


Co jsme probírali minule

- Umělé neuronové sítě - stručná historie
- Biologický neuron
- Strojové učení - základní pojmy



Strojové učení

Princip

- vychází z biologických principů, model se "vytvoří sám"
- výpočetní model se učí 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

Strojové učení

Úloha strojového učení s učitelem

- je dána množina trénovacích dat: vstupní a výstupní vzory (požadované výstupy)
- **aproximace** – chceme, aby model co nejlépe aproximoval 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

Typy úloh strojového učení s učitelem

- **regrese** – predikujeme numerickou hodnotu / hodnoty
- **klasifikace** – predikujeme diskrétní hodnotu / hodnoty
- **učení strukturovaných dat**

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

Dnešní hodina


- 1 Matematický model neuronu a jeho geometrická interpretace
- 2 Nejstarší modely umělých neuronů: Perceptrons (Rosenblatt, 1955) , Culloch and Pitts neurons (1943)
- 3 Perceptron a reprezentace logických funkcí
- 4 Perceptron a lineární separabilita
- 5 asi až příště: Perceptron a algoritmy učení

Matematický model neuronu



- parametry neuronu:
 - vektor vah $\vec{w} = (w_1, \dots, w_n) \in R^n$,
 - práh h
 - 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



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

Geometrická interpretace

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

$$\xi = w_1x_1 + w_2x_2 - h = 0$$

$$x_2 = -\frac{w_1}{w_2}x_1 + \frac{h}{w_2}$$




Matematický model neuronu

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

Skoková přenosová funkce:

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




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


→ perceptron může sloužit jako **lineární klasifikátor**: klasifikuje vzory do dvou tříd (zde A, B)

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




Matematický model neuronu



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



Alternativní definice: práh \rightarrow 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



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: $y = f(\xi)$

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 chvíli

- **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:

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

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

→ 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:

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

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

→ funkce **signum** (sign)



Logický prahový obvod


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

Logický prahový obvod

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

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

Logický prahový obvod - 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?

Logický prahový obvod - NOT (negace)

bipolární model


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



$$y = \text{sign}(w_0 + w_1x) = \text{sign}(-x)$$

binární model

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




$$y = \text{bsign}(w_0 + w_1x) = \text{bsign}(0.5 - x)$$

Otázka: Napadly by vás i další řešení?

Logický prahový obvod - NOT (negace)


Příklad: štěstí = \neg smůla



Logický prahový obvod - 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?


Logický prahový obvod - ID (identita)

bipolární model


x	y = x
-1	-1
1	1

binární model

x	y = x
0	0
1	1



$$y = \text{sign}(w_0 + w_1x) = \text{sign}(x)$$




$$y = \text{bsign}(w_0 + w_1x) = \text{bsign}(-0.5 + x)$$

→ není co řešit

Logický prahový obvod - 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


$$y = \text{sign}(w_0 + w_1x_1 + w_2x_2)$$

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

Logický prahový obvod - 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




$$y = \text{sign}(w_0 + w_1x_1 + w_2x_2)$$

$$= \text{sign}(-1 + x_1 + x_2)$$

binární model

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




$$y = \text{bsign}(w_0 + w_1x_1 + w_2x_2)$$


$$= \text{bsign}(-1.5 + x_1 + x_2)$$

Otázka: Mohla by být i další řešení?

Logický prahový obvod - AND (konjunkce)




Příklad: duha = slunce \wedge déšť



Logický prahový obvod - AND (konjunkce)

jak nastavíme váhy v obecném případě? ...

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




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

Logický prahový obvod - AND (konjunkce)

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


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




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

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

Logický prahový obvod - 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

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


$$y = \text{sign}(w_0 + w_1x_1 + w_2x_2)$$

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

Logický prahový obvod - 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




$$y = \text{sign}(w_0 + w_1x_1 + w_2x_2)$$

$$= \text{sign}(1 + x_1 + x_2)$$

binární model

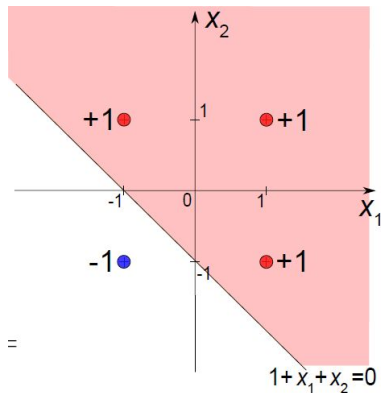
x_1	x_2	$y = x_1 \vee x_2$
0	0	0
0	1	1
1	0	1
1	1	1




$$y = \text{bsign}(w_0 + w_1x_1 + w_2x_2)$$

$$= \text{bsign}(-0.5 + x_1 + x_2)$$

Logický prahový obvod - OR (disjunkce)




Příklad: úspěch = štěstí \vee příprava



Logický prahový obvod - OR (disjunkce)

jak nastavíme váhy v obecném případě? ...

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




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

Logický prahový obvod - OR (disjunkce)

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


bipolární model



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

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

binární model




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

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

Logický prahový obvod

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




Odbočka: nejprve si definujeme umělou neuronovou síť

Neuronová síť

- Skládá se z neuronů, které jsou navzájem pospojovány tzv. 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



Neuronová síť

Výstupní neurony

- jejich výstupy tvoří dohromady výstup neuronové sítě
- **typicky:** nevedou z nich žádné hrany do jiných neuronů

Vstupní neurony

- mají na vstupu vstupní vzory
- **typicky:** nevedou do nich žádné hrany z 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 (hran)
- $I \subseteq N$ je neprázdná množina vstupních neuronů
- $O \subseteq N$ je neprázdná množina výstupních neuronů
- $w : C \rightarrow R$ je váhová funkce
- $t : N \rightarrow R$ je prahová funkce


Konfigurace neuronové sítě

- Váhy všech hran a prahy všech neuronů


Neuronová síť

Architektura neuronové sítě

- cyklická, rekurentní
- acyklická, dopředná - „všechny hrany jdou stejným směrem“
(tj. graf lze topologicky uspořádat)




- hierarchická (vrstevnatá) - dělí se na vrstvy, propojeny jsou jen neurony ze dvou po sobě jdoucích vrstev



Logický prahový obvod


- z perceptronů pro NOT, ID, AND, OR a ID můžeme sestavit neuronovou síť reprezentující složitější logické funkce



- AND realizuje průnik konvexních útvarů a OR jejich sjednocení

Logický prahový obvod

- z perceptronů pro NOT, ID, AND, OR a ID můžeme sestavit neuronovou síť reprezentující složitější logické funkce



Záludné otázky: Jak se změní logická funkce realizovaná perceptronem, když:

- vynásobím všechny váhy (včetně prahu) kladným číslem?
- vynásobím všechny váhy (včetně prahu) záporným číslem (např. -1)?
- vynásobím některé váhy -1 ?

Logický prahový obvod - příklady

Příklad 1: Předpověď úrody

úroda = $((\text{teplo} \wedge \text{děšť}) \vee (\text{teplo} \wedge \text{zavlažování})) \wedge \text{hnojiva} \wedge \neg \text{škůdci}$

- 1 Navrhněte perceptronovou síť pro tuto logickou funkci s využitím základních logických operací.
 - Kolik má vstupů a výstupů, kolik neuronů a kolik vrstev?
- 2 Navrhněte perceptronovou síť, která bude mít hierarchickou (vrstevnatou) architekturu.
- 3 Minimalizujte tuto logickou funkci a navrhněte neuronovou síť pro minimalizovanou verzi.
- 4 Lze tuto logickou funkci reprezentovat jedním perceptronem?

Logický prahový obvod - příklady

Příklad 2: Majoritní obvod


$$y = (x_1 \wedge x_2) \vee (x_1 \wedge x_3) \vee (x_2 \wedge x_3)$$

- 1 Navrhněte neuronovou síť pro majoritní obvod s využitím základních logických operací.
- 2 Lze ho reprezentovat jedním perceptronem?
- 3 Jaké bude řešení v obecném případě (pro obecné n)?

Logický prahový obvod - příklady

Příklad 3: 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



binární model

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

$$y = \text{sign}(w_0 + w_1x_1 + w_2x_2)$$

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

Logický prahový obvod - příklady

Příklad 3: 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

$$1... w_0 - w_1 - w_2 < 0$$

$$2... w_0 - w_1 + w_2 > 0$$

$$3... w_0 + w_1 - w_2 > 0$$

$$4... w_0 + w_1 + w_2 < 0$$

sečteme 1. a 4., 2. a 3.:

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

$$2w_0 < 0$$

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

$$2w_0 > 0$$

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


→ spor

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

Logický prahový obvod - příklady

Příklad 3: Exkluzivní OR (XOR)

- XOR nelze realizovat jedním perceptronem



- XOR lze realizovat pomocí perceptronové sítě

Logický prahový obvod - příklady

Příklad 3: Exkluzivní OR (XOR) - dobrovolný domácí úkol do příští přednášky

- 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

Logický prahový obvod - příklady

Příklad 3: Exkluzivní OR (XOR) - dobrovolný domácí úkol do příští přednášky

- 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?

