

Neuronové sítě

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

Neuronové sítě

– Učení bez učitele –

Doc. RNDr. Iveta Mrázová, CSc.

Katedra teoretické informatiky

Matematicko-fyzikální fakulta

Univerzity Karlovy v Praze

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 BĚL.

Učení bez učitele (3)



DIVČÍ 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)

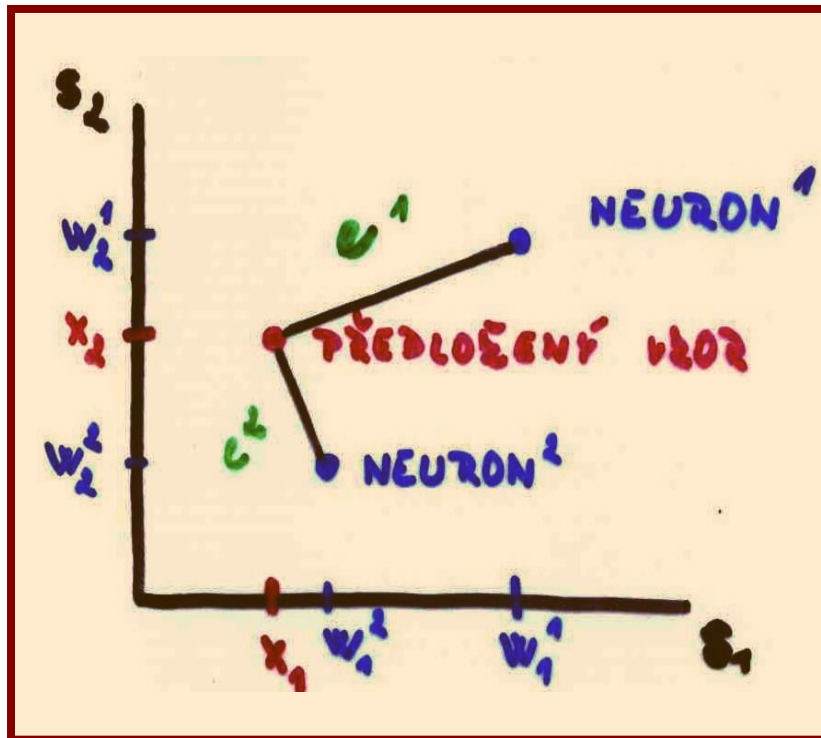
Posilované učení (reinforcement):

- ◆ 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}^*

Kompetiční učení bez učitele (9)

Klastrovací metody pro empirická vícerozměrná data:

- ◆ dva základní přístupy:
 - k nejbližších sousedů
 - algoritmus k středů
- ◆ **k nejbližších sousedů** (učení s učitelem)
 - Vzory z trénovací množiny jsou uloženy a klasifikovány do jedné z l různých tříd
 - Neznámý vstupní vektor je zařazen do té třídy, ke které patří většina z k nejbližších vektorů z uložené množiny

Kompetiční učení bez učitele (10)

- ◆ **algoritmus k středů** (k -means clustering)
 - Učení bez učitele
 - Vstupní vektory jsou klasifikovány do k různých shluků (na začátku učení obsahuje každý shluk právě 1 vektor)
 - Nový vektor \vec{x} je zařazen k tomu shluku k , jehož centroid \vec{c}_k je nejbližší tomuto vzoru

Kompetiční učení bez učitele (11)

- ♦ **algoritmus k středů** (pokračování)

- Centroid \vec{c}_k je pak aktualizován pomocí:

$$\vec{c}_k(\text{new}) = \vec{c}_k(\text{old}) + \frac{1}{n_k} (\vec{x} - \vec{c}_k(\text{old}))$$

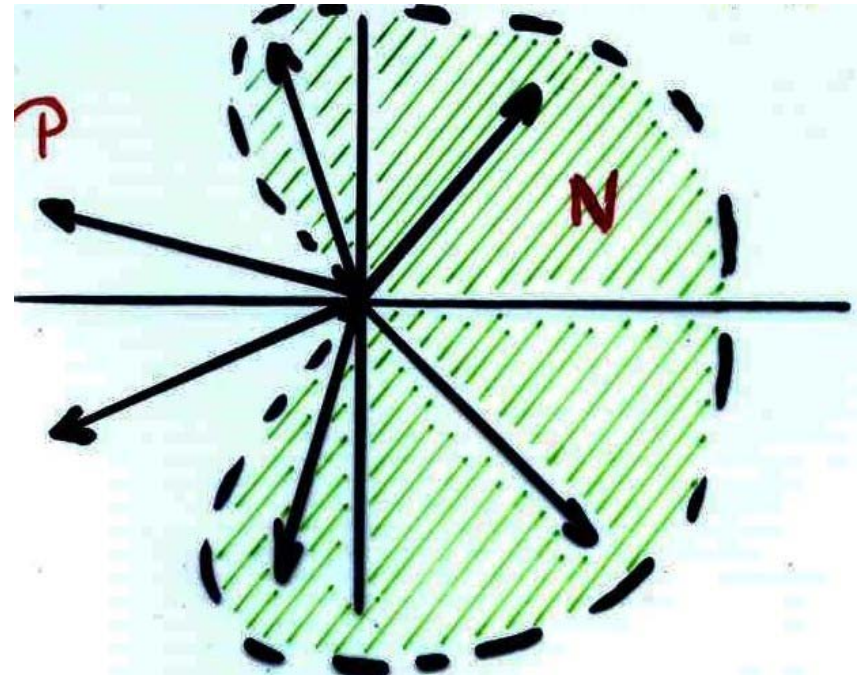
n_k Počet vektorů již přiřazených shluku k

- Tato procedura se iterativně opakuje pro celou množinu dat (jejich strukturu pak vystihují „váhové vektory“ \vec{c}_i ; $i = 1, \dots, k$)

→ **Vektorová kvantizace**

Problém shlukování


- ◆ Dvě množiny vektorů:
 - P a N
- ◆ Obtížná „separace“ shluků pomocí jednoduchého perceptronu tak, aby:



$$\vec{w} \cdot \vec{p} \geq 0 \quad \forall \vec{p} \in P \quad \wedge \quad \vec{w} \cdot \vec{n} < 0 \quad \forall \vec{n} \in N$$

Problém shlukování (2)

- ◆ Tři váhové vektory pro tři shluky



- ◆ Tři různé vektory \vec{w}_1 , \vec{w}_2 a \vec{w}_3 mohou sloužit jako „reprezentanti“ v jednotlivých shlucích A , B a C

Problém shlukování (3)

- ◆ Každý z těchto tří vektorů je „relativně blízko“ ke každému vektoru z příslušného shluku
- ◆ Každý váhový vektor odpovídá jednomu bezprahovému neuronu, který je aktivní pouze v případě, že je vstupní vektor dostatečně blízko tomuto váhovému vektoru

==> Jak určit počet a rozložení shluků?

Kompetiční učení - algoritmus

- ◆ Necht' $X = \{\vec{x}_1, \vec{x}_2, \dots, \vec{x}_l\}$ je množina normovaných vstupních vektorů v n – rozměrném prostoru, které chceme zařadit do k různých shluků
- ◆ Neuronová síť se skládá z k neuronů, z nichž každý má n vstupů a nulový práh

Inicializace:

- ◆ Normované váhové vektory $\vec{w}_1, \dots, \vec{w}_k$ jsou generovány náhodně

Kompetiční učení – algoritmus (2)

Test:

- ◆ Náhodně vyber vektor $\vec{x}_j \in X$
- ◆ Spočítej $\vec{w}_i \cdot \vec{x}_j$ pro $i = 1, \dots, k$
- ◆ Vyber \vec{w}_m takový, že $\vec{w}_m \cdot \vec{x}_j \geq \vec{w}_i \cdot \vec{x}_j$ ($\forall i = 1, \dots, k$)
- ◆ Proved' Aktualizaci

Aktualizace:

- ◆ Nahrad' \vec{w}_m (*new*) vektorem \vec{w}_m (*old*) + \vec{x}_j a znormuj
- ◆ Pokračuj v Testu

Kompetiční učení – algoritmus (3)

- ◆ Po provedení předem určeného počtu kroků lze algoritmus ukončit
- ◆ Váhové vektory k neuronů jsou „přitahovány“ směrem k centru jednotlivých shluků ve vstupním prostoru
- ◆ Algoritmus je založen na principu „**vítěz bere vše**“ (~ WINNER-TAKES-ALL)

Kompetiční učení – algoritmus (4)

- ◆ Použití normovaných vektorů zabraňuje tomu, aby byl některý z váhových vektorů příliš velký, takže by „vyhrával“ kompetici příliš často
 - Ostatní neurony by se pak nikdy neaktualizovaly a zůstaly by nevyužité → **„mrtvé neurony“**
- ◆ Protože jsou vstupní i váhové vektory normované, je skalární součin $\vec{w}_i \cdot \vec{x}_j$ váhového a vstupního vektoru roven kosinu úhlu mezi těmito dvěma vektory

Kompetiční učení – algoritmus (5)

- ♦ Algoritmus učení zaručuje, že bude aktualizován ten vektor \vec{w}_m , který leží nejbliž k předloženému vstupnímu vzoru
- ♦ Při aktualizaci je váhový vektor \vec{w}_m otočen směrem k \vec{x}_j

Různá pravidla učení:

- ♦ **Aktualizace pomocí parametru učení**

$$\Delta \vec{w}_m = \eta \vec{x}_j \quad ; \quad \eta \in (0,1) \text{ pomalu klesá v čase}$$

→ **plasticita sítě**

Kompetiční učení – algoritmus (6)

Různá pravidla učení (pokračování):

◆ Diferenční aktualizace

$$\Delta \vec{w}_m = \eta (\vec{x}_j - \vec{w}_m)$$

- „oprava“ odpovídá rozdílu mezi oběma vektory


◆ Dávková aktualizace

- „korekce“ vah pro jednotlivé vzory se kumuluje
- Váhy se změňí po několika iteracích nejednou
→ stabilnější proces učení

Kompetiční učení – algoritmus (7)

Stabilita řešení

- ◆ Nutnost vhodné míry pro „dobré shlukování“
 - **nejjednodušší řešení:** určit vzdálenost mezi shluky
- ◆ Dva shluky vektorů a dva vektory „reprezentativních vah“:
 - Oba vektory „reprezentantů“ leží blízko vektorů, které leží v jejich odpovídajícím shluku

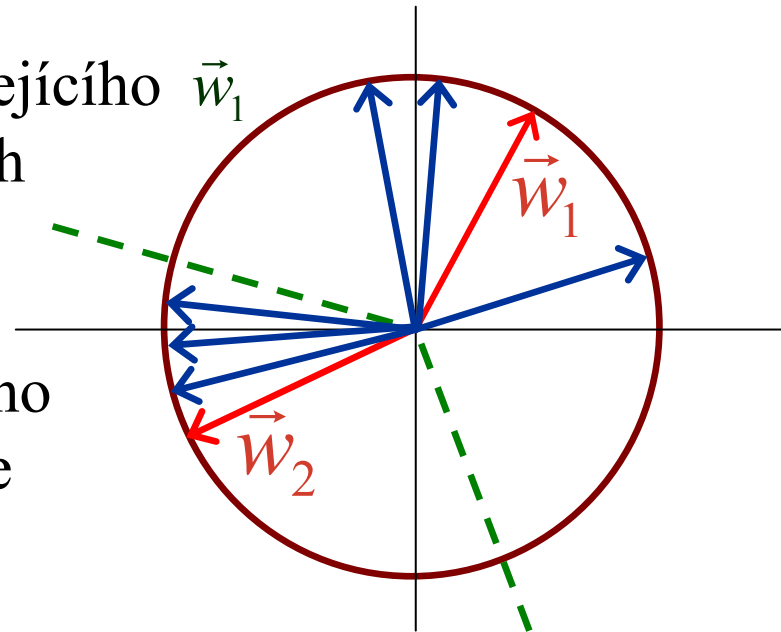


Kompetiční učení – algoritmus (8)

Stabilita řešení (pokračování):

- \vec{w}_1 leží uvnitř „svazku“ definovaného vektory svého shluku
- \vec{w}_2 leží vně „svazku“ příslušejícího \vec{w}_1
- Vektor \vec{w}_1 v dalších iteracích už „neopustí“ svůj „svazek“
- Vektor \vec{w}_2 se v některé z dalších iterací dostane do svého svazku a dál v něm už zůstane

→ takové řešení bude stabilní



Kompetiční učení – algoritmus (9)

Řešení ve stabilním rovnovážném stavu:

- ◆ **Intuitivní představa:**
 - **stabilní rovnovážný stav vyžaduje jasně ohraničené shluky**
- ◆ Pokud se jednotlivé shluky navzájem překrývají nebo jsou příliš rozsáhlé, nemusí být stabilní řešení nalezeno
 - ==> nestabilní rovnovážný stav**

Stabilita řešení - analýza

Definice:

Nechť P je množina $\{\vec{p}_1, \dots, \vec{p}_m\}$ n – rozměrných ($n \geq 2$) vektorů ležících ve stejném poloprostoru (\sim formální omezení velikosti shluku).

Svazek K definovaný pomocí P je množina všech vektorů \vec{x} tvaru $\vec{x} = \alpha_1 \vec{p}_1 + \dots + \alpha_m \vec{p}_m$, kde $\alpha_1, \dots, \alpha_m$ jsou kladná reálná čísla.

- ◆ Svazek shluku obsahuje všechny vektory „uvnitř“ shluku
- ◆ Průměr svazku definovaného normovanými vektory odpovídá největšímu možnému úhlu mezi vektory ve shluku

Stabilita řešení – analýza (2)

Definice:

(Úhlový) průměr φ svazku K definovaného normovanými vektory $\{\vec{p}_1, \dots, \vec{p}_m\}$ odpovídá:

$$\varphi = \sup \left\{ \arccos(\vec{a} \cdot \vec{b}) \mid \forall \vec{a}, \vec{b} \in K ; \|\vec{a}\| = \|\vec{b}\| = 1 \right\}$$

kde $0 \leq \arccos(\vec{a} \cdot \vec{b}) \leq \pi$

- ◆ Postačující podmínkou pro stabilní řešení je, aby byl úhlový průměr svazků menší než jejich vzájemná vzdálenost

Stabilita řešení – analýza (3)

Definice:

Nechť $P = \{\vec{p}_1, \dots, \vec{p}_m\}$ a $N = \{\vec{n}_1, \dots, \vec{n}_k\}$ jsou dvě neprázdné množiny normovaných vektorů v n -rozměrném prostoru ($n \geq 2$), které definují svazky K_P a K_N

- Jestliže je průnik těchto dvou svazků prázdný, je (úhlová) vzdálenost mezi K_N a K_P dána pomocí:

$$\psi = \inf \left\{ \arccos(\vec{p} \cdot \vec{n}); \vec{p} \in K_P, \vec{n} \in K_N \text{ a } \|\vec{p}\| = \|\vec{n}\| = 1 \right\}$$

$$\text{kde } 0 \leq \arccos(\vec{p} \cdot \vec{n}) \leq \pi$$

- Jestliže se K_P a K_N prolínají, je $\psi_{P,N} = 0$

Stabilita řešení – analýza (4)

- ◆ Jestliže je úhlová vzdálenost mezi shluky větší než úhlový průměr svazků, potom existuje stabilní řešení
 - Váhové vektory budou ležet ve svazku jim příslušejícího shluku
 - Jestliže se váhový vektor už „dostal“ dovnitř příslušného svazku, zůstane tam i nadále

Kontrola kvality shlukování:

- ◆ Výhodnější je menší počet „kompaktnějších“ shluků
- ◆ Ohodnocovací funkce pro penalizaci příliš vysokého počtu shluků


PCA – Principal Component Analysis

- ~ redukce dimenzionality vstupních dat
 - použít méně příznaků bez ztráty podstatné informace
 - výběr nejdůležitějších příznaků
- ~ dána množina m n – rozměrných vektorů:
- ~ prvním „nejdůležitějším“ příznakem pro tuto množinu vektorů je vektor \vec{w} , který maximalizuje

výraz

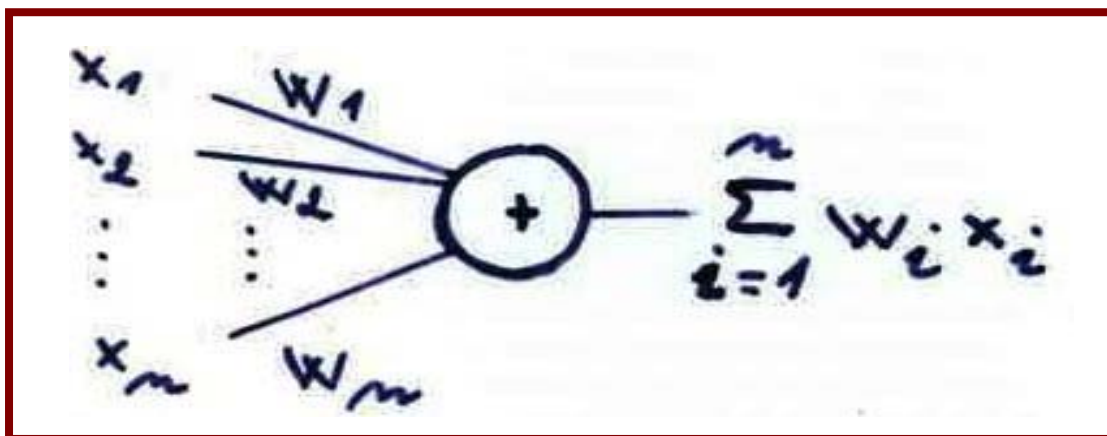
$$\frac{1}{m} \sum_{i=1}^m \left\| \vec{w} \cdot \vec{x}_i \right\|^2$$

PCA – Principal Component Analysis (2)



- ◆ Rozložení vstupních dat:
 - 1. PC: největší rozptyl
 - 2. PC: kolmá k 1. PC a největší rozptyl
(~ odečíst od \vec{x} jeho ortogonální projekci na 1. PC)

PCA – Principal Component Analysis (3)



◆ Použitý model:

- Lineární asociátor
 - jako výsledek počítá pouze vážený součet vstupů
- Posilované učení – Ojův algoritmus učení

Výpočet nejdůležitějších příznaků pomocí umělých neuronových sítí

Ojův algoritmus učení (E. Oja, 1982)
(pro výpočet prvního nejdůležitějšího příznaku)

Předpoklad:

- Těžiště vstupních dat je vycentrováno v počátku

Start:

- Necht' X je množina n – rozměrných vektorů
- Vektor \vec{w} je inicializován náhodně ($\vec{w} \neq \mathbf{0}$)
- Je zvolen parametr učení γ ($0 < \gamma \leq 1$)

Výpočet nejdůležitějších příznaků pomocí umělých neuronových sítí (2)

Ojův algoritmus učení (pokračování):

Adaptace:

- z množiny X je náhodně vybrán vektor \vec{x}
- Spočítá se skalární součin $\Phi = \vec{x} \cdot \vec{w}$
- Nový váhový vektor je $\vec{w} + \gamma \Phi (\vec{x} - \Phi \vec{w})$
- Zmenši γ a přejdi k „Adaptaci“

Podmínka pro ukončení adaptace

- např. počet provedených iterací

Výpočet nejdůležitějších příznaků pomocí umělých neuronových sítí (3)

◆ **Parametr učení γ**

- Parametr učení je třeba zvolit dostatečně malý, aby byla zaručena adekvátní adaptace vah (omezení velkých oscilací)

◆ **„Automatická normalizace“ váhového vektoru**

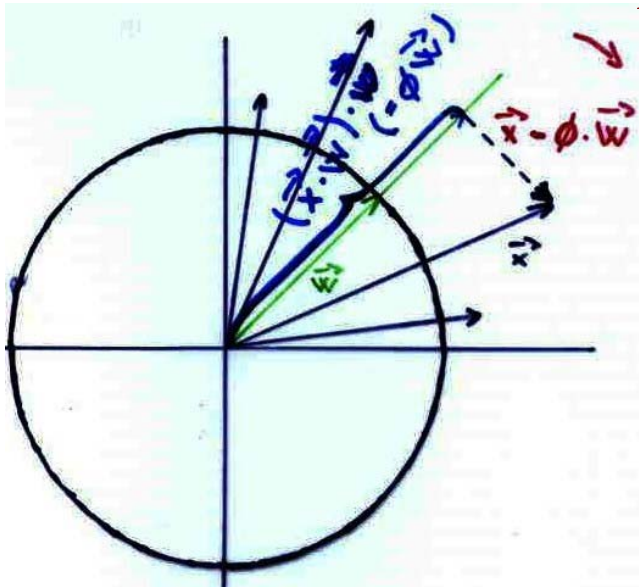
- Odpadá nutnost znát globální informaci o všech vzorech
- Postačí lokální informace o aktualizované váze, vstupu a skalárním součinu asociátoru

◆ **První nejdůležitější příznak odpovídá směru nejdelšího vlastního vektoru korelační matice uvažovaných vstupních vektorů**

Konvergence Ojova algoritmu učení

Pokud existuje jednoznačné řešení, bude Ojův algoritmus učení konvergovat:

Idea důkazu:



Adaptace \vec{w} směrem k \vec{x}

-) začne-li Ojův algoritmus učení s váhovým vektorem uvnitř svazku, bude v něm oscilovat, ale neopustí ho
-) pro $\|\vec{w}\| = 1$ odpovídá skalární součin $\Phi = \vec{x} \cdot \vec{w}$ délce projekce \vec{x} na \vec{w}

Konvergence Ojova algoritmu učení (2)

Idea důkazu (pokračování):

-) vektor $\vec{x} - \Phi \vec{w}$ je kolmý na \vec{w}
-) iterace Ojova algoritmu učení přitahují \vec{w} k vektorům ze shluku X
-) pokud zůstane délka \vec{w} rovna 1 (anebo blízko 1), umístí se \vec{w} v procesu učení v centru shluku
-) dále je ještě třeba ukázat, že vektor \vec{w} je Ojovým algoritmem automaticky normován:
Idea: a) délka vektoru \vec{w} je větší než 1
b) délka vektoru \vec{w} je menší než 1


Konvergence Ojova algoritmu učení (3)

a) délka vektoru \vec{w} je větší než **1**

- Délka vektoru $(\vec{x} \cdot \vec{w})\vec{w}$ je větší než délka ortogonální projekce \vec{x} na \vec{w}
- Dále předpokládejme, že $\vec{x} \cdot \vec{w} > 0$, tj. že vektory \vec{x} a \vec{w} nejsou navzájem příliš vzdálené
- Vektor $\vec{x} - (\vec{x} \cdot \vec{w})\vec{w}$ má zápornou projekci na \vec{w} ,

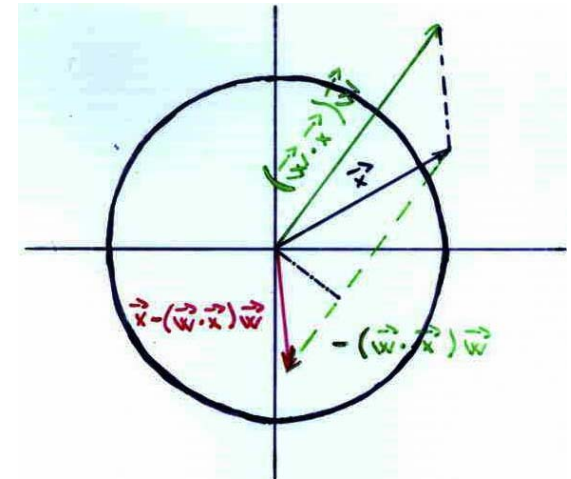
protože

$$\begin{aligned} & (\vec{x} - (\vec{x} \cdot \vec{w})\vec{w}) \cdot \vec{w} = \\ & = \vec{x} \cdot \vec{w} - \|\vec{w}\|^2 \vec{x} \cdot \vec{w} < 0 \end{aligned}$$



Konvergence Ojova algoritmu učení (4)

- Výsledek po větším počtu iterací:
 - (vektor $\vec{x} - (\vec{x} \cdot \vec{w})\vec{w}$ má jednu složku kolmou na \vec{w} a druhou složku, která směřuje opačným směrem než \vec{w})
 - \vec{w} přejde do centra shluku vektorů (kolmá složka v průměru vymizí)
 - \vec{w} se bude s rostoucím počtem iterací tohoto typu zmenšovat (!pozor na nebezpečí změny orientace \vec{w} v jedné iteraci)



Konvergence Ojova algoritmu učení (5)

- **Vhodná volba parametru učení γ a normalizace vektorů z trénovací množiny před začátkem učení:**

- jestliže má vektor \vec{x} pozitivní skalární součin Φ s \vec{w} , měl by mít i nový váhový vektor pozitivní skalární součin s \vec{x} :
- mělo by tedy platit: $\vec{x} \cdot (\vec{w} + \gamma \Phi (\vec{x} - \Phi \vec{w})) > 0$

$$\Phi + \gamma \Phi \|\vec{x}\|^2 - \gamma \Phi \Phi^2 > 0$$

$$\Phi \left(1 + \gamma \left(\|\vec{x}\|^2 - \Phi^2 \right) \right) > 0$$

$$> 0 \Rightarrow \gamma \left(\|\vec{x}\|^2 - \Phi^2 \right) > -1$$

- Pro dostatečně malé kladné γ platí vždy

Konvergence Ojova algoritmu učení (6)

a) délka vektoru \vec{w} je menší než **1**

(analogicky k a))

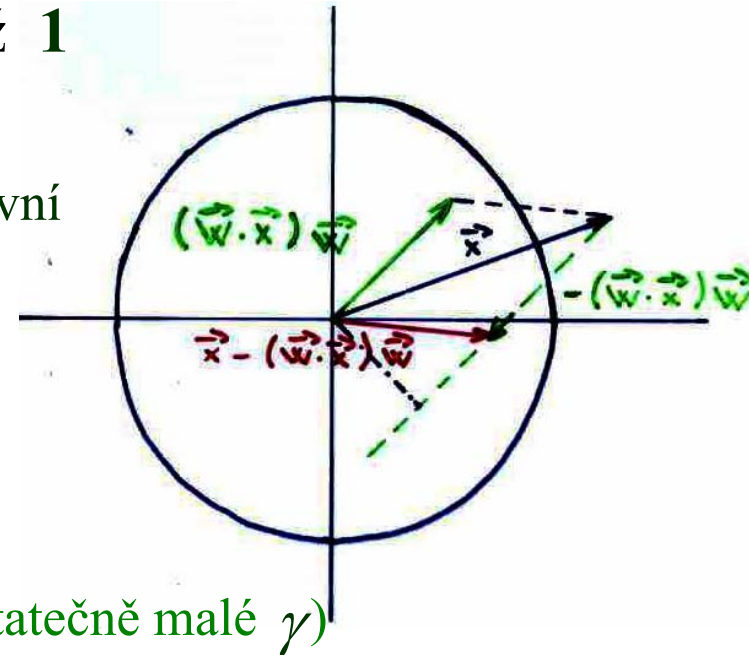
→ vektor $\vec{x} - (\vec{x} \cdot \vec{w})\vec{w}$ má pozitivní projekci na \vec{w}

→ zvětšování \vec{w}

□ Kombinace a) a b) $\Rightarrow \vec{w}$ se dostane do centra shluku a délka

bude oscilovat kolem 1 (pro dostatečně malé γ)

□ problémy:
„řidké“ shluky



Ojův algoritmus učení: problémy a zobecnění

Problémy: -) „řidké“ shluky

-) příliš velké rozdíly v délce vstupních vektorů

Výpočet většího počtu
nejdůležitějších příznaků:

