

NEURÓNOVÉ SIETE

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


História vývoja neurónových sietí

Generácie neurónov

Typy neurónových sietí

Fenomén neurónových sietí (NS)

- sú inšpirované biologickými neurónovými sieťami
- využívajú distribuované, paralelné spracovanie informácie pri vykonaní výpočtov
- znalosti sú ukladané predovšetkým prostredníctvom sily väzieb medzi jednotlivými neurónmi



História



Warren McCulloch & Walter Pitts, wrote a paper on how neurons might work; they modeled a simple neural network with electrical circuits.

Nathaniel Rochester from the IBM research laboratories led the first effort to simulate a neural network.

John von Neumann suggested imitating simple neuron functions by using telegraph relays or vacuum tubes.

STORY BY DATA

1943

1949

1950s

1956

1957

1958

HISTORY OF NEURAL NETWORKS

1943-2019

Donald Hebb reinforced the concept of neurons in his book, *The Organization of Behavior*. It pointed out that neural pathways are strengthened each time they are used.

The **Dartmouth Summer Research Project** on Artificial Intelligence provided a boost to both artificial intelligence and neural networks.

Frank Rosenblatt began work on the Perceptron; the oldest neural network still in use today.

1982

1981

1969

1959

1982

John Hopfield presented a paper to the national Academy of Sciences. His approach to create useful devices; he was likeable, articulate, and charismatic.

Progress on neural network research halted due fear, unfulfilled claims, etc.

Marvin Minsky & Seymour Papert proved the Perceptron to be limited in their book, *Perceptrons*.

Bernard Widrow & Marcian Hoff of Stanford developed models they called ADALINE and MADALINE; the first neural network to be applied to a real world problem.

1982

1985

1997

1998

NOW

US-Japan Joint Conference on Cooperative/Competitive Neural Networks; Japan announced their Fifth-Generation effort resulted in US worrying about being left behind and restarted the funding in US.

American Institute of Physics began what has become an annual meeting - **Neural Networks for Computing**.

A recurrent neural network framework, LSTM was proposed by **Schmidhuber & Hochreiter**.

Yann LeCun published *Gradient-Based Learning Applied to Document Recognition*.

Neural networks discussions are prevalent; the future is here!

História

- Warren Mc Culloch, Walter Pitts, 1943
- Donald Hebb: The Organization of Behavior, 1949, učiace pravidlo pre synapsie neurónov
- prvý neuropočítač Smark, 1951, Marwin Minsky
- Frank Rosenblatt, 1958... perceptrón, učiaci algoritmus - Principles of Neurodynamics
- Nils Nilsson: Learning Machines, 1965 – kritický postoj
- 1967-1982 - ojedinelý výskum, NS zaznávané
- 1982, 84 John Hopfield – významne sa zaslúžil o pokračovanie vo výskume NS

História


- **1986** – **D. I. Rumelhart, J. E. Hinton a R. J. Williams** a súčasne **S. I. Bartsev a V. A. Okhonin** znova objavili a vylepšili metódu spätného šírenia chyby. Začal sa boom v trénovaní neurónových sietí.
- **2007 J. Hinton** z University of Toronto vytvoril algoritmy pre hlboké učenie sa viacvrstvových neurónových sietí. Úspech je v tom, že Hinton na trénovanie nižších vrstiev siete použil **ohraničený Boltzmannov stroj** (RBM - Restricted Boltzmann Machine).

História

Éra hlbokého učenia, 2010 →

- **ImageNet:** V roku 2009, na začiatku modernej éry hlbokého učenia **Fei-Fei Li** (Stanford) vytvorila ImageNet, veľký súbor vizuálnych údajov, ktorý bol chválený ako projekt, ktorý priniesol revolúciu AI vo svete.
- Server ImageNet obsahoval viac ako **14 miliónov obrázkov** vo viac ako **20 000 kategóriách** a dodnes zostáva základným kameňom technológie rozpoznávania objektov.

Na Slovensku



1947-1990





- Fedor P., Majerník V. (1977). A neuron model as an universal element of self-learning networks for pattern recognition. *Biological Cybernetics*, 26: 25–33.
- Fedor P. (1977). Principles of the design of D-neuronal networks I. A neural model for pragmatic analysis of simple melodies. *Biological Cybernetics*, 27: 129–146.
- P. Sinčák, G. Andrejková: Neurónové siete: Inž. prístup. Diel 1. a 2. Košice: Elfa, 1996
- V. Kvasnička et al.: Úvod do teórie neurónových sietí, IRIS, 1997

Umelé neurónové siete sú vlastne

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

Perceptrón; funkcia, ktorú počíta



Neurón 1. generácie

Učiacie pravidlá pre perceptrón

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 (príklad) 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 - navrhnuť perceptrón, ktorý pre každý vstupný vektor \mathbf{x}^k tréningovej množiny dá výstup y^k , ktorý sa zhoduje s cieľom d^k .

$$\text{Teda } y^k = \text{sgn}(\mathbf{w}^T \mathbf{x}^k) = d^k, k=1, 2, \dots, m.$$

Riešenie \mathbf{w}^* - učiacie pravidlo (Rosenblatt, 1962):

$$\begin{cases} \mathbf{w}^1 = \text{náhodne vybraté,} \\ \mathbf{w}^{k+1} = \mathbf{w}^k + r_0 (d^k - y^k) \mathbf{x}^k \quad k=1, 2, \dots \end{cases} \quad \text{kde } r_0 \text{ je kladná konštanta - učiaci pomer } (0 < r_0 < 1).$$

Poznámky k učiacemu pravidlu


- 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 ρ , ktorá koriguje prezentáciu dvojice (príklad, trieda);
- počet korekcií závisí od výberu počiatočných hodnôt vektora váh \mathbf{w}^1 ;
- ak riešenie neexistuje, perceptrón to neodhalí;
- vektor riešenia existuje, vtedy a len vtedy daná tréningová množina je lineárne separovateľná

Poznámky k učiacemu pravidlu

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.

Dva perceptróny



Trénigová vzorka:


X	Y
(3, 4) (1, 1)
(2, -2) (-1, 1)
...	

4 triedy:

(1, 1)
(1, -1)
(-1, 1)
(-1, -1)

Použijeme 2 neuróny. Ako bude vyzerat' ich tréovanie?

Neurón 2. generácie



f – aktivačná funkcia

Ako **aktivačná funkcia** sa najčastejšie používa

- nelineárna sigmoidálna funkcia monotónne rastúca medzi dvoma asymptotickými hodnotami 0 a 1 alebo -1 a 1:
 $f(y) = 1 / (1 + e^{-y})$
- po častiach lineárna: $f(x) = 0$, ak $x < 0$, $f(x) = 1$, ak $x > 1$, $f(x) = x$ inak

Siete s neurónmi 2. generácie

- Typické príklady NS 2. generácie - **dopredné a rekurentné sigmoidálne NS**, ako aj siete radiálnych základných funkcionálnych jednotiek (RBF siete).
- Tieto siete sú schopné vypočítať (pomocou prahov na výstupe siete) **ľubovoľné booleovské funkcie**.
- NS 2. generácie sú schopné počítat' funkcie s analógovým vstupom a výstupom. Sú **univerzálne** pre analógové výpočty - akúkoľvek spojitú funkciu na kompaktnej doméne môžu ľubovoľne dobre aproximovať (s ohľadom na rovnomernú konvergenciu).
- Ďalšou charakteristickou črtou 2. generácie modelov NS je, že podporujú **algoritmy učenia** založené na gradientovom zostupe, ako je napríklad **backprop**.

Neurón 3. generácie – spiking neurón





FIGURE 1. Simultaneous recordings (over 4 sec) of the firing times of 30 neurons from monkey striate cortex by Krüger & Aiple (1988). Each firing is denoted by a short vertical bar, with a separate row for each neuron. For comparison we have marked the length of an interval of 100 msec by two vertical lines. This time span is known to suffice for the completion of some complex multilayer cortical computations.

Neurón 3. generácie – spiking neurón

- Spiking neurónové siete (SNN) sú umelé neurónové siete, ktoré viac **napodobňujú prirodzené neurónové siete**.
- Okrem neurónového a synaptického stavu začleňujú SNN do svojho operačného modelu aj **pojmem času**.
- Wolfgang Mass, 1995, 1996 definoval SNN
- Konečná množina V spiking neurónov, E je podmnožina $V \times V$ synapsie,
- Váha synapsie medzi u a v $W(u,v) \geq 0$
- Funkcia odpovede (response) $\tau_{u,v}: \mathbb{R}^+ \rightarrow \mathbb{R}$...závislá na čase
- Prahová funkcia každého neurónu u $\sigma(u): \mathbb{R}^+ \rightarrow \mathbb{R}^+$
- Ak F_u je množina časov aktivácie (firing) neurónu u , tak potenciál v spúšťacej zóne neurónu v v čase t je daný ako

$$P_v(t) = \sum_{u: \langle u,v \rangle \in E} \sum_{s \in F_u, s < t} W(u,v) * \tau_{u,v}(t-s)$$







Spiking neuróny



- v predstavuje membránový potenciál

Typy neurónových sietí

- Feedforward
 - Perceptron
 - Multilayer – Error Backpropagation
- Competitive
 - Hemming
 - Maxnet
- Variácie pre Competitive
 - Adaptive Resonance Theory (ART)
 - Kohonen
- Hopfield



- Hlboké neurónové siete

O datasete v cvičeniach

- [MindBigDataVisualMnist2021-Muse2v0.17.zip](#)
- [Zo stránky MindBigData the MNIST of Brain Digits](#)

Lightweight Design

This ultra light rechargeable battery delivers hours of continuous run time on a single charge.

Heart Rate Detection

Advanced sensors on the Muse 2 accurately measure heart rate and blood circulation.



Sturdy Over Ear Design

This headband is specially designed to stay firmly in place during usage while also being comfortable and lightweight.

SmartSense EEG

Our award winning SmartSense EEG sensors detect brain activity and provide you with valuable real-time feedback.

K dátam

Päť typov dát

- Raster číslice
- EEG dáta
- PGG
- ACC
- Gyro
- acceleration (ACC), gyroscope (GYRO), photoplethysmography (PPG)
- Akcelerometer je nástroj, ktorý meria správne zrýchlenie. Správne zrýchlenie je zrýchlenie (miera zmeny rýchlosti) telesa v jeho vlastnom okamžitom pokojovom rámci; to sa líši od súradnicového zrýchlenia, čo je zrýchlenie v pevnom súradnicovom systéme.

K dátam

- Fotopletyzmogram (PPG) je opticky získaný pletyzmogram, pomocou ktorého možno zistiť zmeny objemu krvi v mikrovaskulárnom riečisku tkaniva. PPG sa často získava pomocou pulzného oxymetra, ktorý osvetľuje pokožku a meria zmeny v absorpcii svetla. Bežný pulzný oxymeter monitoruje perfúziu krvi do dermy a podkožného tkaniva kože.
- Gyroskop je zariadenie používané na meranie alebo udržiavanie orientácie a uhlovej rýchlosti. Je to rotujúce koleso alebo disk, v ktorom os rotácie (os rotácie) môže sama o sebe prevziať akúkoľvek orientáciu. Pri otáčaní nie je orientácia tejto osi ovplyvnená nakláňaním alebo otáčaním držiaka podľa zachovania momentu hybnosti.

Je možné použiť neurónovú sieť namiesto deterministického konečno-stavového automatu (akceptora)?

Deterministický konečnostavový automat (DKA) – regulárne jazyky

K DKA vieme skonštruovať neurónovú sieť, ktorá bude realizovať činnosť automatu. Nepoužijeme algoritmus na trénovanie váh, ale váhy a prahy neurónov vhodne nastavíme.

Tiež nás zaujíma veľkosť neurónovej siete vzhľadom na počet stavov DKA.

Alon, N., Dewdney, A. K., Teunis, J. O.: Efficient Simulation of Finite Automata by Neural Nets, Journal of ACM, Vol. 38, No. 2, April 1991, pp.495-514.

Konštrukcia neurónovej siete


- Nech je daný DKA $A=(Q, \Sigma, \delta, q_0, F)$, $\Sigma=\{0, 1\}$
- Architektúra siete:
- Každý stav $q \in Q$ je reprezentovaný 2 neurónmi, označme ich $(q,0)$ a $(q,1)$
- V neurónovej sieti vytvoríme prepojenia tak, že v čase t neurón (q, i) bude aktivovaný vtedy a len vtedy, keď v originálny automat A v čase t je v stave q a dostáva vstup i .
- K sieti týchto neurónov je potrebné pridať jeden výstupný neurón. Teda celkový počet neurónov je $2 \cdot m + 1$, ak $m = |Q|$

Nastavenie váh


- Pre ľubovoľné dva stavy q_j a q_k ,
 - $w[(q_j, i), (q_k, o)] = w[(q_j, i), (q_k, 1)] \in \{0, 1\}$,
- a rovná sa 1 vtedy a len vtedy, keď v DKA A zo stavu q_j je prechod do stavu q_k cez vstup i .
- Pre vstupné váhy platí, $w_o(q, 0) = -1$ a $w_o(q, 1) = +1$ pre všetky q .
- Pre výstupné váhy, $w[(q, i), 2m+1] = \tau(q, i)$ (τ je výstupná funkcia).
- Všetky tu nezmiernené váhy sú rovné 0.
- Prahy sú nastavené: $c(q, 1) = 2$, $c(q, 0) = 1$ a $c(2m+1) = 1$.
- Je zrejmé, že ak v čase $t = 0$ presne jeden z neurónov (q, i) , $q \in Q$, $i = 0, 1$, je aktívny, tak ľubovoľnom čase $t \geq 1$ práve jeden z týchto neurónov bude aktívny a dynamika siete bude presne taká istá ako u DKA A.

Príklad

- $A_1 = (Q, \Sigma, \delta, q_1, \{q_1\})$ je DKA, ktorý akceptuje všetky slová a len tie slová s párnym počtom núl a párnym počtom jednotiek.



Príklad - pokračovanie



Aktivačná funkcia neurónov je $F(x)=1$, ak $x \geq 0$, inak $F(x)=0$.

Výpočet

- Aktivačná funkcia neurónov je
- $F(x)=1$, ak $x \geq 0$, inak $F(x)=0$.
- Výpočet urobiť v tabuľke.