

# Segmentación de imágenes de color imitando la percepción humana del color

Miguel Contreras Murillo, Farid García Lamont,  
Alma Delia Cuevas Rasgado

Universidad Autónoma del Estado de México,  
Centro Universitario UAEM Texcoco, Texcoco-Estado de México,  
México

miguelc297@gmail.com, fgarcial@uaemex.mx, almadeliacuevas@gmail.com

**Resumen.** Normalmente, en los trabajos de segmentación de imágenes de color entrenan redes neuronales con los colores de la imagen a segmentar, después se obtiene el número de colores dominantes dentro de la imagen para posteriormente procesar la imagen con fuzzy c-means, en donde los colores son representados en el espacio RGB. La desventaja que tienen estos trabajos es que, por un lado, deben entrenar las redes neuronales cada vez que se procesa una nueva imagen; por otro lado, en el espacio RGB la cromaticidad de un color puede ser modificada por su intensidad. En este trabajo proponemos segmentar las imágenes con información cromática de los colores, entrenando una red neuronal con muestras de cromaticidad de diferentes colores, que puede emplearse para segmentar cualquier imagen sin necesidad de volverla a entrenar; la cantidad de colores que reconoce la red neuronal depende de su tamaño. Se presentan experimentos con imágenes de la base de segmentación de Berkeley empleando redes neuronales competitivas y mapas auto-organizados.

**Palabras clave:** Segmentación, redes neuronales artificiales, espacios de color.

## Color Image Segmentation by Mimicking the Human Perception of Color

**Abstract.** Usually, related works on color image segmentation train neural networks with the colors of the image to segment, then the number of dominant colors within the image is obtained in order to process the image using fuzzy c-means, where the colors are represented in the RGB space. The drawback with these methods is the neural networks must be trained every time a new image is given; but also, in the RGB space the color's chromaticity can be altered by its intensity. In this paper we propose to segment the images using chromatic data of colors, by training a neural network with chromaticity samples of different colors, which can be employed to segment any image just training it just once; the number of colors the neural network recognizes depends on its size. We show experiments with images of the Berkeley segmentation database using competitive neural networks and self-organizing maps.

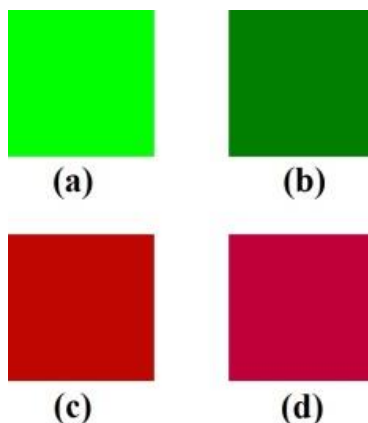
**Keywords:** Segmentation, artificial neural networks, color spaces.

## 1. Introducción

La segmentación de imágenes es un tema ampliamente estudiado para la extracción y reconocimiento de objetos, de acuerdo a las características de textura, color, forma, entre otros. Dependiendo de la naturaleza del problema, las características de color de los objetos pueden proporcionar información relevante sobre ellos. Por ejemplo, la segmentación de imágenes de color ha sido aplicado en diferentes áreas como análisis de alimentos [1,2], geología [3], medicina [4,5] entre otras [6-9].

Los trabajos que abordan la segmentación de imágenes por características de color emplean diferentes técnicas [10,11], pero las más empleadas son las redes neuronales (RN) [12-14] y métodos basado en agrupamiento, específicamente, fuzzy c-means (FCM) [15-20]. Las RN son entrenadas para reconocer colores específicos, es decir, estas son entrenadas con los colores de la imagen a ser segmentada. Si se da una nueva imagen la RN debe ser entrenada nuevamente. Al emplear métodos basados en agrupamiento, se crean grupos de colores con características similares. La desventaja con tales métodos es que se requiere definir previamente la cantidad de grupos en que se divide la información; por lo tanto, el número de grupos se define dependiendo de la naturaleza de la escena.

Nuestra propuesta consiste en entrenar a la RN para reconocer diferentes colores, tratando de emular la percepción humana del color. Los seres humanos identifican principalmente los colores por su cromaticidad, después por su intensidad [21]. Por ejemplo, si se le pregunta a cualquier persona cual es el color de los cuadros (a) y (b) de la Fig. 1, lo más seguro es que responderá “verde”; nótese que el cuadro (a) es más brillante que el cuadro (b) pero la cromaticidad no cambia. Ahora, si se le vuelve a preguntar a esa misma persona cual es el color de los cuadros (c) y (d) de la Fig. 1, lo más seguro es que responda “rojo y rosa, respectivamente”; es importante mencionar que los cuadros (c) y (d) tienen la misma intensidad pero diferentes cromaticidades.



**Fig. 1.** Cuadros (a) y (b) con la misma cromaticidad pero con diferentes intensidades; cuadros (c) y (d) con diferentes cromaticidades pero con la misma intensidad

Los seres humanos tienen la capacidad innata de reconocer colores; al observar su entorno pueden reconocer, hasta cierto punto, regiones y/o objetos dentro de una escena por sus características cromáticas. Es importante mencionar que los humanos no necesitan aprender a identificar los colores cada vez que se les muestra una escena; ellos solo emplean su conocimiento previamente adquirido.

La contribución de este artículo es una propuesta para segmentar imágenes de color por características cromáticas, emulando la forma en que los seres humanos reconocen los colores. Con el fin de emular esta capacidad humana, proponemos entrenar un mapa auto-organizado (MAO), con muestras de cromaticidad de diferentes colores, una vez entrenada, el MAO procesa la imagen. En donde dependiendo de la cantidad de neuronas que tenga la RN es la cantidad de colores que puede reconocer la RN y en consecuencia el número de secciones que puede tener la imagen.

En la mayoría de los trabajos relacionados se emplea el espacio RGB para representar colores; sin embargo, este espacio es sensible a la iluminación por lo que la extracción de la cromaticidad de los colores no es precisa porque esta puede ser alterada por los cambios de intensidad. De aquí que, nosotros empleamos el espacio de color HSV, porque en este espacio la cromaticidad es separada de la intensidad [22].

El artículo está organizado de la siguiente forma: en la sección 2 se muestran las características de los espacios de color RGB y HSV. Presentamos nuestra propuesta para la segmentación de imágenes en la sección 3. En la sección 4 se muestran los experimentos realizados y se discuten los resultados obtenidos. Finalmente, el artículo termina con las conclusiones y trabajo futuro en la sección 5.

## 2. Espacios de color

Aunque el espacio RGB es ampliamente aceptado para representar colores por la comunidad de procesamiento de imágenes, los seres humanos no perciben el color como es representado en dicho espacio. La percepción humana del color es similar a la representación en el espacio HSV [21,22], de aquí que empleamos este espacio. En las secciones 2.1 y 2.2 se presentan las características de cada espacio.

### 2.1 Espacio de color RGB

El espacio RGB está basado en el sistema de coordenadas Cartesiano en donde los colores son puntos definidos por vectores que se extienden desde el origen, en donde el negro está en el origen y el blanco está ubicado en la esquina opuesta al origen [22], ver Fig. 2.



Fig. 2. Espacio de color RGB

El color de un pixel  $p$  se escribe como una combinación lineal de los vectores base de verde, rojo y azul [22]:

$$\phi_p = r_p \hat{i} + g_p \hat{j} + b_p \hat{k}. \quad (1)$$

en donde  $r_p$ ,  $g_p$  y  $b_p$  son los componentes de rojo, verde y azul, respectivamente. La orientación y magnitud de un vector de color define la cromaticidad e intensidad del color, respectivamente [22]. Como se ha mencionado antes, este espacio es sensible a la iluminación; es decir, a pesar de que dos vectores tengan la misma cromaticidad, estos representan diferentes colores si sus intensidades son diferentes.

## 2.2 Espacio de color HSV

La representación de color en el espacio HSV emula la percepción humana del color ya que la cromaticidad es desacoplada de la intensidad [21,22]. En este espacio el color de un pixel  $p$  se representa por sus componentes de tono ( $h$ ), saturación ( $s$ ) e intensidad ( $v$ ):

$$\varphi_p = [h_p, s_p, v_p]. \quad (2)$$

El tono es la cromaticidad, la saturación es el nivel de blancura del color y la intensidad es el brillo del color; la Fig. 3 muestra la apariencia del espacio HSV. Los rangos de valores reales del tono, saturación e intensidad son  $[0, 2\pi]$ ,  $[0, 1]$  y  $[0, 255]$ , respectivamente.

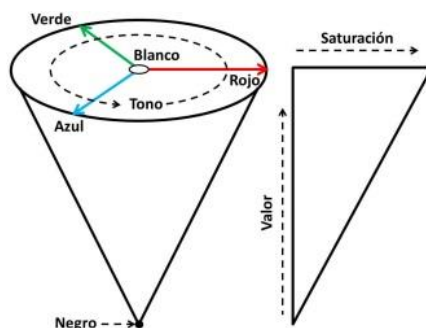


Fig. 3. Espacio de color HSV

## 3. Propuesta de segmentación

En esta sección presentamos nuestra propuesta para la segmentación de imágenes de color, en donde entrenamos una RN con muestras de cromaticidad de diferentes colores. Posteriormente se extrae la cromaticidad de cada pixel de la imagen a segmentar al mapear el color al espacio HSV, la cromaticidad extraída es procesada por la RN y el nuevo tono del pixel es el tono de la neurona ganadora. Cuando todos los pixeles son procesados, la imagen es mapeada al espacio RGB.

### 3.1 Entrenamiento de la red neuronal

Debido a la naturaleza difusa del color, no es posible reconocer todos los colores del espectro; de aquí que, el espectro de color es “dividido” en un conjunto finito de colores. El número de colores que la RN puede reconocer depende de su tamaño; en este artículo se realizan pruebas con una red neuronal competitiva (RNC) con 9, 16 y 25 neuronas, y con MAO de 3×3, 4×4 y 5×5 neuronas. Las RN son entrenadas con los elementos del conjunto  $\Psi$  construido con muestras de cromaticidad como sigue:

$$\Psi = \left\{ \psi_k = [\cos \theta_k, \sin \theta_k] \mid \theta_k = \frac{2\pi}{256} k : k = 0, 1, \dots, 255 \right\}. \quad (3)$$

La cromaticidad es transformada en un vector debido al caso cuando el valor del tono es casi 0 o  $2\pi$ . Considérese los cuadros (c) y (d) de la Fig. 1, sus valores son  $\pi/100$  y  $19\pi/10$ , respectivamente. Numéricamente ambos valores son muy distintos pero las cromaticidades de ambos cuadros son muy similares; si la cromaticidad de ambos cuadros es clasificado solamente por el valor escalar del tono, la cromaticidad es reconocida como si fueran muy diferentes.

Este problema se resuelve como sigue; sea  $\varphi_p$  el color de un pixel representado en el espacio HSV como se muestra en la ec. (2), le cromaticidad es modelada como:

$$\psi_p = [\cos h_p, \sin h_p]. \quad (4)$$

### 3.2 Procesamiento de la imagen

La segmentación de la imagen se hace al agrupar los colores empleando la cromaticidad de los colores de cada pixel de la imagen. Es importante mencionar que las RNs son entrenadas con información de la cromaticidad de los colores, por lo que no pueden reconocer el negro ni el blanco porque estos dos colores no tienen una cromaticidad definida. El blanco se obtiene cuando la saturación de un color es bajo, es decir, cuando  $s \approx 0$ ; por otra parte, el negro se obtiene cuando la intensidad del color es baja, esto es, cuando  $v \approx 0$ .

Por lo tanto, antes de que un color sea procesado por la RN se debe evaluar su saturación e intensidad para clasificarlo como blanco o negro, respectivamente. Procesar el color de un pixel conlleva realizar los siguientes pasos. Sea el vector de color  $\phi_p$  del pixel  $p$  representado en el espacio RGB:

1. El vector  $\phi_p$  se mapea al espacio HSV obteniendo  $\varphi_p = [h_p, s_p, v_p]$ .
2. Se verifica si el color del pixel es negro; si  $v_p \leq \delta_v$  entonces  $v_p^* = 0$  y  $s_p^* = 0$ , ir al paso 5.
3. En caso contrario, se verifica si el color del pixel es blanco; si  $s_p \leq \delta_s$  entonces  $v_p^* = 191$  y  $s_p^* = 0$ , ir al paso 5.
4. En caso contrario, es decir, si  $v_p > \delta_v$  y  $s_p > \delta_s$  entonces:
  - a. Calcular el vector  $\psi_p$  y procesarlo con la RN.
  - b. Se obtiene el vector de peso de la neurona ganadora  $\mathbf{w}_i = [w_{i,1}, w_{i,2}]$  y se etiqueta al pixel con el número  $i$ .
  - c. Calcular el tono con  $h_p^* = \tan^{-1}(w_{i,2}/w_{i,1})$ .

- d. Se asignan los valores de saturación e intensidad:  $v_p^* = 191$  y  $s_p^* = 1$ .
5. El nuevo vector  $\phi_p^* = [h_p^*, s_p^*, v_p^*]$  es mapeado al espacio RGB obteniendo el vector  $\phi_p^* = [r_p^*, g_p^*, b_p^*]$ .

En donde  $\delta_s$  y  $\delta_v$  son los umbrales para saturación e intensidad, respectivamente. Dada la naturaleza difusa del color, no hay valores específicos para decidir exactamente cuando un color es blanco o negro; de forma experimental encontramos que los mejores umbrales son  $\delta_s = \mu_s - \sigma_s$  y  $\delta_v = \mu_v - \sigma_v$ ; en donde  $\mu_s$  y  $\mu_v$  son la media de saturación e intensidad de la imagen, respectivamente;  $\sigma_s$  y  $\sigma_v$  son la desviación estándar de la saturación e intensidad de la imagen, respectivamente.

#### 4. Experimentos y discusión

Recientemente la base de segmentación de Berkeley<sup>1</sup> (BSB) se está convirtiendo en la referencia para probar algoritmos de segmentación de imágenes de color [16]. Para los experimentos, implementados en Matlab 2014a, se seleccionó aleatoriamente un conjunto de 9 imágenes de las 300 imágenes que contiene la BSB, ver Fig. 4.

En la Fig. 5 se muestran las imágenes obtenidas al procesar las imágenes de la Fig. 4 empleando las RNCs con los diferentes tamaños que se indican. A su vez en la Fig. 6 se muestran las imágenes resultantes al ser procesadas las imágenes de la Fig. 4 empleando los MAOs con los tamaños que se indican.

Se puede observar fácilmente de las imágenes resultantes que estas pueden ser segmentadas solamente utilizando información de la cromaticidad; pero la segmentación también depende de la cantidad de neuronas de las RNs. Esto es, entre más grande sea la RN, mayor la cantidad de colores son reconocidos; de hecho, se puede apreciar que con los MAO se reconocen más colores que con las RNC, ya que se pueden observar más secciones o dentro de la imagen empleando los MAO. Aunque también, por lo mismo, hay algunas partes de la imagen que no son segmentadas homogéneamente.

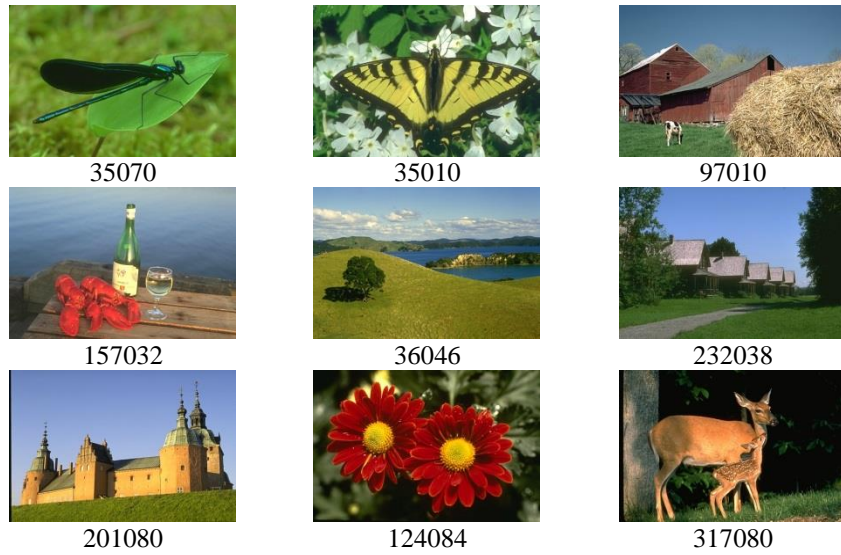
Al observar las imágenes se puede ver que estas tienen mejor segmentación empleando los MAOs. Por ejemplo, en las imágenes obtenidas al procesar la imagen 35070 con las RNCs, el fondo se combina con la hoja; mientras que la misma imagen procesada por los MAOs se puede ver que la hoja es segmentada del fondo, a pesar de tener ambos tonos verdes pero los MAOs son capaces de distinguir la diferencia de tonos.

Otro ejemplo, en las imágenes obtenidas de la imagen 35010 utilizando las RNCs, prácticamente el fondo de las hojas son segmentadas en verde, mientras que con los MAOs se pueden apreciar tonos en amarillo en los centros de las hojas. Las alas de la mariposa son segmentadas exitosamente con todas las redes neuronales, excepto utilizando la RNC de 25 neuronas, las cuales son segmentadas con el mismo tono de verde de las hojas del fondo. Una posible explicación es que esa red neuronal no “aprendió” correctamente a reconocer el tono amarillo durante el entrenamiento, por lo que la red neuronal debe ser entrenada nuevamente.

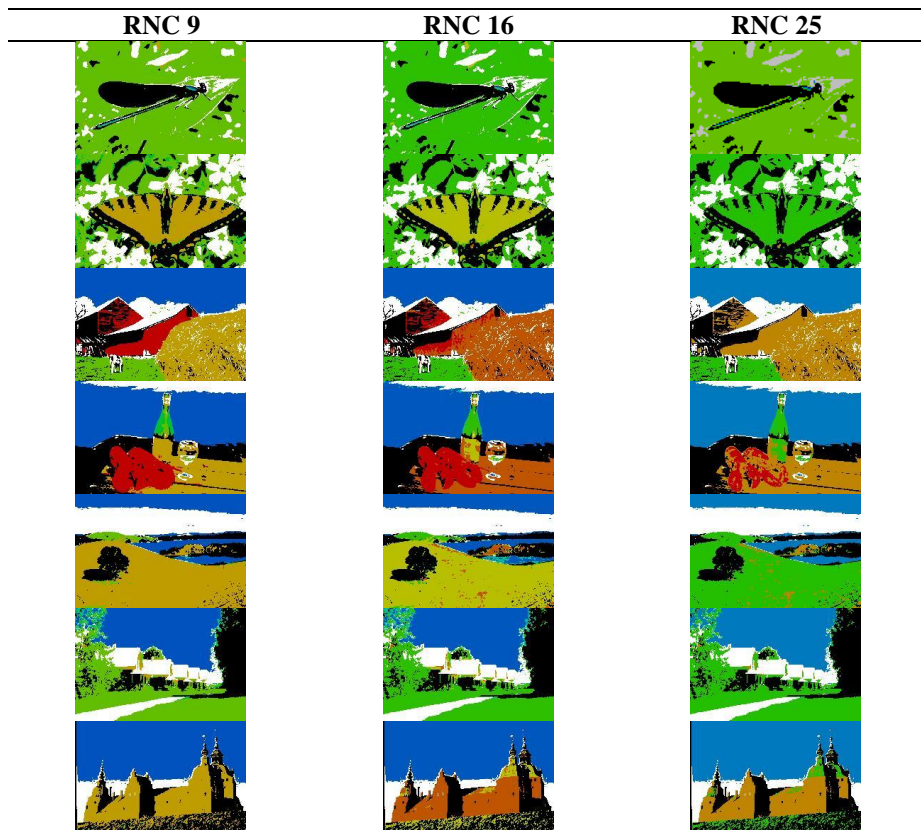
---

<sup>1</sup> <http://www.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>

*Segmentación de imágenes de color imitando la percepción humana del color*



**Fig. 4.** Imágenes extraídas de la BSB, empleadas para los experimentos realizados




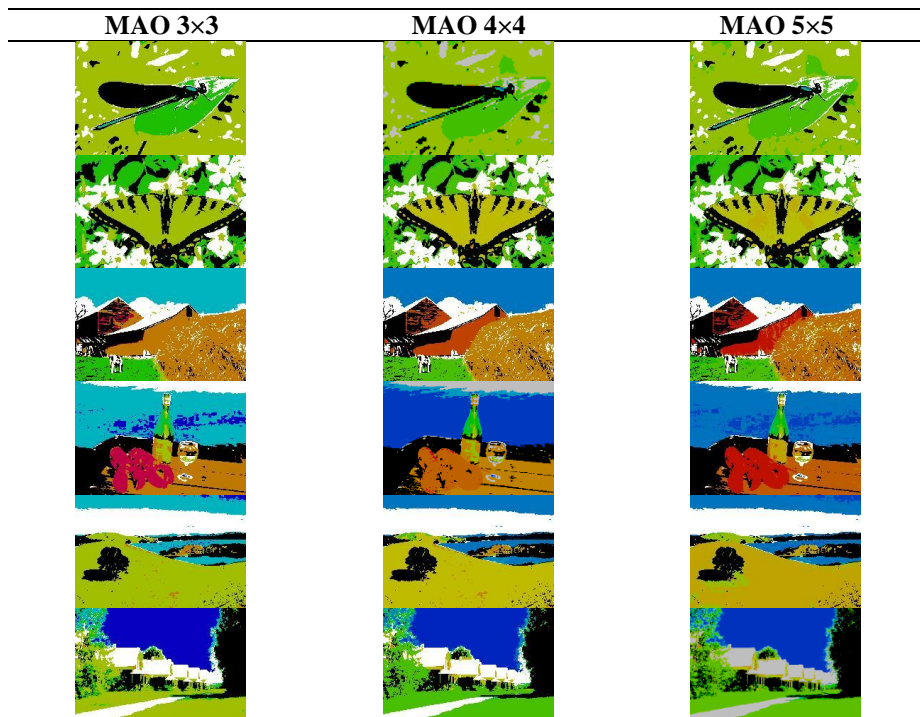



Fig. 5. Imágenes obtenidas empleando redes neuronales competitivas de 9, 16 y 25 neuronas

Dada la apariencia de las imágenes, la segmentación de las imágenes utilizando las RNCs es mejor cuando la red neuronal es pequeña, mientras que con los MAOs es lo contrario; es decir, el resultado de la segmentación de las imágenes utilizando los MAOs es mejor cuando la red neuronal es grande. Por ejemplo, la imagen 124084 obtenida con la RNC de 9 neuronas es muy parecida a la obtenida utilizando el MAO de 5×5 neuronas. Ocurre de forma similar con las imágenes 97010, 157032, 201080 y 35010 si se utiliza un la RNC de 9 neuronas y el MAO de 5×5 neuronas.

## 5. Conclusiones y trabajo futuro







**Fig. 6.** Imágenes obtenidas empleando mapas auto-organizados de 3×3, 4×4 y 5×5 neuronas

En este trabajo se ha presentado una propuesta para segmentar imágenes por características de color. Se presentan pruebas empleando redes neuronales competitivas y mapas auto-organizados de diferentes tamaños, que son entrenadas con muestras de cromaticidad de diferentes colores; posteriormente se procesan las imágenes extrayendo sólo la cromaticidad de los colores de las imágenes, al mapear previamente las imágenes al espacio HSV. Cada pixel es agrupado con el tono de la neurona ganadora de la red neuronal, finalmente la imagen resultante es mapeada al espacio RGB.

Los mapas auto-organizados mostraron, en cuanto a la apariencia de la imagen, tener mejor desempeño que las redes neuronales competitivas; es decir, aunque la cantidad y forma de las secciones obtenidas empleando ambas redes neuronales son parecidas, los tonos asignados por los mapas auto-organizados se asemejan más a los de las imágenes originales.


La cantidad de colores que pueden reconocer las redes neuronales depende de la cantidad de neuronas que tienen. Las redes neuronales con pocas neuronas funcionan mejor en imágenes que tienen pocos colores; mientras que las redes neuronales con un número grande de colores tienen mejor desempeño con las imágenes que tienen varios colores.

Como trabajo futuro se contempla hacer una evaluación cuantitativa de la segmentación de las imágenes obtenidas con nuestra propuesta. Empleando las métricas de índice aleatorio probabilístico y de variación de información, que se están volviendo últimamente en las métricas estándar para medir el desempeño de los algoritmos de segmentación de color [16]. La imagen segmentada con nuestra propuesta es comparada con las imágenes segmentadas a mano que se encuentran en la BSB que sirven como referencia. Cada imagen de la BSB tiene un conjunto de 5 imágenes segmentadas a mano, con las que se hace la comparación. Por ejemplo, en la Fig. 7 se muestra las imágenes segmentadas a mano de la imagen 35010 de la BSB.



**Fig. 7.** Ejemplo de imágenes segmentadas a mano de la BSB

Las imágenes segmentadas obtenidas con nuestra propuesta son comparadas con cada una de las imágenes segmentadas a mano de la BSB, en donde la similitud de la segmentación se mide con las métricas mencionadas anteriormente. En la Fig. 8 se muestran dos ejemplos de imágenes segmentadas a mano, (a) y (c), y dos que se obtienen con nuestra propuesta, (b) y (d).



**Fig. 8.** Ejemplo de comparación de las imágenes: (a) y (c), segmentadas a mano y las segmentadas con nuestra propuesta, (b) y (d)

Por otra parte se contempla hacer pruebas con imágenes con ruido para observar el comportamiento de nuestra propuesta.

**Agradecimientos.** El primer autor agradece al CONACyT la beca para realizar estudios de maestría, con el número de registro 634201.

## Referencias

1. Gökmen, V., Sügüt, I.: A non-computer vision based analysis of color in foods. *Int. J. Food Eng.*, Vol. 3, No. 5 (2007)
2. Lopez, J.J., Cobos, M., Aguilera, E.: Computer-based detection and classification of flaws in citrus fruits. *Neural Comput. Appl.*, Vol. 20, No. 7, pp. 975–981 (2011)
3. Lespitö, L., Kuntuu, I., Visa, A.: Rock image classification using color features in Gabor space. *J. Electron. Imaging*, Vol. 14, No. 4, pp. 1–3 (2005)
4. Ghoeneim, D.M.: Optimizing automated characterization of liver fibrosis histological images by investigating color spaces at different resolutions. *Theor. Biol. Med. Model.*, Vol. 8, No. 25 (2011)
5. Harrabi, R., Braiek, E.B.: Color image segmentation using multi-level thresholding approach and data fusion techniques: application in the breast cancer cells images. *EURASIP J. Image Video Process.*, Vol. 11 (2012)
6. Wang, G., Man, L., Wang, B., Xiao, Y., Pan, W., Lu, X.: Fuzzy-based algorithm for color recognition of license plates. *Pattern Recognit. Lett.*, Vol. 29, No. 7, pp. 1007–1020 (2008)
7. del Fresno, M., Macchi, A., Marti, Z., Dick, A., Clausse, A.: Application of color image segmentation to estrus detection. *J. Vis.*, Vol. 9, No. 2, pp. 171–178 (2006)

8. Rotaru, C., Graf, T., Zhang, J.: Color image segmentation in HSI space for automotive applications. *J. Real-Time Image Process.*, Vol. 3, No. 4, pp. 311–322 (2008)
9. Bianconi, F., Fernandez, A., Gonzalez, E., Saetta, S.A.: Performance analysis of color descriptors for parquet sorting. *Expert Syst. Appl.*, Vol. 40, No. 5, pp. 1636–1644 (2013)
10. Aghbarii, Z.A., Haj, R.A.: Hill-manipulation: an effective algorithm for color image segmentation. *Image Vis. Comput.*, Vol. 24, No. 8, pp. 894–903 (2006)
11. Mignotte, M.: A non-stationary MRF model for image segmentation from a soft boundary map. *Pattern Anal. Appl.*, Vol. 17, No. 1, pp. 129–139 (2014)
12. Mousavi, B.S., Soleymani, F., Razmjooy, N.: Color image segmentation using neuro-fuzzy system in a novel optimized color space. *Neural Comput. Appl.*, Vol. 23, No. 5, pp. 1513–1520 (2013)
13. Ong, S., Yeo, N., Lee, K., Venkatesh, Y., Cao, D.: Segmentation of color images using a two-stage self-organizing network. *Image Vis. Comput.*, Vol. 20, No. 4, pp. 279–289 (2002)
14. Jiang, Y., Zhou, Z.H.: SOM ensemble-based image segmentation. *Neural Process. Lett.*, Vol. 20, No. 3, pp. 171–178 (2004)
15. Wang, L., Dong, M.: Multi-level low-rank approximation-based spectral clustering for image segmentation. *Pattern Recognit. Lett.*, Vol. 33, No. 16, pp. 2206–2215 (2012)
16. Mújica-Vargas, D., Gallegos-Funes, F.J., Rosales-Silva, A.J.: A fuzzy clustering algorithm with spatial robust estimation constraint for noisy color image segmentation. *Pattern Recognit. Lett.*, Vol. 34, No. 4, pp. 400–413 (2013)
17. Huang, R., Sang, N., Luo, D., Tang, Q.: Image segmentation via coherent clustering in  $L^*a^*b^*$  color space. *Pattern Recognit. Lett.*, Vol. 32, No. 7, pp. 891–902 (2011)
18. Nadernejad, E., Sharifzadeh, S.: A new method for image segmentation based on fuzzy c-means algorithm on pixonal images formed by bilateral filtering. *Signal Image Video Process.*, Vol. 7, No. 5, pp. 855–863 (2013)
19. Guo, Y., Sengur, A.: A novel color image segmentation approach based on neutrosophic set and modified fuzzy c-means. *Circuits Syst. Signal Process.*, Vol. 32, No. 4, pp. 1699–1723 (2013)
20. Kim, J.Y.: Segmentation of lip region in color images by fuzzy clustering. *Int. J. Control Autom. Sys.*, Vol. 12, No. 3, pp. 652–661 (2014)
21. Ito, S., Yoshioka, M., Omatu, S., Kita, K., Kugo, K.: An image segmentation method using histograms and the human characteristics of HSI color space for a scene image. *Artif. Life and Robot.*, Vol. 10, No. 1, pp. 6–10 (2006)
22. Gonzalez, R.C., Woods, R.E.: *Digital Image Processing*. 2nd ed. Prentice Hall (2002)