

شبکه‌های عصبی مصنوعی

۰۱-۷۱۳-۱۱-۱۳

بخش سوه



دانشگاه شهید بهشتی


دانشکده‌ی مهندسی برق و کامپیوتر

زمستان ۱۳۹۳

احمد محمودی ازناوه


فهرست مطالب

- مقدمه‌ای بر RBF (توابع پایه شعاعی)
- قضیه‌ی cover
- نقش RBF در جداسازی کلاس‌ها
- نقش RBF در تقریب توابع
- شیوه‌های آموزش
- چند مثال



پیش‌گفتار

- در اینجا به طراحی شبکه‌ی عصبی به صورت یک مسأله‌ی «برازش منحنی» (curve fitting) و «درون‌یابی» نگریسته می‌شود.
- با این نگاه مسأله محادل یافتن یک رویه در فضای چند بعدی است که به بهترین نحو با داده‌های آموزشی تطابق داشته باشد.
- **قضیه‌ی cover:**
 - در یک مسأله‌ی پیچیده‌ی بازشناخت الگو، با نگاشت به فضای high dimensional با احتمال بیشتری جدایی‌پذیر فطی خواهد بود.



Cover, T. M. (1965). "Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition." Electronic Computers, IEEE Transactions on EC-14(3): 326-334.


Radial Basis Function

کلاس‌های جدایی ناپذیر
قطبی


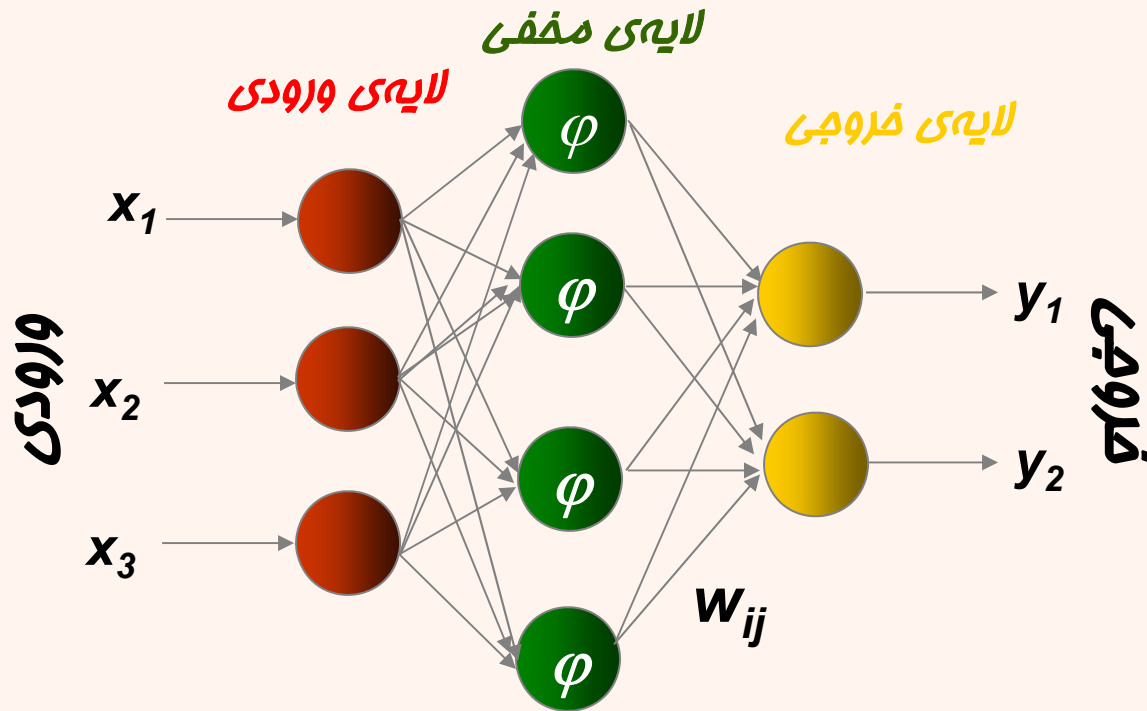
Transform to
"higher"-dimensional
vector space

کلاس‌های جدایی پذیر
قطبی

- در شبکه‌های RBF سه نوع لایه وجود دارد:
- لایه ورودی (sensory unit)
- لایه مخفی (hidden layer)
 - گره‌های منبع شبکه و رابط شبکه با دنیای بیرون
- لایه خروجی (output layer)
 - هر گره، تابعی شعاعی که مرکز و شعاعی مختص به خود را داراست، به ورودی‌ها اعمال می‌کند.
- ترکیبی قطبی از توابع لایه‌های مخفی




- ساختار یک شبکه‌ی RBF همانند MLP است؛ بدین ترتیب می‌تواند برای «دسته‌بندی» و یا «تقریب تابع» استفاده شود.



Radial Basis Function

$$f(\mathbf{x}) = \sum_{i=1}^{m_1} w_i \phi_i(\mathbf{x})$$



Decomposition
Feature Extraction
Transformation




- همان گونه که گفته شد شبکه‌های RBF بر تعریف تابعی وابسته به فاصله از مرکز استوار است.

$$\phi_i(\mathbf{x}) = \phi(\|\mathbf{x} - \mathbf{x}_i\|)$$


شکل

فاصله

مرکز



$$\|\mathbf{x} - \mathbf{y}\| = \sqrt{(\mathbf{x} - \mathbf{y})^t (\mathbf{x} - \mathbf{y})} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$



چند نمونه تابع فاصله‌ای

$$r = \|x - x_j\|$$

• گاوسی


$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad \sigma > 0 \quad \text{and} \quad r \in \mathcal{R}$$

• Hardy Multiquadratic

$$\phi(r) = \sqrt{r^2 + c^2} / c \quad c > 0 \quad \text{and} \quad r \in \mathcal{R}$$



• Inverse Multiquadratic

$$\phi(r) = c / \sqrt{r^2 + c^2} \quad c > 0 \quad \text{and} \quad r \in \mathcal{R}$$





تابع گاوسی

$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad \sigma > 0 \quad \text{and} \quad r \in \mathbb{R}$$



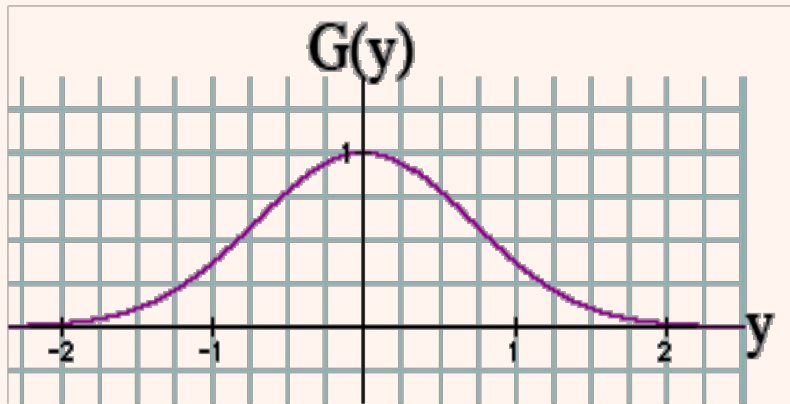
Inverse Multiquadratic

$$\phi(r) = c / \sqrt{r^2 + c^2} \quad c > 0 \quad \text{and} \quad r \in \mathfrak{R}$$



RBF


• تابع گاوسی:



$$G(y) = \exp(-y^2/2\sigma^2)$$

واریانس

• هر چه واریانس کمتر باشد انتخاب‌های محدودتر و هر چه واریانس بالا رود انتخاب‌ها گسترده‌تر است.

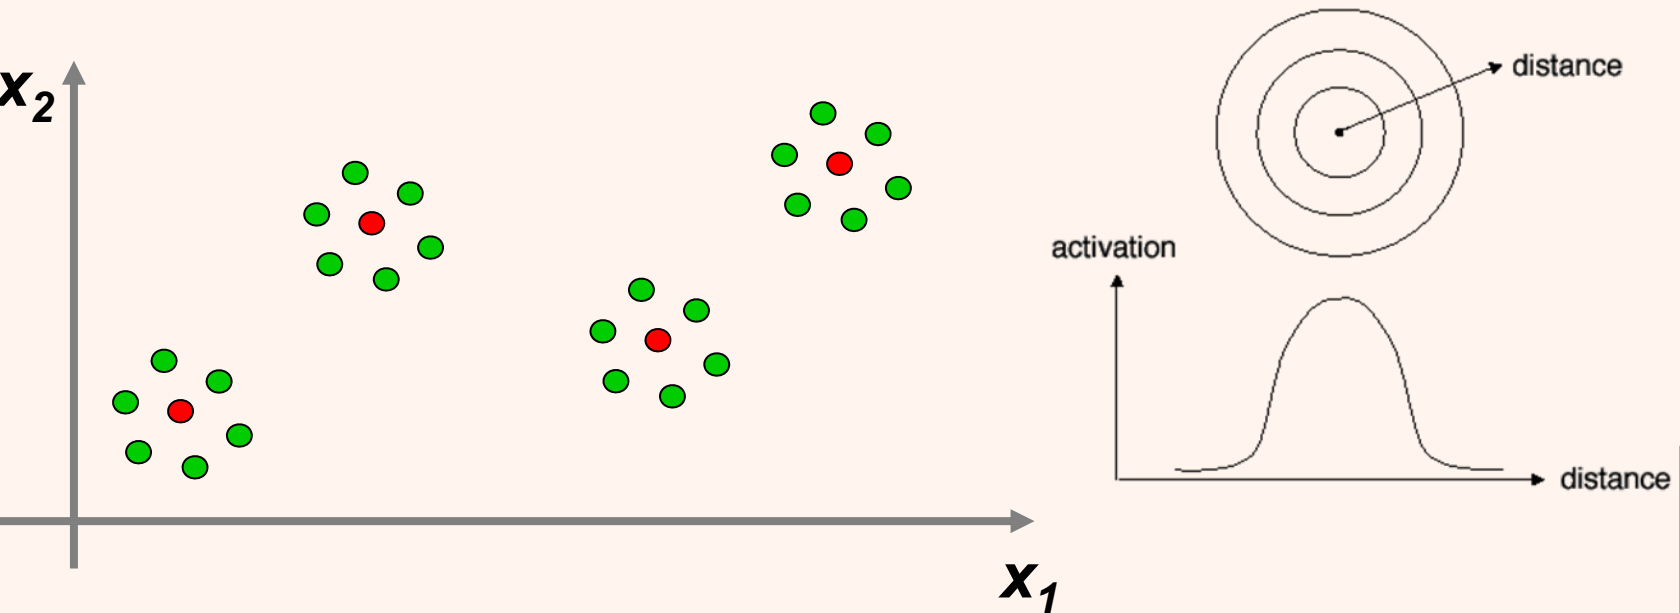


به وسیله‌ی سیگما میزان پراکندگی داده را مشخص می‌کنیم.

بهشتی

توابع پایه


- خاصیت تقارن از مرکز برای فضای n بعدی وجود دارد (n تعداد مراکز است)
- هرچه از مرکز دورتر شویم ورودی اهمیت کمتری پیدا کرده در نتیجه پاسخ کاهش می‌خواهد بود.




● Data points

● Centers

شبکه عصبی



لایه‌ی مخفی متشکل از RBF است



لایه‌ی خروجی متشکل از تابع جدایی‌پذیر خطی است

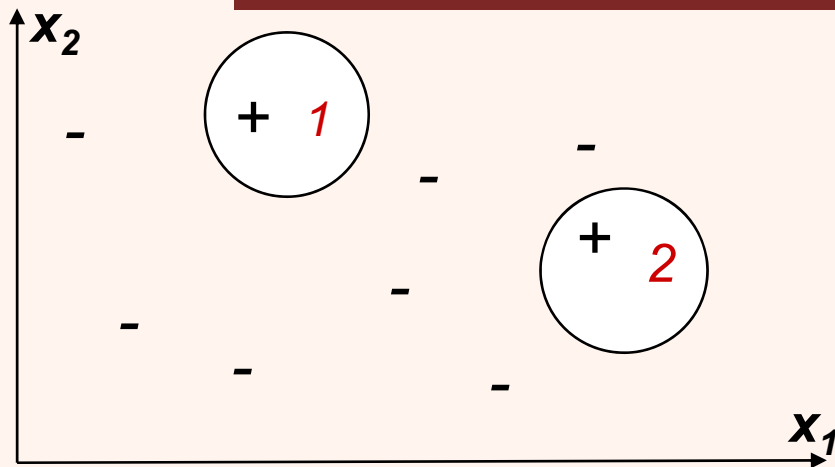
$$y = w_1 \varphi_1(\|x - t_1\|) + \dots + w_{m_1} \varphi_{m_1}(\|x - t_{m_1}\|)$$

$$x = (x_1, \dots, x_{m_0})$$



مثال

در این مثال هدف جداسازی دو کلاس است: + و -



$\langle x_1, x_2 \rangle \rightarrow$ input space

$$\varphi_1(\|x - t_1\|) = \begin{cases} 1 & \text{if } \|x - t_1\| \leq r_1 \\ 0 & \text{if } \|x - t_1\| > r_1 \end{cases}$$



$$\varphi_2(\|x - t_2\|) = \begin{cases} 1 & \text{if } \|x - t_2\| \leq r_2 \\ 0 & \text{if } \|x - t_2\| > r_2 \end{cases}$$

t_1 و t_2 مراکز دو دایره بالا هستند




ادامه‌ی مثال

$\langle \varphi_1, \varphi_2 \rangle \rightarrow$ feature space



$$\varphi(\|x-t\|) = \begin{cases} 1 & \text{if } \|x-t\| \leq c \\ 0 & \text{if } \|x-t\| > c \end{cases}$$


جدا شونده‌ی خطی



مثال


• حل مسأله‌ی XOR با شبکه‌ی RBF

ورودی‌ها




$t_1 = (1,1)$ and $t_2 = (0,0)$

خروجی‌ها



$(0,0)$ و $(1,1)$ نگاشت به صفر شده در یک گروه

$(0,1)$ و $(1,0)$ نگاشت به یک شده در گروه دیگر قرار می‌گیرند



مثال



$$\varphi_1(\|x - t_1\|) = e^{-\|x - t_1\|^2}$$

$$\varphi_2(\|x - t_2\|) = e^{-\|x - t_2\|^2}$$



x_1	x_2	o
0	0	0
0	1	1
1	0	1
1	1	0




$\varphi_1(\underline{x})$	$\varphi_2(\underline{x})$	o'
0.13	1	0
0.36	0.36	1
0.36	0.36	1
1	0.13	0



Decision Boundary



مثال





$$O = -e^{-\|x-t_1\|^2} - e^{-\|x-t_2\|^2} + 1$$

If $O > 0$ then class 1 otherwise class 0

```
x1=[0:.01:1];  
x2=[0:.01:1];  
[X1,X2]=meshgrid(x1,x2);  
f1=exp(-((X1-1).^2+(X2-1).^2));  
f2=exp(-((X1).^2+(X2).^2));  
z=-f1-f2+1;  
contour(x1,x2,z);  
title('xor problem, decision boundary');
```




مرز تصمیم‌گیری



دسته‌بندی خطی

- یک دسته‌بند **پیمایدهی غیرخطی** در فضای m_0 بعدی را می‌توان با نگاشت به یک فضای بزرگ‌تر به صورت دسته‌بند **خطی** معادل ساخت.
- فرض کنید N الگوی x_1, x_2, \dots, x_N با اندازه‌ی $1 \times m_0$ را بخواهیم در دو کلاس A_1 و A_2 طبقه‌بندی کنیم.
- برای هر الگوی آموزشی یک بردار m_1 عضوی جدید که $m_0 \leq m_1$ است تعریف می‌کنیم به گونه‌ای که
$$\varphi(x) = [\varphi_1(x), \dots, \varphi_{m_1}(x)]$$
- پس توسط تابع ϕ می‌خواهیم فرایندی داشته باشیم که:

$$\varphi : R^{m_0} \rightarrow R^{m_1}$$



دسته‌بندی کلاس‌ها

- مجموعه تمامی توابع مخفی را به صورت زیر نشان می‌دهیم:


$$\{\varphi_i(x)\}_{i=1}^{m_1}$$

- حال اگر داشته باشیم:

$$W^T \varphi(x) > 0 \quad \Rightarrow \quad x \in A_1$$



$$W^T \varphi(x) < 0 \quad \Rightarrow \quad x \in A_2$$

بردارهای x_i در فضای m_0 بعدی تبدیل به بردارهای جدید m_1 با خاصیت جدایی پذیری قطعی شده‌اند.





« نشان‌گر رویه‌ی جداکننده است. $W^T \varphi(x) = 0$ »

تقريب تابع





تقریب تابع (ادامه...)





تقریب تابع (ادامه...)

$$y = f(\mathbf{x}) = \sum_{i=1}^{m_1} w_i \phi_i(\mathbf{x})$$





تقریب تابع (ادامه...)

$$y = f(\mathbf{x}) = \sum_{i=1}^{m_1} w_i \phi_i(\mathbf{x})$$



تقریب تابع (ادامه...)

$$y = f(\mathbf{x}) = \sum_{i=1}^{m_1} w_i \phi_i(\mathbf{x})$$



روش‌های یادگیری

- دقیق

– الگوهای آموزشی برابر با تعداد واحدهای مخفی

- درونیابی تقریبی


– الگوهای آموزشی بیشتر از تعداد واحدهای مخفی

- مجهول‌ها

- مراکز t

- واریانس تابع

- وزن‌ها



تعداد واحدهای منفی برابر با تعداد بردارهای ورودی

• حل مساله در حالت کلی:


- N بردار متفاوت در فضای m_0 بعدی: $\left\{ \mathbf{x}_i \in R^{m_0} \right\}_{i=1}^N$

- N عدد حقیقی $\left\{ d_i \in R^1 \right\}_{i=1}^N$

$$F : R^{m_0} \rightarrow R^1$$

- مطلوب است یافتن F

$$F(\mathbf{x}_i) = d_i$$



آموزش دقیق

• شبکه‌ی RBF

$$F(\mathbf{x}) = \sum_{j=1}^N w_j \varphi(\|x - x_j\|)$$


تابع فاصله است

$$\|\mathbf{x} - \mathbf{x}_j\| = \sqrt{\sum_{k=1}^{m_0} (x_k - x_{kj})^2}$$

• یعنی انتخاب F به گونه‌ای که:

$$F(x_i) = \sum_{j=1}^N w_j \varphi(\|x_i - x_j\|) = d_i$$

$$w_1 \varphi_1(\|x_i - x_1\|) + w_2 \varphi_2(\|x_i - x_2\|) + \dots + w_N \varphi_N(\|x_i - x_N\|) = d_i$$




آموزش دقیق (ادامه...)

- برای سادگی از اندیس‌های توابع شعاعی صرفنظر می‌کنیم:

$$\begin{bmatrix} \varphi(\|x_1 - t_1\|) & \varphi(\|x_1 - t_2\|) & \dots & \varphi(\|x_1 - t_N\|) \\ \varphi(\|x_2 - t_1\|) & \varphi(\|x_2 - t_2\|) & \dots & \varphi(\|x_2 - t_N\|) \\ \dots & \dots & \dots & \dots \\ \varphi(\|x_N - t_1\|) & \varphi(\|x_N - t_2\|) & \dots & \varphi(\|x_N - t_N\|) \end{bmatrix} [w_1 \dots w_N]^T = [d_1 \dots d_N]^T$$

$$\Phi \begin{bmatrix} w_1 \\ \dots \\ w_{m1} \end{bmatrix} = \begin{bmatrix} d_1 \\ \dots \\ d_N \end{bmatrix} \Rightarrow \Phi \cdot W = D \Rightarrow W = \Phi^{-1} \cdot D$$

به شرط معکوس پذیری
جواب دارد




معکوس پذیری

- اگر تابع ϕ یکی از توابع زیر باشد و نمونه‌ها تکراری نباشد در این حالت ماتریس درونیابی (nonsingular) است و معکوس پذیر:

$$\phi(r) = e^{-\frac{r^2}{2\sigma^2}} \quad \sigma > 0 \quad \text{and} \quad r \in \mathcal{R}$$

$$\phi(r) = \sqrt{r^2 + c^2} / c \quad c > 0 \quad \text{and} \quad r \in \mathcal{R}$$

$$\phi(r) = c / \sqrt{r^2 + c^2} \quad c > 0 \quad \text{and} \quad r \in \mathcal{R}$$



Micchelli's theorem


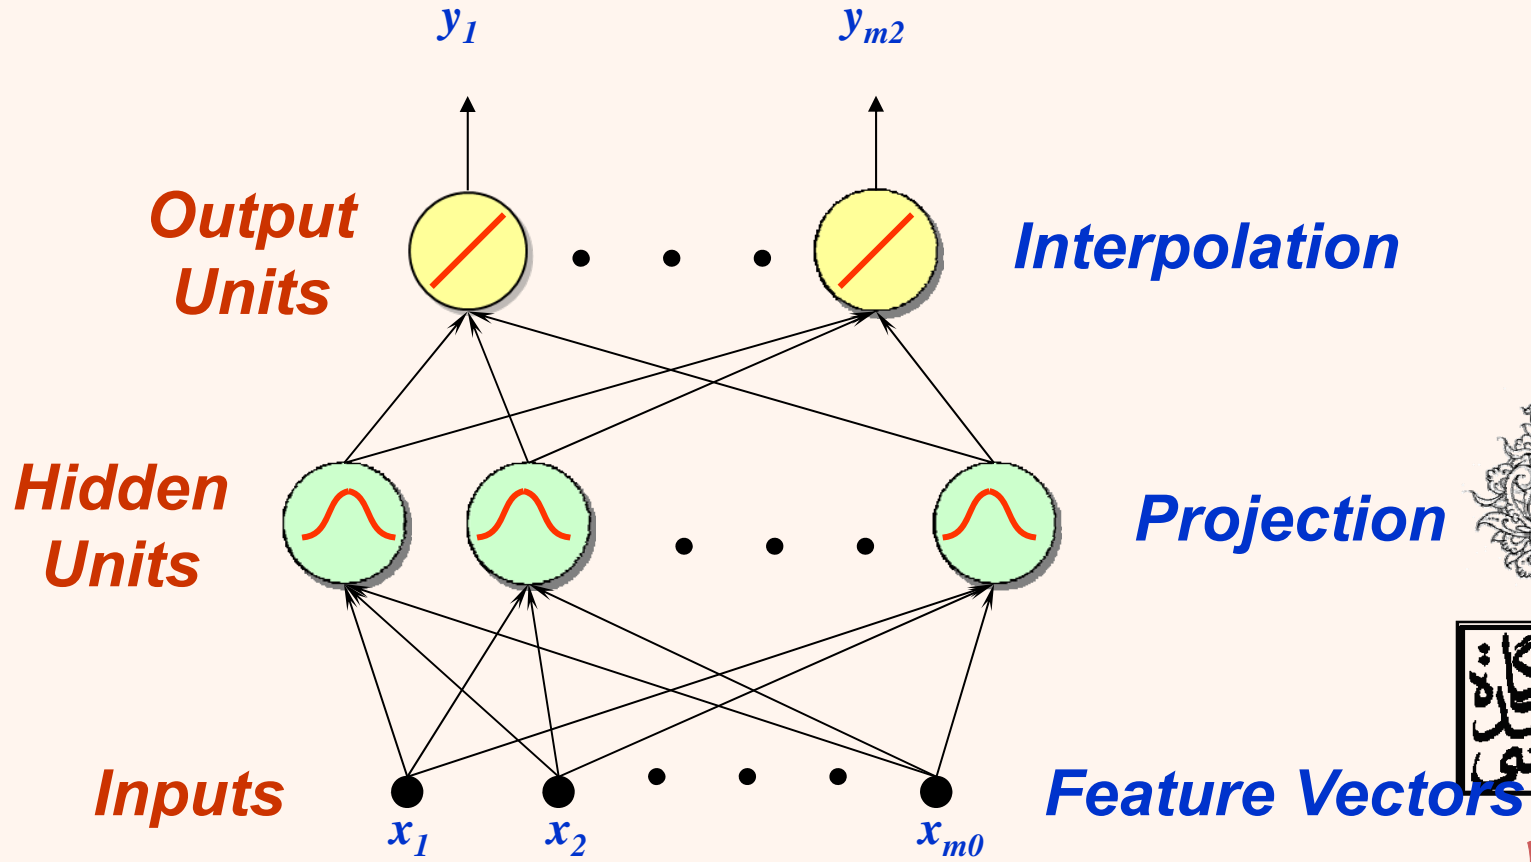
Micchelli, C. (1986). "Interpolation of scattered data: Distance matrices and conditionally positive definite functions." Constructive Approximation 2(1): 11-22.



ساختار شبکه


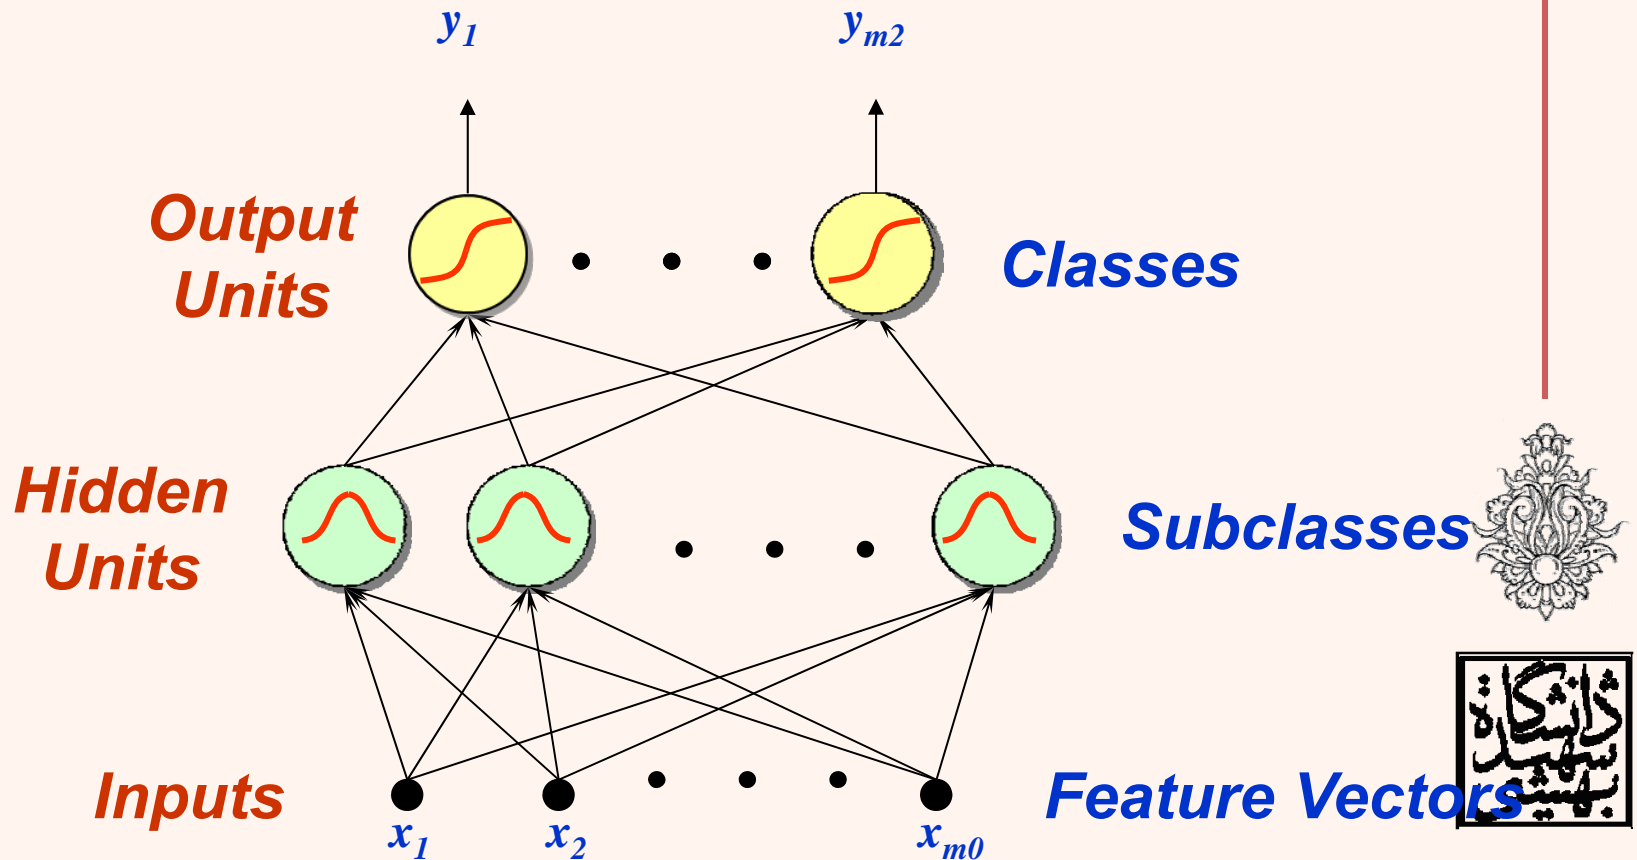
- جهت تخمین توابع می‌توان از ساختاری همانند زیر بهره گرفت:

$$y = f(x)$$



ساختار شبکه

- هنگامی که از RBF به عنوان Classifier استفاده می‌شود:



اندازه‌ی ماتریس


- اگر N تعداد الگوهای آموزشی باشد، تعداد واحدهای لایه‌ی مخفی را برابر با N در نظر می‌گیریم.

- در این حالت هرچه N بزرگ‌تر شود تعداد گره‌های لایه‌ی مخفی هم بیشتر شده و مشکل محکوس نمودن یک ماتریس بزرگ را در پی خواهد داشت.


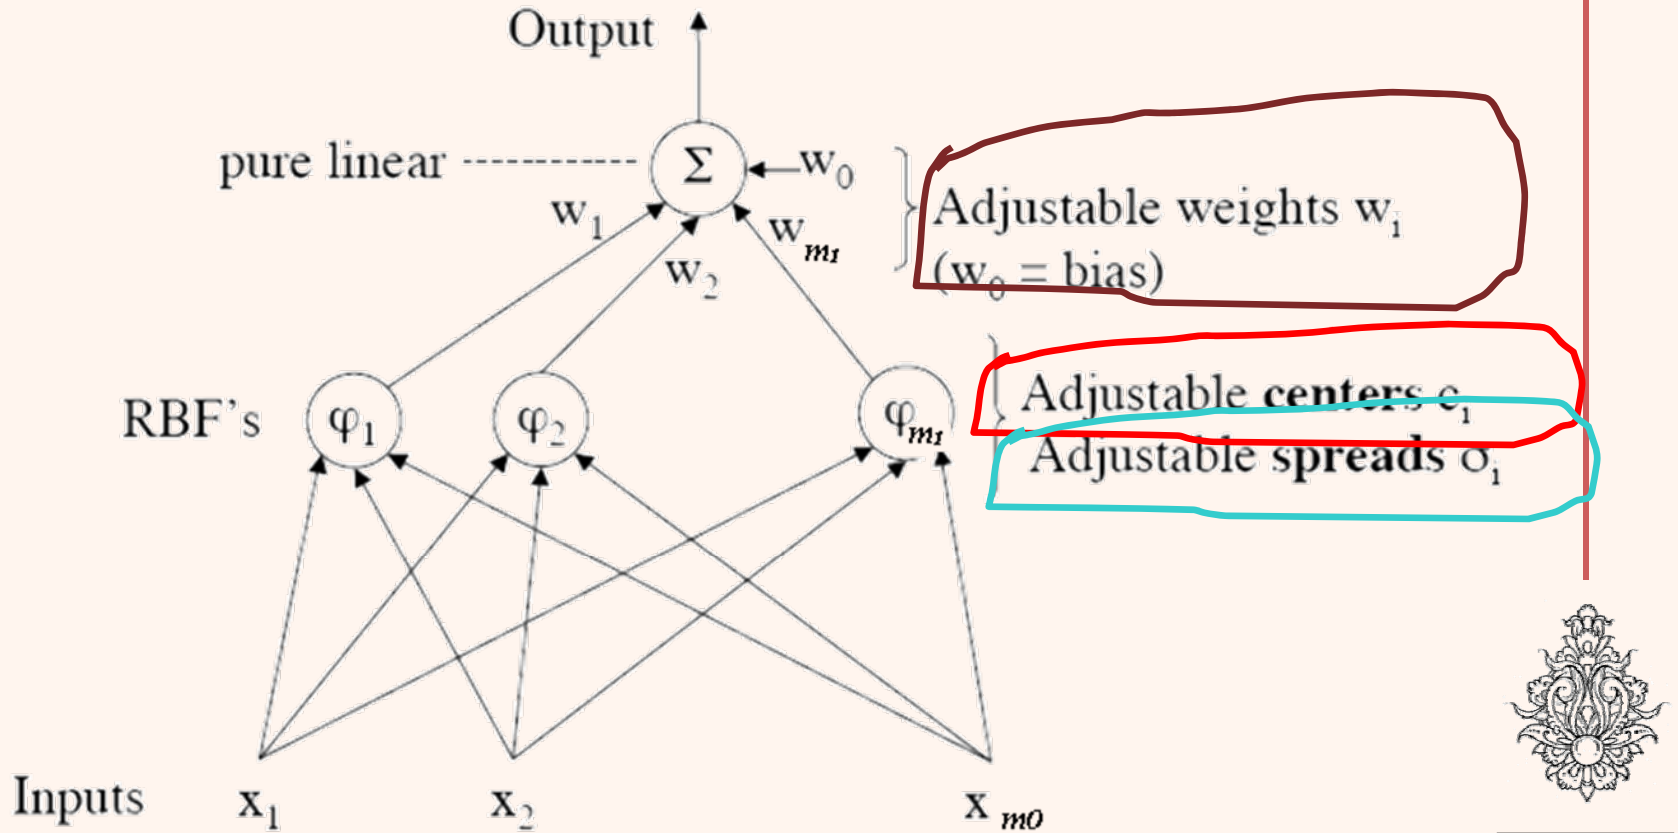
• راه حل

- تعداد واحدهای لایه‌ی مخفی را کم‌تر از N در نظر می‌گیریم ($M < N$)

- در این حالت تعداد الگوهای آموزشی برابر با N و تعداد واحدهای لایه‌ی مخفی M است.



پارامترهای آزاد



ماتریس درون‌یابی

تعداد واحدهای منفی کم‌تر از تعداد بردارهای ورودی


• در این حالت خواهیم داشت:

$$\tilde{F}(\mathbf{x}) = \sum_{j=0}^M w_j \varphi_j(\|\mathbf{x} - \mathbf{x}_j\|) \quad \varphi_0 = 1$$

بیاس

$$\{t_i = x_i, M \leq N\}$$

• t_i همان مراکز هستند که می‌توانند برابر با x ها باشند و یا نباشند.



$$\tilde{F}(\mathbf{x}) \approx F(\mathbf{x}) \quad E(\tilde{F}) = \sum_{j=1}^N (d_j - \tilde{F}(x_j))^2$$




$$\begin{bmatrix} \varphi_1(\|x_1 - t_1\|) & \varphi_2(\|x_1 - t_2\|) & \dots & \varphi_M(\|x_1 - t_M\|) \\ \varphi_1(\|x_2 - t_1\|) & \varphi_2(\|x_2 - t_2\|) & \dots & \varphi_M(\|x_2 - t_M\|) \\ \dots & \dots & \dots & \dots \\ \varphi_1(\|x_N - t_1\|) & \varphi_2(\|x_N - t_2\|) & \dots & \varphi_M(\|x_N - t_M\|) \end{bmatrix} [w_1 \dots w_M]^T = [d_1 \dots d_N]^T$$

$$\Phi_{N \times M} \mathbf{W}_{M \times 1} = \mathbf{D}_{N \times 1}$$

• چون ماتریس نتیجه شده مربعی نیست از طریق محاسبه‌ی ماتریس معکوس نمی‌توان عمل نمود.

– تعداد داده‌ها از پارامترهای آزاد بیشتر است.

Overdetermined problem




- هنگامی جواب بهینه است که حداقل خطا را داشته باشیم:

$$E(\tilde{F}) = \sum_{j=1}^N (d_j - \tilde{F}(x_j))^2$$

$$\mathbf{E} = \|\mathbf{D} - \Phi\mathbf{W}\|^2 = (\mathbf{D} - \Phi\mathbf{W})^T (\mathbf{D} - \Phi\mathbf{W})$$

$$= \mathbf{D}^T \mathbf{D} - \mathbf{W}^T \Phi^T \mathbf{D} - \mathbf{D}^T \Phi \mathbf{W} + \mathbf{W}^T \Phi^T \Phi \mathbf{W}$$

$$= \mathbf{D}^T \mathbf{D} - 2\mathbf{W}^T \Phi^T \mathbf{D} + \mathbf{W}^T \Phi^T \Phi \mathbf{W}$$



ماتریس درونیابی

$$\nabla_{\mathbf{W}} \mathbf{E} = \mathbf{0}$$

• برای حداقل کردن خطا

$$\mathbf{E} = \mathbf{D}\mathbf{D}^T - 2\mathbf{W}^T\Phi^T\mathbf{D} + \mathbf{W}^T\Phi^T\Phi\mathbf{W}$$


$$\nabla_{\mathbf{W}} \mathbf{E} = -2\Phi^T\mathbf{D} + 2\Phi^T\Phi\mathbf{W}$$

$$= -2 \underbrace{\underbrace{\Phi^T}_{M \times N} \underbrace{\mathbf{D}}_{N \times 1}}_{M \times 1} + 2 \underbrace{\underbrace{\underbrace{\Phi^T}_{M \times N} \underbrace{\Phi}_{N \times M}}_{M \times M}}_{M \times 1} \underbrace{\mathbf{W}}_{M \times 1}$$

$$\mathbf{W} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{D}$$

$$\mathbf{W} = \Phi^+ \mathbf{D}$$

$$M = N \rightarrow \mathbf{W} = \Phi^{-1} \mathbf{D}$$



شبکه عصبی

Pseudo Inverse

مثال (XOR)

$$\mathbf{X} = \begin{bmatrix} 1 & 0 & 0 & 1 \\ 1 & 1 & 0 & 0 \end{bmatrix}$$


$$\mathbf{D} = \begin{bmatrix} 0 & 1 & 0 & 1 \end{bmatrix}$$

$$y(x) = \sum_{j=0}^2 w_j \varphi_j(\|x - t_j\|) + w_0$$

$$\varphi(x - t_j) = \exp(-\|x - t_j\|^2)$$


$$t_1 = [1 \ 1]^T \quad t_2 = [0 \ 0]^T$$

$$\Phi \mathbf{W} = \mathbf{D}$$



$$\begin{bmatrix} 1 & 0.13 & 1 \\ 0.36 & 0.36 & 1 \\ 0.13 & 1 & 1 \\ 0.36 & 0.36 & 1 \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ w_3 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 1 \end{bmatrix}$$

$$\mathbf{W} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{D} = \begin{bmatrix} -2.5 \\ -2.5 \\ 2.8 \end{bmatrix}$$




مثال (ادامه...)

$$\mathbf{W} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{D}$$

- در صورت در نظر گرفتن دو ورودی دیگر به عنوان مرکز

$$\mathbf{t}_1 = [1 \ 0]^T \quad \mathbf{t}_2 = [0 \ 1]^T$$

$$\mathbf{W} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{D} = \begin{bmatrix} 1.9 \\ 1.9 \\ -1.4 \end{bmatrix}$$



الگوریتم‌های یادگیری

الگوریتم کی

Fixed Center Selected at Random

– مراکز به صورت ثابت از میان الگوهای آموزشی انتخاب می‌شوند.

– انحراف معیار از رابطه‌ی زیر محاسبه می‌شود:


$$\sigma = \frac{\text{Maximum distance between any 2 centers}}{\sqrt{\text{number of centers}}} = \frac{d_{\max}}{\sqrt{2m_1}}$$

$$\varphi(\|x-t_i\|^2) = \exp\left(-\frac{m_1}{d_{\max}^2} \|x-t_i\|^2\right) \quad i = 1, 2, \dots, m_1$$

– با توجه به مقادیر فوق تابع مورد نظر انتخاب می‌شود.

– وزن‌ها با توجه به رابطه‌ی زیر محاسبه می‌شود:

$$\mathbf{W} = \Phi^+ \mathbf{D}$$



محاسبه‌ی ماتریس شبه معکوس

- اگر G یک ماتریس $N \times M$ باشد، ماتریس‌های متعامد U و V وجود دارند به صورتی که:

$$U = \{u_1, u_2, \dots, u_N\} \quad V = \{v_1, v_2, \dots, v_M\}$$

- به صورتی که:


$$U^T G V = \text{diag}\{\sigma_1, \sigma_2, \dots, \sigma_k\} \quad k = \min\{M, N\}$$

- در این صورت برای محاسبه‌ی G^+ داریم:
- که در آن:

$$G^+ = V \Sigma^+ U^T$$
$$\Sigma^+ = \text{diag}\{1/\sigma_1, 1/\sigma_2, \dots, 1/\sigma_k, 0, 0, \dots, 0\}$$

- با محاسبه‌ی ماتریس فوق وزن‌ها قابل محاسبه است.

where Σ^+ is $M \times N$ matrix



• M واحد مخفی انتخاب می‌شود.

1. مقداردهی اولیه

2. یک سری متغیر تصادفی برای t_k ها (مراکز) در نظر گرفته می‌شود. $t_k(0)$


3. یک ورودی x انتخاب و به شبکه اعمال می‌شود.

4. فاصله‌ی بردار X را از تمامی مراکز به دست می‌آوریم و آن بردار که نزدیک‌ترین است را به روز می‌نماییم:


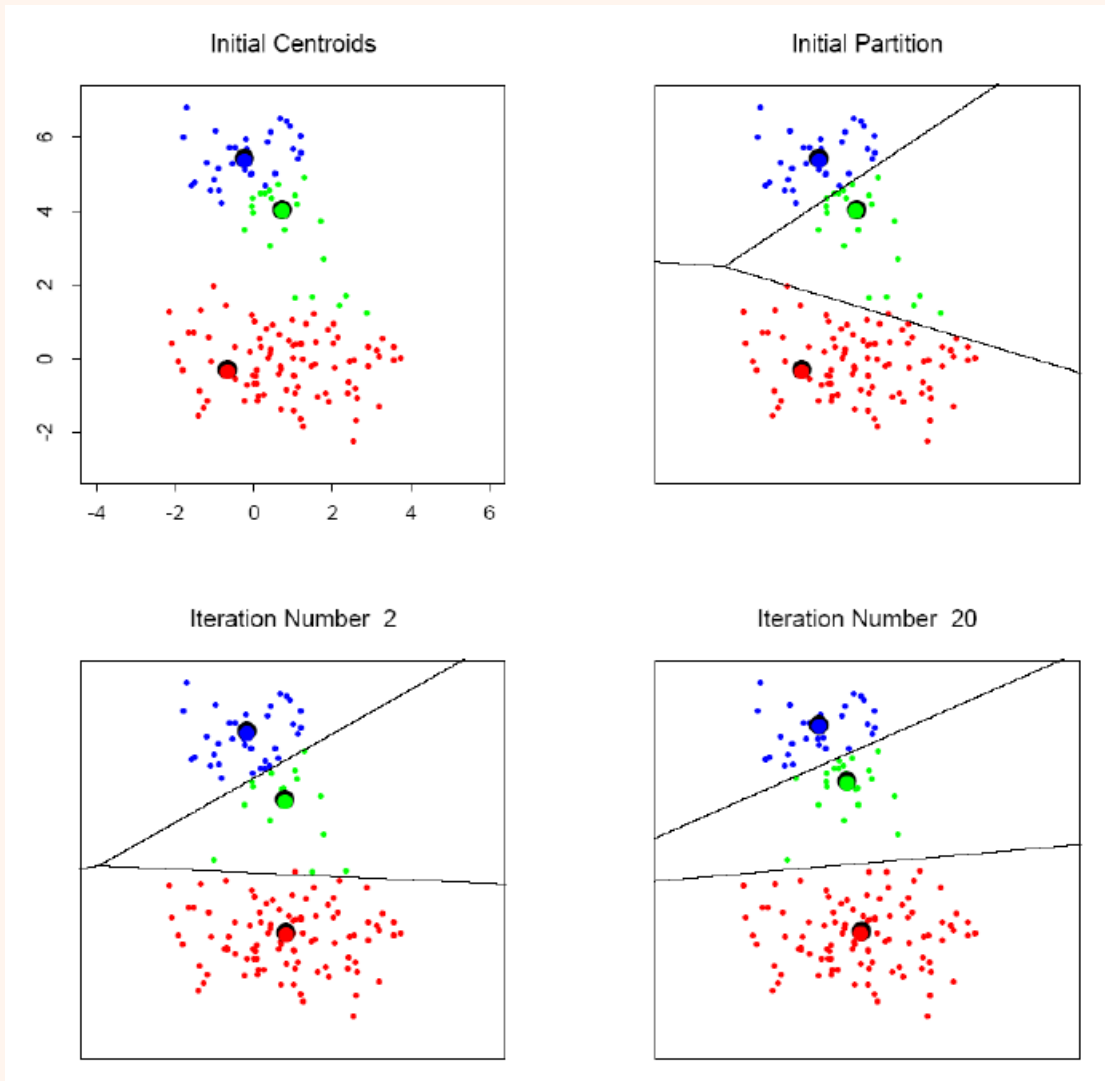
$$h(x) = \arg \min_k \|x - t_k(n)\|^2 \quad k = 1, 2, \dots, M$$

$$t_k(n+1) = \begin{cases} t_k(n) + \eta[x(n) - t_k(n)] & \text{if } k = h(x) \\ t_k(n) & \text{otherwise} \end{cases}$$

5. بازگشت به مرحله‌ی دوم تا زمانی که مراکز تغییر چندانی نداشته باشند.





K-means clustering example





K-means clustering example

مثال





K-means clustering example

مثال





K-means clustering example

مثال




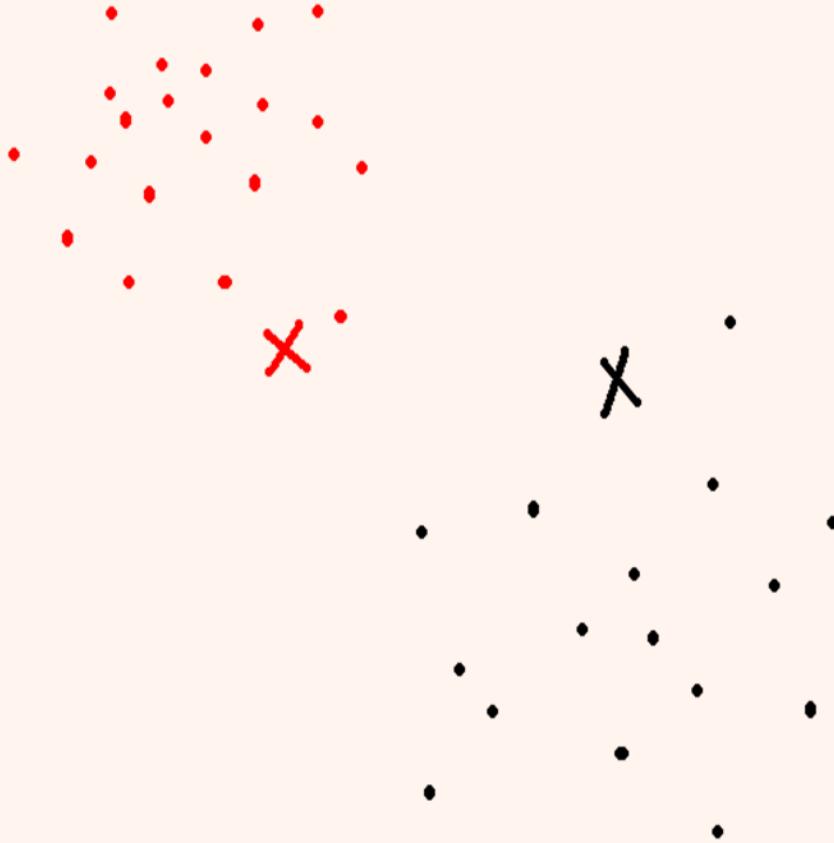
K-means clustering example

مثال





K-means clustering example

مثال



K-means clustering example


مثال



- مراکز از طریق فرآیند خوشه‌بندی (Clustering) مشخص گردید.
- انحراف معیار:

$$\sigma = \frac{\text{Maximum distance between any 2 centers}}{\sqrt{\text{number of centers}}} = \frac{d_{\max}}{\sqrt{2m_1}}$$

- وزن‌ها از طریق الگوریتم LMS محاسبه می‌گردد.




- به روز رسانی وزن ها بر پایه ی G.D است.
- ابتدا تابع معیار خطا تعریف می شود.

$$E(\tilde{F}) = \sum_{j=1}^N (d_j - \tilde{F}(x_j))^2$$

$$= \sum_{j=1}^N \left[d_j - \sum_{i=1}^M w_i \varphi(\|x_j - t_i\|) \right]^2$$

$$\frac{\partial E(n)}{\partial w_i(n)} = \sum_{j=1}^N (-2e_j) \varphi(\|x_j - t_{i(n)}\|)$$

$$w_i(n+1) = w_i(n) - \eta_1 \frac{\partial E(n)}{\partial w_i(n)} \quad 1 \leq i \leq M$$




- برای به روز رسانی مراکز می‌باید از تابع معیار خطا بر حسب t_j مشتق گرفته شود:

$$E(\tilde{F}) = \sum_{j=1}^N (d_j - \tilde{F}(x_j))^2 = \sum_{j=1}^N \left[d_j - \sum_{i=1}^M w_i \varphi(\|x_j - t_i\|) \right]^2$$

$$\begin{aligned} \frac{\partial E(n)}{\partial t_i(n)} &= \sum_{j=1}^N (2e_j)(-w_i) \frac{\partial \varphi(\|x_j - t_i\|)}{\partial t_i} \\ &= \sum_{j=1}^N (-2e_j)(w_i) \frac{\partial \varphi(\|x_j - t_i\|)}{\partial \|x_j - t_i\|^2} \times \frac{\partial \|x_j - t_i\|^2}{\partial t_i} \end{aligned}$$

$$= \sum_{j=1}^N (-2e_j)(w_i) \varphi'(\|x_j - t_i\|) (-2(x_j - t_i))$$


$$t_i(n+1) = t_i(n) - \eta_2 \frac{\partial E(n)}{\partial t_i(n)}$$



$$\frac{\partial E(n)}{\partial \sigma_i(n)} = \sum_{j=1}^N (2e_j)(-w_i) \frac{\partial \phi(\|x_j - t_i\|)}{\partial \sigma_i}$$


$$A = \frac{\partial \exp\left[\frac{-r^2}{2\sigma_i^2}\right]}{\partial \sigma_i} = \frac{4r^2 \sigma_i(n)}{4\sigma_{i(n)}^4} \times \exp\left[\frac{-r^2}{2\sigma_i^2}\right]$$

$$\sigma_i(n+1) = \sigma_i(n) - \eta_3 \frac{\partial E(n)}{\partial \sigma_i(n)}$$


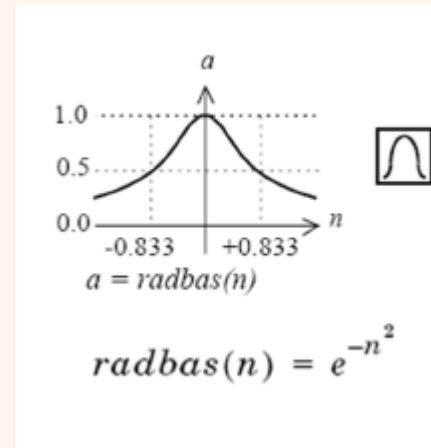
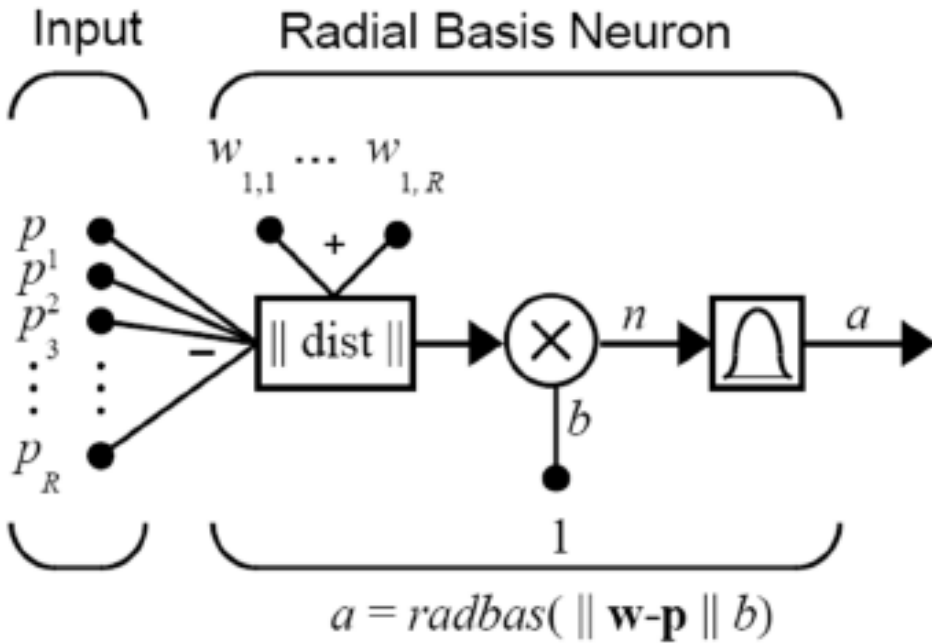


مقایسه میان RBF و MLP

- در MLP می‌توانیم چند لایه‌ی مخفی داشته باشیم حال آن که در RBF یک تنها لایه‌ی مخفی داریم.
- معمولاً در MLP اگر برای pattern classification استفاده شود تمامی توابع غیر خطی‌اند.
- آرگومان توابع در RBF فاصله‌ی اقلیدسی است حال آن که در MLP این آرگومان ضرب داخلی بردار ورودی لایه در وزن هاست.
- در MLP یک تقریب کلی از رابطه‌ی ورودی-خروجی به دست می‌آورد در صورتی که در RBF این تخمین به صورت محلی محاسبه می‌شود.
- سرعت یادگیری RBF بیشتر است، در عین حال تعداد پارامترهای آزاد آن هم بیشتر است.




شبکه‌های RBF در Matlab




مثال-تقریب تابع (ادامه...)

```
p = -3:.1:3;  
a = radbas(p);  
plot(p,a)  
title('Radial Basis Transfer Function');  
xlabel('Input p');  
ylabel('Output a');
```


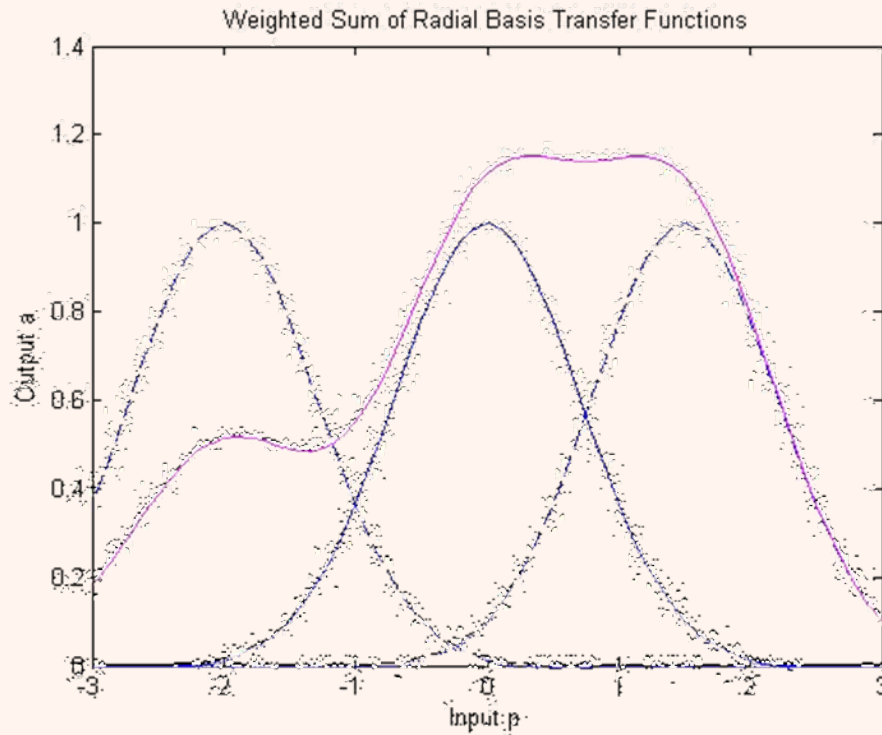


$$\text{radbas}(n) = e^{-n^2}$$

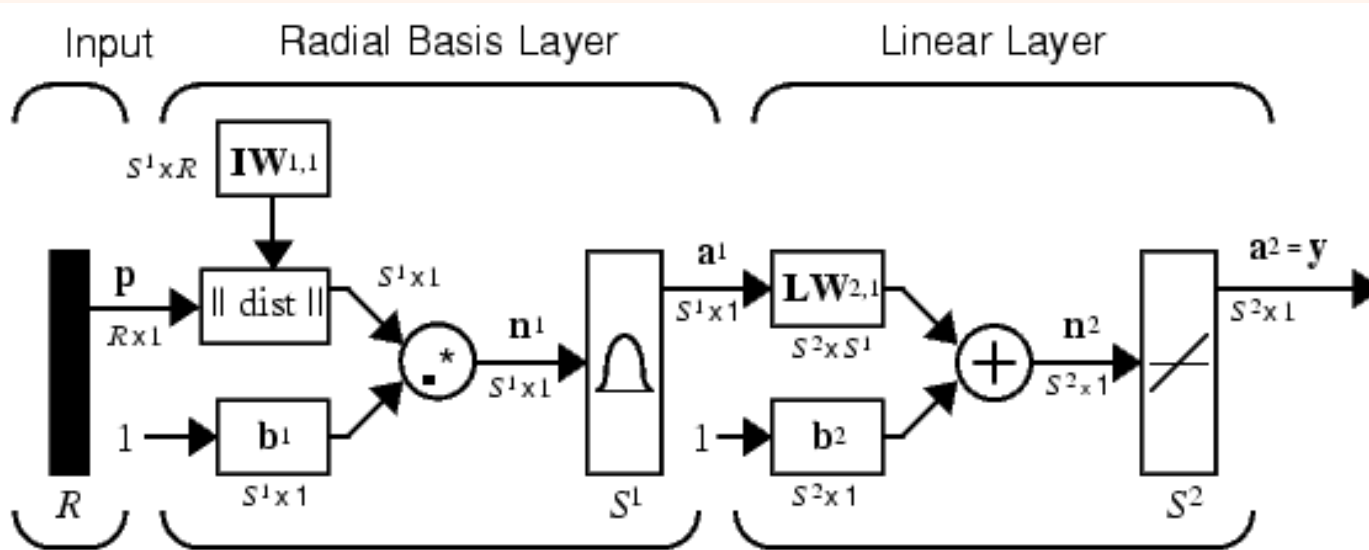


مثال-تقريب تابع (ادامه...)

```
p = -3:.1:3;  
a = radbas(p);  
a2 = radbas(p-1.5);  
a3 = radbas(p+2);  
a4 = a + a2*1 + a3*0.5;  
plot(p,a,'b-',p,a2,'b--',p,a3,'b--',p,a4,'m-')  
title('Weighted Sum of Radial Basis Transfer Functions');  
xlabel('Input p');  
ylabel('Output a');
```



شبکه‌های RBF در Matlab (ادامه...)




Where...

- R = number of elements in input vector
- S^1 = number of neurons in layer 1
- S^2 = number of neurons in layer 2

$$a_i^1 = \text{radbas}(\|\mathbf{IW}_{1,1} - \mathbf{p}\| b_i^1)$$

$$\mathbf{a}^2 = \text{purelin}(\mathbf{LW}_{2,1} \mathbf{a}^1 + \mathbf{b}^2)$$

a_i^1 is i^{th} element of \mathbf{a}^1 where $\mathbf{IW}_{1,1}$ is a vector made of the i^{th} row of $\mathbf{IW}_{1,1}$



ایجاد شبکه‌ی RBF - شیوه‌ی دقیق


```
net = newrbf(P,T,SPREAD)
```

P - input vectors.

T - target class vectors.

SPREAD - of radial basis functions, default = 1.0.

- در این حالت خطا برای داده‌های آموزشی صفر است.
- تعداد نرون‌های لایه‌ی مخفی برابر با داده‌های آموزشی خواهد بود.
- انتخاب SPREAD باید به دقت انجام شود.



ایجاد شبکه‌ی RBF

```
[net] = newrb(P,T,goal,spread,MN,DF)
```

P - input vectors.

T - target class vectors.


SPREAD - of radial basis functions, default = 1.0.

GOAL-Mean squared error goal (default = 0.0)

MN- Maximum number of neurons (default is Q)



DF- Number of neurons to add between displays (default = 25)

- در این حالت، به تعداد نرون‌های لایه‌ی مخفی افزوده می‌شود، تا زمانی که میزان خطا از حد تعیین شده کمتر شود و یا تعداد نرون‌های لایه‌ی مخفی به تعداد ورودی‌ها برسد.



مثال-تقریب تابع

```
P = -1:.1:1;  
T = [-.9602 -.5770 -.0729 .3771 .6405 .6600 .4609 ...  
     .1336 -.2013 -.4344 -.5000 -.3930 -.1647 .0988 ...  
     .3072 .3960 .3449 .1816 -.0312 -.2189 -.3201];  
plot(P,T,'+');  
title('Training Vectors');  
xlabel('Input Vector P');  
ylabel('Target Vector T');
```




مثال-تقریب تابع (ادامه...)


```
P = -1:.1:1;
T = [-.9602 -.5770 -.0729 .3771 .6405 .6600 .4609 ...
     .1336 -.2013 -.4344 -.5000 -.3930 -.1647 .0988 ...
     .3072 .3960 .3449 .1816 -.0312 -.2189 -.3201];
eg = 0.02; % sum-squared error goal
sc = 1;    % spread constant
net = newrb(P,T,eg,sc);
plot(P,T,'+');
xlabel('Input');

X = -1:.01:1;
Y = sim(net,X);

hold on;
plot(X,Y);
hold off;
legend({'Target','Output'})
```





انتخاب انحراف معیار



SPRED=100


SPRED=0.01




مثال

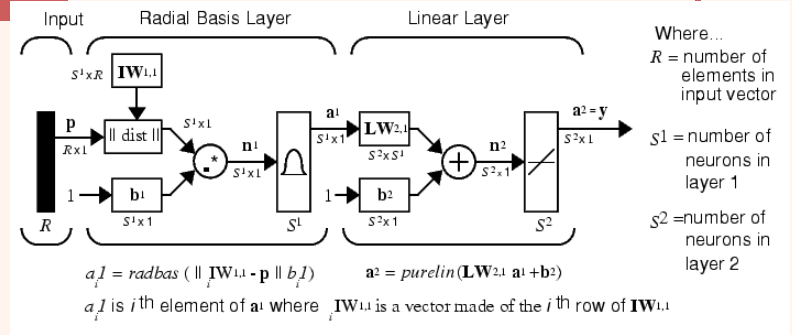
```
%generate training data (input and target)
p = [0:0.4:5];
t = cos(p*pi);
%Define and train RBF Network
net = newrb(p,t);
plot(p,t,'*r');hold;
%generate test data
p1 = [0:0.1:5];
%test network
y = sim(net,p1);
plot(p1,y,'ob');

legend('Training Data','Test Data');
xlabel('input, p');
ylabel('target, t')
```


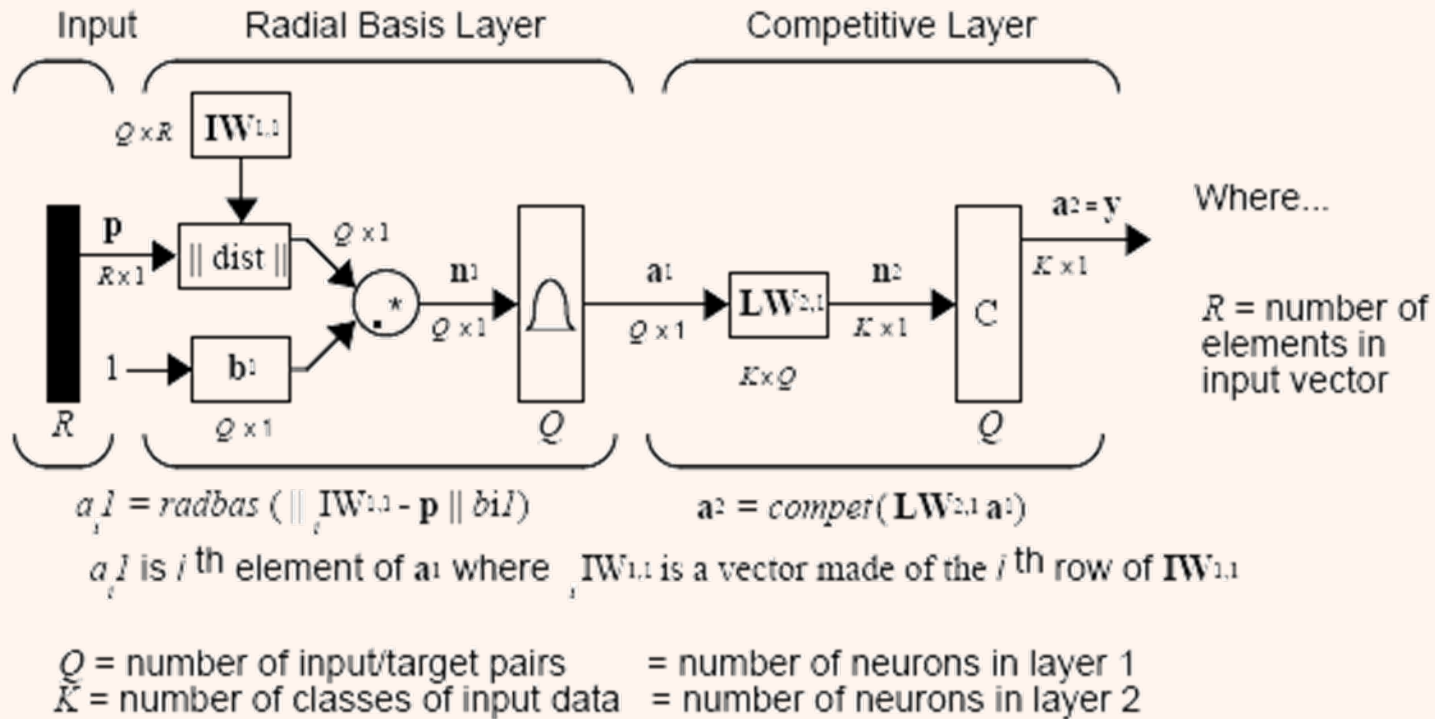




Probabilistic Neural Networks



Probabilistic Neural Network Architecture



Generalized Regression Networks

