


Camada de Kohonen

Classificação por Similaridade

Classes agrupam elementos `similares` entre si



versus classificadores arbitrários

1 - Classificação por Similaridade – Critérios de pertinência

objetos físicos $\bigcirc_1 \bigcirc_2$  objetos matemáticos $\underline{x}_1 \underline{x}_2$

similaridade física  similaridade matemática


$$\bigcirc_1 \approx \bigcirc_2$$

$$\underline{x}_1 \cong \underline{x}_2 \quad \text{ou} \quad |\underline{x}_1 - \underline{x}_2| \ll$$

Classificadores por similaridade

**Cr terios de Pertin ncia
  uma Classe**

Cr terio b sico



Dois elementos pertencem   mesma classe se est o pr ximos entre si

Critério: k vizinhos mais próximos.


Considere os k elementos mais próximos da entrada que se pretende classificar. A entrada pertence à classe à qual pertencem a maioria dos k vizinhos.

Critério simplificado: vizinho mais próximo.

Se $k=1$ uma entrada pertence a uma classe se seu vizinho mais próximo é um elemento desta classe

pouco prático


a descrição de uma classe exige a utilização de todos seus elementos (domínio da classe)



Padrão de classe:

Padrão \underline{w}_i da classe C_i

$$\underline{w}_i = \frac{E}{\forall \underline{x}_j \in C_i} \underline{x}_j = \frac{1}{N_i} \sum_{\forall \underline{x}_j \in C_i, j=1}^{N_i} \underline{x}_j$$




o baricentro é escolhido porque minimiza
a dissimilaridade

ou erro de representação
da classe



1.1 - Critério de pertinência 1 :

Padrão mais similar à entrada




$$\underline{x}_i \in C_i \quad \text{sse} \quad \left| \underline{x} - \underline{w}_i \right|^2 < \left| \underline{x} - \underline{w}_j \right|^2 \quad \forall j \neq i \quad \text{eq (1)}$$


Separadores para o critério 1




Teceragem (diagrama) de Voronoi



1.2 - Critério de pertinência 2 – Padrão que satisfaz uma similaridade mínima



$$\underline{x}_i \in C_i \quad \text{sse} \quad |\underline{x} - \underline{w}_i|^2 < r_0^2$$





eq (2)



r_0 – raio de similaridade

Separadores

Critério 1 - padrão mais similar (mais próximo) a entrada Eq(1)




Critério 2 - mínima similaridade exigida Eq (2)





1.3 - Critérios 1 e 2, Eq(1) + Eq(2)

padrão mais similar & mínima similaridade atingida



2 - Redes Neurais

Neurônio para redes feedforward




$$u_i = \sum_{j=1}^N w_{ij} x_j + w_{i0} = \underline{w}_i^t \underline{x} + w_{i0}$$

$$\tilde{y}_k = \varphi_k(u_k) = \begin{cases} u_k & \text{neurônio linear} \\ \text{tgh}(u_k) & \text{neurônio tgh} \end{cases}$$

Neurônio como medidor de similaridade

uma outra definição

$$u_i = -\|\underline{x} - \underline{w}_i\|^2 = -d_i^2 \leq 0$$



u_i - medida de similaridade entre \underline{x} e \underline{w}_i

$u_i = 0$ distância nula = máxima similaridade

y_i – depende dos outros neurônios

3- Camada de Kohonen

Template Matching

$$u_i = - d_i^2$$



maior u_i =
menor distância =
maior similaridade

u_i é uma medida de similaridade entre \underline{x} e \underline{w}_i

Winner-takes-all

$$y_i = 1 \quad \text{sse} \quad u_i > u_j \quad \forall j \neq i$$

$$y_i = 0 \quad \text{caso contrário}$$




Camada de Kohonen

[versão unidimensional, simplificada (D=0)]

Classe C_i

Padrão \underline{w}_i

Indicador y_i






Se $y_i = 1$ então $\underline{x} \in C_i$

pele critério 1 (padrão mais similar a entrada).

Camada de Kohonen

Treinamento Supervisionado



4 - Treinamento da Camada de Kohonen

$$\underline{x}(n) \in C_i \quad \Rightarrow \quad y_i = 1$$



$$y_j = 0 \quad \forall j \neq i$$

$$\underline{w}_i(n+1) = \underline{w}_i(n) + \alpha [x(n) - \underline{w}_i(n)]$$

$$= (1 - \alpha) \underline{w}_i(n) + \alpha x(n)$$

$$\underline{w}_j(n+1) = \underline{w}_j(n) \quad \forall j \neq i$$

Onde estabiliza, qual o valor final de \underline{w} ?



Evolução do \underline{w} de uma classe

Passo n: $\underline{x}(n)$ $\underline{w}(n)$

$x(n) \in C_i$

$$\begin{cases} \underline{w}_i(n+1) = (1 - \alpha) \underline{w}_i(n) + \alpha \underline{x}(n) \\ \underline{w}_j(n+1) = \underline{w}_j(n) & \forall j \neq i \end{cases}$$

$$\underline{w}(0)$$

$$\underline{w}(1) = (1-\alpha) \underline{w}(0) + \alpha \underline{x}(1)$$

$$\begin{aligned} \underline{w}(2) &= (1-\alpha) \underline{w}(1) + \alpha \underline{x}(2) \\ &= (1-\alpha)[(1-\alpha) \underline{w}(0) + \alpha \underline{x}(1)] + \alpha \underline{x}(2) \\ &= (1-\alpha)^2 \underline{w}(0) + \alpha(1-\alpha) \underline{x}(1) + \alpha \underline{x}(2) \end{aligned}$$

$$\begin{aligned} \underline{w}(3) &= (1-\alpha) \underline{w}(2) + \alpha \underline{x}(3) \\ &= (1-\alpha)[(1-\alpha)^2 \underline{w}(0) + \alpha(1-\alpha) \underline{x}(1) + \alpha \underline{x}(2)] + \alpha \underline{x}(3) \\ &= (1-\alpha)^3 \underline{w}(0) + \alpha(1-\alpha)^2 \underline{x}(1) + \alpha(1-\alpha) \underline{x}(2) + \alpha \underline{x}(3) \end{aligned}$$

⋮

$$\begin{aligned} \underline{w}(n) &= (1-\alpha)^n \underline{w}(0) + \alpha[(1-\alpha)^{n-1} \underline{x}(1) + (1-\alpha)^{n-2} \underline{x}(2) + \dots + \underline{x}_n] \\ &= (1-\alpha)^n \underline{w}(0) + \alpha \sum_{i=1}^n (1-\alpha)^{n-i} \underline{x}(i) \end{aligned}$$

algumas aproximações:

$$0 < \alpha < 1 \quad 0 < (1 - \alpha) < 1 \quad n \gg 1 \quad (1 - \alpha)^n \rightarrow 0$$

$$1 + (1 - \alpha) + (1 - \alpha)^2 + (1 - \alpha)^3 + \dots = \sum_{i=0}^{\infty} (1 - \alpha)^i = \frac{1}{1 - (1 - \alpha)} = \frac{1}{\alpha}$$

$$n \gg 1 \quad \alpha \approx \frac{1}{\sum_{i=0}^{n-1} (1 - \alpha)^i}$$

$$\underline{w}(n) = (1 - \alpha)^n \underline{w}(0) + \alpha \sum_{i=1}^n (1 - \alpha)^{n-i} \underline{x}(i)$$


$$\cong \frac{\sum_{i=1}^n (1 - \alpha)^{n-i} \bar{x}(i)}{\sum_{i=0}^{n-1} (1 - \alpha)^i} = \frac{\sum_{i=0}^{n-1} (1 - \alpha)^i \bar{x}(n-i)}{\sum_{i=0}^{n-1} (1 - \alpha)^i}$$

Média das entradas que pertencem a classe

ponderada geometricamente pelo tempo !

$$\underline{w}_n \cong \frac{\sum_{i=1}^n (1-\alpha)^{n-i} \underline{x}(i)}{\sum_{i=1}^n (1-\alpha)^{n-i}} = \left(\frac{1}{\sum_{i=0}^{n-1} (1-\alpha)^i} \right) \sum_{i=0}^{n-1} (1-\alpha)^i \underline{x}(n-i)$$


instante atual = n

$\underline{x}(n-i)$ = entrada atrasada

de i intervalos de tempo

$(1-\alpha)^i$ = ponderador

para a entrada $\underline{x}(n-i)$



Note que se

$$\alpha \cong 1$$

e a estatística de \vec{x} for invariante no tempo

$$\vec{w}_n \cong \left(\frac{1}{\sum_{i=0}^{n-1} (1-\alpha)^i} \right) \sum_{i=0}^{n-1} (1-\alpha)^i \vec{x}(n-i) \cong E[\vec{x}]$$

$$\vec{w}_n \cong E[\vec{x}]$$

4.1 – Tempo de medida

Fim (prático) da soma ponderada (tempo de medida)

Atraso zero


$$\text{Ponderador} = (1-\alpha)^0 = 1$$

Último atraso à ser considerado:

$$\text{Ponderador} = .02 = (1-\alpha)^i$$

$$i = \frac{\ln .02}{\ln(1-\alpha)} \approx \frac{-4}{-\alpha} \Big|_{\alpha \rightarrow 0}$$


$$i \approx \frac{4}{\alpha}$$



4.2 - Erro na determinação do baricentro:

Se em uma classificação por similaridade cada elemento \underline{x} de uma classe C_k pode ser representado pelo padrão \underline{w}_k da classe adicionado de um vetor de ruído \underline{r} com média nula.

$$\underline{x} = \underline{w}_k + \underline{r}$$



Cada componente x_j de \underline{x} é então representada pela componente correspondente de \underline{w}_k , w_j , adicionada de um ruído r_j de média nula e variância $\sigma_{x_j}^2$

$$x_j = w_j + r_j$$

Com que precisão componente w_j é calculada pela camada de Kohonen, qual a sua variância $\sigma_{w_j}^2$? A componente j de \underline{w} , w_j , em um instante $n \gg 1$ é dada por

$$w_j \cong \left(\frac{1}{\sum_{i=0}^n (1-\alpha)^i} \right) \sum_{i=0}^n (1-\alpha)^i x_j(n-i)$$

Sendo uma soma ponderada sua variância será dada por

$$\sigma_{w_j}^2 \cong \left(\frac{1}{\sum_{i=0}^{\infty} (1-\alpha)^i} \right)^2 \sum_{i=0}^{\infty} (1-\alpha)^{2i} \sigma_{x_j}^2 \quad \text{ou} \quad \sigma_{w_j}^2 \cong \frac{\alpha}{2} \sigma_{x_j}^2$$

4.3 – Compromisso entre Erro vs. Tempo de Medida

Quanto menor α mais precisamente o baricentro será determinado. Mas, como esperado, maior o tempo (número de passos) necessário para calculá-lo

$$\sigma_{wj}^2 \cong \frac{\alpha}{2} \sigma_{xj}^2 \qquad \# \text{ passos} = i \cong \frac{4}{\alpha}$$

Exemplo:

$$\sigma_x = .05 \quad (5\%)$$

$$\sigma_w = .01 \quad (1\%) \text{ requerido}$$

$$\alpha = \frac{2\sigma_{wj}^2}{\sigma_{xj}^2} = .08 \qquad \# \text{ passos} = \frac{4}{\alpha} = 50 \text{ passos}$$

Mas se:

$$\sigma_w = .001 \quad (.1\%) \text{ requerido}$$

$$\alpha = \frac{2\sigma_{wj}^2}{\sigma_{xj}^2} = .0008 \qquad \# \text{ passos} = \frac{4}{\alpha} = 5.000 \text{ passos !!}$$

4.4 Considerações:

4.4.1. Fim do treinamento ?



$$E[\Delta \underline{w}] = \underline{0}$$




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

$$E(\Delta \bar{w}) = E[\alpha (\bar{x} - \bar{w})] = \alpha [E(\bar{x}) - \bar{w}] = 0$$

$$\bar{w} = E(\bar{x})$$

4.4.2. Valores iniciais das sinapses

Irrelevantes ! Mas escolher o valor inicial como o primeiro elemento da classe acelera o treinamento, porque a sinapse já começa dentro da classe.



4.4.3. Passo de treinamento

reduzir ao longo do tempo $\alpha(n) = \alpha_0 e^{-\frac{n}{N_0}}$

$$\alpha(0) = \alpha_0 \quad \alpha(n+1) = k \alpha(n) \quad \text{onde} \quad k = 1 - \frac{1}{N_0}$$

o processo acaba ($\alpha(n) \ll \alpha_0$) para $n > 4N_0$

e as sinapses pouco ativadas (classes pouco populosas) ?


usar α diferenciado por sinapse

$$\alpha_{w_j}(0) = \alpha_0 \quad \alpha_{w_j}(n_j + 1) = k \alpha_{w_j}(n_j)$$

onde n_j é o número de vezes que a sinapse w_j foi treinada.

4.4.4 Treinamento dinâmico, adaptativo



Uma classe varia de posição no tempo. Como saber ?



O valor médio de $u_i = -d_i^2$ diminui

(o valor da distância média (ou a da moda) aumenta)

Como corrigir ? Ligar o treinamento até que d_i^2 volte a seus valores normais.



Se a variação do baricentro for lenta e o treinamento estiver ligado o padrão segue o baricentro

5 – Um método alternativo


LVQ – Learning Vector Quantization

$\vec{x}(n) \in C_i$ aproxima o padrão vencedor de $\vec{x}(n)$ e afasta os demais padrões de $\vec{x}(n)$

$$\vec{x}(n) \in C_i \quad \begin{cases} y_i = 1 \\ y_j = 0 \quad \forall j \neq i \end{cases}$$

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

$$\vec{w}_j(n+1) = \vec{w}_j(n) - \alpha[\vec{x}(n) - \vec{w}_j(n)] \quad \forall j \neq i$$



ou, usando uma fórmula única

$$\vec{x}(n) \in C_i \quad \begin{cases} y_i = 1 \\ y_j = 0 \quad \forall j \neq i \end{cases}$$

$$\vec{w}_j(n+1) = \vec{w}_j(n) + (2y_i - 1) \alpha [\vec{x}(n) - \vec{w}_j(n)] \quad \forall j$$

O passo de aprendizagem deve decrescer com o tempo


$$\alpha = \alpha(n) = \alpha_0 \exp\left(-\frac{n}{\tau_\alpha}\right) \quad \alpha_0 = 0,1 \quad \tau_\alpha = 1000$$

Este processo melhora as fronteiras de classificação (Haykin).

O equilíbrio é atingido quando $E[\Delta\vec{w}_i] = \vec{0}$, o que ocorre quando

$$\begin{aligned}\vec{w}_i &= p_i \underline{E}_{\forall \vec{x} \in C_i}(\vec{x}) - (1-p_i) \underline{E}_{\forall \vec{x} \notin C_i}(\vec{x}) = \\ &= 2p_i \underline{E}_{\forall \vec{x} \in C_i}(\vec{x}) - \underline{E}_{\forall \vec{x}}(\vec{x}) = \\ &= 2p_i \vec{m}_i - \vec{m}\end{aligned}$$

onde p_i é a probabilidade de uma entrada \vec{x} pertencer à classe C_i , \vec{m}_i é o baricentro de C_i e \vec{m} é o baricentro de todas as entradas, normalmente $\vec{m} = \vec{0}$. O efeito é deslocar os padrões das classes (*) para longe do centro de todas as entradas (●) mas também dos baricentros (○) das mesmas.



Este processo corresponde a otimizar a função objetivo

$$F(\vec{w}_i) = \sum_{\forall \vec{x} \in C_i} |\vec{x} - \vec{w}_i|^2 - \sum_{\forall \vec{x} \notin C_i} |\vec{x} - \vec{w}_i|^2$$

isto é, minimizar a dispersão intra classe de C_i e maximizar a distância de w_i aos elementos das outras classes.


6 - E o segundo critério (similaridade mínima) ?

Camada de Kohonen (aumentada)

$$u_0 = -r_0^2$$

Se $y_i = 1$ então

$$\underline{x} \in C_i$$



pelos critérios **1** (padrao mais similar a entrada) e **2** (satisfaz a similaridade minima exigida).

Se $y_i = 1$ então

$$\underline{x} \in C_i$$


pelos critérios

- 1 (centro de classe mais similar à entrada) e
- 2 (satisfaz à similaridade mínima)

Se $y_0 = 1$ então

$$\underline{x} \notin C_i \quad \forall i$$

\underline{x} não satisfaz ao critério 2
para nenhuma classe



7 – HVQ – Hierarquical Vector Quantization

