

MAPAS AUTOORGANIZATIVOS Y MODELOS SIMILARES

José D. Martín Guerrero, Emilio Soria, Antonio J. Serrano

PROCESADO Y ANÁLISIS DE DATOS AMBIENTALES

Curso 2009-2010



Esquema.

Mapas autoorganizativos.

Learning Vector...

Radial Basis Function

[Home Page](#)

[Title Page](#)



[Page 1 of 11](#)

[Go Back](#)

[Full Screen](#)

[Close](#)

[Quit](#)

1. Esquema.

- Mapas autoorganizativos.
- Learning Vector Quantization.
- Radial Basis Function Neural Network.

Esquema.

Mapas autoorganizativos.

Learning Vector . . .

Radial Basis Function

[Home Page](#)

[Title Page](#)



Page 2 of 11

[Go Back](#)

[Full Screen](#)


[Close](#)

[Quit](#)

2. Mapas autoorganizativos.

Arquitectura: Mapa de neuronas.

Idea: Patrones de entrada similares quedan asociados a neuronas cercanas en el mapa mediante un proceso de autoorganización (*Self-Organizing Map: SOM*) \Rightarrow Preserva las relaciones topológicas con los patrones de entrada.



Actualización de los pesos de la neurona ij :

$$\mathbf{w}_{ij}(t+1) = \mathbf{w}_{ij}(t) + \alpha(t)h_t(\mathbf{w}_{ij})(\mathbf{x}(t) - \mathbf{w}_{ij}(t))$$

- $\mathbf{x}(t)$ es el patrón de entrada correspondiente.
- $\alpha(t)$ determina el ritmo del aprendizaje (decreciente por razones de estabilidad).
- $h_t(\mathbf{w}_{ij})$ es la función de vecindad: establece el radio de neuronas vecinas de la neurona ganadora que se actualizan y el grado en el que lo hacen.

Esquema.

Mapas autoorganizativos.

Learning Vector...

Radial Basis Function

Home Page

Title Page

◀ ▶

◀ ▶

Page 3 of 11

Go Back

Full Screen

Close

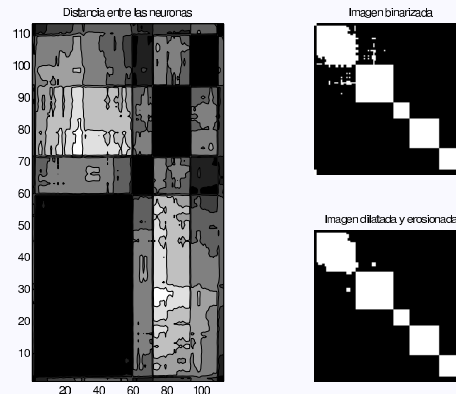
Quit

Variantes del SOM:

- Estructuras toroidales para vencer el problema de actualización de las neuronas situadas en los bordes del mapa.
- Neural Gas.
- Algoritmo de consciencia.
- Growing Grid Algorithm.

Extracción de grupos:

- Tratamiento digital de imágenes: distancias entre neuronas, binarización, erosión y dilatación.



- Método basado en agrupamiento jerárquico: unión de neuronas próximas en el mapa + algoritmo de agrupamiento jerárquico de enlace completo.

Esquema.

Mapas autoorganizativos.

Learning Vector...

Radial Basis Function

Home Page

Title Page



Page 4 of 11

Go Back

Full Screen

Close

Quit

3. Learning Vector Quantization

Arquitectura y funcionamiento: SOM

Tipo de aprendizaje: supervisado.

Algoritmo clásico \Rightarrow LVQ1:

1. Se inicializan prototipos.
2. \forall patrón de entrada se encuentra el prototipo más cercano:
 - (a) Si las clases del vector de entrada y del vencedor son iguales, se acerca el vector ganador al de entrada:

$$w^* = w^* + \alpha(x - w^*) \text{ si } \text{clase}(x) = \text{clase}(w^*)$$

- (b) En caso contrario, se alejan:

$$w^* = w^* - \alpha(x - w^*) \text{ si } \text{clase}(x) \neq \text{clase}(w^*)$$

3. Existe un vector de pesos asociado a cada *cluster*.
4. Una vez entrenado puede funcionar como un clasificador.
5. Habitualmente α es inversamente proporcional al número de iteraciones, pero existe una variante (Optimum LVQ1) en el que viene definida por la siguiente expresión:

$$\alpha_l(n) = \frac{\alpha_l(n-1)}{1 + (-1)^\beta \alpha_l(n-1)}$$

donde $\beta = 0$ si se clasifica correctamente el patrón y 1 en caso contrario.

Esquema.

Mapas autoorganizados.

Learning Vector ...

Radial Basis Function

Home Page

Title Page

◀ ▶

◀ ▶

Page 5 of 11

Go Back

Full Screen

Close

Quit

Algoritmo LVQ2.1: Tiene en cuenta tanto el peso (prototipo) vencedor como el 2º clasificado. La adaptación de estos pesos depende de varios factores:

- Los dos pesos corresponden a clases diferentes.
- El vector de entrada pertenece a la misma clase que uno de ellos.
- El vector de entrada está en una ventana definida sobre el punto medio de estos dos vectores:

$$\min \left(\frac{d_1}{d_2}, \frac{d_2}{d_1} \right) > \frac{1 - \omega}{1 + \omega}$$

siendo d_1 y d_2 las distancias de los dos vectores más próximos al vector de entrada y ω la anchura de la ventana. Actualización de los pesos:

$$w_k = w_k + \alpha(x - w_k)$$

$$w_j = w_j - \alpha(x - w_j)$$

donde los pesos k y j son los más cercanos, y $x \in C_k$

Algoritmo LVQ3: Se preocupa de donde acaban los pesos al final del proceso de aprendizaje. Si los dos pesos más cercanos representan a la misma clase, ambos se actualizan:

$$w_k = w_k + \beta\alpha(x - w_k)$$

donde $\beta < 1$. Los pesos no solamente respetan las fronteras de decisión sino también la distribución de los datos de entrada.

CONSEJOS PRÁCTICOS:

- Utilizar OLVQ1 hasta la convergencia.
- Realizar ajuste fino con LVQ1 o LVQ3.
- No utilizar durante muchas iteraciones LVQ2.1.

Esquema.

Mapas autoorganizativos.

Learning Vector . . .

Radial Basis Function

Home Page

Title Page

◀◀ ▶▶

◀ ▶

Page 7 of 11

Go Back

Full Screen

Close

Quit


4. Radial Basis Function

Arquitectura: una capa de entrada, una capa de neuronas que realizan un procesado no lineal de las entradas y una capa de salida.

Salida i -ésima:

$$y_i = f_i(\mathbf{x}) = \sum_{k=1}^N w_{ik} \phi_k(\mathbf{x}, \mathbf{c}_k) = \sum_{k=1}^N w_{ik} \phi_k(\|\mathbf{x} - \mathbf{c}_k\|_2), \quad i = 1, 2, \dots, m$$

donde $\mathbf{x} \in \mathbb{R}^{n \times 1}$ es el vector de entrada, $\phi_k(\cdot) : \mathbb{R}^+ \rightarrow \mathbb{R}$, w_{ik} los pesos de la capa de salida, N el número de neuronas de la capa oculta y $\mathbf{c}_k \in \mathbb{R}^{n \times 1}$ los centros RBF de los vectores de entrada.



Esquema.

Mapas autoorganizativos.

Learning Vector...

Radial Basis Function

Home Page

Title Page

◀ ▶

◀ ▶

Page 8 of 11

Go Back

Full Screen

Close

Quit

Típicas funciones $\phi(\cdot)$:

1. Función lineal: $\phi(x) = x$
2. Aproximación cúbica: $\phi(x) = x^3$
3. Función “thin-plate-spline”: $\phi(x) = x^2 \ln x$
4. Función Gaussiana: $\phi(x) = \exp\left(\frac{-x^2}{\sigma^2}\right)$
5. Función multicuadrática: $\phi(x) = \sqrt{x^2 + \sigma^2}$
6. Función multicuadrática inversa: $\phi(x) = \frac{1}{\sqrt{x^2 + \sigma^2}}$

En estas funciones x se refiere a $\|x - c\|$. En la capa oculta de la RBF, se calculan las distancias respecto a los centros (entrada y centro asociado).

Esquema.

Mapas autoorganizativos.

Learning Vector . . .

Radial Basis Function

Home Page

Title Page



Page 9 of 11

Go Back

Full Screen

Close

Quit

Aprendizaje de las RBF

- 1ª fase: Cálculo de los centros y de los parámetros de la función base de manera no supervisada (minimización de la dispersión inter-grupo).
- 2ª fase: Cálculo de los pesos w_{ik} minimizando:

$$J(n) = \frac{1}{2} |e(n)|^2 = \frac{1}{2} \left[y_d(n) - \sum_{k=1}^N w_k(n) \phi \{x(n), c_k(n)\} \right]^2$$

Si la RBF es gaussiana:

$$J(n) = \frac{1}{2} \left[y_d(n) - \sum_{k=1}^N w_k(n) \exp \left(-\frac{\|x(n) - c_k(n)\|_2^2}{\sigma_k^2(n)} \right) \right]^2$$

Ecuaciones de actualización:

$$w(n+1) = w(n) - \mu_w \frac{\partial J(n)}{\partial w}$$

Los parámetros calculados en la primera fase también se pueden calcular por descenso de gradiente.

Esquema.

Mapas autoorganizativos.

Learning Vector...

Radial Basis Function

Home Page

Title Page



Page 10 of 11

Go Back

Full Screen

Close

Quit

Home Page

Title Page



Page 11 of 11

Go Back

Full Screen

Close

Quit

RBF comparado con (MLP):

- Activación igual en hiperelipsoides (hiperplanos).
- Información localizada (distribuida).
- Estructura fija de dos capas diferenciadas (múltiples capas).
- Aprendizaje rápido (no lineal).
- Aprendizaje en dos etapas: supervisada y no supervisada (una etapa supervisada).

Consejos:

- Se debe usar RBF en sistemas adaptativos de aprendizaje rápido, cuando haya fuertes no linealidades presentes o cuando la función de distribución dé idea de la importancia de los datos.
- Se debe usar MLP cuando haya escasez de muestras o se necesite extrapolación de datos.