

Neuronové sítě 1 - Umělý neuron


18NES1 - 2. hodina, LS 2024/25

Zuzana Petříčková

20. února 2025

Co jsme probírali minule

- Úvod do problematiky: umělá inteligence a strojové učení
- Strojové učení - základní pojmy
- Umělé neuronové sítě - stručná historie



Mourtzis, Dimitris & Angelopoulos, John. (2020). An intelligent framework for modeling and simulation of artificial neural networks (ANNs) based on augmented reality. International Journal of Advanced Manufacturing Technology. 111. 10.1007/s00170-020-06192-y.


Opakování – Strojové učení

Princip

- počítačový systém se „vytváří sám“, tj. učí se na základě dat (trénovací množina) nebo předchozích zkušeností

Metody učení


- Učení s učitelem (supervised learning)**
 - trénovací množina ve tvaru [vstup, požadovaný výstup]
- Učení bez učitele (unsupervised learning, samoorganizace)**
 - trénovací množina ve tvaru [vstup]
- Zpětnovazebné učení (reinforcement learning)**
 - program se učí optimální strategii na základě předchozích zkušeností



Opakování – Strojové učení

Učení s učitelem (supervised learning) - typy úloh:

- **Klasifikace:** predikce třídy (kategorie)



- **Regresce:** predikce numerické hodnoty (cena, teplota, sklon písma, . . .)



- **Učení strukturovaných dat** (např. výrazy v přirozeném jazyce)

Opakování – Strojové učení

Typický průběh řešení úlohy strojového učení



- Předzpracování dat
 - převedení dat do formátu, se kterým se bude modelu strojového učení nejlépe pracovat
 - např. výběr příznaků
- Učení modelu
 - jaký typ modelu? (záleží na problému)
 - jaký model daného typu? (volba vhodných parametrů)
- Vyhodnocení modelu – nejlépe na nových datech

Opakování – Stručná historie oboru umělých neuronových sítí

Vývoj probíhal ve vlnách:

- Střídala se období rozkvětu oboru a velkých očekávání a následného zklamání a útlumu

Zásadní období:

- 1940 – 1960 : první teoretické základy
- 1960 – 1970 : první boom - období „jednoho neuronu“
- 1970 – 1980 : první „Neuronová zima“
- 1980 – 1990 : druhý boom - období „mělkých“ neuronových sítí
- 1990 – 2000 : postupné zklidnění
- 2000 – 2010 : druhá „Neuronová zima“
- 2010 – současnost : třetí boom - období „hlubokých“ neuronových sítí

Dnešní hodina: jeden neuron


Dnes:

- ① Od biologického neuronu k umělému
- ② Nejstarší modely umělých neuronů: Culloch and Pitts neurons (1943), Perceptrons (Rosenblatt, 1955)
- ③ Perceptron a reprezentace logických funkcí

Příští týden:

- ① Perceptronová síť – logický prahový obvod
- ② Geometrická interpretace perceptronu, lineární separabilita
- ③ Perceptron a jeho algoritmy učení

Model biologického neuronu



Biologický neuron

- základní stavební jednotka biologické 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 dendrity 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 synapsí a vah neuronů
- uchování informace v řádu hodin až dnů
- klíčovou roli hraje hipokampus

- **Dlouhodobý paměťový mechanismus**

- klíčovou roli pro dlouhodobou změnu synapsí hrají bílkoviny v jádřech neuronů
- uchování informace až celý život

Od biologického neuronu k umělému neuronu:




Model neuronu:

- vstupy x_1, \dots, x_n (0 nebo 1)
- váhy vstupů w_1, \dots, w_n ,
- práh h
- vnitřní potenciál ... vážený součet vstupů


$$\xi = w_1x_1 + w_2x_2 + \dots + w_nx_n$$
- výstup 1 nebo 0 (v závislosti na tom, zda je vnitřní potenciál větší než práh nebo ne)

Matematický model neuronu - formálněji



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

Matematický model neuronu - formálněji



Výpočet výstupu neuronu:

- vnitřní potenciál: $\xi = \sum_{i=1}^n w_i \cdot x_i - h = \vec{w} \vec{x}^T - h$
- výstup: $y = f(\xi)$

Matematický model neuronu - formálněji

- používaná terminologie vychází z nejstarších modelů neuronu: Perceptron (Rosenblatt, 1955), Culloch and Pitts neurons (1943)
- oba modely používaly skokovou přenosovou funkci

Skoková přenosová funkce:

- $f(\xi) = 1$ pro $\sum_{i=1}^n w_i x_i \geq h$, tj.


$$\xi = \sum_{i=1}^n w_i x_i - h \geq 0$$

... neuron je **aktivní**

- $f(\xi) = 0$ pro $\sum_{i=1}^n w_i x_i < h$, tj.

$$\xi = \sum_{i=1}^n w_i x_i - h < 0$$


... neuron je **pasivní**



Matematický model neuronu

Geometrická interpretace umělého neuronu

- vstupy neuronu si představme jako body v n-rozměrném Euklidovském prostoru (vstupní, příznakový prostor)
- položme vnitřní potenciál neuronu $\xi = 0$ a získáme rovnici dělící nadroviny



Perceptron (Rosenblatt, 1955) , Culloch and Pitts neurons (1943)


→ perceptron může sloužit jako **lineární klasifikátor**: klasifikuje vzory do dvou tříd (P a \bar{P}).

- **lineární:** hranicí mezi třídami je nadrovina

$w_1x_1 + w_2x_2 + \dots + w_nx_n - h = 0$: bod, přímka, rovina, ...

Skoková přenosová funkce:

- $f(\xi) = 1$ pro $\sum_{i=1}^n w_i \cdot x_i \geq h$, tj. $\xi \geq 0$
... neuron je **aktivní** (třída P)
 - $f(\xi) = 0$ pro $\sum_{i=1}^n w_i \cdot x_i < h$, tj. $\xi < 0$
... neuron je **pasivní** (třída \bar{P})



Culloch and Pitts neurons (1943)

Binární varianta:


- binární vstupy: $x_i \in \{0, 1\}$
- binární výstupy: $y \in \{0, 1\}$
- váhy: $w_i \in \{-1, 1\}$
- skoková přenosová funkce

Bipolární varianta:

- bipolární vstupy: $x_i \in \{-1, 1\}$
- bipolární výstupy: $y \in \{-1, 1\}$
- váhy: $w_i \in \{-1, 1\}$
- skoková přenosová funkce

→ využití: reprezentace logických funkcí (AND, OR, NOT,...) ...
ukážeme si za chvíliku

- **nevýhoda:** pro model neexistoval učící algoritmus (až později ... hebbovské učení)




Perceptrony (Rosenblatt, 1955)


- reálné vstupy ... $x_i \in R$
- reálné váhy a prahy ... $w_i \in R$
- výstupy:
 - **binární** ... $y \in \{0, 1\}$
 - **bipolární** ... $y \in \{-1, 1\}$

Varianty skokové přenosové funkce pro binární perceptron:

$$f(\xi) = \begin{cases} 1 & \text{pro } \xi \geq 0 \quad \dots \text{neuron je aktivní} \\ 0 & \text{pro } \xi < 0 \quad \dots \text{neuron je pasivní} \end{cases}$$



$$f(\xi) = \begin{cases} 1 & \text{pro } \xi > 0 \quad \dots \text{neuron je aktivní} \\ 0.5 & \text{pro } \xi = 0 \quad \dots \text{neuron je tichý} \\ 0 & \text{pro } \xi < 0 \quad \dots \text{neuron je pasivní} \end{cases}$$



→ funkce **signum** (bsign)

Perceptrony (Rosenblatt, 1955)



- reálné vstupy ... $x_i \in R$
- reálné váhy ... $w_i \in R$ a prahy
- výstupy:
 - binární ... $y \in \{0, 1\}$
 - bipolární ... $y \in \{-1, 1\}$

Varianty skokové přenosové funkce pro bipolární perceptron:


$$f(\xi) = \begin{cases} 1 & \text{pro } \xi \geq 0 \quad \dots \text{neuron je aktivní} \\ -1 & \text{pro } \xi < 0 \quad \dots \text{neuron je pasivní} \end{cases}$$

$$f(\xi) = \begin{cases} 1 & \text{pro } \xi > 0 \quad \dots \text{neuron je aktivní} \\ 0 & \text{pro } \xi = 0 \quad \dots \text{neuron je tichý} \\ -1 & \text{pro } \xi < 0 \quad \dots \text{neuron je pasivní} \end{cases}$$

→ funkce **signum** (sign)




Matematický model neuronu - původní definice



Klasická definice: práh h

- vnitřní potenciál: $\xi = \sum_{i=1}^n w_i \cdot x_i - h = \vec{w} \vec{x}^T - h$
- výstup: $y = f(\xi)$


Matematický model neuronu - moderní definice



Alternativní definice: práh → bias

- vnitřní potenciál: $\xi = \sum_{i=1}^n w_i \cdot x_i + b = \vec{w} \vec{x}^T + b$
- výstup: $y = f(\xi)$

Matematický model neuronu - „maticová“ definice



Alternativní definice: zavedení fiktivního vstupu

- rozšířený příznakový prostor ... $\vec{x} = (x_0 = 1, x_1, \dots, x_n)$
- rozšířený prostor vah ... $\vec{w} = (w_0 = b = -h, w_1, \dots, w_n)$
- vnitřní potenciál: $\xi = \sum_{i=0}^n w_i \cdot x_i = \vec{w} \vec{x}^T$
- výstup: $y = f(\xi)$

Neuronové sítě 1 - hodina 2: Umělý neuron

- 1 Opakování
- 2 Od biologického neuronu k umělému
- 3 Matematický model neuronu
- 4 Perceptron a reprezentace logických funkcí

Perceptron a reprezentace logických funkcí

Pomocí perceptronu lze realizovat základní logické funkce


- NOT (negace)
- ID (identita)
- AND (konjunkce)
- OR (disjunkce)

→ z perceptronů můžeme složit **logický prahový obvod**

... reprezentace libovolných logických (booleovských) funkcí

Perceptron a reprezentace logických funkcí

Budeme uvažovat následující model perceptronu:



$$\begin{aligned}\xi &= \vec{w} \cdot \vec{x}^T = \sum_{i=0}^n w_i x_i \\ &= w_0 + \sum_{i=1}^n w_i x_i\end{aligned}$$

Binární perceptron

- vstupy: $x_i \in \{0, 1\}$
- výstupy: $y \in \{0, 0.5, 1\}$
- $y = f(\xi) = bsign(\xi)$

$$bsign(\xi) = \begin{cases} 1 & \text{pro } \xi > 0 \\ 0.5 & \text{pro } \xi = 0 \\ 0 & \text{pro } \xi < 0 \end{cases}$$

Bipolární perceptron


- vstupy: $x_i \in \{-1, +1\}$
- výstupy: $y \in \{-1, 0, +1\}$
- $y = f(\xi) = sign(\xi)$

$$sign(\xi) = \begin{cases} 1 & \text{pro } \xi > 0 \\ 0 & \text{pro } \xi = 0 \\ -1 & \text{pro } \xi < 0 \end{cases}$$

Logické funkce – NOT (negace)

bipolární model

x	$y = \neg x$
-1	1
1	-1



$$y = \text{sign}(w_0 + w_1 x)$$

binární model


x	$y = \neg x$
0	1
1	0

- jak zvolíme w_0 a w_1 v případě bipolárního modelu?
- a jak v případě binárního modelu?

Logické funkce – NOT (negace)

bipolární model


x	$y = \neg x$
-1	1
1	-1



$$y = \text{sign}(w_0 + w_1 x) = \text{sign}(-x)$$

binární model

x	$y = \neg x$
0	1
1	0




$$y = b\text{sign}(w_0 + w_1 x) = b\text{sign}(0.5 - x)$$

Otázka: Napadly by vás i další řešení?

Logické funkce – NOT (negace)


Příklad: štěstí = \neg smůla



Logické funkce – ID (identita)

bipolární model

x	$y = x$
-1	-1
1	1



$$y = \text{sign}(w_0 + w_1 x)$$

binární model


x	$y = x$
0	0
1	1

- jak zvolíme w_0 a w_1 v případě bipolárního modelu?
- a jak v případě binárního modelu?

Logické funkce – ID (identita)

bipolární model


x	y = x
-1	-1
1	1



$$y = \text{sign}(w_0 + w_1 x) = \text{sign}(x)$$

binární model

x	y = x
0	0
1	1




$$y = \text{bsign}(w_0 + w_1 x) = \text{bsign}(-0.5 + x)$$

→ není co řešit

Logické funkce – AND (konjunkce)

bipolární model

x_1	x_2	$y = x_1 \wedge x_2$
-1	-1	-1
-1	+1	-1
+1	-1	-1
+1	+1	+1



binární model

x_1	x_2	$y = x_1 \wedge x_2$
0	0	0
0	1	0
1	0	0
1	1	1


$$y = \text{sign}(w_0 + w_1 x_1 + w_2 x_2)$$

- jak zvolíme w_0 , w_1 a w_2 v případě bipolárního modelu?
- a jak v případě binárního modelu?

Logické funkce –AND (konjunkce)

bipolární model


x_1	x_2	$y = x_1 \wedge x_2$
-1	-1	-1
-1	+1	-1
+1	-1	-1
+1	+1	+1



$$\begin{aligned}y &= \text{sign}(w_0 + w_1 x_1 + w_2 x_2) \\&= \text{sign}(-1 + x_1 + x_2)\end{aligned}$$

binární model


x_1	x_2	$y = x_1 \wedge x_2$
0	0	0
0	1	0
1	0	0
1	1	1




$$\begin{aligned}y &= b\text{sign}(w_0 + w_1 x_1 + w_2 x_2) \\&= b\text{sign}(-1.5 + x_1 + x_2)\end{aligned}$$

Oázka: Mohla by být i další řešení?

Logické funkce – AND (konjunkce)



Příklad: duha = slunce \wedge déšť




(bipolární model)

Logické funkce – AND (konjunkce)

jak nastavíme váhy v obecném případě? ...

$$y = x_1 \wedge x_2 \wedge \cdots \wedge x_n$$




$$y = sign(w_0 + \sum_{i=1}^n w_i x_i)$$

Logické funkce – AND (konjunkce)

$$y = x_1 \wedge x_2 \wedge \cdots \wedge x_n$$


bipolární model



$$y = \text{sign}(w_0 + \sum_{i=1}^n w_i x_i)$$

$$= \text{sign}(1 - n + \sum_{i=1}^n x_i)$$

binární model




$$y = b\text{sign}(w_0 + \sum_{i=1}^n w_i x_i)$$

$$= b\text{sign}(0.5 - n + \sum_{i=1}^n x_i)$$

Logické funkce – OR (disjunkce)

bipolární model

x_1	x_2	$y = x_1 \vee x_2$
-1	-1	-1
-1	+1	+1
+1	-1	+1
+1	+1	+1



binární model

$$y = \text{sign}(w_0 + w_1 x_1 + w_2 x_2)$$


x_1	x_2	$y = x_1 \vee x_2$
0	0	0
0	1	1
1	0	1
1	1	1

- jak zvolíme w_0 , w_1 a w_2 v případě bipolárního modelu?
- a jak v případě binárního modelu?

Logické funkce – OR (disjunkce)

bipolární model


x_1	x_2	$y = x_1 \vee x_2$
-1	-1	-1
-1	+1	+1
+1	-1	+1
+1	+1	+1



$$\begin{aligned}y &= \text{sign}(w_0 + w_1x_1 + w_2x_2) \\&= \text{sign}(1 + x_1 + x_2)\end{aligned}$$


binární model

x_1	x_2	$y = x_1 \vee x_2$
0	0	0
0	1	1
1	0	1
1	1	1




$$\begin{aligned}y &= \text{bsign}(w_0 + w_1x_1 + w_2x_2) \\&= \text{bsign}(-0.5 + x_1 + x_2)\end{aligned}$$

Logické funkce – OR (disjunkce)




Příklad: úspěch = štěstí \vee
příprava



Logické funkce – OR (disjunkce)

jak nastavíme váhy v obecném případě? ...

$$y = x_1 \vee x_2 \vee \dots \vee x_n$$




$$y = sign(w_0 + \sum_{i=1}^n w_i x_i)$$


Logické funkce – OR (disjunkce)

$$y = x_1 \vee x_2 \vee \cdots \vee x_n$$

bipolární model



binární model



$$y = \text{sign}(w_0 + \sum_{i=1}^n w_i x_i)$$

$$= \text{sign}(n - 1 + \sum_{i=1}^n x_i)$$


$$y = b\text{sign}(w_0 + \sum_{i=1}^n w_i x_i)$$

$$= b\text{sign}(-0.5 + \sum_{i=1}^n x_i)$$

Logické funkce – Exkluzivní OR (XOR)

bipolární model

x_1	x_2	$y = x_1 \otimes x_2$
-1	-1	-1
-1	+1	+1
+1	-1	+1
+1	+1	-1



$$y = \text{sign}(w_0 + w_1 x_1 + w_2 x_2)$$

binární model

x_1	x_2	$y = x_1 \otimes x_2$
0	0	0
0	1	1
1	0	1
1	1	0

- jak zvolíme w_0 , w_1 a w_2 v případě bipolárního modelu?
- a jak v případě binárního modelu?

Logické funkce – Exkluzivní OR (XOR)

bipolární model

x_1	x_2	$y = x_1 \otimes x_2$	
-1	-1	-1	1... $w_0 - w_1 - w_2 < 0$
-1	+1	+1	2... $w_0 - w_1 + w_2 > 0$
+1	-1	+1	3... $w_0 + w_1 - w_2 > 0$
+1	+1	-1	4... $w_0 + w_1 + w_2 < 0$

sečteme 1. a 4., 2. a 3.:

$$\text{sign}(w_0 - w_1 - w_2) = -1 \quad 2w_0 < 0$$

$$\text{sign}(w_0 - w_1 + w_2) = +1 \quad 2w_0 > 0$$


$$\text{sign}(w_0 + w_1 - w_2) = +1 \quad \rightarrow \text{spor}$$

$$\text{sign}(w_0 + w_1 + w_2) = -1$$

Závěr: Logickou funkci XOR nemůžeme realizovat jedním perceptronem.

Logické funkce – Exkluzivní OR (XOR)


- XOR nelze realizovat jedním perceptronem



- Ale: XOR by mohlo jít realizovat pomocí více perceptronů (logického prahového obvodu)

Logický prahový obvod

- pomocí perceptronů pro NOT, ID, AND a OR můžeme sestavit složitější logické funkce



→ stačí je poskládat vhodně za sebe (do neuronové sítě, konkrétně do logického prahového obvodu)
 AND realizuje průnik konvexních útvarů a OR jejich sjednocení

Logický prahový obvod

Exkluzivní OR (XOR) - dobrovolný domácí úkol do příště

- ① XOR můžeme pomocí základních logických operací (AND, OR, NOT) reprezentovat různě, zvládnete navrhnout několik různých způsobů?
- ② Navrhněte co nejmenší neuronovou síť, která bude reprezentovat XOR. Kolik bude obsahovat neuronů?

x_1	x_2	$y = x_1 \otimes x_2$
-1	-1	-1
-1	+1	+1
+1	-1	+1
+1	+1	-1