

Redes Neuronales Artificiales Competitivas No Supervisadas

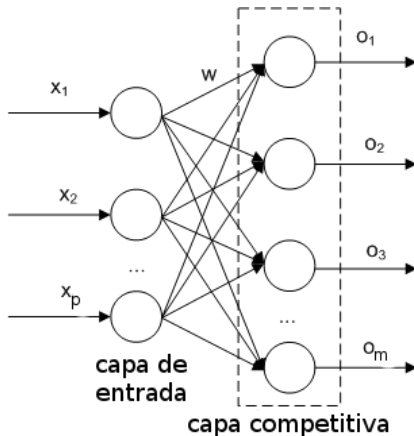
Carleos Arttime, C.; Corral Blanco, N.

13 de mayo de 2021

Redes Neuronales Artificiales Competitivas No Supervisadas

Red Neuronal Competitiva No Supervisada

- Las neuronas de salida compiten entre ellas para activarse.
- Sólo se activa la que alcanza un mayor *potencial sináptico*.
- Las neuronas se especializan en detectar la presencia de ciertos patrones de entrada.



Redes Neuronales Artificiales Competitivas No Supervisadas

Los elementos básicos de estas redes son:

- La capa de entrada. Vector de entrada: $\vec{x} = (x_1, \dots, x_p)$
- La capa de salida, que tiene naturaleza competitiva:
 - Sus neuronas son de naturaleza binaria.
 - Sólo pueden activarse una con cada patrón de entrada.
- Potencial sináptico de la neurona de salida k :

$$h_k = \sum_{r=1}^p w_{kr} x_r - \frac{1}{2} \sum_{r=1}^p w_{kr}^2 = -\frac{1}{2} \|\vec{w}_k - \vec{x}\|^2 + \text{constante}$$

- La neurona con mayor potencial sináptico es la que tiene la menor distancia euclídea entre su vector de pesos \vec{w}_k y \vec{x} .
- La salida k vale: $o_k = \begin{cases} 1 & \text{si } h_k = \text{máx}\{h_1, \dots, h_m\} \\ 0 & \text{en otro caso} \end{cases}$

Redes Neuronales Artificiales Competitivas No Supervisadas

Entrenamiento de la red:

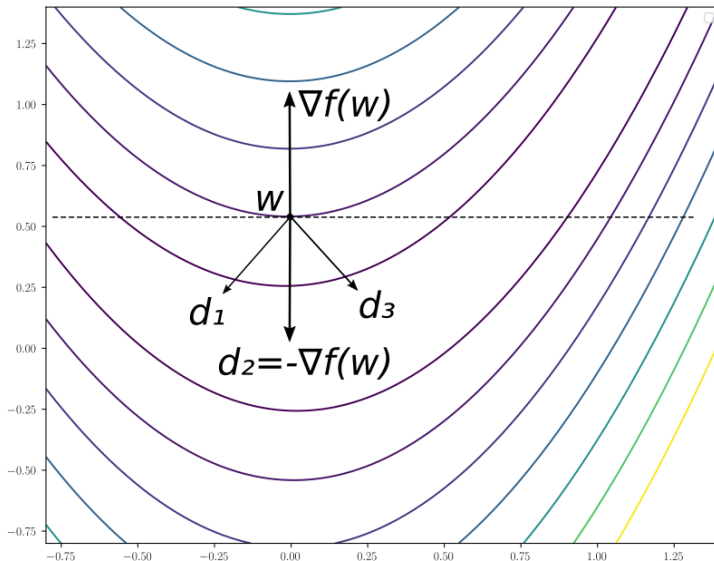
- Objetivo: Conseguir que los pesos sean una buena representación de los datos de entrenamiento.
- Procedimiento: Activar la neurona cuyos pesos sean los más parecidos al patrón de entrada.

Para ello se define el siguiente error:

$$E(\vec{x}) = \sum_{k=1}^m a_k \|\vec{x} - \vec{w}_k\|^2 = \sum_{k=1}^m a_k \sum_{r=1}^p (x_r - w_{kr})^2$$

$$\text{donde } a_k = \begin{cases} 1 & \text{si } \|\vec{x} - \vec{w}_k\|^2 = \min_{i=1, \dots, m} \|\vec{x} - \vec{w}_i\|^2 \\ 0 & \text{en el resto} \end{cases}$$

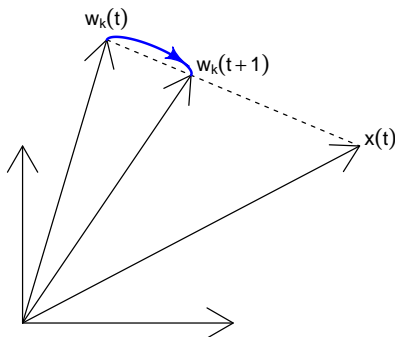
Redes Neuronales Artificiales Competitivas No Supervisadas



Redes Neuronales Artificiales Competitivas No Supervisadas

Los pesos sinápticos se estiman, de manera iterativa, usando el descenso del gradiente para minimizar el error

$$w_{kj}(t+1) = w_{kj}(t) - \eta_t \frac{\partial E}{\partial w_{kj}} = w_{kj}(t) + \eta_t a_k \sum_{r=1}^p (x_r - w_{kr})$$



Redes Neuronales Artificiales Competitivas No Supervisadas

Los pesos sinápticos se estiman, de manera iterativa, usando el descenso del gradiente para minimizar el error

$$w_{kj}(t+1) = w_{kj}(t) - \eta_t \frac{\partial E}{\partial w_{kj}} = w_{kj}(t) + \eta_t a_k \sum_{r=1}^p (x_r - w_{kr})$$

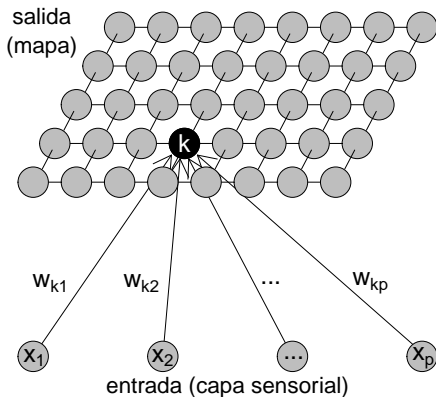
En cada iteración sólo cambian los pesos de la neurona ganadora.

La tasa de aprendizaje debe disminuir con cada iteración del proceso de entrenamiento. Algunos criterios habituales son:

- $\eta_t = \eta_0 e^{-t/\lambda}$
- $\eta_t = 1 - \frac{t}{T}$ con $T =$ número máximo de iteraciones

Mapas de Kohonen (Self Organizing Map, SOM)

- Son redes de aprendizaje no supervisado.
- Tienen naturaleza competitiva.
- Se construyen teniendo en cuenta las posiciones que ocupan las neuronas.



Mapas de Kohonen

Los elementos básicos de una red de Kohonen son:

- La capa de salida está formada por una rejilla rectangular, de neuronas binarias, de tamaño $m_1 \times m_2$. La rejilla también puede ser hexagonal.
- Cada neurona k de la capa de salida tiene asociado un vector de posición en el plano $\vec{p}_k = (p_{k1}, p_{k2})$
- La proximidad entre las neuronas de la capa de salida. La función más usual es

$$T_{g,k} = \exp\left(-\frac{d^2(\vec{p}_g, \vec{p}_k)}{2\sigma^2}\right)$$

donde

$$d(p_g, p_k) = \left(|p_{g1} - p_{k1}|^\alpha + |p_{g2} - p_{k2}|^\alpha\right)^{\frac{1}{\alpha}}$$

- $\alpha = 1 \implies d$ es la distancia de Manhattan
- $\alpha = 2 \implies d$ es la distancia euclídea

Mapas de Kohonen

Etapas del algoritmo de una red de Kohonen:

- 1 Calcular el valor de activación de cada neurona de salida

$$h_k(\vec{x}) = \exp(-d^2(\vec{x}, \vec{w}_k))$$

Neurona ganadora: vector de pesos más cercano al patrón de entrada.

- 2 Medir la proximidad de las neuronas respecto a la ganadora g :

$$T_{g,k}(t) = \exp\left(-\frac{d^2(\vec{p}_g, \vec{p}_k)}{2\sigma_t^2}\right)$$

Influye el radio de vecindad, σ_t , que va decreciendo con cada iteración. Un criterio habitual es $\sigma_t = \sigma_0 \exp(-t/\tau)$.

- 3 Los pesos se modifican teniendo en cuenta la cercanía a la ganadora

$$w_{kr}(t+1) = w_{kr}(t) + \eta_t T_{g,k}(t)(x_r - w_{kr})$$

En el entrenamiento de una red de Kohonen hay dos etapas.

- 1 Auto-organización: Organización topológica de los vectores de pesos. Inicialmente se consideran una tasa de aprendizaje y radio de vecindad altos. Por ejemplo, $\eta_0 = 1$ y $\sigma_0 = \text{diámetro del mapa}$.
- 2 Convergencia: Está dirigida a obtener valores estables de los pesos sinápticos. Se suele emplear una tasa de aprendizaje pequeña (0,05) y un radio igual a 1 (distancia mínima entre intersecciones de la rejilla).

En implementaciones simplificadas como la de `class` de R, se usa

$$T_{g,k}(t) = \begin{cases} 1 & d(\vec{p}_g, \vec{p}_k) \leq \sigma_t \\ 0 & d(\vec{p}_g, \vec{p}_k) > \sigma_t \end{cases}$$

Entonces, para $\sigma_t = \sigma$ fijo,

$$\lim_{t \rightarrow \infty} \vec{w}_k = \bar{x}_{k,\sigma} = \frac{\sum_g T_{g,k} \sum V_g}{\sum_g T_{g,k} \cdot \#V_g}$$

donde $V_g = \{\vec{x}_i \mid g = \arg \min_j \|\vec{x}_i - \vec{w}_j\|\}$ es el conjunto de patrones de entrada asociados a la neurona de salida g .

Par tanto, los pesos de k tienden a la media de los patrones asociados a las neuronas de salida próximas a k .

Se repite el cálculo para una secuencia $\sigma_1 > \sigma_2 > \dots > \sigma_n = 0$