

Binary Pattern Descriptors for Scene Classification

S. Cervantes, A. Mexicano, J. Cervantes, R. Rodríguez, and J. Fuentes-Pacheco

Abstract—Scene classification is a computer vision task that aims to identify the kind of scene (such as forest, mountain, beach) where a picture was taken. Scene classification has application in the development of automatic surveillance systems, robotic navigation, content-based image retrieval systems among other areas. According to how a scene is recognized, scene classification algorithms can be divided in two categories: based on object recognition and based on low-level image features obtained by applying descriptors. This paper proposes a new binary descriptor called Local Lineal Binary Pattern and a new framework that allows the combination of the new binary descriptor with another local and global descriptors in order to improve the automatic classification of scene images. This new binary descriptor increases the spatial support for its calculation allowing to add more spatial information than the traditional binary descriptors such as the Local Binary Pattern and the Modified Census Transform. Experiments conducted over indoor and outdoor scene datasets show that the new proposed descriptor and framework help to improve the results obtained by related works.

Index Terms—Binary Patterns, Framework, Scene Classification, Spatial Pyramidal Model.

I. INTRODUCCIÓN

LA clasificación de escenas es una tarea de la visión por computadora que tiene como objetivo clasificar imágenes obtenidas en diversas escenas (tales como bosques, montañas, playas, oficinas) dentro de la categoría apropiada dada una cantidad N de categorías predefinidas. Esta tarea tiene muchas aplicaciones, tales como: el desarrollo de sistemas de recuperación de imágenes basados en contenido [1], sistemas de videovigilancia [2], [3], [4] y de navegación robótica [5]. También puede ser utilizado para mejorar el reconocimiento de objetos mediante la identificación del contexto en el cual comúnmente residen los objetos de interés [6], [7]. Sin embargo, la clasificación de escenas es considerada una tarea bastante complicada debido a que este tipo de imágenes presentan una gran variabilidad (no existe control de los diferentes tipos de elementos que pueden aparecer), lo cual genera las siguientes complicaciones: la existencia de

ambigüedad entre diferentes tipos de escenas, las cuales, pueden presentar diferentes condiciones de iluminación y diferentes tipos de objetos con variaciones de escala y perspectiva; todas estas características dificultan la correcta clasificación de la escena.

Con la intención de tratar las dificultades anteriormente mencionadas, algunos enfoques propuestos en la literatura han sido desarrollados tomando como base la representación global y local de la información contenida en las imágenes.

Por ejemplo, en [8] se desarrolló un descriptor de escenas conocido como GIST, el cual, realiza una descripción global de la escena tomando en consideración las siguientes dimensiones perceptuales: expansión, apertura, naturaleza, aspereza y rugosidad. Este descriptor logra un buen desempeño en la clasificación de escenas de exteriores, sin embargo, su desempeño se reduce dramáticamente cuando es utilizado en la clasificación de escenas de interiores, razón por la cual es combinado con otros descriptores [9].

Un modelo bastante utilizado y con un enfoque opuesto a la descripción global de escenas, es la Bolsa de Palabras Visuales (BoW - Bag of Words) [10]. Este enfoque está basado en el modelo de bolsa de palabras utilizado para la clasificación de texto y describe regiones locales de la imagen utilizando descriptores como SIFT (Scale-Invariant Feature Transform) [11] o MCT (Modified Census Transform) [12], [13], [14]. El modelo BoW tiene la desventaja de no considerar la información espacial de las escenas, razón por la cual, Lasebnik [15] propone el uso del método de pirámides espaciales, el cual consiste en dividir una imagen en sub-regiones cada vez más finas, permitiendo obtener información de la distribución de las descripciones obtenidas sobre una imagen.

Otra alternativa para mejorar la clasificación de escenas es el desarrollo de nuevos descriptores. En [16] se propone el descriptor CENTRIST (CENSus TRansform HISTogram), el cual, es una representación holística que captura propiedades estructurales y reduce la información textural detallada a través del modelado de la distribución de estructuras locales y el uso de pirámides espaciales.

En [17] se propone el descriptor LDBP (Local Different Binary Pattern), este descriptor codifica el signo y la magnitud de la diferencia de intensidades entre un píxel central y sus píxeles vecinos dentro de una ventana de 3×3 píxeles; este descriptor se compone de otros dos descriptores: el descriptor LMBP (Local difference Magnitude Binary Pattern) que codifica la magnitud y el descriptor LSBP (Local difference Sign Binary Pattern) el cual es idéntico al descriptor MCT [12] y codifica el signo. Ambos descriptores son calculados de forma individual aplicando el enfoque de pirámides espaciales,

S. Cervantes, Centro Universitario de los Valles, Universidad de Guadalajara, Jalisco, México, salvador.cervantes@valles.udg.mx

A. Mexicano, Instituto Tecnológico de Cd. Victoria, Tamaulipas, México, mexicanoa@gmail.com

J. A. Cervantes, Centro Universitario de los Valles, Universidad de Guadalajara, Jalisco, México, antoniocervantes@valles.udg.mx

R. Rodríguez, Universidad Autónoma de Ciudad Juárez, Chihuahua, México, ricardo.jorge@uacj.mx

J. Fuentes-Pacheco, Universidad Autónoma del Estado de Morelos, Morelos, México, jorge.fuentes@uaem.mx.

obteniendo como resultado un vector de características por cada descriptor [18], [19]. Dichos vectores son procesados aplicando el algoritmo PCA (Principal Component Analysis) con el objetivo de reducir los vectores a sus 20 eigenvectores más discriminativos. Finalmente, los vectores reducidos son combinados dentro de un sólo vector de características cuyas dimensiones son relativamente pequeñas en comparación con los vectores de características obtenidos con descriptores como CENTRIST. Este tipo de descriptores locales son utilizados para diversas tareas, por ejemplo, el reconocimiento de rostros [20] o la clasificación de células [21]. En años recientes, han surgido marcos de trabajo (frameworks) que combinan descriptores globales y locales. En [22] se propone una mejora al descriptor CMCT (Contextual Mean Census Transform), la cual, consiste en añadir información espacial de vecinos distantes y mediante un marco de trabajo que combina el descriptor mejorado junto con el descriptor GIST, información espacial y estadística de las imágenes se logra una mejora en la clasificación automática de las imágenes.

En este trabajo de investigación se propone un nuevo descriptor binario llamado LL-BP (Local Lineal Binary Pattern) para mejorar la clasificación de escenas. Otra aportación relevante que se ofrece en este artículo es la descripción de un nuevo marco de trabajo que permite combinar el descriptor LL-BP con descriptores globales y locales como GIST y MCT, permitiendo agregar información espacial mediante un modelo de pirámide espacial. Adicionalmente, se propone un nuevo enfoque para el cálculo de forma local del umbral del descriptor LMBP. En el resto del artículo el descriptor es referenciado como LMBP-LT (Local difference Magnitude Binary Pattern-Local Threshold) para indicar que el umbral es calculado de forma local.

El resto del artículo está organizado de la siguiente forma: en la Sección II, se describen los descriptores MCT y LMBP-LT. En la Sección III se analiza el nuevo descriptor llamado LL-BP. En la Sección IV se describe el marco de trabajo propuesto para combinar los descriptores. En la Sección V, se presentan los resultados obtenidos sobre 3 conjuntos de imágenes de escenas y son comparados contra los resultados obtenidos por trabajos relacionados. Finalmente, en la Sección 6, se presentan las conclusiones.

II. DESCRIPTORES MCT Y LMBP-LT

A. Descriptor MCT

El descriptor MCT [12] produce un código binario utilizando como umbral la media $\bar{I}(x,y)$ de los valores de los píxeles de una ventana de 3x3 píxeles $I(x,y)$ cuyo píxel central I_c está localizado en las coordenadas (x,y) . Todos los píxeles de la ventana son comparados con $\bar{I}(x,y)$, si el valor del píxel es mayor o igual que $\bar{I}(x,y)$ se coloca un 1, de otra forma se coloca un 0, como se indica en la Ecuación (1). Donde \otimes representa la operación de concatenación, I_p es un píxel en la posición (i, j) que pertenece a la ventana $I(x,y)$, $N'(x,y)$ es igual a $N(x, y) \cup (x, y)$ y $N(x, y)$ define una vecindad espacial local del píxel I_c , de tal manera que $I_c \notin N$. Por último, ζ representa la comparación entre dos valores (ver Ecuación (2)).

$$MCT(x, y) = \otimes_{p \in N'(x,y)} \zeta(I_p, \bar{I}(x, y)) \quad (1)$$

tal que:

$$\zeta(I_p, \bar{I}(x,y)) = \begin{cases} 1, & I_p \geq \bar{I}(x,y) \\ 0, & I_p < \bar{I}(x,y) \end{cases} \quad (2)$$

En el descriptor MCT, si todos los píxeles de la ventana son comparados con $\bar{I}(i,j)$, se genera un código de 9 bits (MCT9), pero si el píxel central I_c no es considerado, entonces se obtiene un código de 8 bits, esta última versión del descriptor MCT es conocida como MCT8 [23] y se referencia en el resto de este artículo como MCT. Otro descriptor bastante conocido es el descriptor LBP (Local Binary Pattern) [24], el cual, en lugar de utilizar la media de los valores de una ventana de píxeles, utiliza el valor del píxel central I_c y lo compara con los valores de los píxeles vecinos dentro de una ventana de píxeles. Ambos descriptores locales generan un código binario, con la diferencia de que el descriptor MCT utiliza como umbral la media de los valores de una ventana mientras que el descriptor LBP utiliza como umbral el valor del píxel central I_c . Combinando ambos enfoques se genera el descriptor LMBP-LT.

B. Descriptor LMBP-LT

El descriptor LMBP-LT es calculado sobre una ventana de 3x3 píxeles $I(i,j)$. Para el cálculo del descriptor, se selecciona el píxel con el menor valor I_L , de los píxeles de la ventana $I(i,j)$, y su valor es sustraído a todos los píxeles de la ventana $I(i,j)$ como se indica en la Ecuación (3).

$$I_n(i,j) = I(i,j) - I_L \quad (3)$$

donde $I_n(i,j)$ representa el resultado de sustraer I_L a los valores de los píxeles de la ventana $I(i,j)$. Como resultado de la sustracción, uno o más píxeles (en el caso de regiones homogéneas) pueden tener un valor de cero.

Subsecuentemente, se obtiene la media $\bar{I}_n(i,j)$ de los valores de $I_n(i,j)$. Usando los valores de $I_n(i,j)$, LMBP-LT calcula el valor absoluto de la diferencia entre el píxel central $I_c(x,y)$ de la ventana $I_n(i,j)$ y cada uno de los píxeles restantes de dicha ventana, si el valor obtenido es mayor o igual a la media $\bar{I}_n(i,j)$ se coloca un 1, en caso contrario se coloca un 0 como se indica en la Ecuación (4).

$$LMBP-LT(x, y) = \sum_{p=0}^{N-1} \zeta(I_c(x, y), I_p) * 2^p \quad (4)$$

tal que:

$$\zeta(I_c(x,y), I_p) = \begin{cases} 1, & |I_c(x,y) - I_p| \geq \bar{I}_n(i,j) \\ 0, & |I_c(x,y) - I_p| < \bar{I}_n(i,j) \end{cases} \quad (5)$$

donde I_p es un píxel vecino de $I_c(x,y)$ y pertenece a la ventana

$I_n(i,j)$, N es el número de vecinos de $I_c(x,y)$ de la ventana $I_n(i,j)$ y ζ representa la comparación entre dos valores (ver Ecuación (5)). El descriptor LMBP-LT puede ser considerado un caso especial del descriptor LMBP [17] donde el umbral es la media de la media obtenida en cada una de las ventanas de 3x3 píxeles generadas sobre una imagen.

En la Figura 1 se presenta un ejemplo artificial de una ventana de 3x3 píxeles, el ejemplo muestra la importancia de aplicar la operación de sustraer el píxel con menor valor I_L a los píxeles de $I(i,j)$.

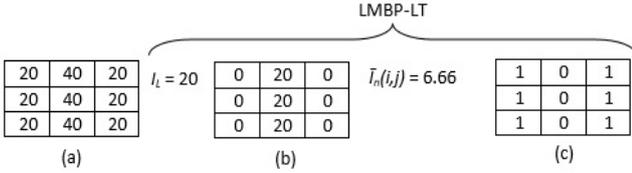


Fig. 1. a) Ventana de 3x3 píxeles con valores artificiales, b) resultado de sustraer el valor de I_L de los valores de la ventana de a), c) ventana de píxeles obtenida después de aplicar el descriptor LMBP-LT sobre la ventana de píxeles de b).

En el ejemplo de la Figura 1, si el proceso de sustraer el píxel con el menor valor I_L a los píxeles de la ventana $I(i,j)$ es omitido, se obtiene una media $\bar{I}_n(i,j)$ igual a 26.66. El valor de la media obtenida es mayor que el valor absoluto de la diferencia entre el píxel central $I_c(x,y)$ y cualquiera de sus píxeles vecinos, por lo tanto, al aplicar el descriptor LMBP-LT se obtiene un código binario conformado solamente con el número 0, lo cual no provee información de las discontinuidades de las intensidades de los píxeles.

Debido a que el descriptor LMBP-LT usa como umbral el valor del píxel central $I_c(x,y)$, las regiones de píxeles con variaciones similares en relación al píxel central $I_c(x,y)$ producirán un mismo código binario (ver Figura 2). Con el objetivo de diferenciar entre este tipo de regiones, dentro del marco de trabajo propuesto se incorpora el descriptor MCT.

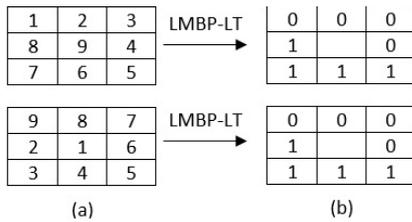


Fig. 2. a) Ventanas de píxeles con variaciones similares en relación al píxel central, b) Ventanas resultantes de aplicar el descriptor LMBP-LT sobre las ventanas de píxeles de a).

Con el objetivo de mostrar el comportamiento del descriptor LMBP-LT y sus diferencias con los descriptores MCT y LBP, se ha procesado una imagen en escala de grises con los tres descriptores (ver Figura 3).

La imagen resultante de aplicar el descriptor LMBP-LT (Figura 3b) muestra la detección de variaciones menores entre las intensidades de píxeles adyacentes en comparación con los resultados obtenidos por los descriptores MCT (Figura 3c) y LBP (Figura 3d).

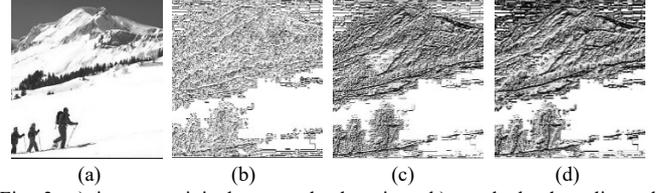


Fig. 3. a) imagen original en escala de grises, b) resultado de aplicar el descriptor LMBP-LT sobre la imagen original, c) resultado de aplicar el descriptor MCT sobre la imagen original, d) resultado de aplicar el descriptor LBP sobre la imagen original.

III. DESCRIPTOR LL-BP

Los descriptores MCT, LBP y LMBP-LT, así como otros descriptores binarios [25] han demostrado un buen desempeño en la tarea de clasificación de escenas, sin embargo, este tipo de descriptores están limitados a ventanas de 3x3 píxeles, lo cual, no provee suficiente información espacial para diferenciar entre estructuras locales contenidas en diferentes contextos. Estos descriptores tienen la ventaja de generar pequeños vectores de características de 256 dimensiones.

En este sentido, el descriptor CTDN (Census Transform of Distant Neighbors) [22] utiliza información espacial fuera de una ventana de 3x3 píxeles. Este descriptor calcula el promedio de las intensidades de una ventana de 3x3 píxeles $\bar{I}_w(i,j)$ con un píxel central $I_c(x,y)$. El valor de $\bar{I}_w(i,j)$ es utilizado junto con las intensidades de 8 píxeles vecinos que se encuentran a una distancia de n píxeles ($n > 3$) del píxel central $I_c(x,y)$ para calcular el descriptor MCT, obteniendo un vector de características de 256 dimensiones. A pesar de que el descriptor CTDN proporciona información complementaria dentro del marco de trabajo propuesto en [22], no proporcionó información complementaria significativa dentro del marco de trabajo propuesto en este artículo. Por tal razón, se diseñó el descriptor LL-BP el cual sigue la propuesta del descriptor CTDN de incrementar el soporte espacial de la descripción. A diferencia del descriptor CTDN, LL-BP hace uso de los valores originales de la imagen sin necesidad de calcular el promedio de valores en ventanas de 3x3 píxeles.

El descriptor LL-BP es calculado considerando estructuras lineales y diagonales que cruzan un píxel central $I_c(x,y)$ dentro de una ventana de 7x7 píxeles. El descriptor LL-BP utiliza el valor del píxel central $I_c(x,y)$ y los valores de 6 píxeles dentro de una estructura diagonal o lineal para calcular un código binario que puede representar un valor dentro del rango de 0-63. En total se generan 4 códigos binarios de 6 bits usando el descriptor LL-BP en cuatro diferentes variantes: LL-BP \ (Figura 4a), LL-BP / (Figura 4b), LL-BP | (Figura 4c) y LL-BP- (Figura 4d).

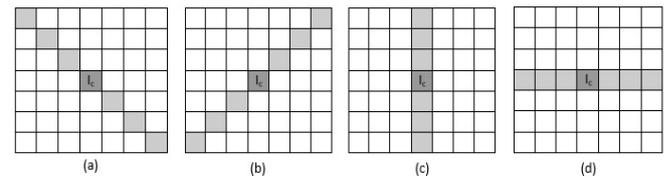


Fig. 4. a) píxeles considerados en el LL-BP \, b) píxeles considerados en el LL-BP /, c) píxeles considerados en el LL-BP |, d) píxeles considerados en el LL-BP-.

De forma similar al proceso de sustracción propuesto para calcular el detector LMBP-LT, en las cuatro variantes del descriptor LL-BP se aplica el mismo proceso tomando en consideración los siete píxeles $I_n(i,j)$ involucrados en cada variante y sustrayendo a cada píxel el píxel con el menor valor, obteniendo como resultado un nuevo conjunto de valores $I_m(i,j)$. Posteriormente, se calcula la media $\bar{I}_m(i,j)$ de $I_m(i,j)$. Finalmente, el descriptor LL-BP calcula el valor absoluto de la diferencia entre el píxel central $I_c(x,y)$ de $I_m(i,j)$ y cada uno de los píxeles restantes de $I_m(i,j)$; si el resultado es menor o igual que la media $\bar{I}_m(i,j)$, se coloca un 0, de lo contrario se coloca un 1 tal y como se muestra en la Ecuación (6).

$$LL-BP(x, y) = \sum_{p=0}^{N-1} \zeta(I_c(x, y), I_p) * 2^p \quad (6)$$

tal que:

$$\zeta(I_c(x, y), I_p) = \begin{cases} 0, & |I_c(x, y) - I_p| \leq \bar{I}_m(i, j) \\ 1, & |I_c(x, y) - I_p| > \bar{I}_m(i, j) \end{cases} \quad (7)$$

donde ζ representa la comparación entre 2 valores (ver Ecuación (7)), I_p es un píxel vecino de $I_c(x, y)$ que pertenece a $I_m(i, j)$ y N es el número de píxeles en $I_m(i, j)$ excluyendo el píxel central $I_c(x, y)$. Los resultados obtenidos al aplicar las 4 variantes del descriptor LL-BP en una imagen en escala de grises son presentados en la Figura 5.

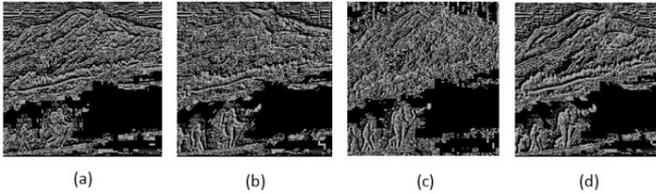


Fig. 5. Resultado de aplicar el descriptor LL-BP/ a la imagen de la Figura 3a, b) resultado de aplicar el descriptor LL-BP/ a la imagen de la Figura 3a, c) resultado de aplicar el descriptor LL-BP/ a la imagen de la Figura 3a, resultado de aplicar el descriptor LL-BP/ a la imagen de la Figura 3a. (Las imágenes presentadas en esta figura fueron ecualizadas para su mejor apreciación).

IV. MARCO DE TRABAJO PROPUESTO

El marco de trabajo propuesto incluye el uso de los descriptores MCT, LMBP-LT, las cuatro variantes del descriptor LL-BP, el descriptor GIST e información espacial y estadística de la escena. Este marco de trabajo tiene como objetivo combinar descriptores locales y globales junto con el descriptor LL-BP para mejorar la clasificación de escenas.

A. Información Espacial

La representación de la distribución espacial de los descriptores en la escena ha demostrado que puede ayudar a mejorar la discriminación entre imágenes de diferentes categorías, por ejemplo, en [15], [16], [26] se utiliza una representación piramidal para obtener resultados competitivos en la clasificación de imágenes de escenas de interiores y exteriores. Por esa razón en este marco de trabajo se desarrolla una representación piramidal de tres niveles (ver Figura 6). En

el primer nivel de la pirámide, la imagen es descrita mediante la aplicación del descriptor MCT sobre ventanas de 9x9 píxeles. Cada ventana de 9x9 píxeles es dividida en 9 sub-ventanas no solapadas de 3x3 píxeles y en cada sub-ventana se calcula la media de las intensidades de los píxeles. La media de cada sub-ventana es utilizada para formar una nueva ventana de 3x3 píxeles, donde el valor de la media de cada sub-ventana es ubicado dentro de la nueva ventana respetando la relación espacial de las sub-ventanas. El descriptor MCT es aplicado en la nueva ventana de 3x3 píxeles y subsecuentemente, se genera un histograma de 256 dimensiones con los resultados generados al utilizar el descriptor MCT. En el segundo y tercer nivel de la pirámide, las imágenes resultantes al aplicar los descriptores MCT, LMBP-LT y las cuatro variantes del descriptor LL-BP son divididas en matrices de 2x2 celdas y 4x4 celdas como se muestra en la Figura 6. En cada celda se calcula un histograma, obteniendo histogramas de 256 dimensiones para las celdas descriptas con los descriptores MCT y LBMP-LT, mientras que para las celdas descriptas con las 4 versiones del descriptor LL-BP se obtienen histogramas de 64 dimensiones.

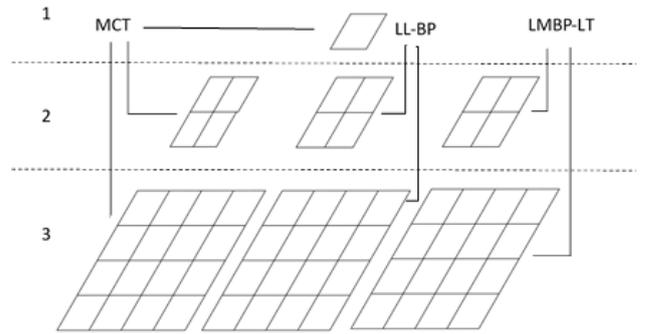


Fig. 6. Pirámide espacial de 3 niveles y el conjunto de descriptores (MCT, LMBP-LT y LL-BP) aplicados en los diferentes niveles.

Con el objetivo de reducir el tamaño del vector de características, se aplica el algoritmo PCA en varios vectores generados por los histogramas. En el primer nivel de la pirámide, el algoritmo PCA es aplicado al vector obtenido con el descriptor MCT y se seleccionan los primeros 20 eigenvectores. En el segundo y tercer nivel de la pirámide, el algoritmo PCA es aplicado a los vectores de cada celda obtenidos con los descriptores MCT y LMBP-LT y se seleccionan los 10 primeros eigenvectores. En estos 2 últimos niveles de la pirámide, los vectores obtenidos al utilizar las 4 versiones del descriptor LL-BP son combinados dentro de un vector de características de 256 dimensiones y posteriormente se aplica el algoritmo PCA, seleccionando los 10 primeros eigenvectores. Todos los eigenvectores seleccionados en cada nivel de la pirámide, son combinados dentro de un vector de características de 620 dimensiones.

B. Información Estadística

Con el objetivo de extraer información estadística de las escenas, las 5 imágenes resultantes de aplicar el descriptor LMBP-LT y las cuatro variantes del descriptor LL-BP sobre una imagen en escala de grises, son particionadas en celdas

como se muestra en los niveles 2 y 3 de la pirámide espacial presentada en la Figura 6; en cada celda se calcula la media y la varianza. La imagen resultante de aplicar el descriptor LMBP-LT es procesada aplicando por separado el descriptor LMBP-LT y las cuatro variantes del descriptor LL-BP, obteniendo 5 nuevas imágenes. Las 5 imágenes nuevas son particionadas en celdas como se muestra en los niveles 2 y 3 de la pirámide espacial presentada en la Figura 6 y para cada celda se calcula la media y la varianza. Los valores de la media y la varianza obtenidos en cada celda de las 10 imágenes son combinados en un vector de 400 dimensiones. El aplicar un descriptor binario sobre el resultado obtenido por otro descriptor binario (similar a como se realiza en [23]) tiene como objetivo diferenciar entre ventanas de 3x3 píxeles que contienen estructuras similares pero que se encuentran contenidas en contextos diferentes.

Por otro lado, se genera una imagen de contraste mediante la aplicación de la Ecuación (8), la cual calcula la varianza de cada píxel (VAR_p) dentro de ventanas de 3x3 píxeles [25]:

$$VAR_p = \frac{1}{N} \sum_{p=0}^{N-1} (I_p - \mu)^2 \quad (8)$$

tal que:

$$\mu = \frac{1}{N} \sum_{p=0}^{N-1} I_p \quad (9)$$

donde I_p es el p -ésimo píxel de una ventana de 3x3 píxeles y N es el número de píxeles contenidos en una ventana de 3x3 píxeles. Las imágenes de contraste y las imágenes en escala de grises son particionadas como se muestra en los niveles 2 y 3 de la pirámide espacial de la Figura 6 y en cada celda se calcula la media, generando un vector de características de 40 dimensiones. Uniendo los dos vectores de características generados en esta sección junto con el vector de características obtenido en la Sección 4A, se obtiene un vector de características de 1,060 dimensiones.

C. Descriptores GIST y LL-BP

Por último, dentro del marco de trabajo propuesto, el descriptor GIST y las cuatro variantes del descriptor LL-BP son aplicados sobre la imagen en escala de grises. El descriptor GIST realiza una descripción holística de una escena permitiendo medir el grado de expansión, apertura, naturaleza, aspereza y rugosidad de la escena. La configuración utilizada para aplicar el descriptor GIST es: 4 escalas, 8 orientaciones por escala y rejillas de 4 celdas; usando esta configuración, se obtiene un vector de características de 512 dimensiones. Mediante la aplicación de las cuatro variantes del descriptor LL-BP sobre la imagen original se obtiene un vector de 64 dimensiones por cada variante. Uniendo los vectores de características obtenidos por los descriptores GIST, las 4 variantes del descriptor LL-BP junto con el vector obtenido en la Sección 4B, se obtiene un vector de 1828 dimensiones.

V. RESULTADOS EXPERIMENTALES

En esta sección se presentan los resultados obtenidos al utilizar el marco de trabajo propuesto para la clasificación de

imágenes de escenas. Los conjuntos de imágenes seleccionados incluyen imágenes de interiores y exteriores. Estos conjuntos son ampliamente utilizados en la literatura, lo cual, permite comparar los resultados obtenidos con los reportados en otros trabajos relacionados.

Para todos los experimentos, se seleccionaron imágenes de forma aleatoria para los conjuntos de entrenamiento y prueba. Con el objetivo de validar los resultados obtenidos por el marco de trabajo propuesto, el número de imágenes para los conjuntos de entrenamiento y prueba fue ajustado utilizando la configuración reportada en los trabajos relacionados. En todos los experimentos, las imágenes fueron escaladas a un tamaño de 256x256 píxeles y las imágenes a color fueron convertidas a escala de grises.

Para la tarea de clasificación de escenas, se utilizó el enfoque de SVM (Support Vector Machine) con el HIK [27] (Histogram Intersection kernel) disponible en [28]. El HIK fue seleccionado debido a que ha mostrado un buen desempeño para la tarea de clasificación utilizando histogramas de descriptores [22].

Los algoritmos fueron implementados en el lenguaje C++ con el apoyo de la librería OpenCV 3.2. Las pruebas experimentales fueron realizadas utilizando el sistema operativo Linux Ubuntu 16.04 de 64 bits y un equipo de cómputo con un procesador Intel® Core™ i7 de 2.81GHz con 4 núcleos con 2 hilos de procesamiento por núcleo y 16 GB de RAM.

A. Conjuntos de Imágenes

Los conjuntos de imágenes de escenas para evaluar el desempeño del marco de trabajo propuesto y del descriptor LL-BP son descritas a continuación:

Conjunto de imágenes UIUC-8 [29]. Este conjunto contiene 1579 imágenes a color distribuidas en 8 categorías: *badminton* (200 imágenes), *bocce* (137 imágenes), *croquet* (236 imágenes), *polo* (182 imágenes), *rockclimbing* (194 imágenes), *rowing* (250 imágenes), *sailing* (190 imágenes) y *snowboarding* (190 imágenes). Los experimentos en este conjunto de imágenes se desarrollaron mediante la selección aleatoria de 70 imágenes de entrenamiento y 60 imágenes para prueba para cada una de las categorías.

Conjunto de imágenes 8-scene [8]. Este conjunto consiste de 2688 imágenes a color organizadas en 8 categorías: *coast* (360 imágenes), *forest* (328 imágenes), *mountain* (374 imágenes), *opencountry* (410 imágenes), *highway* (260 imágenes), *insidicity* (308 imágenes), *Tallbuilding* (356 imágenes) y *street* (292 imágenes). En contraste con los experimentos realizados en el conjunto ICUC-8, en el conjunto 8-scene se seleccionaron de forma aleatoria 100 imágenes de cada categoría para conformar el conjunto de entrenamiento y el resto fueron utilizadas en el conjunto de prueba.

Conjunto de imágenes 15-scene [15]. Este conjunto consiste de 4485 imágenes en escala de grises, distribuidas en 15 categorías, de las cuales 8 categorías pertenecen al conjunto 8-scene. Las nuevas categorías añadidas a este conjunto son: *bedroom* (216 imágenes), *kitchen* (210 imágenes), *livingroom* (289 imágenes), *office* (215 imágenes), *suburb* (241 imágenes), *industrial* (311 imágenes) y *store* (315 imágenes). En los

experimentos realizados sobre este conjunto se seleccionaron 100 imágenes de forma aleatoria de cada categoría para conformar el conjunto de entrenamiento y el resto para el conjunto de prueba.

B. Experimentos

En esta sección se presentan los experimentos realizados utilizando los conjuntos de imágenes UIUC-8, 8-scene y 15-scene. Los resultados obtenidos son mostrados en matrices de confusión, las cuales permiten identificar algunas posibles causas de la clasificación errónea de imágenes pertenecientes a diferentes categorías. Finalmente, se presenta una comparación entre los resultados obtenidos por el marco de trabajo propuesto y los resultados reportados por trabajos relacionados.

1) Experimento realizado sobre el conjunto UIUC-8

La Figura 7 muestra la matriz de confusión resultante de realizar una prueba sobre el conjunto UIUC-8. En particular, se puede apreciar la obtención de un 100% de efectividad para la categoría *badminton*. El resultado obtenido puede justificarse debido a que la mayoría de las imágenes de la categoría *badminton* son de escenas de interiores (ver Figura 8a) en contraste al resto de categorías, las cuales, están conformadas por imágenes de escenas de exteriores.

badminton	1.00							
bocce	0.05	0.65	0.20	0.02	0.05	0.02	0.02	
croquet		0.13	0.78	0.05	0.03			
polo	0.02	0.10	0.03	0.78	0.03		0.02	0.02
RockClimbing		0.05			0.87	0.03		0.05
rowing	0.02		0.02	0.03	0.02	0.88	0.02	0.02
sailing		0.02	0.02			0.05	0.92	
snowboarding	0.02	0.02	0.05	0.03	0.07		0.02	0.80

Fig. 7. Matriz de confusión resultante de la ejecución de un experimento en el conjunto UIUC-8 (no se muestran valores inferiores a 0.01).

Otro resultado destacable presentado en la Figura 7, es que las categorías *bocce* y *croquet* tienen las tasas más elevadas de clasificación incorrecta, estas dos categorías presentan una alta similitud perceptual en sus entornos (ver Figura 8b y 8c).

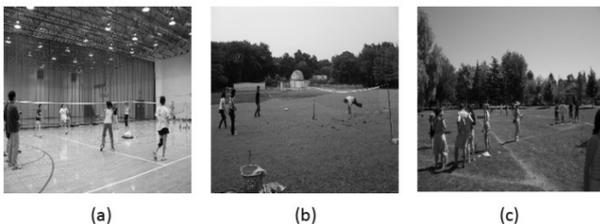


Fig. 8. Imágenes del conjunto UIUC-8, a) imagen de ejemplo de la categoría *badminton* en interiores, b) imagen de ejemplo de la categoría *badminton* en exteriores, c) imagen de ejemplo de la categoría *bocce*.

2) Experimento realizado sobre el conjunto 8-scene

La matriz de confusión presentada en la Figura 9 corresponde a un experimento realizado sobre el conjunto de imágenes 8-

scene. En esta matriz, se puede observar que en la categoría *opencountry* se obtiene un desempeño inferior al obtenido en el resto de las categorías. Las imágenes de la categoría *opencountry* son principalmente mal clasificadas dentro de las categorías *coast* y *mountain*.

coast	0.87		0.02		0.02	0.08		
forest		0.93			0.04	0.02		
highway	0.03		0.90	0.01	0.01	0.03	0.01	0.01
insidicity				0.87			0.06	0.06
mountain		0.03	0.01		0.85	0.10		
opencountry	0.08	0.03	0.03		0.05	0.80		
street			0.02	0.03	0.01		0.93	0.02
tallbuilding		0.01		0.05	0.02			0.92

Fig. 9. Matriz de confusión resultante de la ejecución de un experimento en el conjunto 8-scene (no se muestran valores inferiores a 0.01).

3) Experimento realizado sobre el conjunto 15-scene

En la Figura 10 se muestra la matriz de confusión obtenida al realizar un experimento sobre el conjunto 16-scene. En esta matriz se puede observar que las dos categorías que obtuvieron menor desempeño (*bedroom* y *livingroom*) presentan un elevado porcentaje de confusión en la clasificación de las imágenes entre ambas categorías. Por otro lado, el bajo desempeño obtenido en la clasificación de escenas de interiores ha sido demostrado en trabajos como [30], lo cual, se refleja en la matriz de confusión con los resultados obtenidos en las categorías *bedroom*, *kitchen*, *livingroom* and *store*, siendo una excepción la categoría *PARoffice*, que en este experimento obtuvo un 95% de exactitud.

bedroom	0.67		0.06	0.07	0.16				0.01					0.03	0.01	
CALsuburb		0.99			0.01											
industrial	0.01		0.72	0.02	0.02	0.03			0.03	0.01				0.02	0.02	0.09
kitchen	0.04		0.03	0.77	0.09				0.01						0.05	0.02
livingroom	0.15		0.03	0.07	0.63	0.01			0.01	0.01				0.01	0.05	0.04
MITcoast						0.87			0.04							
MITforest			0.01				0.95			0.03	0.01	0.01				
MIThighway					0.01			0.89	0.01	0.01	0.05	0.02	0.01			
MITinsidicity			0.04	0.01				0.01	0.82		0.01	0.01	0.06		0.03	
MITmountain						0.03				0.86	0.08		0.02			
MITopencountry			0.01				0.08	0.05	0.02		0.09	0.75				
MITstreet			0.02						0.01	0.02	0.01	0.01	0.91	0.02		0.01
MITtallbuilding	0.02		0.04							0.03	0.02			0.86		0.01
PARoffice	0.02			0.02	0.02										0.95	
store	0.01		0.07	0.07	0.05					0.01				0.01	0.01	0.76

Fig. 10. Matriz de confusión resultante de la ejecución de un experimento en el conjunto 15-scene (no se muestran valores inferiores a 0.01).

C. Comparación con otros Enfoques

Con el objetivo de validar el desempeño obtenido por el marco de trabajo propuesto y el descriptor LL-BP, se realizó una comparación de los resultados obtenidos en este trabajo contra los resultados reportados en la literatura para los conjuntos de imágenes UIUC-8, 8-scene y 15-scene. Todos los experimentos fueron repetidos 5 veces y para cada experimento

se seleccionaron de forma aleatoria las imágenes de entrenamiento y prueba, tal y como se realizó en trabajos previos de la literatura [16], [22], [31].

En la Tabla 1 se presentan los resultados reportados en diferentes trabajos de la literatura, así como los resultados obtenidos por el actual trabajo de investigación. En la columna “métodos” se indica el nombre del método utilizado y la referencia del mismo. La columna “Dimensión del vector” indica la dimensión del vector de características generado por cada método; en esta columna se indican dos dimensiones de vectores para el método LDBP[17] debido a que utiliza una configuración para clasificar solamente imágenes de escenas de exteriores obteniendo un vector de 840 dimensiones y en el caso de considerar categorías con escenas de interiores, la configuración es alterada para mejorar el desempeño del método, obteniendo como resultado un vector de 1260 dimensiones. En el caso del trabajo GECMCT-SpatialMCT se indican dos dimensiones, debido que se combinan a través de la regla “Producto” los métodos GECMCT y SpatialMCT obteniendo para cada método vectores de características de 1340 y 1302 dimensiones respectivamente, por lo que los requerimientos computacionales para dicha propuesta son mayores a los del resto de los métodos comparados.

TABLA I
COMPARACIÓN ENTRE LOS RESULTADOS EXPERIMENTALES OBTENIDOS EN LOS CONJUNTOS DE IMÁGENES UIUC-8, 8-SCENE Y 15-SCENE. LOS MEJORES RESULTADOS SON RESALTADOS EN NEGRITAS

Método	Dimensión del vector	UIUC-8	8-scene	15-scene
GIST [8]	512	61.2%	82.8%	74.3%
CENTRIST [16]	1302	78.3%	86.2%	83.9%
GBPWHGO [31]	1536	81.8%	88.4%	85.2%
LDBP [17]	840 1260	83.0%	88.1%	84.1%
GECMCT-SpatialMCT [22]	1340&1302	81.5%	89.0%	86.8%
Método propuesto	1828	84.3%	89.0%	85.7%

En las columnas “UIUC-8”, “8-scene” y “15-scene”, se presentan los porcentajes de exactitud obtenidos por los métodos evaluados en los conjuntos de imágenes correspondientes. Los mejores resultados obtenidos, para cada conjunto son resaltados con negrita. En el conjunto UIUC-8 el marco de trabajo propuesto obtuvo el mejor desempeño con 84.3% de exactitud, mientras que el método LDBP [17] presentó el desempeño más cercano con un 83.0% de exactitud. En el conjunto 8-scene, tanto el marco de trabajo propuesto como el GECMCT-SpatialMCT [22] obtuvieron un 89% de exactitud. Finalmente, en el conjunto 15-scene el GECMCT-SpatialMCT [22] obtuvo el mejor resultado con un 86.8% de exactitud, mientras que el marco propuesto obtuvo el segundo mejor resultado con un 85.7% de exactitud. Se puede observar, que tanto el marco de trabajo propuesto como el GECMCT-SpatialMCT [22] obtienen el mejor desempeño general en los 3 conjuntos de imágenes, sin embargo, el GECMCT-SpatialMCT [22] requiere del cálculo de dos vectores, teniendo un total de 2642 características y adicionalmente cada vector es usado para entrenar un modelo de SVM, mientras que el marco de trabajo propuesto maneja un solo vector de características 1828 dimensiones para entrenar a un único modelo de SVM. Por otro

lado, cuando el descriptor LL-BP no es incluido dentro del marco de trabajo propuesto, el desempeño se redujo a un 83.8%, 88.4% y 85.3% de exactitud en los conjuntos UIUC-8, 8-scene y 15-scene respectivamente. Esto se debe a que el descriptor LL-BP proporciona una descripción con un soporte espacial mayor que el resto de los descriptores binarios no proporcionan.

VI. CONCLUSIONES

En este artículo se presentó un marco de trabajo que permite combinar un conjunto de descriptores locales y globales para mejorar la clasificación de escenas. Los resultados obtenidos muestran que en el marco de trabajo propuesto se genera un vector de características cuyas dimensiones son mayores a la mayoría de los vectores obtenidos con los métodos comparados, sin embargo, el marco de trabajo presenta un mejor desempeño al mejorar la exactitud en la clasificación. El GECMCT-SpatialMCT presentó un desempeño similar al marco de trabajo propuesto, no obstante, el marco de trabajo propuesto tiene la ventaja de generar un solo vector de características y de requerir solamente del entrenamiento de un único modelo de SVM para realizar la tarea de clasificación de escenas, reduciendo la cantidad de procesos computacionales requeridos para dicha tarea.

Otra aportación importante es el desarrollo del nuevo descriptor binario LL-BP, el cual, al ser utilizado dentro del marco de trabajo propuesto ayuda a mejorar la exactitud en la clasificación de escenas. Adicionalmente, durante el desarrollo del descriptor LL-BP se estableció un nuevo proceso de normalización de valores de los píxeles para el cálculo de un umbral local, el cual fue utilizado para calcular los descriptores LL-BP y LMBP-LT. En ambos descriptores, el uso de un umbral local permitió que las descripciones obtenidas fueran complementarias con las descripciones obtenidas por el resto de descriptores utilizados en el marco de trabajo propuesto, lo cual ayudó a mejorar los resultados obtenidos.

REFERENCIAS

- [1] B. Anbarasu and G. Anitha, “Indoor Scene Recognition for Micro Aerial Vehicles Navigation using Enhanced-GIST Descriptors,” *Defence Science Journal*, Vol. 68, No. 2, pp. 129-137, 2018.
- [2] R. Osorio, I. López, J. Savage, M. Peña, V. Lomas and G. Lefranc, “Surveillance System Mobile Object Using Segmentation Algorithms,” *IEEE Latin America Transactions*, Vol. 13, No. 7, pp. 2441-2446, July, 2015.
- [3] K. Huang, D. Tao, Y. Yuan, X. Li and T. Tan, “Biologically inspired features for scene classification in video surveillance,” *IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics*, Vol. 41, No. 1, pp. 307-313, 2011.
- [4] T. Le, M. Thonnat, A. Boucher and F. Brémond, “Surveillance Video Indexing and Retrieval using Object Features and Semantic Events,” *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 23, No. 7, pp. 1439-1476, 2009.
- [5] K. Jungho, P. Chaehoon and K. In So, “Vision-Based Navigation with Efficient Scene Recognition,” *Intelligent Service Robotics*, Vol. 4, No. 3, pp. 191-202, 2011.
- [6] J. Yao, S. Fidler, R. Urtasun, “Describing the scene as a whole: Joint object detection, scene classification and semantic segmentation,” *2012 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 702-709, 2012.
- [7] V. C. Gonzalo, S. Das, J. P. Sousa, N. D. Lobo, M. Shah, “Improved scene identification and object detection on egocentric vision of daily

- activities,” *Computer Vision and Image Understanding*, Vol. 156, pp. 92-103, 2017.
- [8] A. Oliva and A. Torralba, “Building the Gist of a Scene: The Role of Global Image Features in Recognition,” *Progress in Brain Research*, Vol. 155, pp. 23-36, 2006.
- [9] J. Chu and G. H. Zhao, “Scene classification based on SIFT combined with GIST,” 2014 International Conference on Information Science, Electronics and Electrical Engineering (ISEEE), Vol. 1, pp. 331-336, 2014.
- [10] F. Jiangfan, L. Yuanyuan, W. Lin, “Bag of Visual Words Model with Deep Spatial Features for Geographical Scene Classification,” *Computational Intelligence and Neuroscience*, Vol. 2017, pp. 1-14, 2017.
- [11] S. Banerji, A. Sinha and C. Liu, “A New Bag of Words LBP (BoWL) Descriptor for Scene Image Classification,” *International Conference on Computer Analysis of Images and Patterns (CAIP 2013)*, pp. 490-497, 2013.
- [12] B. Fröba and A. Ernst, “Face Detection with the Modified Census Transform,” *Proceedings of the Sixth IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 91-96, 2004.
- [13] K. Jeong and J. Choi, “Semi-Local Structure Patterns for Robust Face Detection,” *IEEE Signal Processing Letters*, Vol. 22, No. 9, pp. 1400-1403, 2015.
- [14] F. Ozdemir, E. Ozkan and O. Goksel, “Graphical Modeling of Ultrasound Propagation in Tissue for Automatic Bone Segmentation,” *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016*, Vol. 9901, pp. 256-264, 2016.
- [15] S. Lazebnik, C. Schmid and J. Ponce, “Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories,” *Proceedings of the 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 2169-2178, 2006.
- [16] J. Wu and J. M. Rehg, “CENTRIST: A Visual Descriptor for Scene Categorization,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 33, No. 8, pp. 1489-1501, 2011.
- [17] X. Meng, Z. Wang and L. Wu, “Building Global Image Features for Scene Recognition” *Pattern Recognition*, Vol. 45, No. 1, pp. 373-380, 2012.
- [18] M. Song and P. Guo, “Combining Local Binary Patterns for Scene Recognition,” *Journal of Software*, Vol. 9, No. 1, pp. 203-210, 2014.
- [19] C. Gao, N. Sang and R. Huang, “Spatial multi-scale gradient orientation consistency for place instance and Scene category recognition,” *Information Science*, Vol. 372, pp. 84-97, 2016.
- [20] A. Fernández, J. L. Carús, R. Usamentiaga and R. Casado, “Face Recognition and Spoofing Detection System Adapted to Visually-Impaired People”, *IEEE Latin America Transactions*, Vol. 14, No. 2, pp. 913-921, 2016.
- [21] D. Liu, S. Wang, D. Huang, G. Deng, F. Zeng and H. Chen, “Medical image classification using spatial adjacent histogram based on adaptive local binary patterns”, *Computers in Biology and Medicine*, Vol. 72, pp. 185-200, 2016.
- [22] K. Gazolli and E. Salles, “Exploring Neighborhood and Spatial Information for Improving Scene Classification,” *Pattern Recognition Letters*, Vol. 46, No. 1, pp. 83-88, 2014.
- [23] K. Gazolli and E. Salles, “A Contextual Image Descriptor for Scene Classification,” *Online Proceedings on Trends in Innovative Computing*, pp. 66-71, 2012.
- [24] T. Ojala, M. Pietikäinen and T. Mäenpää, “Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Pattern,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, No. 7, pp. 971-987, 2002.
- [25] S. Banerji, A. Shina and C. Liu, “Scene Image Classification: Some Novel Descriptors,” *IEEE International Conference on Systems, Man, and Cybernetics (SMC 2012)*, 2012, pp. 14-17.
- [26] F. X. Lu and J. Huang, “Beyond Bag of Latent Topics: Spatial Pyramid Matching for Scene Category Recognition,” *Frontiers of Information Technology & Electronic Engineering*, Vol. 16, No. 10, pp. 817-828, 2015.
- [27] J. Wu and J. M. Rehg, “Beyond the Euclidean Distance: Creating Effective Visual Codebooks Using the Histogram Intersection Kernel,” *IEEE 12th International Conference on Computer Vision*, pp. 630-637, 2009.
- [28] C. C. Chang and C. J. Lin, “LIBSVM: A Library for Support Vector Machines,” *ACM Transactions on Intelligent Systems and Technology (TIST)*, Vol. 2, No. 3, pp. 1-27, 2011.

[29] L. J. Li and L. Fei-Fei, “What, Where and Who? Classifying Events by Scene and Object Recognition,” *IEEE 11th International Conference on Computer Vision*, pp. 1-8, 2007.

[30] A. Quattoni and A. Torralba, “Recognizing Indoor Scenes,” *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 413-420, 2009.

[31] L. Zhou, Z. Zhou and D. Hu, “Scene Classification Using Multi-Resolution Low-Level Feature Combination,” *Neurocomputing*, Vol. 122, pp. 284-297, 2013.



Salvador Cervantes, recibió el grado de Maestro y el grado de Doctor en Ciencias de la Computación por el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) en México. Actualmente se desempeña como profesor-investigador de tiempo completo en el Centro Universitario de los Valles de la Universidad de Guadalajara en México. Sus áreas de interés son: Procesamiento Digital de Imágenes, Reconocimiento de Patrones e Inteligencia Artificial.



Adriana Mexicano Santoyo obtuvo el grado de Doctora en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) en el año 2012. Actualmente es profesora en el Instituto Tecnológico de Cd. Victoria. Sus áreas de interés incluyen el análisis de algoritmos, optimización combinatoria, descubrimiento de conocimiento, entre otras.



José Antonio Cervantes Alvarez, recibió el grado de Maestro en Ciencias de la Computación por el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) y el grado de Doctor en Ciencias en Ingeniería Eléctrica por el Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV). Actualmente es profesor-investigador en el Centro Universitario de los Valles de la Universidad de Guadalajara, México. Sus áreas de interés incluyen modelado de funciones cognitivas bio-inspiradas, modelado de normas morales y éticas para sistemas autónomos e interfaces cerebro-computadora.



Ricardo Rodríguez Jorge se doctoró en Ciencias en Ingeniería Mecánica en el área de especialidad de Ingeniería en Sistemas y Control por la Universidad Técnica Checa en Praga. Actualmente es profesor titular en el departamento de Ingeniería Industrial y Manufactura de la Universidad Autónoma de Ciudad Juárez. Sus intereses de investigación se orientan en el área de procesamiento de señales, predicción de series de tiempo, reconocimiento de patrones, inteligencia artificial y redes neuronales artificiales.



J. Fuentes-Pacheco, recibió el grado de Ingeniero por el Instituto Tecnológico de Chilpancingo en el 2006, el grado de Maestro y Doctor en Ciencias de la Computación por el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) en México, en 2009 y 2014 respectivamente. Durante los años 2015 y 2016 realizó una estancia posdoctoral en el Centro de Investigación en Ciencias (CInC) de la Universidad Autónoma del Estado de Morelos en Cuernavaca, México. Actualmente es Catedrático CONACYT asignado al CInC. Sus áreas de interés son Visión por Computadora, Robótica e Inteligencia Artificial.