

Dobývání znalostí

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

Dobývání znalostí

– Umělé neuronové sítě –

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze


Základní biologické poznatky (1)

♦ Model neuronu


- ~ základní „výpočetní jednotka“ složitějšího celku – neuronové sítě
- ~ biologický neuron se skládá z:
těla (somatu), dendritů, axonu a synapsí



Formální neuron



$$y = f_h \left(\sum_{i=1}^n w_i x_i + \vartheta \right)$$



DĚLICÍ NADROVINA

$$x_2 = -\frac{w_1}{w_2} x_1 - \frac{\vartheta}{w_2}$$


$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta \geq 0: \text{ TŘÍDA A} \\ 0 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta < 0: \text{ TŘÍDA B} \end{cases}$$

Typy přenosových funkcí


Skoková

$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta \geq 0: \text{ TŘÍDA A} \\ 0 & \text{if } \sum_{i=1}^n w_i x_i + \vartheta < 0: \text{ TŘÍDA B} \end{cases}$$


Sigmoidální



Radiální (RBF)



Waveletová



Definice formálního neuronu

Neuron s vahami $(w_1, \dots, w_n) \in R^n$, prahem $\vartheta \in R$ a přenosovou funkcí $f : R^{n+1} \times R^n \rightarrow R$ počítá pro libovolný vstup $\vec{z} \in R^n$ svůj výstup $y \in R$ jako hodnotu přenosové funkce v $\vec{z}$, $f[\vec{w}, \vartheta](\vec{z})$.

Nejčastěji se uvažuje tzv. sigmoidální přenosová funkce:

$$y = f[\vec{w}, \vartheta](\vec{z}) = f(\xi) = \frac{1}{1 + e^{-\xi}}$$

$\xi = \sum_{i=1}^n z_i w_i + \vartheta$ označuje tzv. potenciál neuronu, R množinu reálných čísel.

Definice stavů neuronu

Nechť $\vec{z}$ označuje vstup neuronu.

- Jestliže $f[\vec{w}, \vartheta](\vec{z}) = 1$, říkáme, že je neuron aktivní;

- Jestliže $f[\vec{w}, \vartheta](\vec{z}) = \frac{1}{2}$, říkáme, že je neuron tichý;

Tato skutečnost znamená, že příslušný vstup leží v dělicí nadrovině určené tímto neuronem.

- Jestliže $f[\vec{w}, \vartheta](\vec{z}) = 0$, říkáme, že je neuron pasivní.

Učení a rozpoznávání

◆ Učení:

- **S učitelem - trénovací množina** tvaru [vstup/požadovaný výstup]
- **Bez učitele (samoorganizace)** - chybí požadovaný výstup

⇒ **Cíl:** nastavení (adaptace) synaptických vah

(např. minimalizací střední kvadratické odchylky)

Cílová funkce: např.
$$\sum_p \sum_j (y_{p,j} - d_{p,j})^2$$

y je skutečný a d je požadovaný výstup

◆ Rozpoznávání:

- **nově předkládaných vstupních vzorů**

⇒ **Cíl:** získat odezvu (výstup) neuronové sítě

Perceptron a lineární separabilita (1)

D: **Jednoduchý perceptron** je výpočetní jednotka s prahem ϑ , která pro n reálných vstupů $x_1, x_2, \dots, x_n$ a váhy $w_1, \dots, w_n$ dává výstup 1, jestliže platí nerovnost

$$\sum_{i=1}^n w_i x_i \geq \vartheta \quad (\text{tzn. pokud } \vec{w} \cdot \vec{x} \geq \vartheta) \text{ a } 0 \text{ jinak.}$$

Pozn.: Obdobně pro tzv. **rozšířený váhový a vstupní vektor**:

$$\vec{w} = (w_1, w_2, \dots, w_n, w_{n+1}) \quad ; \quad w_{n+1} = -\vartheta$$

$$\vec{x} = (x_1, x_2, \dots, x_n, 1)$$

$$\Rightarrow \text{výstup } 1, \text{ jestliže } \vec{w} \cdot \vec{x} \geq 0$$

Perceptron a lineární separabilita (2)

Lineární separabilita:

D: Dvě množiny A a B se nazývají **lineárně separabilní** v n -rozměrném prostoru, pokud existuje $n+1$ reálných čísel $w_1, \dots, w_n, \vartheta$ takových, že každý bod $(x_1, x_2, \dots, x_n) \in A$ splňuje $\sum_{i=1}^n w_i x_i \geq \vartheta$ a každý bod $(x_1, x_2, \dots, x_n) \in B$ splňuje $\sum_{i=1}^n w_i x_i < \vartheta$

Perceptron a lineární separabilita (4)

Absolutní lineární separabilita:

D: Dvě množiny A a B se nazývají **absolutně lineárně separabilní** v n -rozměrném prostoru, pokud existuje $n+1$ reálných čísel $w_1, \dots, w_n, \vartheta$ takových, že každý bod $(x_1, x_2, \dots, x_n) \in A$ splňuje $\sum_{i=1}^n w_i x_i > \vartheta$ a každý bod $(x_1, x_2, \dots, x_n) \in B$ splňuje $\sum_{i=1}^n w_i x_i < \vartheta$

Dělicí nadrovina – pro rozšířený váhový, resp. příznakový prostor (2)

D: Dělicí nadrovina určená $\mathbf{n}$ – rozměrným váhovým vektorem $\vec{w}$ je množina všech bodů $\vec{x} \in R^n$, pro které $\vec{w} \cdot \vec{x} = 0$


Problém: Nalézt takové váhy, resp. práh, které by umožnily separaci (oddělení) dvou množin vzorů

=> např. **PERCEPTRONOVÝ ALGORITMUS UČENÍ**

Předpoklad:

- ♦ A ... množina vstupních vektorů v $\mathbf{n}$ –rozměrném prostoru
- ♦ B ... množina vstupních vektorů v $\mathbf{n}$ –rozměrném prostoru

Perceptronový algoritmus učení (1)



Hledáme váhový vektor $\vec{w}$ s pozitivním skalárním součinem pro všechny vektory reprezentované body v P a se záporným skalárním součinem pro všechny vektory reprezentované body v N

Perceptronový algoritmus učení (2)

⇒ **OBEZNĚ:** za předpokladu, že P a N jsou množiny n – rozměrných vektorů chceme nalézt takový váhový vektor $\vec{w}$, že:

$$\vec{w} \cdot \vec{x} > 0 \quad \forall \vec{x} \in P$$

$$\vec{w} \cdot \vec{x} < 0 \quad \forall \vec{x} \in N$$

- ◆ Perceptronový algoritmus učení začíná s náhodně zvoleným váhovým vektorem $\vec{w}_0$
- ◆ Pokud existuje vektor $\vec{x} \in P$ takový, že $\vec{w} \cdot \vec{x} < 0$, znamená to, že úhel mezi těmito dvěma vektory je větší než 90°
 - Váhový vektor je nutné adaptovat ($\sim$ otočit) ve směru $\vec{x}$ (tak, aby se tento vektor dostal do „pozitivního“ poloprostoru definovaného $\vec{w}$)

Perceptronový algoritmus učení (3)

- Otočení ve směru $\vec{x}$ lze provést přičtením $\vec{x}$ k vektoru $\vec{w}$
- ♦ Pokud existuje vektor $\vec{x} \in N$ takový, že $\vec{w} \cdot \vec{x} > 0$, znamená to, že úhel mezi těmito dvěma vektory je menší než 90°
 - Váhový vektor je nutné zadaptovat ($\sim$ otočit) směrem od $\vec{x}$ (tak, aby se tento vektor dostal do „negativního“ poloprostoru definovaného $\vec{w}$)
 - Otočení směrem od $\vec{x}$ lze provést odečtením $\vec{x}$ od vektoru $\vec{w}$
- ♦ vektory z P tedy otáčejí váhový vektor opačným směrem než vektory z N
- ♦ Pokud existuje řešení, lze ho nalézt v konečném počtu kroků

Perceptronový algoritmus učení (4)

Krok 1: Inicializace vah malými náhodnými hodnotami $w_i(0)$

$w_i(0)$... váha vstupu i v čase 0 ; $(1 \leq i \leq n+1)$

Krok 2: Předložení trénovacího vzoru ve tvaru

$(x_1, \dots, x_{n+1})$... vstupní vzor a

$d(t)$ požadovaný výstup (pro předložený vstup)

Krok 3: Výpočet skutečného výstupu (odezvy sítě)

$$y(t) = \operatorname{sgn} \left(\sum_{i=1}^{n+1} w_i(t) x_i(t) \right)$$

Krok 4: Adaptace vah podle:

$w_i(t+1) = w_i(t)$ výstup je správný

$w_i(t+1) = w_i(t) + x_i(t)$ výstup je 0 a měl být 1

$w_i(t+1) = w_i(t) - x_i(t)$ výstup je 1 a měl být 0

Krok 5: Pokud t nedosáhl požadované hodnoty, přejdi ke Kroku 2

Perceptronový algoritmus učení (5)

- ◆ Heuristika pro počáteční nastavení vah:

Začít s průměrem „pozitivních“ vstupních vektorů minus průměr „negativních“ vektorů

- ◆ Modifikace: parametr učení η ($0 \leq \eta \leq 1$)
(stupeň adaptivity vah $\sim$ plasticita sítě)

- Adaptace vah podle:

$$w_i(t+1) = w_i(t)$$

výstup je správný

$$w_i(t+1) = w_i(t) + \eta x_i(t)$$

výstup je 0 a měl být 1

$$w_i(t+1) = w_i(t) - \eta x_i(t)$$

výstup je 1 a měl být 0

Konvergence perceptronového algoritmu učení (Rosenblatt, 1959)


V: Necht' P a N jsou konečné a lineárně separabilní množiny. Potom provede perceptronový algoritmus učení **konečný počet aktualizací** váhového vektoru $\vec{w}_t$.

(Pokud se budou cyklicky testovat jeden po druhém vzory z P a N , najde perceptronový algoritmus učení po provedení konečného počtu aktualizací váhový vektor, pomocí něhož lze navzájem separovat P a N .)

Vrstevnaté neuronové sítě (1)

D: Neuronová síť je uspořádaná 6-tice $M=(N,C,I,O,w,t)$, kde:

- N je konečná neprázdná množina neuronů,
 - $C \subseteq N \times N$ je neprázdná množina orientovaných spojů mezi neurony
 - $I \subseteq N$ je neprázdná množina vstupních neuronů
 - $O \subseteq N$ je neprázdná množina výstupních neuronů
 - $w: C \rightarrow \mathbf{R}$ je váhová funkce
 - $t: N \rightarrow \mathbf{R}$ je prahová funkce
- ($\mathbf{R}$ označuje množinu reálných čísel)



Vrstevnaté neuronové sítě (2)

- D:** Vrstevnatá síť (BP-síť) B je neuronová síť s orientovaným acyklickým grafem spojů. Její množina neuronů je tvořena posloupností $l + 2$ vzájemně disjunktních podmnožin zvaných vrstvy.
- První vrstva zvaná **vstupní vrstva** je množinou všech vstupních neuronů B , tyto neurony nemají v grafu spojů žádné předchůdce; jejich vstupní hodnota x je rovna jejich výstupní hodnotě.
 - Poslední vrstva zvaná **výstupní vrstva** je množinou všech výstupních neuronů B ; tyto neurony nemají v grafu spojů žádné následníky.
 - Všechny ostatní neurony zvané skryté neurony jsou obsaženy ve zbylých l vrstvách zvaných **skryté vrstvy**.

Algoritmus zpětného šíření (1)

Cíl: najít takovou matici vah, která by zaručovala pro všechny vstupní vzory z trénovací množiny to, že skutečný výstup neuronové sítě bude stejný jako její požadovaný výstup

Přitom není specifikována ani skutečná, ani požadovaná aktivita skrytých neuronů.

- ◆ Pro konečnou množinu trénovacích vzorů lze celkovou chybu vyjádřit pomocí rozdílu mezi skutečným a požadovaným výstupem sítě u každého předloženého vzoru.

Algoritmus zpětného šíření (2)

Chybová funkce

- vyjadřuje odchylku mezi skutečnou a požadovanou odezvou sítě:

$$E = \frac{1}{2} \sum_p \sum_j (y_{j,p} - d_{j,p})^2$$


Diagrammatic annotations for the equation above:

- Arrows from the text "vzory" point to the summation index p .
- Arrows from the text "výstupní neurony" point to the summation index j .
- An arrow from the text "požadovaná odezva" points to the term $d_{j,p}$.
- An arrow from the text "skutečná odezva" points to the term $y_{j,p}$.

- cílem procesu učení je minimalizovat tuto odchylku na dané trénovací množině

⇒ **algoritmus zpětného šíření**
(Back-Propagation)

Vrstevnaté neuronové sítě (BP-sítě)



- ♦ výpočet skutečné odezvy pro daný vzor
- ♦ porovnání skutečné a požadované odezvy
- ♦ adaptace vah a prahů
 - proti gradientu chybové funkce
 - od výstupní vrstvy směrem ke vstupní

BP-sítě: adaptační pravidla (1)

Aktualizace synaptických vah proti směru gradientu:

$$w_{ij}(t + 1) = w_{ij}(t) + \Delta_E w_{ij}(t)$$

$\Delta_E w_{ij}(t)$ přírůstek váhy w_{ij} přispívající k minimalizaci E
chyba na výstupu sítě

$$\Delta_E w_{ij} = - \frac{\partial E}{\partial w_{ij}} = - \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}}$$

potenciál neuronu j

skutečný výstup váha spoje

BP-sítě: adaptační pravidla (2)

Aktualizace synaptických vah pro výstupní vrstvu:

$$\begin{aligned}\Delta_E w_{ij} &\cong - \frac{\partial E}{\partial w_{ij}} = - \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} = \\&= - \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} \frac{\partial}{\partial w_{ij}} \sum_{i'} w_{i'j} y_{i'} = \\&= - \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} y_i = - \frac{\partial E}{\partial y_j} f'(\xi_j) y_i = \\&= - (y_j - d_j) f'(\xi_j) y_i = \delta_j y_i\end{aligned}$$

BP-sítě: adaptační pravidla (3)

Aktualizace synaptických vah pro skryté vrstvy:

$$\begin{aligned}\Delta E \cdot w_{ij} &\cong - \frac{\partial E}{\partial w_{ij}} = - \left(\sum_k \frac{\partial E}{\partial \xi_k} \frac{\partial \xi_k}{\partial y_j} \right) \frac{\partial y_j}{\partial \xi_j} y_i = \\ &= - \left(\sum_k \frac{\partial E}{\partial \xi_k} \frac{\partial}{\partial y_j} \sum_{j'} w_{j'k} y_{j'} \right) \frac{\partial y_j}{\partial \xi_j} y_i = \\ &= - \left(\sum_k \frac{\partial E}{\partial \xi_k} w_{jk} \right) \frac{\partial y_j}{\partial \xi_j} y_i = \\ &= \left(\sum_k \delta_k w_{jk} \right) f'(\xi_j) y_i = \delta_j y_i\end{aligned}$$

BP-sítě: adaptační pravidla (4)

Výpočet derivace sigmoidální přenosové funkce podle:

$$f'(\xi_j) = \lambda y_j (1 - y_j)$$

Aktualizace vah podle:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i + \alpha_m (w_{ij}(t) - w_{ij}(t-1))$$

■ kde

$$\delta_j = \begin{cases} (d_j - y_j) \lambda y_j (1 - y_j) & \text{pro výstupní neuron} \\ \left(\sum_k \delta_k w_{jk} \right) \lambda y_j (1 - y_j) & \text{pro skrytý neuron} \end{cases}$$

Algoritmus zpětného šíření (1)

Krok 1: Zvolte náhodné hodnoty synaptických vah

Krok 2: Předložte nový trénovací vzor ve tvaru:

[vstup $\vec{X}$, požadovaný výstup $\vec{d}$]

Krok 3: Vypočtete skutečný výstup

aktivita neuronů v každé vrstvě je dána pomocí:

$$y_j = f(\xi_j) = \frac{1}{1 + e^{-\lambda \xi_j}}, \text{ kde } \xi_j = \sum_i y_i w_{ij}$$

Takto vyjádřené aktivity pak tvoří vstup následující vrstvy.

Algoritmus zpětného šíření (2)

Krok 4: Aktualizace vah

Při úpravě synaptických vah postupujte směrem od výstupní vrstvy ke vstupní. Váhy se adaptují podle:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i + \alpha_m (w_{ij}(t) - w_{ij}(t-1))$$

$$\delta_j = \begin{cases} (d_j - y_j) \lambda y_j (1 - y_j) & \text{pro výstupní neuron} \\ \left(\sum_k \delta_k w_{jk} \right) \lambda y_j (1 - y_j) & \text{pro skrytý neuron} \end{cases}$$

$w_{ij}(t)$ váha z neuronu i do neuronu j v čase t

α, α_m parametr, resp. moment učení ($0 \leq \alpha, \alpha_m \leq 1$)

ξ_j , resp. δ_j potenciál, resp. chyba na neuronu j

k index pro neurony z vrstvy nad neuronem j


λ strmost přenosové funkce

Krok 5: Přejdi ke Kroku 2

BP-sítě: analýza modelu

- ◆ Jeden z nejpoužívanějších modelů
- ◆ Jednoduchý algoritmus učení
- ◆ Poměrně dobré výsledky
- ◆ **Nevýhody:**
 - interní reprezentace znalostí - „černá skříňka“
 - chybová funkce (znalost požadovaných výstupů)
 - „větší“ a „vyvážené“ trénovací množiny
 - kontrola výstupů sítě při rozpoznávání
 - počet neuronů a generalizační schopnosti sítě
 - prořezávání a doučování

BP-sítě: analýza modelu



Nevýhody:

- ♦ „větší“ a „vyvážené“ trénovací množiny

Algoritmus zpětného šíření a urychlení učení (1)

- ♦ **Standardní algoritmus zpětného šíření je poměrně pomalý**
 - špatná volba počátečních parametrů ho může ještě zpomalit
- ♦ **Problém učení umělých neuronových sítí je obecně NP-úplný**
 - výpočetní náročnost roste exponenciálně s počtem proměnných
 - přesto dosahuje standardní algoritmus zpětného šíření často lepších výsledků než mnohé „rychlé algoritmy“
 - hlavně v případě, že má úloha realistickou úroveň složitosti a velikost trénovací množiny přesáhne kritickou mez


Algoritmus zpětného šíření a urychlení učení (2)

Algoritmy s cílem urychlit proces učení:

- ♦ **Zachovávající pevnou topologii sítě**
- ♦ **Modulární sítě**
 - Výrazně zlepšují aproximační schopnosti neuronových sítí
- ♦ **Adaptace parametrů (vah, prahů apod.) i topologie sítě**

Algoritmus zpětného šíření s momentem (1)

Minimalizace chybové funkce pomocí gradientní metody



Algoritmus zpětného šíření s momentem (2)

- ◆ Pokud je pro danou úlohu minimum chybové funkce v „úzkém údolí,“ může vést sledování gradientu k náhlým (častým a velkým) oscilacím během učení
- ◆ Řešení: **zavést člen odpovídající momentu**
 - Kromě aktuální hodnoty gradientu chybové funkce je třeba vzít v úvahu i předchozí změny parametrů (vah)
 - **Setrvačnost** ~ měla by pomoci zamezit extrémním oscilacím v „úzkých údolích chybové funkce“

Algoritmus zpětného šíření s momentem (3)

- ♦ Pro síť s n různými vahami $w_1, \dots, w_n$ je změna váhy w_k v kroku $i + 1$ dána vztahem

$$\begin{aligned}\Delta w_k(i+1) &= -\alpha \frac{\partial E}{\partial w_k(i)} + \alpha_m \Delta w_k(i) = \\ &= -\alpha \frac{\partial E}{\partial w_k(i)} + \alpha_m (w_k(i) - w_k(i-1))\end{aligned}$$

kde: α parametr učení

α_m ... moment učení

Algoritmus zpětného šíření: strategie pro urychlení procesu učení (1)

1. Adaptivní parametr učení:

lokální parametr učení α_i pro každou váhu w_i

adaptace vah podle:
$$\Delta w_i = - \alpha_i \frac{\partial E}{\partial w_i}$$

◆ Varianty algoritmů:

- Silva & Almeida
- Delta-bar-delta
- Super SAB

Algoritmus Silvy & Almeidy (2)

Heuristika:

- ♦ **URYCHLUJ**, pokud se za poslední dvě po sobě jdoucí iterace nezměnilo znaménko parciální derivace

- ♦ **ZPOMALUJ**, pokud se znaménko změnilo

$\Delta_i E^{(k)}$... parciální derivace chybové funkce podle váhy w_i v k -té iteraci

$\alpha_i^{(0)}$... počáteční hodnota parametru učení ($i = 1, \dots, n$)
inicializace malými náhodnými hodnotami

Algoritmus Silvy & Almeidy (3)

- ♦ V k –té iteraci se hodnota parametru učení aktualizuje pro další krok (pro každou váhu) podle:

$$\alpha_i^{(k+1)} = \begin{cases} \alpha_i^{(k)} u & , \quad \text{jestliže} \quad \nabla_i E^{(k)} \cdot \nabla_i E^{(k-1)} > 0 \\ \alpha_i^{(k)} d & , \quad \text{jestliže} \quad \nabla_i E^{(k)} \cdot \nabla_i E^{(k-1)} < 0 \end{cases}$$

- ♦ Konstanty u a d jsou pevně zvolené tak, že $u > 1$ a $d < 1$
- ♦ Adaptace vah podle: $\Delta^{(k)} w_i = -\alpha_i^{(k)} \nabla_i E^{(k)}$

Algoritmus zpětného šíření: strategie pro urychlení procesu učení (2)

2. Algoritmy druhého řádu:

- berou v úvahu více informací o tvaru chybové funkce než jen gradient $\rightarrow$ zakřivení chybové funkce
- metody 2. řádu používají kvadratickou aproximaci chybové funkce

$\vec{w} = (w_1, \dots, w_n)$... vektor všech vah sítě

$E(\vec{w})$ chybová funkce

$\rightarrow$ Taylorova řada pro aproximaci chybové funkce E :

$$E(\vec{w} + \vec{h}) \approx E(\vec{w}) + \nabla E(\vec{w})^T \vec{h} + \frac{1}{2} \vec{h}^T \nabla^2 E(\vec{w}) \vec{h}$$

Algoritmy druhého řádu (2)

$\nabla^2 E(\vec{w})$ Hessianá matice $(n \times n)$ parciálních derivací druhého řádu:

$$\nabla^2 E(\vec{w}) = \begin{pmatrix} \frac{\partial^2 E(\vec{w})}{\partial w_1^2} & \frac{\partial^2 E(\vec{w})}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E(\vec{w})}{\partial w_1 \partial w_n} \\ \frac{\partial^2 E(\vec{w})}{\partial w_2 \partial w_1} & \frac{\partial^2 E(\vec{w})}{\partial w_2^2} & \dots & \frac{\partial^2 E(\vec{w})}{\partial w_2 \partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 E(\vec{w})}{\partial w_n \partial w_1} & \frac{\partial^2 E(\vec{w})}{\partial w_n \partial w_2} & \dots & \frac{\partial^2 E(\vec{w})}{\partial w_n^2} \end{pmatrix}$$

Algoritmy druhého řádu (3)

→ Gradient chybové funkce (zderivováním $\nabla E(\vec{w} + \vec{h})$):

$$\nabla E(\vec{w} + \vec{h})^T \approx \nabla E(\vec{w})^T + \vec{h}^T \nabla^2 E(\vec{w})$$

→ Gradient by měl být nulový (hledá se minimum E):

$$\vec{h} = - \left(\nabla^2 E(\vec{w}) \right)^{-1} \nabla E(\vec{w})$$

==> Newtonovské metody:

- Pracují iterativně
- Aktualizace vah v k – té iteraci podle:

$$\vec{w}^{(k+1)} = \vec{w}^{(k)} - \left(\nabla^2 E(\vec{w}) \right)^{-1} \nabla E(\vec{w})$$

- Rychlá konvergence
- × Problémem může být výpočet inverzní Hessianové matice

Algoritmy druhého řádu (4)

Pseudonewtonovské metody:

- ◆ Pracují se „zjednodušenou aproximací“ Hessianové matice
- ◆ V úvahu se berou pouze prvky na diagonále: $\left(\frac{\partial^2 E(\vec{w})}{\partial w_i^2} \right)$
- ◆ Ostatní prvky Hessianové matice jsou vynulovány

- ◆ **Adaptace vah podle:**

$$w_i^{(k+1)} = w_i^{(k)} - \frac{\nabla_i E(\vec{w})}{\frac{\partial^2 E(\vec{w})}{\partial w_i^2}}$$

Algoritmy druhého řádu (5)

Pseudonewtonovské metody:

- ◆ Odpadá potřebná inverze Hessianové matice
- ◆ Metody „dobře fungují,“ pokud má chybová funkce kvadratický tvar, v opačném případě však mohou nastat problémy

◆ Variety algoritmů:

- Quickprop
- Levenberg-Marquardtův algoritmus

Algoritmus Quickprop (1)

- ◆ Bere v úvahu i informace 2. řádu
 - ✗ Minimalizační kroky provádí pouze v jednom rozměru
 - Informace o zakřivení chybové funkce ve směru adaptace se získává ze současné a předchozí parciální derivace chybové funkce
- ◆ Nezávislá optimalizace pro každou váhu pomocí kvadratické jednorozměrné aproximace chybové funkce

Algoritmus Quickprop (2)

- ♦ Aktualizace vah v k – té iteraci podle:

$$\vec{w}_i^{(k+1)} = \vec{w}_i^{(k)} + \Delta^{(k)} w_i, \text{ kde}$$

$$\Delta^{(k)} w_i = \Delta^{(k-1)} w_i \cdot \frac{\nabla_i E^{(k)}}{\nabla_i E^{(k-1)} - \nabla_i E^{(k)}}$$

Předpoklad: chybová funkce byla spočtena v kroku $(k-1)$ a v kroku k , a to pro váhy s rozdílem $\Delta^{(k-1)} w_i$ - buď standardním algoritmem zpětného šíření nebo pomocí algoritmu Quickprop

Algoritmus Quickprop (3)

- ♦ Aktualizaci vah lze psát i jako:

$$\Delta^{(k)} w_i = - \frac{\nabla_i E^{(k)}}{\frac{\nabla_i E^{(k)} - \nabla_i E^{(k-1)}}{\Delta^{(k-1)} w_i}}$$

- ♦ Jmenovatel odpovídá diskretní aproximaci parciální derivace 2. řádu $\partial^2 E(\vec{w})/\partial w_i^2$
- ♦ Quickprop $\sim$ pseudonewtonovská diskretní metoda, která používá tzv. „**SEKANTOVÝ KROK**“

Levenberg-Marquardtův algoritmus

- ♦ rychlejší a přesnější v oblasti minima chybové funkce
- ♦ kombinace gradientní a Newtonovy metody

$$\vec{w}_{\min} = \vec{w}_0 - (H + \lambda I)^{-1} \cdot \vec{g}$$

gradient

Hessovská matice

- ♦ pro 1 výstup: $g_i = \frac{\partial e}{\partial w_i} = 2 (y - d) \frac{\partial y}{\partial w_i}$


$$\frac{\partial^2 e}{\partial w_i \partial w_j} = 2 \left[\frac{\partial y}{\partial w_i} \frac{\partial y}{\partial w_j} + (y - d) \cancel{\frac{\partial^2 y}{\partial w_i \partial w_j}} \right]$$

Algoritmus zpětného šíření: strategie pro urychlení procesu učení (3)


3. Relaxační metody – perturbace vah:

- ♦ V každé iteraci se počítá diskretní aproximace gradientu porovnáním chybové funkce pro výchozí váhy $E(\vec{w})$ a chybové funkce pro mírně změněné váhy $\vec{w}'$ (k váze w_i byla přičtena malá perturbace β) – $E(\vec{w}')$
- ♦ Aktualizace vah pomocí:
$$\Delta w_i = -\alpha \frac{E(\vec{w}') - E(\vec{w})}{\beta}$$
- ♦ Aktualizace se iterativně opakuje pro vždy náhodně zvolenou váhu

Hopfieldovy sítě



Skoková přenosová funkce: f_h



- ♦ n neuronů se skokovou přenosovou funkcí
- ♦ Bipolární vstupy i výstupy $\{+1, -1\}$
- ♦ Synaptické váhy w_{ij} (mezi všemi neurony navzájem)
- ♦ m trénovacích vzorů (tříd)
- ♦ Učení s učitelem
- ♦ Rozpoznávání
- ♦ Použití:
 - Asociativní paměť
 - Optimalizační úlohy

Hopfieldův model (bipolární)

Krok 1: Učení - nastavte hodnoty synaptických vah

$$w_{ij} = \begin{cases} \sum_{s=1}^m x_i^s x_j^s & \text{pro } i \neq j \\ 0 & \text{pro } i = j \end{cases}$$

w_{ij} Váha synapse mezi neurony i a j
 $x_i^s \in \{-1, +1\}$ i – tá složka s – tého vzoru
 $1 \leq i, j \leq n$

Hopfieldův model (bipolární) (2)

Krok 2: Inicializace - předložte neznámý vstupní

vzor: $y_i(0) = x_i \quad 1 \leq i \leq n$

$y_i(t)$ Výstup neuronu i v čase t

$x_i \in \{-1, +1\}$ i – tá složka předloženého vzoru

Krok 3: Iterace

$$y_j(t+1) = f_h \left[\sum_{i=1}^n w_{ij} y_i(t) \right] \quad 1 \leq j \leq n$$

f_h Skoková přenosová funkce

Hopfieldův model (bipolární) (3)

Iterativní proces se při rozpoznávání opakuje, dokud se výstupy neuronů neustálí. Výstupy neuronů pak reprezentují ten trénovací vzor, který nejlépe odpovídá předloženému (neznámému) vzoru.

Krok 4: Přejděte ke Kroku 2.

Hopfieldův model (bipolární) (4)

Konvergence (Hopfield):

- ◆ Symetrické váhy: $w_{ij} = w_{ji}$
- ◆ Asynchronní aktualizace výstupu jednotlivých neuronů

Nevýhody:

- ◆ Kapacita ($m < 0.15 n$) $n / 2 \log n$
- ◆ Stabilita ($\rightarrow$ ortogonalizace)

Hopfieldův model – příklad

Učení:

♦ Vzory: $[-1, -1, 1, 1]$
 $[1, -1, 1, -1]$

♦ Nastavení vah:

$$w_{ij} = \sum_{m=1}^M x_i^{(m)} x_j^{(m)} \quad i \neq j$$

$$w_{ij} = 0 \quad i = j$$

Hopfieldův model – příklad (2)

- ◆ Nastavení vah:


$$W = \begin{bmatrix} 0 & 0 & 0 & -2 \\ 0 & 0 & -2 & 0 \\ 0 & -2 & 0 & 0 \\ -2 & 0 & 0 & 0 \end{bmatrix}$$

Rozpoznávání:

- ◆ Vzor:

$[-1, -1, 1, -1]$

$[1, -1, 1, -1]$ $[-1, -1, 1, 1]$



Hopfieldův model - rozpoznávání

Po předložení vzoru $\vec{x}_1$ bude vektor potenciálů sítě

$$\begin{aligned}\vec{\xi} &= \vec{x}_1 \cdot W = \vec{x}_1 \cdot \left(\vec{x}_1^T \vec{x}_1 + \dots + \vec{x}_m^T \vec{x}_m - mI \right) = \\ &= \underbrace{\vec{x}_1 \vec{x}_1^T \vec{x}_1}_{=n} + \underbrace{\vec{x}_1 \vec{x}_2^T \vec{x}_2}_{=\alpha_{12}} + \dots + \underbrace{\vec{x}_1 \vec{x}_m^T \vec{x}_m}_{=\alpha_{1m}} - m\vec{x}_1 I = \\ &= (n - m)\vec{x}_1 + \underbrace{\sum_{j=2}^m \alpha_{1j} \vec{x}_j}_{PERTURBACE}\end{aligned}$$

Hopfieldův model – rozpoznávání (2)

$\alpha_{12}, \dots, \alpha_{1m}$ Skalární součin $\vec{x}_1$ s každým dalším vektorem $\vec{x}_2, \dots, \vec{x}_m$

→ Stav $\vec{x}_1$ je stabilní, jestliže $m < n$ a

perturbace $\sum_{j=2}^m \alpha_{1j} \vec{x}_j$ je malá

$$\left(\Rightarrow \operatorname{sgn} \left(\vec{\xi} \right) = \operatorname{sgn} \left(\vec{x}_1 \right) \right)$$

→ Malý počet ortogonálních vzorů


Hopfieldův model – rozpoznávání (3)

- ♦ Stav neuronů zachován, dokud nejsou vybrány k aktualizaci
 - ♦ Výběr pro aktualizaci se provádí náhodně
 - ♦ Neurony jsou navzájem plně propojeny
 - ♦ Symetrické váhy: $w_{ij} = w_{ji}$
 - ♦ $w_{ii} = 0$
- Konvergence ke stabilnímu řešení při rozpoznávání
- nutná podmínka:
- symetrická váhová matice s nulovou diagonálou
a asynchronní dynamikou

Hopfieldův model - příklady

- ♦ Váhová matice s nenulovou diagonálou nemusí vést ke stabilním stavům

$$W = \begin{pmatrix} -1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & -1 \end{pmatrix}$$




- Synchronní dynamika: $(-1, -1, -1) \leftrightarrow (1, 1, 1)$
- Asynchronní dynamika:
 - Náhodný výběr jednoho z osmi možných vzorů

Hopfieldův model – příklady (2)


- ◆ Nesymetrická matice:

$$W = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$$

- Asynchronní dynamika:



cyklické změny



Energetická funkce

Energetická funkce $E(\vec{x})$ Hopfieldovy sítě s n neurony a váhovou maticí W vyjadřuje energii sítě ve stavu $\vec{x}$:

$$E(\vec{x}) = -\frac{1}{2} \vec{x} W \vec{x}^T = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ij} x_i x_j$$

(Obdobně i pro sítě s prahovými neurony:

$$\begin{aligned} E(\vec{x}) &= -\frac{1}{2} \vec{x} W \vec{x}^T + \vec{\theta} \vec{x}^T = \\ &= -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i \end{aligned})$$

Energetická funkce (2)

Věta:

Hopfieldova síť s asynchronní dynamikou dosáhne z libovolného počátečního stavu sítě stabilního stavu v lokálním minimu energetické funkce.

Idea důkazu:

♦ Počáteční stav

- Předložený vzor: $\vec{x} = (x_1, \dots, \underline{x_k}, \dots, x_n)$

Energetická funkce (3)

Idea důkazu (pokračování):

$$E(\vec{x}) = -\frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n w_{ij} x_i x_j$$

K aktualizaci vybrán neuron k

- k nezmění svůj stav $\rightarrow E(\vec{x})$ se nezmění
- k změní svůj stav $\rightarrow \vec{x}' = \left(x_1, \dots, \underline{x_k}', \dots, x_n \right)$

Energetická funkce (4)

Idea důkazu (pokračování):

$$E(\vec{x}') = -\frac{1}{2} \sum_{\substack{j=1 \\ j \neq k}}^n \sum_{\substack{i=1 \\ i \neq k}}^n w_{ij} x_i x_j -$$

symetrie vah $\swarrow$

$$- \sum_{i=1}^n w_{ik} x_i x_k' = \left\{ \begin{array}{l} -\frac{1}{2} \sum_{j=1}^n w_{kj} x_k' x_j \\ -\frac{1}{2} \sum_{i=1}^n w_{ik} x_i x_k' \end{array} \right.$$

Energetická funkce (5)

Idea důkazu (pokračování):

- ◆ Rozdíl energií:

$$E(\vec{x}) - E(\vec{x}') = - \sum_{i=1}^n w_{ik} x_i x_k - \left(- \sum_{i=1}^n w_{ik} x_i x'_k \right) =$$
$$w_{kk} = 0 \longrightarrow = - \underbrace{\left(x_k - x'_k \right)}_{\text{různé znaménko (jinak by nedošlo ke změně stavu)}} \underbrace{\sum_{i=1}^n w_{ik} x_i}_{\text{POTENCIÁL}} > 0$$

různé znaménko (jinak by
nedošlo ke změně stavu)

Energetická funkce (6)

Idea důkazu (pokračování):

- Vždy, když dojde ke změně stavu neuronu, sníží se celková energie sítě
- ◆ Konečný počet možných stavů
 - Stabilní stav, kdy energii sítě už nelze snižovat

QED

Stochastické modely neuronových sítí


- ♦ Hopfieldův model se používá k řešení optimalizačních problémů, které lze vyjádřit ve formě minimalizované energetické funkce (i když není zaručeno nalezení globálního optima)
- ♦ **Problém:** zabránit „uvíznutí“ v lokálním minimu energetické funkce

Stochastické modely neuronových sítí (2)

Modifikace Hopfieldova modelu:

1. strategie: zvětšení počtu možných cest k řešení ve stavovém prostoru
→ dovolit i stavy ve formě reálných hodnot (sigmoidální přenosová funkce)
==> **spojitý model**
2. strategie: omezení lokálních minim energetické funkce pomocí „zašuměné dynamiky sítě“
→ dočasné povolení aktualizace stavu sítě i za cenu přechodného zvýšení energetické hladiny
==> **simulované žíhání, Boltzmannův stroj**

Simulované žíhání



Simulované žíhání (2)

- ◆ Při minimalizaci energetické funkce E se tento jev simuluje následujícím způsobem:
 - Hodnota proměnné $\mathbf{x}$ se změní vždy, když může aktualizace $\Delta\mathbf{x}$ zmenšit hodnotu energetické funkce E
 - Pokud by se při aktualizaci $\mathbf{x}$ naopak hodnota E zvýšila o ΔE , bude nová hodnota $\mathbf{x}$ (tj. $\mathbf{x} + \Delta\mathbf{x}$) přijata s pravděpodobností $p_{\Delta E}$:

$$p_{\Delta E} = \frac{1}{1 + e^{\Delta E/T}}$$

kde T je tzv. teplotní konstanta

Simulované žíhání (3)

- ♦ Pro velké hodnoty T bude: $p_{\Delta E} \approx \frac{1}{2}$
a aktualizace stavu nastane zhruba v polovině těchto případů
- ♦ Pro $T = 0$ bude docházet pouze k takovým aktualizacím, kdy se hodnota E sníží
- ♦ **Postupná změna hodnot T z velmi vysokých hodnot směrem k nule odpovídá zahřátí a postupnému ochlazování v procesu žíhání**

Simulované žíhání (4)

- ◆ Navíc lze ukázat, že touto strategií lze dosáhnout (asymptoticky) globálního minima energetické funkce
- ◆ Sigmoida nejlépe odpovídá funkcím používaným v termodynamice (pro analýzu teplotní rovnováhy)

Boltzmannův stroj

Definice:

Boltzmannův stroj je Hopfieldova síť, která se skládá z n neuronů se stavy $x_1, x_2, \dots, x_n$.

Stav neuronu i se aktualizuje asynchronně podle pravidla:

$$x_i = \begin{cases} 1 & \text{s pstí } p_i \\ 0 & \text{s pstí } 1 - p_i \end{cases}$$

kde

$$p_i = \frac{1}{1 + e^{-\left(\sum_{j=1}^n w_{ij} x_j - \vartheta_i\right) / T}}$$

Boltzmannův stroj (2)

Ve vztahu:
$$p_i = \frac{1}{1 + e^{-\left(\sum_{j=1}^n w_{ij} x_j - \vartheta_i\right) / T}}$$

označuje T kladnou teplotní konstantu, w_{ij} váhy sítě a ϑ_i prahy neuronů

Energetická funkce Boltzmannova stroje:

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \vartheta_i x_i$$

Boltzmannův stroj (3)

- ◆ Rozdíl mezi Boltzmannovým strojem a Hopfieldovým modelem spočívá ve stochastické aktivaci neuronů
- ◆ Pokud je T velmi malé, bude $p_i \sim 1$, jestliže je

$$\sum_{j=1}^n w_{ij} x_j - \mathcal{G}_i > 0$$

× pokud je excitace neuronu záporná, bude $p_i \sim 0$

→ dynamika Boltzmannova stroje aproximuje dynamiku diskrétní Hopfieldovy sítě a Boltzmannův stroj najde lokální minimum energetické funkce

Boltzmannův stroj (4)

- ◆ Pro je $T > 0$ je pravděpodobnost změny anebo posloupnosti změn ze stavu $x_1, \dots, x_n$ do jiného stavu vždy nenulová
 - Boltzmannův stroj nezůstane v jediném stavu
 - snižování a zároveň možnost zvyšování energie systému
- ◆ Pro **veliké hodnoty** T projde síť téměř celý stavový prostor
 - ✗ V ochlazovací fázi má síť tendenci zůstat déle v oblastech blízkých atraktorům lokálních minim

Boltzmannův stroj (5)

Pokud se teplota snižuje správným způsobem, můžeme očekávat, že systém dosáhne globálního minima *s pravděpodobností 1*

Učení bez učitele

◆ Učení bez učitele:

- Samoorganizace a shlukování

◆ Motivace:

- Síť sama rozhodne, která odezva je pro daný vzor nejlepší a podle toho nastaví své váhy

◆ Problém:


- Určit počet a rozložení shluků v příznakovém prostoru

Učení bez učitele (2)



NEVĚDĚT, ŽE JE NA NAŠÍ STRANĚ PRAVDA, TAK BYCH SE DOCELA BÁL.

Učení bez učitele (3)



DÍVČÍ VÁLKA VLASTNĚ NIKDY NEBYLA. ROZMĚLNILA SE IHNEĎ V DROBNÉ ŠARVÁTKY.

Učení bez učitele (4)

Kompetiční učení:

- ♦ Boj o „právo reprezentovat předložený vzor“
- ♦ „Potlačování soupeřů“ → **INHIBICE**
- ♦ Pravidlo „vítěz bere vše“
(WTA – Winner_takes_all)


Posilované učení (reinforcement):

- ♦ Důraz na co nejlepší reprodukci vstupů

Kompetiční učení bez učitele

- ♦ **n** – rozměrný vstupní vzor je zpracováván pomocí takového počtu neuronů, který odpovídá (předpokládanému) počtu shluků
- ♦ Neurony v tomto případě počítají (Euklidovskou) **vzdálenost mezi předloženým vzorem a svým váhovým vektorem**

Kompetiční učení bez učitele (2)



- ♦ V kompetici „vítězí“ neuron, který ke nejblíže předloženému vzoru
- ♦ Vítězný neuron bude nejaktivnější a bude potlačovat – **inhibovat** – aktivitu ostatních neuronů

Kompetiční učení bez učitele (2a)

- ◆ Inhibice pomocí „laterálních spojů“
==> **laterální inhibice**
- ◆ Pro rozhodnutí, zda bude neuron aktivní nebo ne, je nutná globální informace o stavu všech neuronů v síti
- ◆ Aktivita neuronu signalizuje příslušnost předloženého vstupu ke shluku vektorů reprezentovaných tímto neuronem

Kompetiční učení bez učitele (3)

- ♦ Vítězný neuron zadaptuje své váhy směrem k předloženému vzoru:

$$\Delta \vec{w} = \alpha \cdot (\vec{x} - \vec{w})$$

plasticita sítě (během učení pomalu klesá)

Cíl:

- ♦ Umístit neurony do středu shluků vzorů
- ♦ Zachovat již vytvořenou strukturu sítě

Kompetiční učení bez učitele (4)

♦ Urychlení procesu učení:

- Vhodná inicializace vah
- Např. podle náhodně vybraných vzorů

♦ Problémy:

- Mrtvé (nevyužité) neurony
 - Mřížka v Kohonenově vrstvě
 - Topologické okolí neuronu
 - Řízená kompetice a mechanismus svědomí

Kompetiční učení bez učitele (5)

- ♦ Během učení by se měly váhy jednotlivých neuronů nastavit tak, aby odpovídaly „těžišti příslušného shluku“
- ♦ Energetická funkce množiny n – rozměrných normovaných vstupních vzorů $X = \{\vec{x}_1, \dots, \vec{x}_m\}; (n \geq 2)$ je pro 1 neuron s váhovým vektorem $\vec{w}$ dána pomocí:

$$E_X(\vec{w}) = \sum_{i=1}^m \|\vec{x}_i - \vec{w}\|^2 ; \quad \vec{w} \in R^n$$

Kompetiční učení bez učitele (6)

==> lze ukázat, že v optimálním případě je vektor vah umístěn v těžišti shluku vstupních vzorů

$$\begin{aligned} E_X(\vec{w}) &= \sum_{i=1}^m \|\vec{x}_i - \vec{w}\|^2 = \sum_{i=1}^m \sum_{j=1}^n (x_{ij} - w_j)^2 = \\ &= \sum_{i=1}^m \sum_{j=1}^n (x_{ij}^2 - 2x_{ij}w_j + w_j^2) = \\ &= m \left(\sum_{j=1}^n w_j^2 - \frac{2}{m} \sum_{j=1}^n w_j \left(\sum_{i=1}^m x_{ij} \right) \right) + \sum_{i=1}^m \sum_{j=1}^n x_{ij}^2 = \end{aligned}$$

Kompetiční učení bez učitele (7)


$$\begin{aligned} E_X(\vec{w}) &= m \sum_{j=1}^n \left(w_j^2 - \frac{2}{m} w_j \left(\sum_{i=1}^m x_{ij} \right) + \frac{1}{m^2} \left(\sum_{i=1}^m x_{ij} \right) \left(\sum_{i=1}^m x_{ij} \right) \right) - \\ &\quad - \underbrace{\frac{1}{m} \sum_{j=1}^n \left(\sum_{i=1}^m x_{ij} \right) \left(\sum_{i=1}^m x_{ij} \right) + \sum_{i=1}^m \sum_{j=1}^n x_{ij}^2}_{= K} = \\ &= m \left(\sum_{j=1}^n \left(w_j - \frac{1}{m} \sum_{i=1}^m x_{ij} \right)^2 \right) + K = \\ &= m \left\| \vec{w} - \vec{x}^* \right\|^2 + K \end{aligned}$$

Kompetiční učení bez učitele (8)


- vektor $\vec{X}^*$ představuje centroid shluku $\{\vec{X}_1, \vec{X}_2, \dots, \vec{X}_m\}$ a K je konstanta
- energetická funkce má globální minimum v $\vec{X}^*$

Kohonenovy mapy


- ◆ Teuvo Kohonen – fonetický psací stroj



Topologické okolí



Kohonenovy mapy (2)



- ◆ **Učení: bez učitele**
- ◆ **Rozpoznávání**
- ◆ **Použití:**
 - Fonetický psací stroj
 - Ekonomie

Kohonenův model – algoritmus učení

Motivace:


- ♦ Mřížka, na níž jsou uspořádané neurony, umožňuje identifikaci nejbližších sousedů daného neuronu
 - v průběhu učení se aktualizují váhy příslušných neuronů i jejich sousedů

Cíl: sousední neurony by měly také reagovat na velmi podobné signály

Kohonenův model – algoritmus učení (2)

Problém (1-dim):

- ♦ Rozčlenění n – rozměrného prostoru pomocí jednorozměrného řetězce „Kohonenovských neuronů“
- ♦ Neurony uspořádané do posloupnosti a označené od 1 do n



Kohonenův model – algoritmus učení (3)

Problém (1-dim – pokračování):

- ♦ Jednorozměrná mřížka neuronů:
 - Každý neuron „dostává“ n –rozměrný vstup $\vec{x}$ a na základě n –rozměrného váhového vektoru $\vec{w} = (w_1, \dots, w_n)$ spočítá svou excitaci

Cíl: „specializace“ každého neuronu na jinou oblast vstupního prostoru (tuto „specializaci“ charakterizuje maximální excitace příslušného neuronu pro vzory z dané oblasti)

Kohonenův model – algoritmus učení (4)

Problém (1-dim – pokračování):

- „Kohonenovské“ neurony počítají Euklidovskou vzdálenost mezi vstupem $\vec{x}$ a příslušným váhovým vektorem $\vec{w}$
 - „nejbližšímu“ neuronu bude odpovídat maximální excitace

Kohonenův model – algoritmus učení (5)

Definice okolí:

- ♦ V jednorozměrné Kohonenově mapě patří do okolí neuronu k s poloměrem 1 neurony $k - 1$ a $k + 1$
- ♦ Neurony na obou koncích jednorozměrné Kohonenovy mapy mají asymetrické okolí
- ♦ V 1 – rozměrné Kohonenově mapě patří do okolí neuronu k o poloměru r všechny neurony, které jsou od k vzdáleny až o r pozic doleva či doprava
- ♦ Obdobně pro vícerozměrné Kohonenovy mapy a zvolenou metriku na mřížce (čtvercová, hexagonální, ...)


Kohonenův model – algoritmus učení (6)

Funkce laterální interakce $\Phi(i,k)$:

~ „síla laterální vazby“ mezi neurony i a k během učení

Příklad:

- ♦ $\Phi(i,k)=1 \quad \forall i$ z okolí k s poloměrem r a $\Phi(i,k)=0$
 $\forall$ ostatní i
- ♦ Funkce „mexického klobouku“
- ♦ ... a další ...



Kohonenovy samoorganizující se příznakové mapy: algoritmus

Krok 1: Zvol hodnoty vah mezi N vstupními a M výstupními neurony jako malé náhodné hodnoty. Zvol počáteční poloměr okolí a funkci laterální interakce Φ .

Krok 2: Předlož nový trénovací vzor.

Krok 3: Spočítej vzdálenosti d_j mezi vstupním a váhovým vektorem pro každý výstupní neuron j pomocí:

$$d_j = \sum_{i=0}^{N-1} \left(x_i(t) - w_{ij}(t) \right)^2$$

Kde $x_i(t)$ je vstupem neuronu i v čase t a $w_{ij}(t)$ je váhou synapse ze vstupního neuronu i k výstupnímu neuronu j v čase t . Tuto vzdálenost lze upravit váhovým koeficientem a předat kompetiční vrstvě.

Kohonenovy samoorganizující se příznakové mapy: algoritmus (2)

Krok 4: Vyber (např. pomocí laterální interakce) takový výstupní neuron c , který má minimální d_j a označ ho jako „vítěze“.

Krok 5: Váhy se aktualizují pro neuron c a všechny neurony v okolí definovaném pomocí N_c . Nové váhy jsou:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \Phi(c,j) (x_i(t) - w_{ij}(t))$$

Pro $j \in N_c$; $0 \leq i \leq N-1$

$\alpha(t)$ je vigilanční koeficient ($0 < \alpha(t) < 1$), který klesá v čase (vigilance $\sim$ bdělost) .

Kohonenovy samoorganizující se příznakové mapy: algoritmus (3)

Pro volbu $\alpha(t)$ by mělo platit:

$$\sum_{t=1}^{\infty} \alpha(t) = \infty \quad \wedge \quad \sum_{t=1}^{\infty} \alpha^2(t) < \infty$$

Při procesu učení tak vítězný neuron upraví svůj váhový vektor směrem k aktuálnímu vstupnímu vektoru.

Totéž platí pro neurony v okolí „vítěze“.

Hodnota funkce $\Phi(c, j)$ klesá s rostoucí vzdáleností neuronů od středu okolí N_c .

Krok 6: Přejdi ke Kroku 2.

Analýza konvergence ~ stabilita řešení a uspořádaný stav (6)

PROBLÉMY:

- ♦ „rozvinutí“ planární mřížky a podmínky, za kterých k němu dojde
 - ♦ „metastabilní stavy“ a nevhodná volba funkce laterální interakce (příliš rychlý pokles)
- **konvergence pro 1-dimenzionální případ za předpokladu rovnoměrného rozložení a adaptačního pravidla**

$$w_k^{new} = w_k^{old} + \gamma \left(\xi - w_k^{old} \right)$$

kde k označuje vítězný neuron a jeho dva sousedy (Cottrell & Fort, 1986)

Varianty algoritmu učení pro Kohonenovy mapy

Učení s učitelem:

(LVQ ~ Learning Vector Quantization)

LVQ1:

- ♦ Motivace:
 -) $\vec{x}$ by měl patřit ke stejné třídě jako nejbližší $\vec{w}_i$
- ♦ nechť $c = \arg \min_i \{ \|\vec{x} - \vec{w}_i\| \}$ je index $\vec{w}_i$ ležícího nejbliž k $\vec{x}$ ($c \sim$ „vítězný“ neuron)

Varianty algoritmu učení pro Kohonenovy mapy (2)

LVQ1 (pokračování):

→ **adaptační pravidla** ($0 < \alpha(t) < 1$):

$$\vec{w}_c(t+1) = \vec{w}_c(t) + \alpha(t) [\vec{x}(t) - \vec{w}_c(t)]$$

jestliže $\vec{x}$ a $\vec{w}_c$ jsou klasifikovány stejně

$$\vec{w}_c(t+1) = \vec{w}_c(t) - \alpha(t) [\vec{x}(t) - \vec{w}_c(t)]$$

jestliže $\vec{x}$ a $\vec{w}_c$ jsou klasifikovány jinak

$$\vec{w}_i(t+1) = \vec{w}_i(t) \quad \text{jestliže } i \neq c$$

Varianty algoritmu učení pro Kohonenovy mapy (3)

LVQ2.1:

- ♦ **Motivace:** adaptace dvou nejbližších sousedů $\vec{x}$ současně
 - Jeden z nich musí patřit ke správné třídě a druhý k nesprávné
 - Navíc musí být $\vec{x}$ z okolí dělicí nadplochy mezi $\vec{w}_i$ a $\vec{w}_j$ (~ z „okénka“)
 - Je-li d_i (resp. d_j) Euklidovská vzdálenost mezi $\vec{x}$ a $\vec{w}_i$ (resp. mezi $\vec{x}$ a $\vec{w}_j$), lze „okénko“ definovat pomocí vztahu:

$$\min \left(\frac{d_i}{d_j}, \frac{d_j}{d_i} \right) > s, \quad \text{kde} \quad s = \frac{1 - w}{1 + w}$$

(doporučované hodnoty w (~ šířky „okénka“): **0.2 – 0.3**)

Varianty algoritmu učení pro Kohonenovy mapy (4)

LVQ2.1 (pokračování):

→ **adaptační pravidla** ($0 < \alpha(t) < 1$):

- $\vec{w}_i(t+1) = \vec{w}_i(t) - \alpha(t) [\vec{x}(t) - \vec{w}_i(t)]$
- $\vec{w}_j(t+1) = \vec{w}_j(t) + \alpha(t) [\vec{x}(t) - \vec{w}_j(t)]$
- $\vec{w}_i$ a $\vec{w}_j$ leží nejbližší k $\vec{x}$
- přitom $\vec{x}$ a $\vec{w}_j$ patří ke stejné třídě
- a $\vec{x}$ a $\vec{w}_i$ patří k různým třídám
- $\vec{x}$ je z „okénka“

Varianty algoritmu učení pro Kohonenovy mapy (5)

LVQ3 (motivace):

♦ aproximace rozložení tříd a stabilizace řešení

→ **adaptační pravidla** ($0 < \alpha(t) < 1$):

$$\bullet \vec{w}_i(t+1) = \vec{w}_i(t) - \alpha(t) [\vec{x}(t) - \vec{w}_i(t)]$$

$$\bullet \vec{w}_j(t+1) = \vec{w}_j(t) + \alpha(t) [\vec{x}(t) - \vec{w}_j(t)]$$

$\vec{w}_i$ a $\vec{w}_j$ leží nejblíže k $\vec{x}$; přitom $\vec{x}$ a $\vec{w}_j$ patří ke stejné třídě a $\vec{x}$ a $\vec{w}_i$ patří k různým třídám a $\vec{x}$ je z „okénka“

$$\bullet \vec{w}_k(t+1) = \vec{w}_k(t) + \varepsilon \alpha(t) [\vec{x}(t) - \vec{w}_k(t)]$$


pro $k \in \{i, j\}$ jestliže $\vec{x}$, $\vec{w}_i$ i $\vec{w}_j$ patří do stejné třídy

Varianty algoritmu učení pro Kohonenovy mapy (6)

LVQ3 (pokračování):

- ♦ volba parametrů:

- $0.1 \leq \varepsilon \leq 0.5$
- $0.2 \leq w \leq 0.3$




Varianty algoritmu učení pro Kohonenovy mapy (7)

Další varianty:

- ◆ Vícevrstvé Kohonenovy mapy
 - Strom abstrakce
- ◆ Sítě se vstřícným šířením (Counterpropagation)
 - Učení s učitelem – dvě fáze učení
 - Kohonenovská (klastrovací) vrstva
 - Grossbergovská vrstva (adaptace vah jen pro vítězné neurony z Kohonenovské vrstvy)

Sítě se vstřícným šířením



Učení: s učitelem

Rozpoznávání

Použití:

- ♦ Heteroasociativní paměť

Učící algoritmus pro sítě se vstřícným šířením (1)

Krok 1: Zvolte náhodné hodnoty synaptických vah.

Krok 2: Předložte nový trénovací vzor ve tvaru
(vstup, požadovaný výstup).

Krok 3: Vyberte v Kohonenově vrstvě neuron c , jehož synaptické váhy nejlépe odpovídají předloženému vzoru $\vec{x}(t)$. Pro tento neuron tedy bude platit, že vzdálenost e_k mezi příslušným váhovým vektorem $\vec{v}_k(t)$ a předloženým vzorem $\vec{x}(t)$ je minimální. Použít lze např. Euklidovskou metriku, potom:

$$e_c = \min_k e_k = \min_k \sqrt{\sum_i (x_i(t) - v_{ik}(t))^2}$$

Učící algoritmus pro sítě se vstřícným šířením (2)

Krok 4: Aktualizujeme váhy v_{ik} mezi vstupním neuronem i a neurony Kohonenovské vrstvy, které se nacházejí v okolí N_c neuronu c tak, aby lépe odpovídaly předloženému vzoru $\vec{x}(t)$:

$$v_{ik}(t+1) = v_{ik}(t) + \alpha(t)(x_i(t) - v_{ik}(t))$$

$\alpha(t)$, kde $0 < \alpha(t) < 1$, je parametr učení pro váhy mezi vstupní a Kohonenovskou vrstvou, který klesá v čase. t představuje současný a $t + 1$ následující krok učení.

Učící algoritmus pro síť se vstřícným šířením (3)

Krok 5: Aktualizujte váhy w_{ci} mezi „vítězným“ neuronem c z Kohonenovské vrstvy a neurony Grossbergovské vrstvy tak, aby výstupní vektor lépe odpovídal požadované odezvě $\vec{d}$:


$$w_{cj}(t+1) = (1 - \beta)w_{cj}(t) + \gamma z_c d_j$$

$w_{cj}(t)$ je váha synaptického spoje mezi c -tým neuronem Kohonenovské vrstvy a j -tým neuronem Grossbergovské vrstvy v čase t , $w_{cj}(t+1)$ označuje hodnotu této synaptické váhy v čase $t+1$. β je kladná konstanta ovlivňující závislost nové hodnoty synaptické váhy na její hodnotě v předchozím kroku učení. Kladná konstanta γ představuje parametr učení vah mezi Kohonenovskou a Grossbergovskou vrstvou, z_c označuje aktivitu „vítězného“ neuronu Kohonenovské vrstvy.

Krok 6: Přejděte ke kroku 2.

RBF-sítě (Radial Basis Functions)

- ◆ Hybridní architektura (Moody & Darken)
- ◆ Učení s učitelem



RBF-sítě (Radial Basis Functions)

- ◆ Každý neuron j počítá svůj výstup $g_j(t)$ podle:

$$g_j(\vec{x}) = \frac{\exp\left(\frac{(\vec{x} - \vec{w}_j)^2}{2\sigma_j^2}\right)}{\sum_k \exp\left(\frac{(\vec{x} - \vec{w}_k)^2}{2\sigma_k^2}\right)}$$

$\vec{x}$... vstupní vektor

$\vec{w}_1, \dots, \vec{w}_m$... váhové vektory skrytých neuronů

$\sigma_1, \dots, \sigma_m$... konstanty (nastavené např. podle vzdálenosti mezi příslušným váhovým vektorem a jeho nejbližším sousedem)

RBF-sítě (Radial Basis Functions)

- ♦ výstup každého srytého neuronu je normován
 - vzájemné propojení všech neuronů
- ♦ váhy $z_1, \dots, z_m$ lze nastavit např. pomocí algoritmu zpětného šíření:

$$E = \frac{1}{2} \sum_p \left(\sum_{i=1}^n g_i(\vec{x}_p) z_i - d_p \right)^2$$

d ... požadovaný výstup

p ... počet trénovacích vzorů



γ ... parametr učení

$$\Delta z_i \cong -\frac{\partial E}{\partial z_i} = \gamma g_i(\vec{x}) \left(d - \sum_{i=1}^n g_i(\vec{x}) z_i \right)$$

ART – Adaptive Resonance Theory

(Carpenter & Grossberg)

výstup



vstup

ART – Adaptive Resonance Theory (2)

(Carpenter & Grossberg)

ART 1:

- ◆ Binární vstupy, učení bez učitele
- ◆ Laterální inhibice pro určení výstupního neuronu s maximální odezvou
- ◆ Váhy i pro zpětnou vazbu (z výstupních neuronů směrem ke vstupním) pro porovnání skutečné podobnosti s rozpoznaným vzorem

ART – Adaptive Resonance Theory (3)

(Carpenter & Grossberg)

ART 1 (pokračování):

- ◆ Vigilanční test – parametr bdělosti
- ◆ Mechanismus pro „vypnutí“ výstupního neuronu s maximální odezvou

→ **stabilita × plasticita sítě**

- × síť má velké problémy i při „jen trochu zašuměných vzorech“

→ **narůstá počet ukládaných vzorů**

ART 1 – algoritmus učení

Krok 1: **Inicializace**

$$t_{ij} (0) = 1 \qquad 0 \leq i \leq N-1$$

$$b_{ij} (0) = 1 / (1 + N) \qquad 0 \leq j \leq M-1$$

$$\rho \qquad 0 \leq \rho \leq 1$$

$b_{ij} (t) \sim$ váha mezi vstupním neuronem i a výstupním neuronem j v čase t

$t_{ij} (t) \sim$ váha mezi výstupním neuronem j a vstupním neuronem i v čase t (určují vzor specifikovaný výstupním neuronem j)

$\rho \sim$ práh bdělosti (určuje, jak blízko musí být předložený vstup k uloženému vzoru - aby mohly patřit do stejné kategorie)

ART 1 – algoritmus učení (2)

Krok 2: **Předlož nový vstup**

Krok 3: **Spočítej aktivaci výstupních neuronů**

$$\mu_j = \sum_{i=0}^{N-1} b_{ij}(t) x_i \quad ; \quad 0 \leq j \leq M-1$$

$\mu_j \sim$ výstup výstupního neuronu j

$x_i \sim i$ – tá složka vstupního vektoru ($\in \{0, 1\}$)

Krok 4: **Vyber uložený vzor, který nejlépe odpovídá předloženému vzoru** (např. pomocí laterální inhibice):

$$\mu_{j^*} = \max_j \{ \mu_j \}$$

ART 1 – algoritmus učení (3)

Krok 5: **Test bdělosti**

$$\|\vec{x}\| = \sum_{i=0}^{N-1} x_i \quad \text{a} \quad \|T \cdot \vec{x}\| = \sum_{i=0}^{N-1} t_{ij^*} x_i$$

jestliže $\frac{\|T \cdot \vec{x}\|}{\|\vec{x}\|} > \rho$ přejdi ke Kroku 7

jinak přejdi ke Kroku 6

Krok 6: **Zmrazení nejlépe odpovídajícího neuronu**

výstup neuronu j^* vybraného v Kroku 4 je dočasně nastaven na nulu (a neúčastní se maximalizace v Kroku 4). Poté přejdi ke Kroku 4.

ART 1 – algoritmus učení (4)

Krok 7: **Aktualizace nejlépe odpovídajícího neuronu**

$$t_{ij}^* (t + 1) = t_{ij}^* (t) \cdot x_i$$

$$b_{ij}^* (t + 1) = \frac{t_{ij}^* (t) \cdot x_i}{0.5 + \sum_{i=0}^{N-1} t_{ij}^* (t) \cdot x_i}$$

Krok 8: **Přejdi ke Kroku 2 a opakuj**

(Předtím znovu „zapoj“ všechny neurony
„zmrazené v Kroku 6)