

OPENCOURSEWARE
REDES DE NEURONAS ARTIFICIALES
Inés M. Galván – José M. Valls



Preguntas y Ejercicios para Evaluación: Tema 4

1. Indique características del aprendizaje no supervisado que no aparezcan en el aprendizaje supervisado de las redes de neuronas.

Respuesta

No se disponen de salidas deseadas. Competición entre las neuronas. Concepto de vecindad entre neuronas

2. Señale las afirmaciones correctas (puede haber más de una):
 - a) El aprendizaje competitivo es una forma de aprendizaje no supervisado en el que las neuronas compiten unas con otras.
 - b) El aprendizaje competitivo es una forma de aprendizaje no supervisado utilizado para resolver problemas de clasificación, regresión y agrupación.
 - c) El aprendizaje competitivo es una forma de aprendizaje no supervisado en el que los pesos de la capa de entrada con la neurona ganadora son reforzados.
 - d) El aprendizaje de los mapas de Kohonen es un tipo de aprendizaje competitivo.

Respuesta

a), c) y d)

- 3.Cuál de las siguientes afirmaciones sobre los mapas de Kohonen es cierta:
 - a) Durante el aprendizaje de los mapas de Kohonen los pesos de todas las neuronas de la capa de competición son actualizados en cada ciclo.
 - b) Durante el aprendizaje de los mapas de Kohonen las n neuronas de la capa de competición más cercanas a los patrones de entrada se acercan a los patrones de entrada, aunque no en la misma proporción.
 - c) El aprendizaje de los mapas de Kohonen consiste en posicionar las neuronas de mapa de forma que estén distribuidos por todo el espacio de entrada.
 - d) En los mapas de Kohonen la activación de una neurona de la capa de competición depende de la activación de las neuronas del vecindario.
 - e) En los mapas de Kohonen la activación de una neurona de la capa de competición depende del patrón de entrada y de la posición de la neurona en el espacio de entrada.
 - f) Una vez realizado el aprendizaje de un mapa de Kohonen, cada neurona del mapa representará un patrón de entrada.

Respuesta

b), c) y e)

4. Los pesos μ_{ij} en los mapas autoorganizados de Kohonen se ajustan siguiendo la siguiente ley de aprendizaje:

$$\Delta\mu_{ij} = \frac{\alpha(t)}{d(c_j, c_{ganadora})} (e_i(t) - \mu_{ij}(t))$$

siendo e_i la coordenada i del patrón de entrada, $\alpha(t)$ la razón de aprendizaje y $d(c_j, c_{ganadora})$ el término que mide la distancia del vecindario de la neurona. Conteste brevemente a las siguientes preguntas:

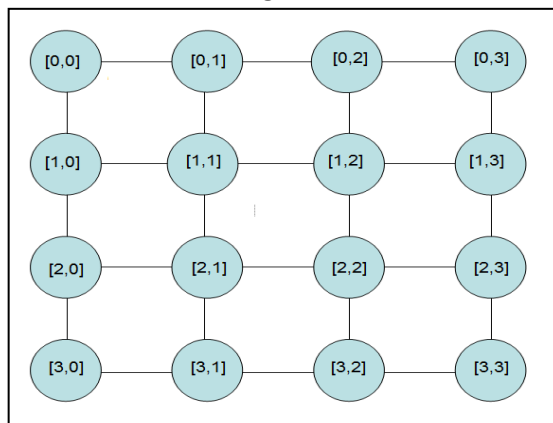
- ¿Cómo afecta en el aprendizaje el parámetro $\alpha(t)$?
- ¿Cómo afecta el término $(e_i(t) - \mu_{ij}(t))$ en el aprendizaje?
- ¿Cómo afecta $\frac{1}{d(c_j, c_{ganadora})}$ en el aprendizaje?

Respuesta

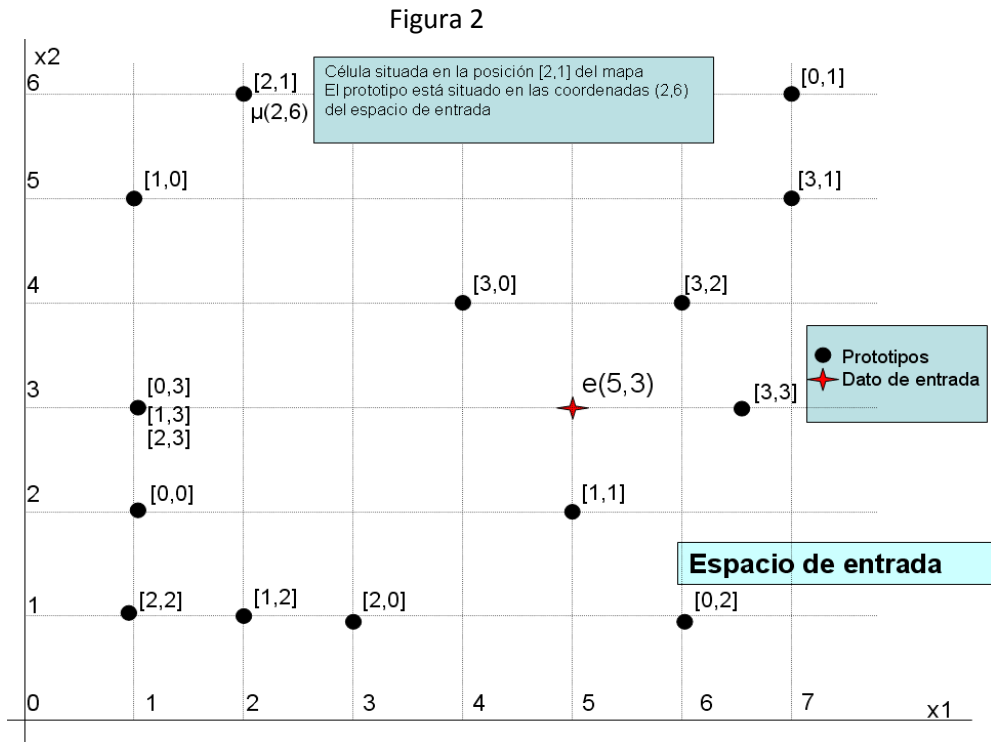
- Controla los cambios en los pesos durante el aprendizaje. Su valor va disminuyendo a lo largo de los ciclos.
- Acerca la neurona j al patrón de entrada $e=(e_1, \dots, e_n)$
- No sólo se acerca la neurona ganadora j (para la cual el término $\sigma(c_i, c_j)$ vale 1), sino que también acerca las neuronas situadas en el vecindario de dicha neurona, acercándose en menor medida cuanto más lejos se encuentre en el vecindario. El valor $\sigma(c_i, c_j)$ va aumentando a medida que se alejan de la neurona ganadora.

5. Se dispone de un mapa de Kohonen rectangular como se muestra en la Figura 1:

Figura1



La capa de entrada tiene dos neuronas. En la figura 2 se muestra la situación inicial de los vectores característicos de cada neurona (prototipos) en el espacio de entrada, así como la posición de un patrón $e(x_1, x_2)$ que se presenta a la red. Los números entre corchetes [a,b] corresponden a la célula en el mapa, no son coordenadas en el espacio de entrada. Las coordenadas se pueden ver con la cuadrícula. Por ejemplo, el prototipo de la célula [1,1] está situado en las coordenadas (5,2).



Se pide: **Calcular** las posiciones que ocuparán los prototipos una vez que se apliquen las ecuaciones de aprendizaje a las células que correspondan. **Dibujar** en el mismo gráfico las nuevas posiciones de los prototipos modificados.

Se tendrán en cuenta las siguientes consideraciones: La tasa de aprendizaje para esta iteración será $\alpha(t) = 0.5$. La topología es rectangular. La distancia de vecindario d de la célula ganadora con ella misma se considerará 1 . Se considerará $d=2$ si las células están a un paso de la ganadora (arriba, abajo, izquierda y derecha), $d=3$ si están a dos pasos, y así sucesivamente. El límite de vecindario es $\vartheta=2$, es decir sólo se verán afectadas las células más cercanas a la ganadora.

Respuesta

Neurona Ganadora [1,1], cuyos pesos son $\mu(5,2)$

Dato de entrada $e(5,3)$

Utilizando la ley de aprendizaje $\Delta\mu_{ij} = \frac{\alpha(t)}{d(c_j, c_{ganadora})} (e_i - \mu_{ij})$, se modifican los

pesos de la neurona ganadora. En este caso $d=1$

$$\Delta \mu_1 = \alpha (e_1 - \mu_1) = 0.5 (5-5)=0; \mu_1=5$$

$$\Delta \mu_2 = \alpha (e_2 - \mu_2) = 0.5 (3-2)=0.5; \mu_2 =2.5$$

Posición final: $\mu(5,2.5)$

Neuronas vecinas [0,1], [2,1], [1,0] y [1,2]

Para [0,1], los pesos son: $\mu(7,6)$

Teniendo em cuenta que $d=2$, los nuevos pesos son:

$$\Delta \mu_1 = \alpha (e_1 - \mu_1) = 0.5/2 (5-7)=-0.5; \mu_1=4.5$$

$$\Delta \mu_2 = \alpha (e_2 - \mu_2) = 0.5/2 (3-6)=-0.75; \mu_2 =5.25$$

Posición final: μ (4.5, 5.25)
Igual con [2,1], [1,0] y [1,2]

6. Disponemos de un conjunto de datos bidimensionales, que siguen una distribución toroidal (ver figura 1). Con estos datos entrenamos un mapa de Kohonen con estructura unidimensional y con 10 neuronas (figura 2).

Figura 1






Figura 2




Dibujar la localización de las neuronas del mapa una vez entrenado cuando se ha utilizado el vecindario (a) y cuando no se ha utilizado (b). Explique el efecto del uso de vecindario en los mapas de Kohonen.

Respuesta

a) Con vecindario



b) Sin vecindario



El uso de vecindario durante el aprendizaje implica que neuronas vecinas en el mapa, lo serán también en el espacio de entrada

7. Disponemos de datos socioeconómicos de 100 países que forman parte de la ONU, compuestos por 45 variables (renta per cápita, índice de alfabetización, producto interior bruto, etc). Queremos utilizar los mapas autoorganizados de Kohonen para extraer información de estos datos, que nos permita detectar grupos de países similares.
- ¿Cuál sería la arquitectura apropiada?
 - ¿Qué parámetros deberían definirse para realizar el aprendizaje?
 - Queremos que neuronas próximas en el mapa representen datos próximos en el espacio de entrada de 45 dimensiones. ¿Qué parámetro es importante?
 - ¿Qué ocurre si no se tiene en cuenta el vecindario, de forma que sólo se actualizan los pesos de la neurona ganadora?.
 - ¿En qué consiste un gráfico umatrix? ¿Para qué sirve?

Respuesta

- Un mapa bidimensional que tenga como máximo 100 neuronas. Sería recomendable que tuviera bastantes menos, por ejemplo, un mapa de 5 x 5 sería adecuado. Los países se distribuirían en 25 zonas.
 - Tasa inicial de aprendizaje y tamaño inicial del vecindario.
 - El tamaño del vecindario.
 - Si no se tiene en cuenta el vecindario, puede ocurrir que neuronas vecinas en el mapa representen a zonas completamente distintas en el espacio de entrada (países de características muy diferentes).
 - Representación bidimensional del mapa, donde las distancias entre los prototipos se codifican con colores o con niveles de gris. Sirve para tener una idea de la distribución de los prototipos en el espacio de entrada.
8. Disponemos de un mapa autoorganizado de Kohonen unidimensional, con 10 neuronas en la capa de competición y dos neuronas de entrada, como se muestra en la Figura 1.




Figura1

Los pesos iniciales del mapa se indican en la Tabla 1 y su representación gráfica en el espacio de entrada en la Figura 2. Se pide:

a) Calcular los nuevos pesos de la red cuando se presenta el patrón (0.2, 0.5), teniendo en cuenta que se define el vecindario como la neurona situada a la derecha y a la izquierda de la neurona ganadora, la distancia de vecindario entre una neurona y sus vecinas es 2 y la razón de aprendizaje es $\alpha=0.1$. La expresión de la ley de aprendizaje es la siguiente:

$$\Delta\mu_{ik} = \frac{\alpha}{D}(e_i - \mu_{ik})$$

$i=1,2$; k indica la neurona cuyo peso se modifica; D : distancia de vecindario a la neurona ganadora

n1	0.62	0.37
n2	0.73	0.05
n3	0.76	0.21
n4	0.01	0.02
n5	0.90	0.79
n6	0.16	0.52
n7	0.58	0.13
n8	0.38	0.05
n9	0.68	0.07
n10	0.16	0.16

Tabla 1




Figura 2

b) Supóngase que los 10 puntos en la figura 2 representan la posición inicial de 10 prototipos para el algoritmo LVQ. Dado el patrón (0.2, 0.5). ¿Podría realizar una iteración del algoritmo? Justifique su respuesta.

Respuesta

a) La neurona n6 (0.16, 0.52) es la más cercana al patrón de entrada (0.2, 0.5). Por tanto las neuronas vecinas serán n5(0.90, 0.79) y n7(0.58, 0.13).

Nuevos pesos de la neurona ganadora n6:

$$\Delta \mu_{16} = \alpha (e_1 - \mu_{16}) = 0.1 (0.2 - 0.16) = 0.004;$$

$$\mu_{16} = 0.16 + 0.004 = \mathbf{0.164}$$

$$\Delta \mu_{26} = \alpha (e_2 - \mu_{26}) = 0.1 (0.5 - 0.52) = -0.002;$$

$$\mu_{26} = 0.52 - 0.002 = \mathbf{0.518}$$

Como puede observarse, la neurona ganadora se ha acercado al patrón de entrada
Posición final: μ_6 (0.164, 0.518)

Nuevos pesos de las neuronas vecinas n5 y n7. Distancia de vecindario = 2

n5(0.9, 0.79):

$$\Delta \mu_{15} = \alpha/2 (e_1 - \mu_{15}) = 0.05 (0.2 - 0.90) = -0.035;$$
$$\mu_{15} = 0.90 - 0.035 = \mathbf{0.865}$$

$$\Delta \mu_{25} = \alpha/2 (e_2 - \mu_{25}) = 0.05 (0.5 - 0.79) = -0.0145;$$
$$\mu_{25} = 0.79 - 0.0145 = \mathbf{0.775}$$

Posición final: μ_5 (**0.865, 0.775**)

n7(0.58, 0.13):

$$\Delta \mu_{17} = \alpha/2 (e_1 - \mu_{17}) = 0.05 (0.2 - 0.58) = -0.019;$$
$$\mu_{17} = 0.58 - 0.019 = \mathbf{0.561}$$

$$\Delta \mu_{27} = \alpha/2 (e_2 - \mu_{27}) = 0.05 (0.5 - 0.13) = 0.0185;$$
$$\mu_{27} = 0.13 + 0.0185 = \mathbf{0.1485}$$

Posición final: μ_7 (**0.561, 0.1485**)

b) No podría hacerse la iteración del algoritmo LVQ porque es necesario que los prototipos estén etiquetados