



Radial Basis Function (RBF) siete

Príklady RBF

- Gaussova:

$$\varphi(r) = e^{-(\varepsilon \cdot r)^2}$$

- Multikvadratická:

$$\phi(r) = \sqrt{1 + (\varepsilon \cdot r)^2}$$

- Inverzná kvadratická:

$$\phi(r) = \frac{1}{1 + (\varepsilon \cdot r)^2}$$

$$r = \|x - x_i\|$$

Definícia:

- Funkcia je radial symetrická (alebo je RBF), ak jej výstup závisí od vzdialenosti medzi vstupným vektorom a vektorom zapamätaným v tejto funkcii
 - Napríklad,

Vzdialenosť $r = \|x - x_i\|$ kde x je vstupný vektor, x_i je vektor asociovaný s RBF

- Pre výstup platí

$$\phi(r_1) \geq \phi(r_2), \text{ ak } r_1 < r_2$$

Príklady RBF

- Inverzná multikvadratická: $\phi(r) = \frac{1}{\sqrt{1 + (\varepsilon \cdot r)^2}}$

- Polyharmonický spline:

$$\phi(r) = r^k, k = 1, 3, 5, \dots$$

$$\phi(r) = r^k \ln r, k = 2, 4, 6, \dots$$

- Tenký spline (špeciálny polyharmonický spline):

$$\phi(r) = r^2 \ln r$$

Vlastnosti Gaussovej funkcie

$$\varphi(r) = e^{-(\varepsilon \cdot r)^2}$$


$$r = \|x - x_i\|$$

- **V 1-rozmernom priestore**
- Symetrická funkcia s centrom (so stredom) v x_i
- r nadobúda rovnaké hodnoty pre body rovnako vzdialené od centra

Gaussova RBF



- Gaussova RBF monotónne klesá vzdialenosťou od centra
- Gaussove RBF sú lokálne (najväčšie odozvy dávajú v okolí centra)
- sú vo všeobecnosti najviac používané

$$\phi(x) = \frac{1}{e^{(\varepsilon \cdot x)^2}}$$





Vlastnosti Gaussovej funkcie

- V 3-rozmernom priestore




Motivácia: XOR funkcia

XOR



x	$\rho_1(x)$	$\rho_2(x)$
(1, 1)	1	0.1353
(0, 1)	0.3678	0.3678
(0, 0)	0.1353	1
(1, 0)	0.3678	0.3678





Radial Basis Function siete

RBF sieť je neurónová sieť navrhnutá tak, aby riešila problém hľadania čo najlepšej krivky - aproximačný problém vo vysoko dimenzionálnom priestore

Učenie je ekvivalentné hľadaniu takej funkcie viacerých premenných, ktorá sa najlepšie zhoduje s tréningovými dátami

Neurónové siete s Radial Basis Funkciami

Lepšia výkonnosť než u sigmoidálnych funkcií

- Niektoré klasifikačné problémy
- Interpolácia funkcií

■ Ešte raz definícia:

- Funkcia je radial symetrická (alebo je RBF), ak jej výstup závisí od vzdialenosti medzi vstupným vektorom a vektorom zapamätaným v tejto funkcii

- Vzdialenosť $r = \|x - x_i\|$ kde x je vstupný vektor, x_i je vektor asociovaný s RBF

- Výstup

$$\phi(r_1) \geq \phi(r_2), \text{ ak } r_1 < r_2$$

Neurónové siete s Radial Basis Funkciami

XOR problém

□ 2-2-1 sieť


- 2 skryté neuróny sú RBF
- Výstupný neurón môže byť sign alebo sigmoidálny
-

$$\rho_1(x) = e^{-\|x-t_1\|^2}, t_1 = [1,1]$$
$$\rho_2(x) = e^{-\|x-t_2\|^2}, t_2 = [0,0]$$


- Ak je na vstupe x :
- Skryté neuróny vypočítajú vzdialenosti a potom je vypočítaný výstup

$$\|x-t_j\|$$

- Všetky váhy do skrytých neurónov sú nastavené na 1
- Váhy do výstupného neurónu sú trénované metódou Least Mean Squared Errors
- t_1 a t_2 môžu byť tiež trénované




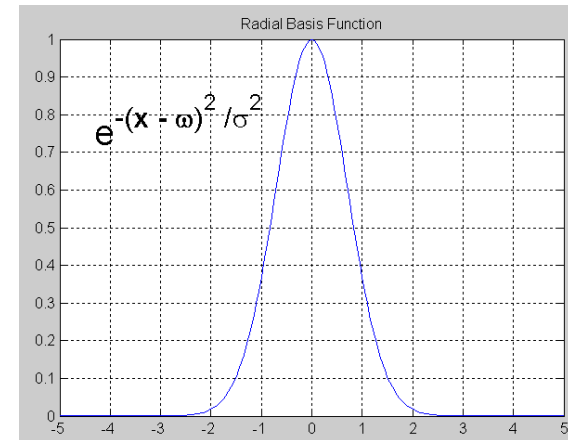
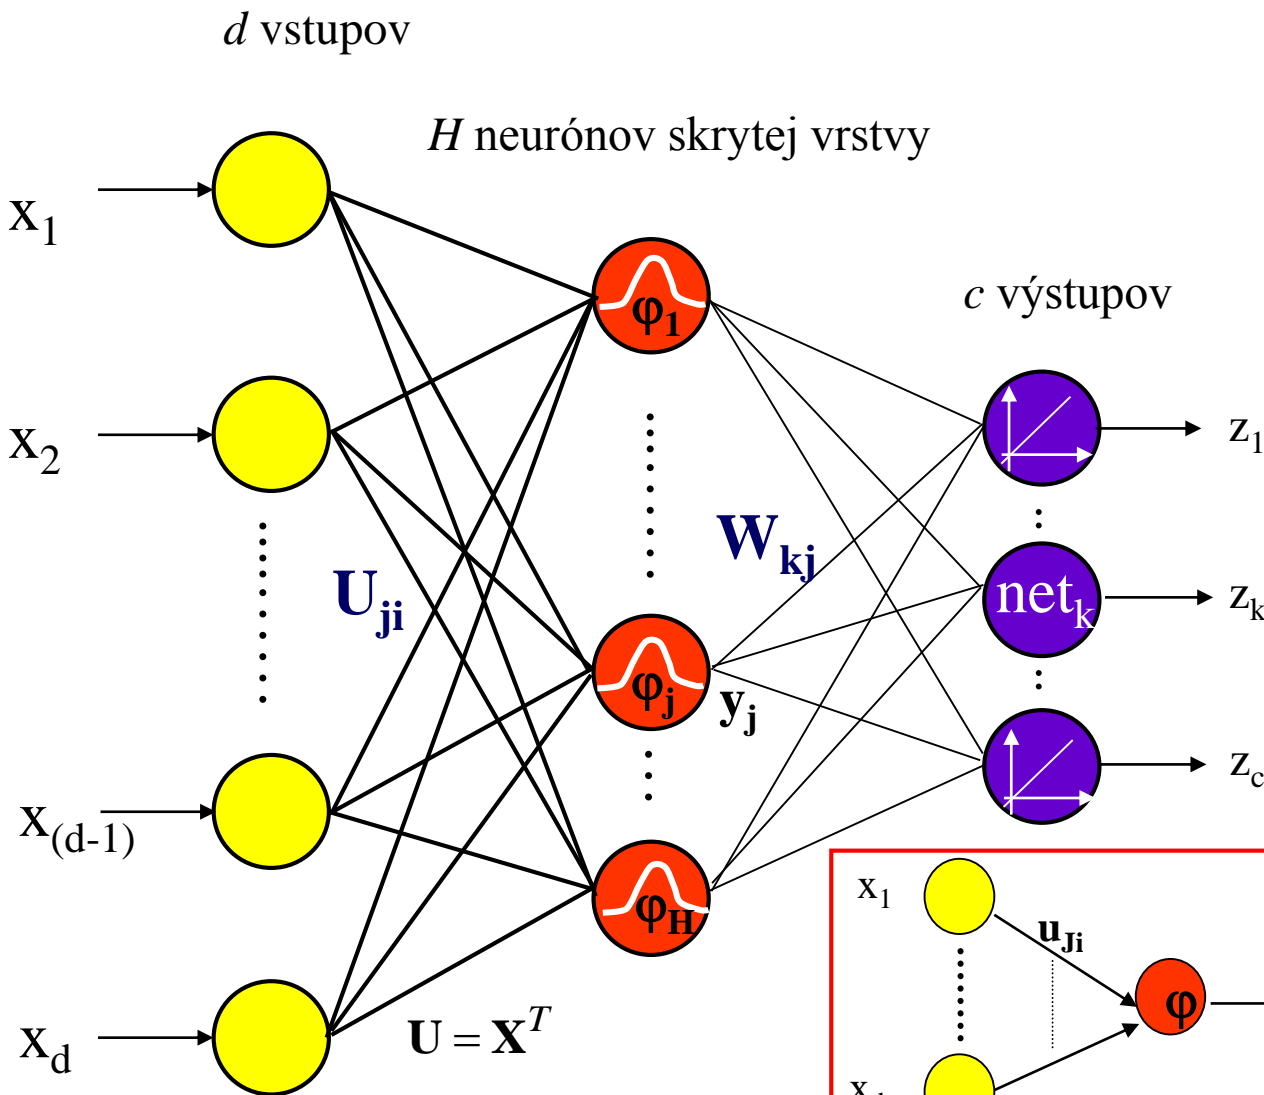
x	$\rho_1(x)$	$\rho_2(x)$
(1, 1)	1	0.1353
(0, 1)	0.3678	0.3678
(0, 0)	0.1353	1
(1, 0)	0.3678	0.3678



Popis RBF sietí

- Pozostáva z 3 vrstiev (vstupná, skrytá, výstupná)
- **Vstupná vrstva** je tvorená neurónmi, ktoré spájajú sieť s prostredím
- Na vstupe každého neurónu (skrytá vrstva), je vypočítaná vzdialenosť medzi centrom neurónu & vstupným vektorom
- Používa RBF (Gaussovú funkciu) na vytvorenie výstupu neurónov
- Výstupná vrstva je lineárna a vydáva odozvu siete na zadané vstupy
- Toto hovorí o veľkej popularite týchto sietí a sú hlavným konkurentom dopredných viacvrstvových sietí

RBF sieť - architektúra



Výstupná vrstva

- Výstupná vrstva vykonáva jednoduchú **váženú** sumu s lineárnym výstupom.
- Ak je RBF sieť používaná na aproximáciu funkcií (zhoda s reálnym číslom) potom výstup je veľmi dobrý.
- Avšak, ak je požadovaná klasifikácia vzorov, tak je potrebné použiť funkciu signum alebo tvrdé ohraničenie, aby bol dosiahnutý výstup 0/1.

Klastrovanie

- Jedinečným základným rysom RBF siete je proces vykonávaný v skrytej vrstve.
- Idea je taká, že vzorky vo vstupnom priestore tvoria klastre.
- Ak sú známe centrá klastrov, tak je možné merať vzdialenosti od centier.
- Ďalej, táto vzdialenosť je meraná nelineárne, takže keď vzorka je v oblasti klastra (blízko centra), tak dáva hodnotu blízku 1.
- Mimo tejto oblasti hodnota dramaticky klesá.
- Dôležité je, že táto oblasť je radiálne symetrická okolo klastrového centra, preto táto nelineárna funkcia sa stáva známou ako radial-basis funkcia.

Meranie vzdialenosti

- Obvykle Euklidova vzdialenosť.
- Pre každý neurón skrytej vrstvy váhy reprezentujú súradnice centra odpovedajúceho klastra.
- Preto pre vstup X , vzdialenosť od centra je určovaná pomocou vzťahu

$$r_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2}$$

Šírka funkcie v skrytých neurónoch

$$(skrytý_neurón)\varphi_j = \exp\left(-\frac{\sum_{i=1}^n (x_i - w_{ij})^2}{2\sigma^2}\right)$$

σ *definuje* šírku alebo radius zvona Gaussovej funkcie a niekedy je určovaná empiricky.

Ak vzdialenosť od centra Gaussovej funkcie dosiahne σ , výstup sa pohybuje v intervale 1 - 0.6.

Hľadanie šírky Gaussovej funkcie

- Keď máme centrá klastrov je možné určiť radius Gaussovej krivky.
- *Je to možné urobiť metódou P-najbližších susedov.*
- Počet P je možné zvoliť, a pre každé centrum je nájdených P najbližších susedov.

- Pre klaster c_j , máme:

$$\sigma_j = \sqrt{\frac{1}{P} \sum_{i=1}^P (c_k - c_i)^2}$$

- Typická hodnota pre P je 2.

Neurónové siete s RBF

- Vzorky klastrov

- Príliš mnoho skrytých neurónov, keď # vzoriek je príliš veľký
- Zgrupovanie podobných vzoriek spolu do N klastrov, každý s
 - Centrálnym vektorom x_i
 - Predpokladaným stredným výstupom φ_i

- Sieťovým výstupom
$$o = \frac{1}{N} \sum_{i=1}^N \varphi_i \rho(\|\mu_i - x\|)$$

- Predpokladajme, že vieme určiť N a vieme ako rozdeliť všetkých P vzoriek do klastrov (nie je to ľahká úloha), φ_i a μ_i môžu byť nastavené učením

Neurónové siete s Radial Basis Funkciami

- Učenie (trénovanie) RBF siete
 - Parametre učenia:

$$w_1 = \frac{\varphi_1}{N}, \dots, w_N = \frac{\varphi_N}{N}, \quad \mu_1, \dots, \mu_N$$

minimalizovať

$$E = \sum_{p=1}^P E_p = \sum_{p=1}^P (d_p - o_p)^2$$

- Metóda klesajúceho gradientu

$$\Delta w_i = \eta_i (d_p - o_p) \rho(\|x_p - \mu_i\|) \text{ and}$$

$$\Delta \mu_{i,j} = -\eta_{i,j} w_i (d_p - o_p) R'(\|x_p - \mu_i\|^2) (x_{p,j} - \mu_{i,j})$$

- Je možno určiť μ_i tiež inými klastrovacími technikami a až potom použiť metódu klesajúceho gradientu len pre váhy

Trénovanie skrytej vrstvy

- Skrytá vrstva v RBF sieti má neuróny, ktoré majú váhy odpovedajúce vektorovej reprezentácii centra klastra.
- Tieto váhy sú nájdené buď tradičnými klastrovacími metódami alebo sú adaptované pomocou základného Kohonenovho algoritmu.
- V oboch prípadoch je trénovanie bez dozoru, len počet k zvolených klastrov je nastavený dopredu. Algoritmus tak nájde k najlepších klastrov.
- **Algoritmus k –mean:**
- Na začiatku je zvolených k bodov (predbežných centier) v priestore náhodne.
- Potom sú nájdené vzdialenosti všetkých bodov v tréningovej vzorke od k centier.

Trénovanie skrytej vrstvy

- Pre každý tréningový bod je vybrané najbližšie centrum – začiatočná klasifikácia, každý bod patrí do jednej triedy určenej centrom.
- Vezmeme všetky body, ktoré patria k centru 1, vypočítame priemerné hodnoty súradníc a tie sa stanú súradnicami nového centra 1.
- Toto sa opakuje pre všetky triedy 2 – k. Tak vznikne k nových centier.
- Proces merania vzdialenosti bodov od centier a reklasifikácia prebieha dovtedy, pokiaľ nastávajú nejaké zmeny – t.j. súčet vzdialenosti je monitorovaný a tréningovanie zastaví, keď celková vzdialenosť sa už nezmenšuje.

Adaptívny k-means

- Alternatívou je použitie k -means algoritmu, ktorý je podobný Kohonenovmu učeniu.
- Vstupné vzory sú prezentované všetkým klastrovým centrám po jednom. Najbližšie klastrové centrum vyhráva a je posunuté smerom k novým údajom.
- Toto má svoju výhodu v tom, že môže byť robené on-line, údaje sú spracovávané len jedenkrát.

Pokles gradientu a chyba

- Pokles gradientu je všeobecný přístup, východiskom je stanovená chyba

$$E(n) = \sum_k [d_k(n) - o_k(n)]^2 = \sum_k e_k(n)^2$$

where k are output nodes (desired output are known)

- Úprava váh

$$\Delta w_{i,j}(n) = -\eta \frac{\partial E(n)}{\partial w_{i,j}}$$

Polynomiálne siete

- Polynomiálne siete
 - Funkcie v neurónoch umožňujú priamo počítať hodnoty polynómov na vstupoch
 - Aproximácie funkcií vyšších radov pomocou viacerých neurónov (hoci bez skrytých neurónov) Každý neurón má viac váhových prepojení
- Siete vyšších radov

$$f\left(w_0 + \sum_{j_1} w_{j_1} i_{j_1} + \dots + \sum_{j_1, j_2, \dots, j_k} w_{j_1, j_2, \dots, j_k} i_{j_1} i_{j_2} \dots i_{j_k}\right)$$

- # váh pre jeden neurón:

$$1 + \binom{n}{1} + \binom{2n}{2} + \dots + \binom{kn}{k}$$

- Môžu byť trénované metódou Least Mean Squared Errors (LMS).

Polynomiálne siete

- Sigma-pi sieť

$$f(w_0 + \dots + \sum_{j_1 \neq j_2 \neq j_3 \neq j_1} w_{j_1, j_2, j_3} i_{j_1} i_{j_2} i_{j_3} + \dots)$$

- Nepovoľuje výrazy s vyššími mocninami vstupov, teda nie sú všeobecným aproximátorom
- # váh na jeden neurón:

$$1 + \binom{n}{1} + \binom{n}{2} + \dots + \binom{n}{k}$$

- Môže byť trébovaná LMS

- Pi-sigma sieť

- Jedna skrytá vrstva so Sigma funkciou:
- Výstupné vrcholy s Pi funkciou:

$$w_{k,0} + \sum_j w_{k,j} i_j$$

- Súčinové neuróny:

$$f\left(\prod_k (w_{k,0} + \sum_j w_{k,j} i_j)\right)$$

- Neurón počíta súčin: $\prod_{j=1}^n i_j^{p_{j,i}}$
- Celočíselná mocnina $p_{j,i}$ môže byť natrébovaná
- Často sa tieto neuróny kombinujú s inými jednotkami (e.g., sigmoid)

Záver

- RBF sa trénuje rýchlejšie ako dopredné NS
- Je lepšia interpretácia použitej siete ako u dopredných NS
- Výsledky ukazujú, že RBF siete s adaptívnymi centrami pracujú lepšie než s fixnými
- Prečo to tak je, nám vysvetľuje Coverova veta.


Príklad

- Tréningová vzorka: $(\mathbf{x}_1; t_1), \dots, (\mathbf{x}_{10}; t_{10})$

i	1	2	3	4	5
x1i	0.5	0.4	0.6	0.6	0.8
x2i	0.7	0.5	0.6	0.4	0.6
t _i	-1	-1	-1	-1	-1

i	6	7	8	9	10
x1i	0.2	0.1	0.9	0.8	0.3
x2i	0.8	0.7	0.3	0.1	0.1
t _i	1	1	1	1	1

Grafické znázornenie



Určenie centier

- Stanovíme počet centier $M = 4$,
- 4 centrá boli určené algoritmom k-means
- $c_1 = [0,1490; 0,7490]^T$,
- $c_2 = [0,8510; 0,4471]^T$,
- $c_3 = [0,5615; 0,1950]^T$,
- $c_4 = [0,5018; 0,5984]^T$.

We set $\sigma = 1$ as before, and this gives us four basis functions $\phi_1(\mathbf{x})$ $\phi_2(\mathbf{x})$ $\phi_3(\mathbf{x})$ and $\phi_4(\mathbf{x})$. e.g.

$$\phi_1(\mathbf{x}) = \exp\left(-\frac{(x_{1,i} - 0.1490)^2 + (x_{2,i} - 0.7490)^2}{2}\right)$$

Over the given ten data samples, form the matrix Φ given by

$$\Phi = \begin{pmatrix} \phi_{1,1} & \phi_{1,2} & \phi_{1,3} & \phi_{1,4} \\ \phi_{2,1} & \phi_{2,2} & \phi_{2,3} & \phi_{3,4} \\ \vdots & \vdots & \dots & \vdots \\ \phi_{9,1} & \phi_{9,2} & \phi_{9,3} & \phi_{9,4} \\ \phi_{10,1} & \phi_{10,2} & \phi_{10,3} & \phi_{10,4} \end{pmatrix}$$

We can write ten linear equations

$$\left\{ \begin{array}{l} \phi_{1,1}w_1 + \phi_{1,2}w_2 + \phi_{1,3}w_3 + \phi_{1,4}w_4 = t_1 \\ \phi_{2,1}w_1 + \phi_{2,2}w_2 + \phi_{2,3}w_3 + \phi_{2,4}w_4 = t_2 \\ \phi_{3,1}w_1 + \phi_{3,2}w_2 + \phi_{3,3}w_3 + \phi_{3,4}w_4 = t_3 \\ \dots\dots\dots \\ \phi_{10,1}w_1 + \phi_{10,2}w_2 + \phi_{10,3}w_3 + \phi_{10,4}w_4 = t_{10} \end{array} \right.$$

which is

$$\Phi w = t$$

with $\mathbf{t} = [-1, -1, -1, -1, -1, 1, 1, 1, 1, 1]^T$. The least squares estimate is calculated as

$$\mathbf{w} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{t}$$


The RBF classifier is given by

$$g(\mathbf{x}) = \sum_{i=1}^4 w_i \phi_i(\mathbf{x})$$

\mathbf{w} is found to be

$$\mathbf{w} = [-74.1191, -65.3503, -8.2930, 138.2853]^T$$

Klasifikácia





A summary of the construction of RBF network

1. Predetermine the number the centers.
2. Use the k-means clustering algorithm to find centers c_i ;
2. Calculate $\phi_i(x)$ for all training data samples;
3. Form matrix Φ and t ;
4. Calculate

$$w = (\Phi_T \Phi)^{-1} \Phi_T t$$

5. Use the resultant classifier $g(x)$ for classification.

Note that k-means clustering algorithm can also be used
RBF neural networks center selection for regression.



Modifikované podľa Dr. Emad A. A. El-Sebahy