

UMĚLÁ INTELIGENCE

2018/2019

0. VÝVOJ, (PRE)HISTORIE, OBSAH

viž slajdy

INTRO

ANNs = matematické modely (výpočetní systémy) inspirované biologickými NN

- skládají se z umělých neuronů, které si posílají signály po tzv. spojeních
- ANN jsou součástí směru v AI známém connectionismem
- význam meze pro AI, ale i zpět pro neurovědy; některé fyzikální modely mají podobnou strukturu
- zaměříme se na aspekty pro AI
- alternativní physical symbol system hypothesis (Newell & Simon 1976):
A physical^{symbol} system has the necessary and sufficient means for general intelligent action.
(AI logic-based, symbolic vs. ANNs "sub-symbolic")
- ANNs are not easily interpretable - disadvantage
↓
knowledge is encoded in many neurons and connections
↓
black box effect
- ANNs outperform symbolic AI systems in many tests:
 - pattern recognition, prediction
 - easy-to-develop tool, many existing applications

šíření signálů

excitací a inhibiční efekty synapsí (podle toho) neuron se akumuluje ("sčítá")

při dostatečně vysoké excitaci (počet rozdílů potenciálů uvnitř a vně

neuronu), dochází k depolarizaci ^{počtu axonu} $\sqrt{7}m$, že klesají ionty

sodíku (Na^+) vstupují do neuronu;

na krátký okamžik (1ms) ms uvnitř neuronu více klesají ~~mířej~~ mívají

mezi vnějším; vede k uvolnění iontů draslíku (K^+) a dochází

k osmovení rozdílů potenciálů uvnitř a vně neuronu (pomocí iontových pump & membránového náboje tělo neuronu)

Zmíněná náhlá změna v potenciálu se šíří podél axonu

rychlostí 0.5 - 130 m/s \rightarrow "šíření signálu" mezi neurony
(rychlost závisí mj. na tloušťce myelinové pochvy axonu)

signál dojde na konec axonu, způsobí uvolnění neurotransmiterů

a dojde k přenosu do dendritů dalšího neuronu atd.

tedy schématicky:

signály (změny v el. potenciálu) se v těle neuronu akumuluje;

a pokud těchto dojde k překročení ^{jistě} prahové hodnoty, signál


se začne šířit dál po axonu k synapsím a dendritům dalších neuronů

firing rate = počet vyvolaných signálů/sec., v lidském mozku \approx 1-100 a více

\rightarrow z této představy vychází ANNs

Perceptron = jednoduchý model neuronu (McCulloch & Pitts 1943)
 také nazýváj Me Culloch - Pitts neuron

model:



$y \in \{0, 1\}$

$w_i \in \mathbb{R}$

$x_i \in \mathbb{R}$

$$y = \begin{cases} 1 & \text{pokud } \sum w_i x_i \geq \theta \\ 0 & \text{jinak} \end{cases}$$

vstupní signál

(z okolí, nepř. okolních neuronů)

váha (\approx vlastnosti synapse
 $w_i > 0$ - excitace
 $w_i < 0$ - inhibice)

Pr.: - perceptron modelující konjunkt




pro $x_1, x_2 \in \{0, 1\}$ je $y = x_1 \wedge x_2$

- implikaci



$y = x_1 \rightarrow x_2$

- liter.



pravd. tabulka:

x_1	x_2	x_3	$\sum w_i x_i$	y
0	0	0	0	0
0	0	1	2	1
0	1	0	-2	0
0	1	1	0	0
1	0	0	2	1
1	0	1	4	1
1	1	0	0	0
1	1	1	2	1

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

Učení perceptronu

idea: dána trénovací množina $T = \{ \langle x_p, y_p \rangle \mid p \in P \}$
 kde " $x_p \in \mathbb{R}^n$, $y_p \in \{0,1\}$ "

Cílem je najít perceptron, který bude realizovat f a y
 takže $\forall p \in P$ je $y(x_p) = y_p$

Pozn.

- Perceptron se má chovat tak, jak více/podpisuje T .
- Chceme "načít" perceptron pomocí více trénovací množiny.
- Číslní perceptron (tj. funkce realizované perceptronem) je dána jeho parametry w_1, \dots, w_n, θ . Cíle je tedy najít tyto parametry.
- Hledání parametrů = učení (adaptace) algoritmus, který parametry hledá = učební algoritmus (adaptace)
- učení zpravidla iterativní proces

2 základní způsoby učení (úpravy parametrů)

- online learning - podobná se na star $\langle x_p, y_p \rangle$, upravit věhy, stát.
- batch learning - podobná se na více star, pak upravit věhy

a oba způsoby provádějí iterativně, dokud není splněna podmínka učení
 pochopíme, např. celý T byl načten (popř. stačí celý T)

Základem pro učení perceptronu je tzv. delta rule (Widrow & Hoff 1960, m. z. (kde byl. učen), nebo také Widrow-Hoff rule:

Je-li star $\langle x_p, y_p \rangle$, tj. $x_p = \langle x_{p1}, \dots, x_{pn} \rangle \in \mathbb{R}^n$ vs x_p , y_p požadovaný výstup, a $y \in \{0,1\}$ skutečný výstup perceptronu upřes θ a w následovně:

$$\theta^{(t+1)} := \theta^{(t)} + \Delta \theta, \text{ kde } \Delta \theta = -\eta (y_p - y) \quad \theta^{(t)} \text{ je } \theta \text{ v čase } t, \dots$$

$$w_i^{(t+1)} := w_i^{(t)} + \Delta w_i, \text{ kde } \Delta w_i = \eta (y_p - y) x_i \quad \eta \in \mathbb{R} \dots \text{ learning rate (rychlost učení)}$$

delta rule, přirození zduřvodnění

Pozn.: S θ lze pracovat jako s vchodem w_0 pro konstantní vstoup $x_0 = -1$:

$$\sum_{i=1}^n w_i x_i \geq \theta \iff \sum_{i=1}^n w_i x_i - \theta \geq 0 \iff \sum_{i=0}^n w_i x_i \geq 0$$

Přijde pravidlo pro adaptaci θ a pravidlo pro adaptaci w_0 .

Algoritmus učení perceptronu (online)

Perceptron-online-training (T, w, θ, η)

repeat

$e \leftarrow 0$

for each $p \in P$ do

if $\sum_{i=1}^n w_i x_{pi} \geq \theta$ then $y = 1$

else $y = 0$

if $y \neq y_p$ then

$\theta \leftarrow \theta - \eta (y_p - y)$

for $i = 1$ to n $w_i \leftarrow w_i + \eta (y_p - y) x_{pi}$

$e \leftarrow e + |y_p - y|$

until $e = 0$

T ... trén. množina

$\{x, \theta\}$... pár hodnoty vch a práhu,
např. měkché nestvře

η ... learning rate (např. = 1)

Algoritmus učení perceptronu (batch)

analogicky, změny w_i a θ se provádějí po průchodu celou T , kumulují se

Pozn.: Pro $x_i = 0$ nedochází k adaptaci; řešením je $x_i = -1$ místo $x_i = 0$; učení probíhá stejně, měkčé je rychlejší. Původně používá v systému ADALINE.

Věta (konvergence algoritmu učení perceptronem)

Necht $T, \alpha, \theta, n > 0$ jsou libovolné vstupy. Jestliže existují v_1, \dots, v_n, φ t.j.

$\forall p \in P$ je $\sum_{i=1}^n v_i x_{pi} \geq \varphi$ pro $y_p = 1$ a $\sum_{i=1}^n v_i x_{pi} < \varphi$ pro $y_p = 0$ (t.j. T je naučitelné)


Pod algoritmus učení, online i batch, skončí (a tedy naučí se množině T).

Důkaz:

Meze perceptronu

Umožňuje naučit se pouze lineárně separabilní množiny.

Geometrický pohled na $\sum_{i=1}^n w_i x_i \geq \Theta$ melo-
 mezinám
 $w_1 x_1 + \dots + w_n x_n - \Theta \geq 0$
 poloprostor

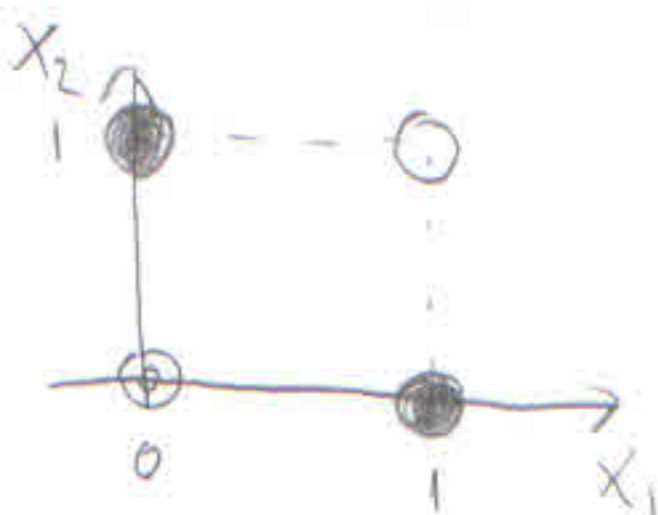


Pokud T není lineárně separabilní, meze perceptron naučit.


Pokud T je —||—, lze —||— (+ teorem o konvergenci zaručuje, že se to podaří).

Pr: Funkce XOR

	0	1
0	0	1
1	1	0



není lin. separabilní




+ Knize str 20 tabulka 3.1

Sítě perceptronů jako řešení prostého lim. nesepravitelnosti

- výstupy neuronů přivedeny na vstupy dalších neuronů

Pr:



Pozn. Sítěmi 2 perceptronů lze reprezentovat i složité funkce.
ROZUŠT

Problém: Zatímco pro jednoduchý perceptron existuje jednoduchý učicí algoritmus s se zaručenou konvergencí, pro síť perceptronů pravidlo (učicí algoritmus) nebylo objeveno.

↳
Minsky & Papert (1969): Perceptrons: An introduction to computational geometry
knihka zastavila vývoj u neuronových sítí na 20 let