



ANALÝZA A KLASIFIKACE BIOMEDICÍNSKÝCH DAT



prof. Ing. Jiří Holčík, CSc.

III. NEURONOVÉ SÍŤE I.

DEFINICE

UMĚLÁ NEURONOVÁ SÍŤ (Artificial Neural Network - ANN) je distribuovaný (v užším smyslu paralelní) výpočetní systém (program), sestávající z dílčích podsystémů (neuronů), který je inspirován neurofyzilogickými poznatky o struktuře a činnosti neuronů a nervových systémů živých organismů a který je ve větší či menší míře modeluje.

DEFINICE

- ☑ **distribuovaný x paralelní systém**

(distribuovaný klade důraz na nezávislé zpracování)

- ☑ **výpočetní systém x program x model**

STRUKTURA ANN

Umělá neuronová síť se skládá z výpočetních jednotek – neuronů – které jsou vzájemně propojeny váhami ohodnocenými spoji. Tímto propojením a schopnostmi adaptovat váhy (učit se) na základě vstupních dat (vzorů) umožňují ANN zobecňovat informaci skrytou v učební množině

STRUKTURA ANN

Je reprezentovaná váhovaným orientovaným grafem s velkým počtem uzlů, z nichž každý představuje jednoduchou výpočetní jednotku. Tyto jednotky komunikují (přijímají a vysílají signály) jednak mezi sebou, jednak s vnějším prostředím.

STRUKTURA ANN

Umělou neuronovou sítí charakterizují tři základní skutečnosti:

- vlastnosti jednotlivých výpočetních jednotek (umělých neuronů);
- topologie sítě, tj. vzájemné propojení neuronových jednotek;
- strategie učení.

ZÁKLADNÍ ASPEKTY VÝPOČTŮ NEURONOVOU SÍTÍ (PŘIROZENOU I UMĚLOU):

- ☑ celkový výpočetní model se skládá z proměnného (časově i strukturálně) vzájemného propojení jednoduchých prvků či jednotek;
- ☑ základem učení je modifikace vlastností vazeb mezi jednotlivými výpočetními elementy \Rightarrow znalost či zkušenost, vnímané jako výsledek učení, jsou reprezentovány strukturou sítě;

ZÁKLADNÍ ASPEKTY VÝPOČTŮ NEURONOVOU SÍTÍ (PŘIROZENOU I UMĚLOU):

- ☑ k tomu, aby byl neuronový systém co k čemu, musí být schopen uchovávat informaci, tj. musí být trénovatelný, a dále musí skýtat naději, že tuto informaci následně dokáže spojit (asociovat) s každým nově zpracovávaným vzorkem či signálem - to znamená, že cílem učení by mělo být vytvoření takové interní struktury neuronové sítě, která je schopná správně identifikovat každou novou vstupní informaci, i když ta není totožná s informací použitou při vlastním učení;
- ☑ neuronové sítě jsou dynamické systémy, jejichž stav (tj. výstupy jednotlivých výpočetních jednotek a váhy vzájemných vazeb) se mění v čase v závislosti na vstupech a počátečním stavu.

CHARAKTERISTIKY APLIKAČNÍCH OBLASTÍ PRO ANN

- ☑ optimalizace struktury např. časového uspořádání nebo obecněji úlohy spojené s prohledáváním prostoru možných řešení;
- ☑ rozpoznávání a klasifikace (zejména, ale nejen z oblasti rozpoznávání řeči či vizuální scény, příp. rozpoznávání psaného písma), včetně výběru příznaků, které mohou být použity pro popis klasifikovaného objektu;
- ☑ zpracování poškozených, scházejících, kontradiktivních, mlhavých (fuzzy) či pravděpodobnostních údajů.

CHARAKTERISTIKY ÚLOH PRO ŘEŠENÍ POMOCÍ ANN

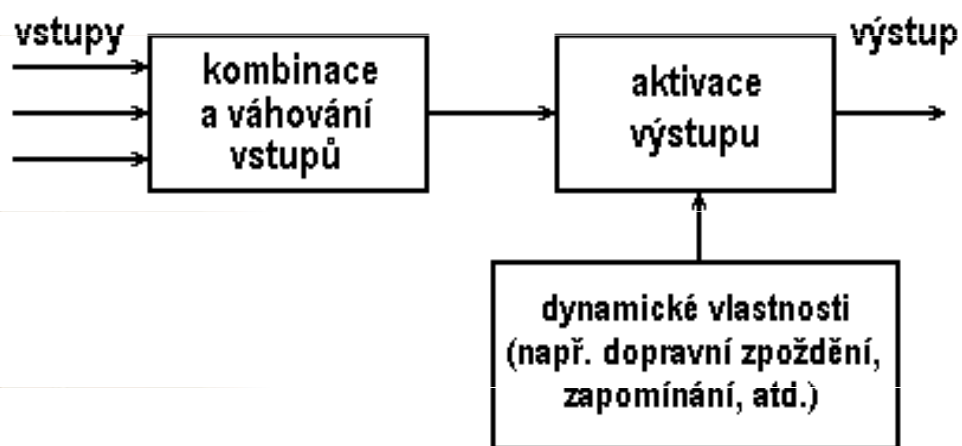
- ☑ velký rozměr problémového prostoru - stav systému (řešení problému) je popsán hodnotami velkého počtu proměnných a parametrů;
- ☑ složité vzájemné vztahy mezi stavovými veličinami;
- ☑ prostor řešení může být prázdný, může obsahovat jediné řešení a nebo (nejčastěji) větší počet téměř stejně užitečných řešení.

MODEL NEURONU

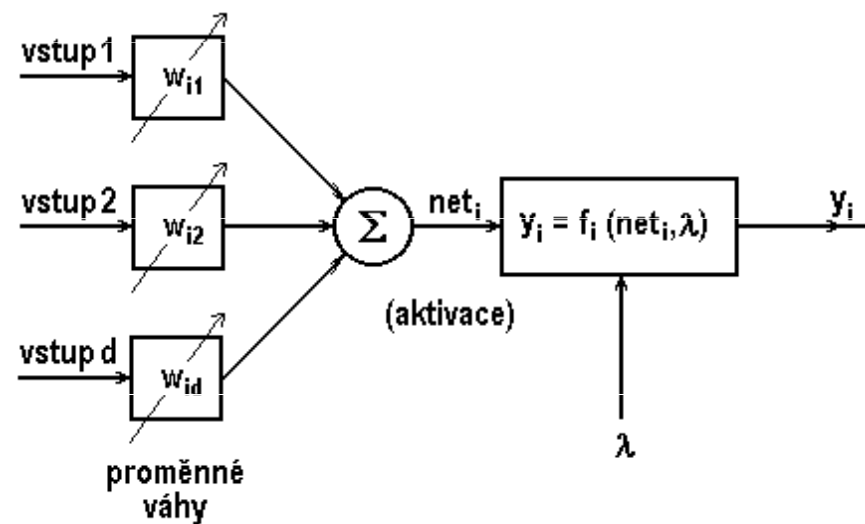
Fáze činnosti neuronu:

- ☑ přenos informace z jednoho neuronu na druhý přes synaptická spojení;
- ☑ nelineární kumulace vstupních stimulů v těle neuronu;
- ☑ prahování potenciálu těla neuronu, jehož výsledkem je rozhodnutí, zda přejde neuron do stavu vybuzení či nikoliv - toto prahování může být spojeno s dalšími operacemi, vyjadřujícími dynamické vlastnosti neuronu (např. dopravní zpoždění, paměť, frekvenční filtraci vstupních hodnot, atp.).

MODEL NEURONU




Blokové schéma abstraktního neuronu



Výpočetní struktura umělého neuronu

MODEL NEURONU



vstup	výstup
$E \geq T; I = 0$	1
$E \geq T; I > 0$	0
$E < T; I = 0$	0
$E < T; I > 0$	0

E: součet aktivovaných excitačních vstupů;
I: součet aktivovaných inhibičních vstupů


McCullochův - Pittsův model neuronu (i) schéma; (ii) převodní pravidla

MODEL NEURONU

0

1

vstupy



vstup

$$\sum_{k=1}^d x_k w_k < T$$

výstup

0

$$\sum_{k=1}^d x_k w_k \geq T$$

1

Lineární model neuronu s prahem

AKTIVACE UMĚLÉHO NEURONU

- ☑ Necht' je každý vstup do neuronu ohodnocen vahou, která udává kvalitativní (stimulace vs. inhibice) i kvantitativní charakteristiku daného vstupu. Předpokládejme, že w_{ij} představuje váhu spojení **z** j-tého neuronu nebo vstupu **do** i-tého neuronu. To znamená, že velké kladné hodnoty w_{ij} představují silný stimulační vstup do neuronu, zatímco velká záporná váha reprezentuje silné tlumení vstupu z j-tého neuronu.

AKTIVACE UMĚLÉHO NEURONU

- ☑ Tato konvence umožňuje vyjádřit aktivaci jednotlivých neuronů pomocí vztahu


$$\text{net}_i = \sum_j w_{ij} y_j$$

kde w_{ij} je prvek matice synaptických vah $\mathbf{W} = [w_{ij}]$ a y_j označuje výstup z j -tého neuronu. Je-li D celkový počet na vstup připojených neuronů, pak hodnoty vstupních signálů lze vyjádřit pomocí sloupcového vektoru $\mathbf{y} = (y_1, y_2, \dots, y_D)^T$. Celkovou aktivaci sítě N neuronů pak můžeme popsat vztahem

$$\mathbf{a} = \mathbf{W} \cdot \mathbf{y},$$

kde $\mathbf{a} = (\text{net}_1, \text{net}_2, \dots, \text{net}_N)$.

PŘEVODNÍ CHARAKTERISTIKY



- ☑ *nastavitelný lineární zisk;*



$$y_i = f(\text{net}_i) = \text{net}_i \quad y_i = f(\text{net}_i) = c_i \cdot \text{net}_i.$$

- ☑ *(reléová) prahová charakteristika;*

$$y_i = f(\text{net}_i) = \begin{cases} 1 & \text{net}_i \geq 0; \\ 0 & \text{net}_i < 0. \end{cases} \quad y_i = f(\text{net}_i) = \begin{cases} +1 & \text{net}_i \geq 0; \\ -1 & \text{net}_i < 0. \end{cases}$$

- ☑ *lineární prahová charakteristika;*

PŘEVODNÍ CHARAKTERISTIKY



- ☑ *obecná sigmoidální charakteristika;*
- ☑ *sigmoidální funkce pro různé hodnoty parametru λ ;*

$$y_i = f(net_i) = (1 + \exp(-\lambda \cdot net_i))^{-1} \quad \frac{dy_i}{dnet_i} = y_i(1 - y_i)$$

DYNAMICKÉ VLASTNOSTI UMĚLÉHO NEURONU

Výše uvedené převodní funkce umožňují výpočet výstupu neuronu, aniž by byly vzaty v potaz jakékoliv dynamické parametry neuronu, jako jsou např. zpoždění signálu mezi vstupem a výstupem, vliv předchozích vstupních či výstupních hodnot, atd.

DYNAMICKÉ VLASTNOSTI UMĚLÉHO NEURONU

Takové dynamické vlastnosti mohou být popsány např. diferenciální rovnicí


$$\frac{d \text{net}_i(t)}{dt} = -\frac{1}{\alpha_i} \text{net}_i(t) + \frac{1}{\alpha_i} \text{net}_i^a(t)$$

kde $\text{net}_i(t)$ je hodnota aktivační funkce neuronu, $\text{net}_i^a(t)$ je hodnota aktivační funkce odpovídající okamžitému vstupu neuronu a α je časová konstanta i -tého neuronu. Diferenciální rovnice tedy umožňuje zahrnout časové změny stavů daného neuronu, tj. zavádí lokální neuronovou paměť.

V případě diskrétního popisu činnosti umělého neuronu lze sestavit ekvivalentní diferenční rovnici.


STRUKUTURA ANN

DOPŘEDNÁ SÍŤ



- ☑ Aktivační vlna se šíří sítí jednosměrně od vstupů k výstupům;
- ☑ realizace buď ve spojitém či diskrétním čase

ZPĚTNOVAZEBNÍ SÍŤ



- ☑ Je třeba stanovit časové okamžiky, ve kterých se odečítá výstup z jednotlivých neuronů;

!!! synchronizace !!!

(!! Je třeba odlišit dynamiku jednotlivých neuronů od dynamiky celé neuronové sítě !!)


NÁVRH STRUKTURY NS

- ☑ výběrem sítě s obecnou strukturou jejíž vlastnosti jsou známy, stejně jako algoritmus jejího učení;
- ☑ adaptací výše uvedené struktury sítě tak, aby odpovídala určité specifické aplikaci. To je možné, použijeme-li jakékoliv informace, která umožní upřesnit vlastnosti a chování jak jednotlivých neuronů, tak jejich skupin. Adaptaci struktury lze provést i prostřednictvím učícího algoritmu.
- ☑ návrhem zcela specifické, na aplikaci závislé konfigurace, která splňuje stanovené požadavky.

OBRÁZKY Z HISTORIE

ADALINE - B. Widrow (1960) adaptivní lineární neuron

Vstupy x_1, \dots, x_N nabývají hodnot ± 1 , přičemž znaménko určuje, zda má vstup excitační či inhibiční charakter. Práh x_0 se zpravidla nastaví na hodnotu ± 1 . Vstupy jsou po vynásobení proměnnými váhovacími koeficienty w_0, w_1, \dots, w_N přivedeny do součtového bloku, jehož výstup je vstupem následujícího bloku s nelinearitou typu *signum*. Váhovací koeficienty jsou nastaveny během učení.



OBRÁZKY Z HISTORIE

PERCEPTRON - F.Rosenberg (1961) tříúrovňový hierarchický model zrakového systému

