

SEGMENTADO DE IMAGEN EMPLEANDO UNA ARQUITECTURA NEURONAL DE TIPO SELF-ORGANIZING MAP

Álvaro Anzueto Ríos (Profesor), Yesenia Eleonor González Navarro, Rafael Santiago Godoy
Academia de Sistemas / Unidad Profesional Interdisciplinaria en Ingeniería y Tecnologías Avanzadas
Instituto Politécnico Nacional – UPIITA
aanzueto@ipn.mx, nohemib2702@gmail.com

Anzueto, A., González, Y. & Santiago, R. (1 de noviembre de 2023). Segmentado de Imagen Empleando Una Arquitectura Neuronal de tipo Self-Organizing Map. Boletín UPIITA. 18 (99).

Resumen

La regla de aprendizaje de Kohonen es implementada en una arquitectura neuronal para generar un Mapa Autoorganizado (Self-Organizing Map, SOM) que es capaz de realizar tareas de agrupamiento de datos. Esta idea es aplicada, en este trabajo, para agrupar píxeles en una imagen considerando como característica de estudio el nivel de gris, aplicándose así en una sola dimensión. La idea inicia organizando los niveles de gris por su número de ocurrencia y se considera un rango numérico de 0 a 255, esto permite generar el histograma correspondiente. Con la obtención del histograma, cada nivel de gris es presentado a la arquitectura SOM y ponderado según su frecuencia de ocurrencia, evitando así procesar de manera individual cada píxel que posea el mismo valor de gris. Una vez concluido el proceso de entrenamiento, la imagen se evalúa una vez más y finalmente cada nivel de gris se reasignado a la neurona cuyo peso es más cercano, generando grupos de píxeles con un mismo valor numérico, en otras palabras, se producen regiones dentro de la imagen que comparten la misma tonalidad de gris, ya que están asignadas a la misma neurona.

Abstract

The Kohonen learning rule is implemented in a neural architecture to generate a Self-Organizing Map (SOM) capable of performing data clustering tasks. This idea is applied in this work to cluster pixels in an image considering the gray level as a study characteristic, thus applying it in a single dimension. The idea begins by organizing the gray levels by their number of occurrences and considers a numerical range from 0 to 255, which allows generating the corresponding histogram. With the histogram obtained, each gray level is presented to the SOM architecture and weighted according to its frequency of occurrence, thus avoiding individual processing of each pixel with the same gray value. Once the training process is finished, the image is evaluated once more and finally each gray level is reassigned to the neuron whose weight is closest, generating groups of pixels with the same numerical value; in other words, regions are produced within the image that share the same gray tone since they are assigned to the same neuron.

1. Introducción

El procesamiento de imágenes digitales es una disciplina esencial en áreas como la visión artificial, la medicina y la teledetección. Uno de los desafíos fundamentales es la segmentación de imágenes, que consiste en dividir una imagen en regiones significativas que compartan propiedades visuales similares, como la intensidad del color o el nivel de gris. Tradicionalmente, técnicas como el umbralizado de Otsu o algoritmos de agrupamiento como k-means han sido utilizados para este propósito. Sin embargo, los Mapas Autoorganizados (SOM), propuestos por Teuvo Kohonen, ofrecen una alternativa potente basada en redes neuronales no supervisadas para la reducción de dimensionalidad y el agrupamiento de datos. En este documento se explora el uso de un SOM unidimensional (1D) para la segmentación de imágenes en escala de grises.

2. Histogramas en Imágenes de Escala de Grises

Un histograma es una representación gráfica de la distribución de las intensidades de los píxeles en una imagen. Para una imagen en escala de grises con niveles de intensidad en el rango $[0, L - 1]$, el histograma es una función discreta:

$$h(r_k) = n_k \quad (1)$$

donde r_k es el k -ésimo nivel de intensidad y n_k es el número de píxeles en la imagen con intensidad r_k . Trabajar con el histograma en lugar de la imagen completa reduce drásticamente el tiempo de cómputo del SOM, ya que el número máximo de entradas para el entrenamiento es siempre 256, independientemente del tamaño de la imagen original.

3. Self-Organizing Maps (SOM)

Los mapas autoorganizados (Self-Organizing Maps, SOM) son un tipo de red neuronal artificial que se entrena mediante aprendizaje no supervisado. A diferencia de otras redes neuronales, los SOM utilizan una función de vecindad para preservar las propiedades topológicas del espacio de entrada. Durante el entrenamiento, la neurona cuyo vector de pesos es más cercano a un dato de entrada (la neurona ganadora o Best Matching Unit, BMU) y sus neuronas vecinas ajustan sus pesos.

La regla de actualización para el peso w_i de la neurona ganadora y sus vecinas se define como:

$$w_i(t+1) = w_i(t) + \eta(t) \cdot h(i, BMU, t) \cdot [x(t) - w_i(t)] \quad (2)$$

donde $\eta(t)$ es la tasa de aprendizaje y $h(i, BMU, t)$ es la función de vecindad centrada en la BMU.

4. Propuesta del SOM 1D para Segmentación de Imágenes

La arquitectura SOM 1D propuesta utiliza una capa de entrada que recibe los niveles de intensidad del histograma y una capa de salida con k neuronas dispuestas linealmente. El valor de k define el número de regiones o niveles de segmentación deseados. El proceso se resume en la Figura 1.

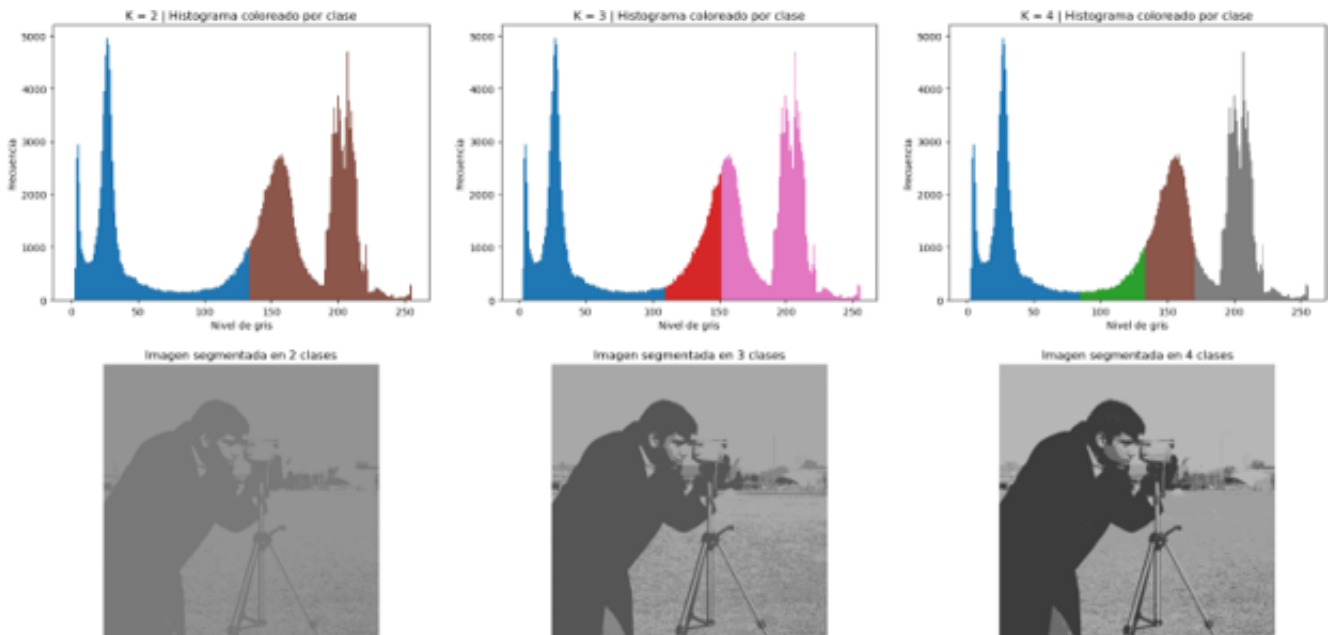


Figura 1 Flujo de procesamiento para la segmentación mediante SOM 1D.

5. Resultados

Para evaluar la propuesta, se procesaron diversas imágenes aplicando diferentes valores de k . Como se observa en la Figura 2, al utilizar $k = 2$ se obtiene una binarización de la imagen, mientras que valores mayores de k permiten capturar transiciones más finas de gris, segmentando la imagen en múltiples regiones de interés.

Clase K	Clase 0	Clase 1	Clase 2	Clase 3
2	156482	107930	-	-
3	82500	123900	57912	-
4	62412	90573	66210	43617

Figura 2 Comparativa de segmentación con distintos valores de k .

6. Conclusiones

Se concluye que el SOM unidimensional (SOM 1D) permite una segmentación eficiente de imágenes en escala de grises, con una clasificación ajustable mediante el número de clases k . Al ajustar k , se puede obtener desde una simple binarización hasta segmentaciones más detalladas que capturan múltiples matices de intensidad. Este método combina la eficiencia de trabajar con histogramas con la capacidad de autoorganización de los SOM, ofreciendo una alternativa adaptable para el agrupamiento de píxeles en diversas aplicaciones de procesamiento de imágenes.

Referencias

- [1] Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson.
- [2] Kanungo, T., Mount, D. M., Netanyahu, N., Piatko, C., Silverman, R., & Wu, A. Y. (2002). An Efficient k-Means Clustering Algorithm: Analysis and Implementation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 881–892.
- [3] MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. *In Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability* (Vol. 1, pp. 281–297).
- [4] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436–444.
- [5] Kohonen, T. (1982). Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*, 43(1), 59–69.