

# SAMOORGANIZUJÚCE SA NEURÓNOVÉ SIETE

## Metóda hlavných komponentov

Igor Farkaš

### 1 Samoorganizácia

Pod samoorganizáciou rozumieme proces učenia sa neurónovej siete v závislosti od prostredia, bez pomoci učiteľa. Možno povedať, že modelovanie samoorganizujúcich sa neurónových sietí (SONS) podstatne viac pripomína princípy neurobiologických štruktúr, než je to v prípade modelov umelých NS učiacich sa s učiteľom. Je to preto, lebo proces samoorganizácie je fundamentálnym javom v organizácii mozgu. Pravdepodobne sa uplatňuje na rôznych úrovniach spracovania informácie, počnúc percepčnými subsystémami a končiac kortikálnymi oblastami, ktoré spracovávajú komplexné informácie.

Samoorganizácia umožňuje **adaptívlosť** neurónovej siete. Vďaka nej nemusí byť siet úplne geneticky predurčená, ale jej funkcia sa môže prispôsobiť, napr. v prípade percepčných subsystémov, podľa aktuálneho prostredia.

Samoorganizujúca sa neurónová siet môže mať rôzne **architektúry**:

- (a) vstupnú a výstupnú vrstvu neurónov, s doprednými prepojeniami (váhami) medzi vrstvami,
- (b) ako v prípade a) plus laterálne prepojenia medzi neurónmi vo výstupnej vrstve,
- (c) viacvrstvovú architektúru s doprednými prepojeniami medzi susednými vrstvami neurónov.

Vo všetkých prípadoch učenie spočíva v iteratívnej modifikácii všetkých parametrov siete (váh) v závislosti od predkladaných vstupov, až kým siet nenaobudne nejakú užitočnú finálnu konfiguráciu. Odpoved', prečo taká finálna konfigurácia môže vzniknúť, možno nájsť v pozorovaní, ktoré sa vzťahuje na mozog ako aj na umelé NS (Turing, 1952):

*Globálny poriadok môže vzniknúť z lokálnych interakcií.*

Inými slovami, súčinnosť' mnohých lokálnych, spočiatku náhodných interakcií medzi susednými neurónmi môže viest' ku **koherentnému správaniu** celej siete, čo je podstatnou črtou samoorganizácie.

Organizácia v NS sa odohráva na dvoch úrovniach, ktoré interagujú pomocou spätnej väzby:

- (a) úroveň aktivít neurónov – generovanie odpovedí siete na základe vstupných podnetov,
- (b) úroveň konektivity – modifikácia váh siete v závislosti od aktivít neurónov.

Aby sa dosiahla samoorganizácia, spätná väzba medzi zmenami váh a zmenami aktivít neurónov musí byť **kladná**.

#### 1.1 Základné princípy samoorganizácie

V SONS možno pozorovať nasledujúce fenomény (von der Malsburg, 1990):

1. modifikácie váh majú tendenciu samozosilnenia,
2. obmedzenie zdrojov NS vedie k "súpereniu" medzi váhami, čo vyvoláva posilňovanie niektorých váh a utlmovanie ostatných (vďaka **synaptickej plasticite**), čím sa zabezpečuje stabilita systému,
3. modifikácie susedných váh majú tendenciu spolupracovať.

Uvedené 3 princípy sa vzťahujú na samotnú NS. Aby však SONS bola schopná naučiť sa nejaké užitočné vstupno-výstupné zobrazenie, je nutné, aby vstupné dátá predkladané sieti boli **redundantné** (Barlow, 1989). V terminológii teórie informácie to možno vyjadriť tak, že informačný obsah

vstupných kanálov musí byť menší než ich prenosová kapacita, rozdiel týchto dvoch veličín predstavuje redundanciu.

## 1.2 Využitie samoorganizujúcich sa neurónových sietí

Z pohľadu učenia majú SONS oproti modelom učiacim sa s učiteľom značnú výhodu v tom, že sa lepšie umožňujú zvládnut' **problém škálovania** (nárast času trénovalia pri zvyšovaní počtu parametrov siete). Je to vďaka tomu, že učiace pravidlá pre SONS majú jednoduchý tvar a zväčša **lokálny** charakter. V prípade viacvrstvových modelov SONS je možné učiť jednotlivé vrstvy nie naraz (ako napr. v back-propagation), ale postupne jednu za druhou.

SONS možno použiť v podstate na riešenie týchto typov úloh:

- PCA – nájdenie tendencií (hlavných smerov) v dátach, t.j. optimálne lineárne kódovanie vzhľadom na strednú kvadratickú chybu rekonštrukcie,
- klastrovanie dát – zatriedenie do kategórií (vektorová kvantizácia),
- topologické zobrazenie príznakov vstupných dát,
- kódovanie dát s maximálnym prenosom informácie na výstup (minimálna redundancia výstupnej reprezentácie).

Použitie SONS sa obyčajne sprevádzané **redukciou dimenzie** vstupných dát, ktorá súvisí s **extrakciou príznakov**.

## 2 Metóda hlavných komponentov

Metóda hlavných komponentov (Principal Component Analysis - PCA) je zrejme najstaršou (Pearson, 1901) a najznámejšou metódou používanou v multivariačnej analýze. Umožňuje efektívne transformovať dátu zo (viacrozmerného) vstupného priestoru do tzv. priestoru **príznakov** s nižšou dimensiou, čím sa dátu premietnu do najdôležitejších lineárnych smerov a tie najmenej podstatné sa zanedbajú. PCA je teda sprevádzaná dvoma atribútmi dôležitými pri analýze dát – **extrakciou príznakov** a **redukciou dimenzie** dát.

Majme  $n$ -rozmerný náhodný vektor  $\mathbf{x}$ , ktorý popisuje vstupné dátum. Predpokladáme, že množina vstupných dát nulovú strednú hodnotu, t.j.

$$\langle \mathbf{x} \rangle = 0 .$$

Nech  $\mathbf{u}$  označuje jednotkový vektor,  $\|\mathbf{u}\| = (\mathbf{u}^T \mathbf{u})^{1/2} = 1$ , tiež dimenzie  $n$ , na ktorý premietneme vektor  $\mathbf{x}$ . Táto projekcia je definovaná ako

$$a = \mathbf{x}^T \mathbf{u} = \mathbf{u}^T \mathbf{x} .$$

Projekcia  $a$  (súradnica v 1D priestore generovaného vektorom  $\mathbf{u}$ ) je náhodná premenná so strednou hodnotou a varianciou, ktoré závisia od štatistiky vektora  $\mathbf{x}$ . Keďže  $\langle \mathbf{x} \rangle = 0$ , potom

$$\langle a \rangle = \mathbf{u}^T \langle \mathbf{x} \rangle = 0 .$$

Variancia  $a$  je potom

$$\sigma^2 = \langle a^2 \rangle = \langle (\mathbf{u}^T \mathbf{x})(\mathbf{x}^T \mathbf{u}) \rangle = \mathbf{u}^T \langle \mathbf{x} \mathbf{x}^T \rangle \mathbf{u} = \mathbf{u}^T \mathbf{R} \mathbf{u} , \quad (1)$$

kde  $\mathbf{R}[n \times n]$  je **korelačná matica** vstupných dát. Je vidieť, že  $\mathbf{R}$  je symetrická, t.j.  $\mathbf{R}^T = \mathbf{R}$ . Z tejto vlastnosti vyplýva, že ak máme nejaké  $n$ -rozmerné vektory  $\mathbf{a}$  a  $\mathbf{b}$ , potom

$$\mathbf{a}^T \mathbf{R} \mathbf{b} = \mathbf{b}^T \mathbf{R} \mathbf{a} . \quad (2)$$

Z rovnice (1) je vidieť, že variacia projekcie  $\sigma^2$  je funkciou jednotkového vektora  $\mathbf{u}$ , čo matematicky vyjadríme vzťahom

$$\sigma^2 = \psi(\mathbf{u}) = \mathbf{u}^T \mathbf{R} \mathbf{u} . \quad (3)$$

## 2.1 Štruktúra vlastných hodnôt PCA

Budeme hľadať taký smer  $\mathbf{u}$ , v ktorom funkcia  $\psi(\mathbf{u})$  nadobúda extrém. Ako uvidíme, riešenie tohto optimalizačného problému závisí od štruktúry vlastných hodnôt korelačnej matice  $\mathbf{R}$ . Ak  $\mathbf{u}$  je taký 1-ový vektor,  $\psi(\mathbf{u})$  nadobúda extrém, potom pre ľubovoľnú malú perturbáciu  $\delta\mathbf{u}$  podľa Taylorovho rozvoja zanedbaním členov vyšších rádov dostaneme

$$\psi(\mathbf{u} + \delta\mathbf{u}) = \psi(\mathbf{u}) . \quad (4)$$

Potom podľa (3)

$$\psi(\mathbf{u} + \delta\mathbf{u}) = (\mathbf{u} + \delta\mathbf{u})^T \mathbf{R} (\mathbf{u} + \delta\mathbf{u}) = \mathbf{u}^T \mathbf{R} \mathbf{u} + 2(\delta\mathbf{u})^T \mathbf{R} \mathbf{u} + (\delta\mathbf{u})^T \mathbf{R} \delta\mathbf{u} .$$

Ak zanedbáme člen druhého rádu, využitím rovnosti (4) dostaneme podmienku

$$(\delta\mathbf{u})^T \mathbf{R} \mathbf{u} = 0 . \quad (5)$$

Súčasne musí platiť, že  $\|\mathbf{u} + \delta\mathbf{u}\| = 1$ , čo môžeme ekvivalentne zapísat' ako  $(\mathbf{u} + \delta\mathbf{u})^T (\mathbf{u} + \delta\mathbf{u}) = 1$ , odkiaľ po rozpísaní, a po zanedbaní člena druhého rádu máme

$$(\delta\mathbf{u})^T \mathbf{u} = 0 . \quad (6)$$

Z toho vyplýva, že perturbácie  $\delta\mathbf{u}$  musia byť kolmé na  $\mathbf{u}$ .

Kedže elementy 1-ého vektora sú fyzikálne bezrozmerné, tak ak chceme skombinovať rovnice (5) a (6), musíme k druhému členu pridať škálovaciu konštantu  $\lambda$  s takými rozmermi, aké majú prvky matice  $\mathbf{R}$ . Potom môžeme písat'

$$(\delta\mathbf{u})^T \mathbf{R} \mathbf{u} - \lambda(\delta\mathbf{u})^T \mathbf{u} = (\delta\mathbf{u})^T (\mathbf{R} \mathbf{u} - \lambda \mathbf{u}) = 0 .$$

Odtiaľ vyplýva, že musí platiť

$$\mathbf{R} \mathbf{u} = \lambda \mathbf{u} ,$$

čo je rovnica známa ako *problém vlastných hodnôt*, s ktorým sa často stretávame v lineárnej algebre. Pre  $\mathbf{u} \neq \mathbf{0}$  má tento problém netriviálne riešenia,  $\lambda$  sa nazývajú **vlastné čísla**, s nimi súvisiace vektory  $\mathbf{u}$  sú **vlastné vektory** korelačnej matice  $\mathbf{R}$ . Jej vlastné čísla majú nezáporné reálne hodnoty.

Označme vlastné čísla kovariančnej matice  $\mathbf{R}[n \times n]$  ako  $\lambda_1, \lambda_2, \dots, \lambda_n$  a vlastné vektory ako  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$ . Potom možno písat'

$$\mathbf{R} \mathbf{u}_j = \lambda \mathbf{u}_j , \quad j = 1, 2, \dots, n . \quad (7)$$

Nech sú vlastné čísla usporiadane zostupne, t.j.  $\lambda_1 > \lambda_2 > \dots > \lambda_n$ , čiže  $\lambda_1 = \lambda_{max}$ . Skonštruujme maticu  $\mathbf{U}$  ako

$$\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n] .$$

Potom možno (7) prepísat' do maticového tvaru

$$\mathbf{R} \mathbf{U} = \mathbf{U} \Lambda , \quad (8)$$

kde  $\Lambda$  je diagonálna matica  $\Lambda = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_n]$ .  $\mathbf{U}$  je *ortogonálna matica*, lebo jej stĺpce sú navzájom ortonormálne:

$$\mathbf{u}_i^T \mathbf{u}_j = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases}$$

Ekvivalentným zápisom je  $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ , odkiaľ je zrejmé, že  $\mathbf{U}^T = \mathbf{U}^{-1}$ . Využitím tejto vlastnosti možno (8) prepísat' do tvaru

$$\mathbf{U}^T \mathbf{R} \mathbf{U} = \mathbf{\Lambda}$$

resp. v rozpisom tvare

$$\mathbf{u}_i^T \mathbf{R} \mathbf{u}_j = \begin{cases} \lambda_j, & j = i \\ 0, & j \neq i \end{cases}, \quad (9)$$

odkiaľ je vidieť, že

$$\psi(\mathbf{u}_j) = \lambda_j, \quad j = 1, 2, \dots, n$$

Vyššie odvodené vztahy možno teda zosumarizovať v dvoch bodoch:

- Vlastné vektory korelačnej matice centrovaných dát sú reprezentované 1-vými vektormi  $\mathbf{u}_j$ , predstavujúcimi hlavné smery, v ktorých variancia  $\psi(\mathbf{u}_j)$  nadobúda extrém.
- Asociované vlastné čísla definujú extrémy variancií  $\psi(\mathbf{u}_j)$ .

## 2.2 Základné reprezentácie dát

Pre  $n$  rôznych vlastných vektorov  $\mathbf{u}_j$  dostávame  $n$  rôznych projekcií vstupného vektora

$$a_j = \mathbf{u}_j^T \mathbf{x} = \mathbf{x}^T \mathbf{u}_j, \quad j = 1, 2, \dots, n$$

ktoré budeme nazývať **hlavnými komponentami**; majú tie isté fyzikálne rozmery ako vstupný vektor  $\mathbf{x}$ . Tento krok označujeme ako *analýza*.

Pri rekonštrukcii pôvodného vektora  $\mathbf{x}$  z projekcií  $a_j$  postupujeme tak, že skombinujeme projekcie  $a_j$  do vektora  $\mathbf{a} = [a_1, a_2, \dots, a_n]^T$  a potom možno písat'

$$\mathbf{a} = [\mathbf{u}_1^T \mathbf{x}, \mathbf{u}_2^T \mathbf{x}, \dots, \mathbf{u}_n^T \mathbf{x}]^T = \mathbf{U}^T \mathbf{x}.$$

Vynásobením oboch strán rovnice maticou  $\mathbf{U}$  zľava dostaneme vztah pre rekonštrukciu

$$\mathbf{x} = \mathbf{U} \mathbf{a} = \sum_{j=1}^n a_j \mathbf{u}_j, \quad (10)$$

ktorý možno chápať ako *syntéza*. V tomto zmysle vektory predstavujú *bázu* priestoru dát. Ide teda transformáciu súradníc, podľa ktorej sa bod  $\mathbf{x}$  vo vstupnom priestore transformuje na bod  $\mathbf{a}$  v priestore *príznakov*.

## 2.3 Redukcia dimenzie

Redukcia dimenzie dát má z pohľadu štatistického rozpoznávania veľký význam. Umožní nám redukovať počet príznakov (súradníc) potrebných na efektívny popis dát. Takto môžeme napr. ignorovať smery, v ktorých majú dáta len malú varianciu (rozlíšiteľnosť) a všímať si len tie s veľkou varianciou (Oja, 1983).

Nech  $\lambda_1, \lambda_2, \dots, \lambda_p$  označujú  $p$  najväčších vlastných čísel korelačnej matice  $\mathbf{R}$ . Rekonštrukciu vektora  $\mathbf{x}$  potom možno aproximovať ako

$$\mathbf{x}' = \mathbf{U} \mathbf{a}' = \sum_{j=1}^p a_j \mathbf{u}_j, \quad p < n \quad (11)$$

Chybu approximácie možno potom vyjadriť ako

$$\mathbf{e} = \mathbf{x} - \mathbf{x}' = \sum_{j=p+1}^n a_j \mathbf{u}_j .$$

Jednoducho sa dá ukázať, že chybový vektor  $\mathbf{e}$  je kolmý na approximáciu  $\mathbf{x}'$ :

$$\mathbf{e}^T \mathbf{x}' = \sum_{i=p+1}^n a_i \mathbf{u}_i \sum_{j=1}^p a_j \mathbf{u}_j = \sum_{i=p+1}^n \sum_{j=1}^p a_i a_j \mathbf{u}_i^T \mathbf{u}_j = 0 .$$

Celkovú varianciu  $p$  komponentov náhodného vektora  $\mathbf{x}$  možno podľa (3) a podľa prvého riadku (9) vyjadriť ako

$$\sum_{j=1}^n \sigma_j^2 = \sum_{j=1}^n \lambda_j ,$$

kde  $\sigma_j^2$  je variancia  $j$ -tej hlavného komponentu  $a_j$ . Analogicky, celková variancia  $m$  elementov approximácie  $\mathbf{x}'$  je rovná

$$\sum_{j=1}^m \sigma_j^2 = \sum_{j=1}^m \lambda_j .$$

$\lambda_{p+1}, \dots, \lambda_p$  je  $n - p - 1$  najmenších vlastných čísel maticy  $\mathbf{R}$ . Odpovedajú členom eliminovaným v approximácii (11). Čím sú tieto vlastné čísla menšie, tým efektívnejšia je redukcia dimenzie z pohľadu množstva zachovanej informácie o vstupných dátach.

Aby sme teda redukovali dimenziu dát pomocou PCA, potrebujeme *vypočítať vlastné čísla a vlastné vektory ich korelačnej maticy, a potom urobiť ortogonálnu projekciu do podpriestoru generovaného vlastnými vektormi odpovedajúcimi najväčším vlastným číslam*. Táto reprezentácia dát patrí do triedy metód označovaných ako *dekompozícia podpriestoru* (Oja, 1983).

### 3 Hebbovo učenie - jeden lineárny neurón

Kanadský psychológ Donald Hebb postuloval pravidlo modifikácie váh vo svojej priekopníckej knihe *The Organization of Behavior* (1949) nasledovne:

Ked' axón bunky A je dostatočne blízko, aby excitoval bunku B a opakovane sa podielala na vyvolaní jej výstupnej aktivity, potom by aspoň v jednej z týchto dvoch buniek mal prebehnúť proces rastu alebo nejaké metabolické zmeny, aby sa zvýšila efektivita bunky A pri vyvolávaní aktivity bunky B.

V analytickom vyjadrení to znamená, že spojenie (synapsa)  $w_{ba}$  vedúce z bunky  $a$  do bunky  $b$  sa má modifikovať podľa vzťahu  $dw_{ba}/dt = \alpha y_a y_b$ , kde  $y_a$  je presynaptická aktivita,  $y_b$  postsynaptická aktivita a  $\alpha$  udáva veľkosť kroku adaptácie.

Uvažujme najprv, že máme jeden lineárny neurón s  $n$  vstupmi, ktorého výstup sa počíta ako

$$y = \sum_{j=1}^n w_j x_j = \mathbf{w}^T \mathbf{x} .$$

Ak by sme priamo uplatnili Hebbov postulát, pravidlo učenia by malo tvar

$$w_j(t+1) = w_j(t) + \alpha y(t)x_j(t) \quad j = 1, 2, \dots, n$$

kde parameter  $\alpha$  je rýchlosť učenia. Je však zrejmé, pri takejto adaptácii by váhy divergovali do nekonečna, čo je fyzikálne neprípustné. Priamym riešením tohto problému je explicitná normalizácia váh po každom kroku (Oja, 1982)

$$w_j(t+1) = \frac{w_j(t) + \alpha y(t)x_j(t)}{(\sum_{j=1}^n [w_j(t) + \alpha y(t)x_j(t)]^2)^{1/2}} ,$$

ktorá vnáša do algoritmu súperenie váh o limitované zdroje (2. princíp samoorganizácie). Za predpokladu, že  $\alpha$  je malé, možno vzťah prepísat pomocou rozvoja ako

$$w_j(t+1) = w_j(t) + \alpha y(t)[x_j(t) - y(t)w_j(t)] + O(\alpha^2) ,$$

kde  $O(\alpha^2)$  v sebe zahŕňa členy druhého a vyšších rádov. Pre malé  $\alpha$  možno tento člen zanedbať, čím dostávame pravidlo učenia (Oja, 1982)

$$w_j(t+1) = w_i(t) + \alpha y(t)[x_j(t) - y(t)w_j(t)] = w_j(t) + \alpha y(t)x_j(t) - \alpha y^2(n)w_j(t) , \quad (12)$$

kde prostredný člen predstavuje Hebbov člen (1. princíp samoorganizácie) a posledný je stabilizačný člen. Je vidieť, že tvar učiaceho pravidla (12) je z pohľadu vstup-výstup opačný k delta pravidlu. Ak urobíme substitúciu

$$x'_j(t) = x_j(t) - y(t)w_j(t) ,$$

kde  $x'_j$  možno interpretovať ako efektívny vstup  $j$ -tej synapsy, potom

$$w_j(t+1) = w_j(t) + \alpha y(t)x'_j(t) ,$$

čo je vzťah podobný pôvodnému tvaru modifikácie, avšak tu už vo vstupe  $x'_j$  je skrytá kombinácia kladnej a zápornej spätej väzby.

### 3.1 Správanie modelu

O lineárnom neuróne s učiacim pravidlom podľa 12 možno vyslovit nasledovné tvrdenia (ak  $\langle \mathbf{x} \rangle = 0$ ):

- váhový vektor  $\mathbf{w}$  konverguje do smeru, ktorý je vlastným vektorom korelačnej matice vstupov  $\mathbf{C} = \langle \mathbf{x}\mathbf{x}^T \rangle$ .

Ak uvažujeme, že po ustálení je stredná hodnota zmien váhových zložiek nulová, môžeme písat  $0 = \langle \Delta w_j \rangle = \langle y(x_j - yw_j) \rangle = \langle \sum_k w_k x_k (x_j - \sum_k w_k x_k w_j) \rangle = \langle \sum_k w_k x_k x_j - \sum_{kl} w_k x_k w_l x_l w_j \rangle = \sum_k c_{jk} w_k - (\sum_{kl} w_k c_{kl} w_l) w_j$ , kde  $c_{jk} = \langle x_j x_k \rangle$  a  $c_{kl} = \langle x_k x_l \rangle$  sú kovariančné koeficienty matice  $\mathbf{C}$ . Vo vektorovom zápise  $\mathbf{0} = \langle \Delta \mathbf{w} \rangle = \mathbf{C}\mathbf{w} - (\mathbf{w}^T \mathbf{C}\mathbf{w})\mathbf{w} \implies \mathbf{C}\mathbf{w} = \lambda \mathbf{w}$ .

- váhový vektor  $\mathbf{w}$  po konvergencii maximalizuje  $\langle y^2 \rangle$ .

Táto vlastnosť je dôsledkom vlastnosti 1:  $\langle y^2 \rangle = \langle (\mathbf{w}^T \mathbf{x})^2 \rangle = \langle \mathbf{w}^T \mathbf{x} \mathbf{x}^T \mathbf{w} \rangle = \mathbf{w}^T \mathbf{C} \mathbf{w}$ , a kvadratická norma  $\mathbf{w}^T \mathbf{C} \mathbf{w}$  nadobúda maximálnu hodnotu  $\iff \mathbf{w}$  leží v smere jej hlavného vlastného vektora.

- po konvergencii norma  $\|\mathbf{w}\| = 1$ .

Z odvodenia pri vlastnosti 1 vyplýva, že  $\lambda = \mathbf{w}^T \mathbf{C} \mathbf{w} = \mathbf{w}^T \lambda \mathbf{w} = \lambda \|\mathbf{w}\|^2 \implies \|\mathbf{w}\| = 1$ .

Možno teda povedať, že lineárny neurón s pravidlom učenia 12 má tendenciú maximalizovať strednú hodnotu kvadrátu výstupu. Pri dátach s nulovou strednou hodnotou tým súčasne dochádza k nájdeniu hlavného komponentu kovariančnej matice vstupných dát.

## 4 Algoritmus GHA

Uvažujme, že máme NS s  $n$  vstupmi a  $p$  výstupmi, pričom  $p < n$ . Nech váha  $w_{ij}$  označuje spojenie  $i$ -teho neurónu s  $j$ -tym vstupom. Pravidlo učenia GHA (Generalized Hebbian Algorithm) navrhnuté Sangerom (1989) má tvar

$$\Delta w_{ij} = \alpha y_i (x_j - \sum_{k=1}^i y_k w_{kj}) \quad \text{pre } i = 1, 2, \dots, p. \quad (13)$$

O tomto pravidle učenia bolo dokázané, že extrahuje  $p$  hlavných komponentov korelačnej matice vstupov. Môže to byť zrejmejšie, keď si pravidlo prepíšeme do tvaru

$$\Delta w_{ij} = \alpha y_i (x'_j - y_i w_{ij}), \quad \text{kde } x'_j = x_j - \sum_{k=1}^{i-1} y_k w_{kj}.$$

Vo vektorovom zápise

$$\Delta \mathbf{w}_i = \alpha y_i (\mathbf{x}' - y_i \mathbf{w}_i) \quad \text{pričom } \mathbf{x}' = \mathbf{x} - \sum_{k=1}^{i-1} y_k \mathbf{w}_k.$$

Pri tomto tvari je vidieť podobnosť s pravidlom pre jeden Ojov neurón, pričom  $\mathbf{x}'$  tu vystupuje ako modifikovaný vstupný vektor. Z pohľadu výstupných neurónov vyzerá teraz situácia nasledovne: Pre neurón 1 je  $\mathbf{x}' = \mathbf{x}$ , t.j. má tendenciu premietat' vstupy do smeru hlavného komponentu. Pre neurón 2 je  $\mathbf{x}' = \mathbf{x} - y_1 \mathbf{w}_1$ , čo znamená, že tento neurón "vidí" vstup, od ktorého bola odpočítaná zložka odpovedajúca hlavnému vlastnému vektoru, preto premieta do smeru druhej hlavnej zložky, atď.

Výhody oproti štandardnej metóde PCA:

- (1) nie je explicitne nutné vopred počítať korelačnú maticu,
- (2) je výpočtovo menej náročný najmä v prípadoch, keď  $p \ll n$ .

Vlastnosti algoritmu:

- (a) nájde hlavné komponenty,
- (b) tie sú usporiadane podľa veľkosti (variancie výstupov v jednotlivých ortogonálnych smeroch),
- (c) výsledky sú reprodukovateľné (až na znamienko),
- (d) vhodná aplikácia: kódovanie dát, kompresia.

### 4.1 Ojova verzia algoritmu

V aplikáciách, kde nie je nutné extrahovať samotné hlavné komponenty, ale stačí nájsť **hlavný podpriestor** (podpriestor generovaný hlavnými komponentami), možno použiť Ojovu verziu učiaceho pravidla v tvari

$$\Delta w_{ij} = \alpha y_i (x_j - \sum_{k=1}^p y_k w_{kj}) \quad \text{pre } i = 1, 2, \dots, p. \quad (14)$$

Vlastnosti algoritmu:

- (a) algoritmus nenájde hlavné komponenty, len podpriestor nimi generovaný,
- (b) výstupy nie sú usporiadane, variancia jednotlivých zložiek na výstupe je približne rovnaká,
- (c) výsledky nie sú reprodukovateľné, závisia od počiatočných podmienok a od poradia predkladania vstupov,
- (d) vhodná aplikácia v prípadoch, ak sa požaduje rovnomerne distribuovaná reprezentácia.

## 5 Algoritmus APEX

Kung & Diamantaras (1990) navrhli iný model na výpočet hlavných komponentov – algoritmus APEX (Adaptive Principal Component Extraction). Okrem dopredných spojení tu existujú i laterálne spojenia medzi výstupnými neurónmi, a to ku každému neurónu od ostatných neurónov s nižším indexovým číslom, t.j.  $i$ -ty neurón má laterálny váhový vektor

$$\mathbf{u}_i = [u_{i1}, u_{i2}, \dots, u_{i,i-1}]^T$$

a jeho výstup sa počíta podľa vzťahu

$$y_i = \mathbf{w}_i^T \mathbf{x} + \mathbf{u}_i^T \mathbf{y}_{i-1}$$

kde výstupný vektor  $\mathbf{y}_{i-1} = [y_1, y_2, \dots, y_{i-1}]^T$ . Dopredné váhy sa modifikujú podľa Sangerovho pravidla 13, a laterálne váhy podľa anti-Hebbovho pravidla (majú inhibičný účinok)

$$\Delta u_{ik} = -\alpha y_i(y_k + y_i u_{ik}) \quad (15)$$

O algoritme APEX bolo dokázané, že váhové vektory  $\mathbf{w}_i$  po poradí konvergujú do smerov vlastných vektorov korelačnej matice vstupov, zatiaľ čo laterálne váhové vektory  $\mathbf{u}_i$  konvergujú k nulovým vektorom. Na rozdiel od (takmer) simultánnej konvergencie váh v algoritme GHA, tu konvergujú váhové vektory postupne.

Bolo navrhnutých viacero neuronálnych algoritmov na výpočet PCA. Možno ich rozdeliť do dvoch skupín (Becker & Plumbe, 1993):

- (a) **reestimačné algoritmy** (napr. GHA), v ktorých existujú len dopredné spojenia, a ktoré sa učia pomocou nejakej verzie Hebbovho pravidla, a
- (b) **dekorelačné algoritmy** (napr. APEX), v ktorých existujú aj laterálne spojenia, modifikované pomocou nejakej verzie anti-Hebbovho pravidla.

PCA možno realizovať i pomocou autoasociácie pri použití NS typu  $n-p-n$  a učenia pomocou BP. V takom prípade k PCA reprezentácii dochádza na neurónoch v skrytej vrstve (Baldi & Hornik, 1989).

## 6 Použitie PCA algoritmov

PCA je vhodné použiť na predspracovanie dát, ktoré majú zhruba Gaussovské rozdelenie. Sprievodnými znakmi predspracovania pomocou PCA sú: (1) dekorelovanie vstupov, (2) zníženie dimenzie dát a (3) extrakcia lineárnych príznakov (hlavných komponentov). Napr. pri takto transformovaných dátach možno dosiahnuť podstatne rýchlejsiu konvergenciu BP vdľa dekorelovanosti súradníc vstupov.

Linsker (1988) ukázal, že PCA je ekvivalentná maximalizácii výstupnej informácie v prípade Gaussovského rozdelenia dát. I z toho vyplýva nevhodnosť predspracovania dát pomocou PCA, ak tie majú výrazne negaussovskú distribúciu, napr. pozostávajú zo zhľukov alebo v nich existujú bezvýznamné mimo ležiace prvky (outliers).

## Literatúra

- Haykin S. (1994). *Neural Networks: A Comprehensive Foundation*. Macmillan College, New York.  
Hertz J., Krogh A. & Palmer R.G. (1991). *Introduction to the Theory of Neural Computation*. Addison-Wesley, Redwood City, CA.