\xi) = 0.5$ pro $\xi = 0$... neuron je tichý



- dělící nadrovina $x_2 = -\frac{w_1}{w_2}x_1 + \frac{h}{w_2}$
- $0 = w_1x_1 + w_2x_2 - h$

Spojité přenosové funkce

Lineární přenosová funkce

- $f(\xi) = \xi$... purelin

Sigmoidální funkce a hyperbolický tangens

- $f(\xi) = \frac{1}{1+e^{-\lambda\xi}}$... logsig

- $f(\xi) = \frac{1-e^{-\lambda\xi}}{1+e^{-\lambda\xi}}$... tansig

Radiální funkce (RBF)

- $f(\xi) = e^{-\frac{\xi^2}{\alpha}}$... radbas

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

Neuronová síť

- Skládá se z neuronů, které jsou navzájem pospojovány synaptickými vazbami (hranami)
- Výstup jednoho neuronu může být vstupem jednoho nebo více dalších neuronů

Architektura (topologie) neuronové sítě

- Orientovaný graf, neurony představují uzly, synaptické vazby představují hrany
- Cyklická / acyklická (dopředná), vrstevnatá

Konfigurace neuronové sítě

- Váhy všech hran a prahy všech neuronů

Neuronová síť

Vstupní / výstupní neurony

- Nevedou do / z nich žádné hrany z / do jiných neuronů

Výstup (odezva) neuronové sítě

- Výstupy (aktivity) výstupních neuronů

Neuronová síť

Definice: Neuronová síť je šestice (N, C, I, O, w, t) :

- N je konečná neprázdná množina neuronů,
- $C \subseteq N \times N$ je neprázdná množina orientovaných spojů mezi neurony
- $I \subseteq N$ je neprázdná množina vstupních neuronů
- $O \subseteq N$ je neprázdná množina výstupních neuronů
- $w : C \rightarrow R$ je váhová funkce
- $t : C \rightarrow R$ je prahová funkce

Učení a rozpoznávání

Učení (s učitelem)

- chceme, aby síť implementovala neznámou funkci
 $F : \Re^n \rightarrow Y^m$
- trénovací množina T tvaru $T = \{(x^1, t^1), \dots, (x^N, t^N)\}$,
 $x^i \in \Re^n, y^i \in Y^m$
- (i-tý) trénovací vzor je uspořádaná dvojice tvaru
 $(x^i, t^i) = (\text{vstup}, \text{požadovaný výstup})$
- cílem učení je adaptace (nastavení) vah a prahů neuronové sítě

Učení a rozpoznávání

Cílová (chybová) funkce

- např. $E = \sum_p \sum_i (y_i^p - d_i^p)^2$
 y je skutečný výstup, d je požadovaný výstup

Rozpoznávání

- předkládání vstupních vzorů x^j
- cílem rozpoznávání je získat skutečný výstup (odezvu)
neuronové sítě $y^j = \varphi(x^j)$

Projekty - příklady úloh

- predikce časové řady - predikce vývoje kurzu akcií (konkrétních), spotřeby elektrické energie, počasí (teplota či jiné údaje),...
- obrázky - rozpoznávání znaků - písmen nebo číslic, obličejů, redukce počtu barev, komprese obrázku, rozpoznávání psů a koček apod
- zvuky - rozpoznání (pohlaví) mluvčího, hudebního stylu, jazyka, tónů v akordech apod.
- odhad ceny - ojetý automobil, byt v Brně, PC sestava, akcie na trhu,...
- odhad čehokoliv (schopnost klienta banky splatit dluh, očekávaná délka nezaměstnanosti v Ostravě, příčina poruchy automobilu...)
- rozpoznání spamu, analýza diskusních příspěvků,...
- medicína - např. vliv tělesných charakteristik na EKG,...

Projekty - příklady úloh

- UCI Machine learning repository
(<http://archive.ics.uci.edu/ml/>)
- <http://www.kdnuggets.com/datasets/>

Příklad: Iris DataSet

- 150 vzorů, 4 příznaky (sepal length in cm, sepal width in cm, petal length in cm, petal width in cm)
- klasifikace do 3 tříd (Setosa, Versicolour, Virginica)



Cvičení - Iris DataSet

- Prohlédněte si informace o datové sadě na UCI Machine learning repository a na Wikipedii
- Natáhněte data v Matlabu ('fisheriris')
- Zjistěte základní charakteristiky u jednotlivých příznaků (střední hodnota, rozptyl,...)
- Zkuste data vhodně zobrazit (boxplot, gscatter, gplotmatrix,...) a popište zjištěný charakter dat