

Clasificación de maderas por corte usando su propio contenido de textura usando la metodología CBIR

Gabriel de Jesús Celis-Escudero¹, Juan Villegas-Cortez¹, Carlos Avilés-Cruz¹, Arturo Zúñiga-López¹, Andrés-Ferreyra Ramírez¹, Roman A. Mora-Gutiérrez², Cesar Benavides-Alvarez³

¹ Universidad Autónoma Metropolitana, Unidad Azcapotzalco, Departamento de Electrónica. San Pablo Xalpa No. 180, Col. Reynosa Tamaulipas, CP 02200, Ciudad de México, México.

² Universidad Autónoma Metropolitana, Unidad Azcapotzalco, Departamento de Sistemas.

³ Universidad Autónoma Metropolitana, Unidad Iztapalapa, Departamento de Ing. Eléctrica, San Rafael Atlixco 186, Vicentina. CP 09340, Ciudad de México, México. gjcelis90@gmail.com, {juanvc, caviles, azl, mgra, fra}@azc.uam.mx, cesarba@xanum.uam.mx

Resumen. En la actualidad la identificación adecuada de la madera a través de sus elementos anatómicos macroscópicos es una actividad importante en la industria y su comercialización. Sin embargo, la identificación por elementos macroscópicos requiere un adiestramiento previo que varios usuarios no poseen. Por ende surge la necesidad de proveer a los usuarios de maderas una herramienta capaz de identificar la especie o género arbóreo a la que pertenece una muestra de madera (tabla, tablón, polín etc.), sin ser expertos agrónomos o botánicos. La textura en las imágenes digitales macroscópicas de madera poseen el potencial para caracterizar, estudiar y clasificar una muestra. En el presente trabajo proponemos clasificar imágenes de muestras de maderas mexicanas con base en su imagen y sus propias características, utilizando la técnica CBIR (Content Based Image Retrieval), siendo la primera aproximación sencilla y efectiva para la madera de especies mexicanas. Se ha entrenado un clasificador de distancia con una base de datos de 39 especies, y se logró una clasificación del 100% de éxito por medio de la técnica de resustitución, con una implementación basada en código abierto en lenguaje Python y librería OpenCV.

Palabras clave: Texturas en las imágenes, Clasificación de maderas mexicanas, CBIR, OpenCV, Reconocimiento de patrones, Tecnología de maderas

Classification of Woods by Cutting Texture by Means of CBIR

Abstract. According to current literature, proper wood identification through its atomic macroscopic elements is an important procedure for the

industry and wood commercialization. Nevertheless, the identification by its macroscopic elements requires previous training which several users do not possess. Therefore, users of wood have the need to identify the taxonomy of woods in order to determine the origin of a wood's sample (such as tablet, plank and pollin) without having expertise on the field. The texture of woods in digital images has the potential to analyze and classify the sample with accuracy. The following paper states a method for classifying Mexican woods samples with the application of Content Based Image Retrieval technique (CBIR). Previous data show a hundred percent success rate in sample classification of 39 species with the CBIR method in conjunction with computer languages such as Python and library OpenCV.

Keywords: Texture of Woods in Digital Images, Classifying Mexican Woods, CBIR, OpenCV, Pattern Recognition

1. Introducción

La inteligencia artificial (IA) busca desarrollar métodos y algoritmos que le permitan comportarse a las computadoras de modo inteligente. La IA comprende un amplio conjunto de algoritmos, y su efectividad esta estrechamente relacionada con la calidad de la información de la cual se aprende con base en el objetivo a alcanzar para tomar decisiones [1].

México es uno de los países mega diversos del mundo; las características geográficas, climáticas y ambientales del mismo determinan que más del 70 % del territorio sea de aptitud preferentemente forestal. El gran potencial forestal de México ha promovido que en los últimos gobiernos se busque incrementar la producción maderable nacional. El potencial maderable del país incluye a una variedad amplia de coníferas tales como: pinos, cedros blancos, entre otros); además de varias latifoliadas como cedro rojo, caoba, palofierro, etc [2].

La gran cantidad de especies arbóreas con aptitud de explotación maderables, plantean la necesidad de un instrumento que permita la identificación y control de la madera para los industriales (aserraderos, transporte de maderas, muebles), en supervisores gubernamentales y usuarios finales. En otras palabras, en la tipificación de maderas es deseable poder conocer la especie maderable con la que se esta trabajando o que se va adquirir. En el presente trabajo la clasificación de maderas se realiza a partir de la imagen de su corte, o en términos técnicos a partir de su textura del corte.

En términos generales se define a la madera como la parte sólida y rígida que se encuentra bajo la piel de los tallos leñosos de los árboles, i.e., es el tejido leñoso que sirve de sostén al árbol [3].

De manera frecuente se clasifica a la madera para diferentes propósitos. La madera se forma por albura y duramen. La albura es madera joven, la cual al paso del tiempo y de procesos físico-químicos se transforman en duramen (también llamada madera vieja, o bien, albura ha pasado por el proceso de duraminización).

En este trabajo mostramos el desarrollo e implementación de un sistema CBIR, aplicado en una base de datos de un grupo de fotografías de maderas mexicanas, aunque se podrá utilizar en otras maderas con un aprendizaje o entrenamiento previo. Al parecer es el primer trabajo de este tipo aplicado a maderas mexicanas, y además en comparación con otros trabajos [4], presentamos un alcance basado en el estudio de textura macroscópica, más sencillo y con la aplicación de caracterizar el patrón de la textura de superficie a partir de rasgos estadísticos. Por ende, las propiedades macroscópicas a considerar en las imágenes de madera son: color, brillo (alto, medio o bajo), textura (efecto visual de la superficie de la madera resultado de la porosidad, anillos de crecimiento y demás estructuras celulares), hilo (forma de crecimiento de las células).

La manera usual de clasificar y por ende determinar las maderas es de manera visual o química, ya sea resinas naturales o artificiales halladas. Muchas veces depende de la habilidad técnica desarrollada por el especialista, o si en algún momento llevo un tratamiento la madera [2]. La metodología CBIR se ha utilizando para el reconocimiento de imágenes por su contenido, por medio de la textura, es así que es prudente su utilización para la clasificación y reconocimiento de maderas por medio de su textura visualizada en el corte.

En la sección 2 presentamos el Estado del arte de la metodología CBIR y sus aplicaciones previas, en la sección 3 la metodología a detalle se explica, en la sección 4 la experimentación y resultados son presentados con explicaciones específicas orientadas para que pueda ser replicada, y los resultados con su análisis se muestran en la sección 5, finalmente en la sección 6 ofrece las conclusiones y el trabajo futuro.

2. Estado del arte

En la última década con el aumento de las imágenes en la Internet, a la par de la masificación de las redes sociales, el aumento de la capacidad de almacenamiento en la red o en la nube junto al auge de las imágenes y el hecho de que no estén clasificadas todas ha propiciado el desarrollo de herramientas que traten de paliar este problema; hablando de cantidades reportadas en el año 2017, se estimó en un billón la cantidad de imágenes digitales acorde a una investigación reportada por el servicio mylio.com (véase URL: <http://tinyurl.com/y2jo5wal>), tal que el 85 % de ellas fueron tomadas por un teléfono móvil. Ante esta realidad se tiene la posibilidad de crear nuevos repositorios de bases de datos de imágenes, pero el reto es clasificarlas acorde a su contenido, de forma no-supervisada, y con una alta eficiencia de forma simple y rápida, todo ello orientado al trabajo fundamental de organizar, proteger y compartir [5].

La técnica CBIR (Content Based Image Retrieval) trabaja y funciona para atacar este problema y tiene resultados probados en identificación y clasificación de imágenes de interés, tales como los escenarios naturales [6] y la clasificación de rostros humanos [7]. Muchos sistemas y herramientas CBIR se han desarrollado para la consulta de imágenes, tal como Query By Image Content (QBIC) desarrollado en los años 90s por IBM, que permite al usuario consultas dentro

de una gran base de datos con base a atributos de la imagen [8].

CBIR es un sistema que tiene dos funciones principales: (i) Inserción de datos, que es un método no supervisado para la extracción de información, tal como color, forma o texturas, de la base de datos para ser guardados autoagrupados por medio de un algoritmo para su futura utilización; y (ii) Procesamiento de consultas, que mediante una imagen de muestra, obteniendo sus características, serán comparadas con métricas específicas hacia los racimos de datos autoagrupados en el paso previo, y así obtener el valor dentro de la clasificación previamente hecha de la base de datos.

Anteriormente la clasificación de las imágenes se llevaba a cabo de forma manual y por medio de metadatos insertados en las imágenes, pero, en una base de datos muy grande conlleva un costo enorme para su clasificación, y otro problema era cuando estos metadatos se realizaban en diferentes idiomas. Con el uso de CBIR se puede automatizar esta tarea de clasificación, ya que se realiza por medio de características de la misma imagen sin necesidad de metadatos, etiquetas o intervención externa.

Cabe mencionar que la investigación anatómica de maderas mexicanas se desarrolló fuertemente a mitad del siglo pasado en México de la mano Investigadores como Juana Huerta Crespo, Ramón Echenique Manrique, Gózaló Novelo Gózales entre otros. Como se mencionó con anterioridad, los estudios de identificación de maderas con base a las propiedades macroscópicas y organolépticas son de suma importancia en el sector forestal, sin embargo en la actualidad la clasificación correcta de la madera depende fuertemente habilidad técnica desarrollada por el especialista [2].

En otros trabajos relacionados, podemos citar a [4], ahí realizan un estudio de la textura de las maderas a nivel microscópica y macroscópica, además de imágenes en estereogramas, a diferencia de la simplicidad de nuestro trabajo donde únicamente usamos fotografías macroscópicas obtenidas de forma controlada en nuestro laboratorio, con muestras comunes de campo; adicionalmente ellos hacen un preprocesado de las imágenes más costoso basado en aplicación de máscaras, y finalmente su mejor aproximación es de un reconocimiento del 90 %, mientras con nuestra propuesta logramos el 100 % de clasificación. Es recomendable revisar ese trabajo para ver los estudios de los intentos previos a su propuesta, mismos que aquí sólo referenciamos.

Se definen como características macroscópicas aquellas cualidades de la madera que pueden ser determinadas a simple vista o haciendo uso de una lupa de 10 aumentos; en contraste, las propiedades organolépticas son aquellas que se aprecian por a través de los sentidos. Las principales cualidades macroscópicas y organolépticas de las maderas a considerar en las clasificaciones son: color, olor sabor, brillo, textura e hilo.

3. Metodología

Para el problema de la clasificación de maderas se propone el modelo mostrado en la figura 1 [7].




Fig. 1. Metodología aplicada para la clasificación de imágenes de cortes de maderas.

En ella se plantean los pasos siguientes:

- Base de datos de fotografías macroscópicas de maderas, de la cual serán extraídas las imágenes para ser analizadas en su contenido,
- Transformar el espacio de color de RGB hacia HSI [8], esto nos proporcionara la información necesaria, tal como es la textura, luminosidad, saturación de color, etc.
- Generar el sembrado de puntos fijos[8] en forma de malla de 10×10 , véase una muestra en la siguiente página en la figura 2
- Obtener los atributos estadísticos de textura de la imagen, siendo la media μ , desviación estándar σ , y homogeneidad h [9].
 - Para la homogeneidad es necesario calcular la probabilidad de cada una de las combinaciones posibles de los elementos, como se muestra en la ecuación 1, para a continuación realizar el calculo de homogeneidad [10] de la región establecida con la ecuación 2.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (1)$$

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i + j)^2} \quad (2)$$

- Normalizar los datos de la matriz obtenida, para ello es necesario obtener el valor máximo y mínimo de cada columna y aplicar la ecuación 3.

$$\frac{Valor - V_{Max}}{V_{Max} - V_{min}} \quad (3)$$

- Una vez normalizada, véase la tabla 1, se crea la matriz indexada, mostrada en la tabla 2 realizada con 20 centroides, donde se encuentran clasificados los datos, observando como están distribuidas las texturas de las imágenes en los k centroides, calculados por k -means,
- Finalmente los datos de la matriz se disponen en orden a partir de la aplicación del algoritmo K -NN basado en métrica euclidiana.




Fig. 2. Distribución regular del sembrado de puntos en la imagen de un corte de madera.

Tabla 1. Datos normalizados de los atributos.

	μ de H	σ de H	h de H	μ de S	σ de S	h de S	μ de I	σ de I	h de I
1	0.1258	0.01025	0.6816	0.2270	0.1254	0.7569	0.8904	0.1894	0.4989
2	0.1262	0.009393	0.8282	0.2956	0.292	0.7677	0.8458	0.209	0.6136
3	0.1287	0.01052	0.7696	0.209	0.1172	0.8099	0.9114	0.1994	0.5722
...	...								
19500	0.09129	0.01496	0.5713	0.6231	0.2982	0.1110	0.3557	0.2583	0.1746

Tabla 2. Matriz indexada, "Matriz de clasificación".

	Cen 1	Cen 2	Cen 3	Cen 4	Cen 5	Cen 6	Cen 7	Cen 8	Cen 9	Cen 10
1	0	0	0	100	0	0	0	0	0	0
2	0	0	0	100	0	0	0	0	0	0
3	0	4	0	96	0	0	0	0	0	0
...	...									
195	35	0	63	0	1	0	0	0	1	0

Una vez realizado el entrenamiento, el siguiente paso es la recuperación. En este proceso realizaremos tres tipos de pruebas de recuperación [11]: La primera por resustitución, estos es, se tomara una imagen dentro de la misma base de aprendizaje para ser consultada y obtener su clasificación; la segunda consta de dejar uno fuera LOO (Leave One Out), donde se toma una muestra de la base de datos que no sera introducida en el proceso de aprendizaje; y tercera por validación cruzada CV (Cross Validation), donde cierto porcentaje de la base de datos no se toma en cuenta en el aprendizaje y se utilizara para prueba como consulta de muestra desconocida, en este trabajo se tomara el 60% de la base de datos para el aprendizaje, y el 40% restante para prueba. Cada uno de los métodos de recuperación son básicamente el mismo, tal como lo muestra la figura 3, la diferencia es la cantidad de imágenes insertadas para el aprendizaje y la consulta. El algoritmo K -NN se ocupa para realizar la recuperación, ya que la principal tarea es realizar una clasificación de las imágenes con los centroides dados por k -Means. En este caso los centroides son la clasificación obtenida en el aprendizaje. Para determinar el porcentaje de precisión se comparara las

primeras 5 imágenes más cercanas a la de consulta.

La implementación se desarrolló en lenguaje Python, de forma secuencial, utilizando la librería OpenCV para el uso de k -Means. El Hardware empleado es una computadora tipo PC con especificaciones: Procesador AMD A8-9600, 4 cores y 4 threads a 3.9Ghz; memoria RAM de 6GB a 2133Mhz; Sistema operativo Linux Ubuntu 18.04 de 64 bits. Las imágenes fueron tomadas con una cámara NIKON D3200 en formato RAW y convertidas a JPG con los mismos valores de revelado.

En el presente trabajo, para obtener una base de datos de imágenes ideales, las fotografías fueron realizadas en un ambiente controlado en el laboratorio de Multimedia de la UAM AZC (URL: <http://zeus.azc.uam.mx/multimedia/>), donde los parámetros: velocidad de obturación, apertura de diafragma, valor de exposición, balance de blancos y cantidad de luz son los mismos. La base de datos consta de 195 elementos y la cual es parte de la contribución del presente trabajo.

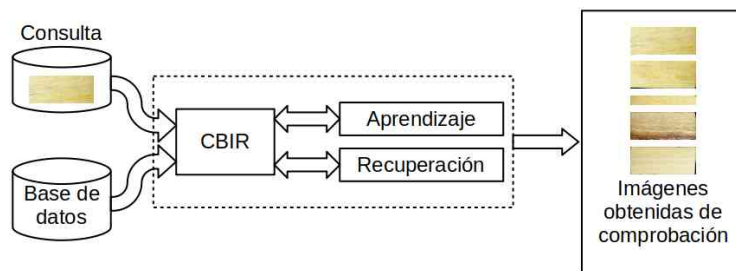


Fig. 3. Metodología de recuperación.

4. Experimentación y resultados

En esta sección mostraremos los resultados de los experimentos, obtenidos por la metodología propuesta.

Para la obtención de resultados, se realizaron dos variaciones en las pruebas; el número de centroides, $K = \{5, 10, 15, 20, 25, 30, 40, 50, 60\}$, y el tamaño de la base de datos introducida en el aprendizaje, tal que son el 100% (toda la base de datos dentro del aprendizaje), 99.49% (se deja una imagen fuera del aprendizaje), y 60% (117 imágenes de la base de datos son introducidas en el aprendizaje).

Las fotografías de la base de datos son de dimensiones variables. El número de iteraciones en k -Means fue de 100, siendo el mismo número en cada proceso, la variación del tiempo de aprendizaje es con base en el número de centroides que se establezcan y la cantidad de imágenes introducidas, como se muestra en la figura 4.

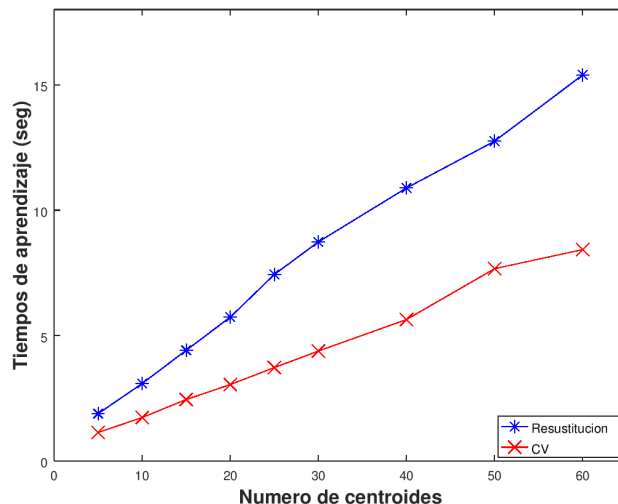


Fig. 4. Tiempos de aprendizaje para recuperación y CV.

La recuperación se basa en encontrar por medio de la clasificación a las imágenes mas cercanas usando la métrica euclidiana. Esto es:

- Carga de la *imagen de consulta*.
- *Transformación del espacio* de color RGB a HSI.
- *Sembrado de puntos*.
- Obtención de *atributos estadísticos*.
- Normalizar los valores de μ , σ y h . Para normalizar se utilizaron los valores de mínimos y máximos obtenidos en el aprendizaje.
- Aplicación de *k-Means* para obtener los centroides, y *K-NN* para clasificar la consulta con base al aprendizaje.
- Por ultimo, se debe introducir el resultado de la clasificación de la consulta a *K-NN* y utilizar como centroides a la clasificación obtenida en el aprendizaje.

Usando la matriz de confusión se realizó el cálculo de porcentaje de precisión de nuestra propuesta, utilizando la ecuación 4, siendo los valores de la diagonal de la matriz de confusión y el calculo de porcentaje de recuperación se lleva acabo con la ecuación 5. En la figura 5 se muestra un ejemplo de las clases obtenidas en el aprendizaje. La clase 1 son maderas claras de brillo alto de textura media e hilo recto; la clase 2 corresponde a maderas pardas de textura media brillo medio; clases 4 a 6 son duramen de maderas con color característico, textura fina de hilo recto; las clases 3, 7 a 9 corresponden a maderas de textura gruesa de hilo recto, la 3 y 7 presentan albura y duramen en la misma muestra, mientras que la muestra 9 muestra un defecto en la madera.

$$Precision = \frac{Numero\ de\ imagenes\ relevantes\ recuperadas}{Total\ de\ numero\ de\ imagenes\ relevantes} \times 100\% \quad (4)$$

$$Recuperacion = \frac{Numero\ de\ imagenes\ relevantes\ recuperadas}{Total\ de\ numero\ de\ imagenes\ de\ la\ base\ de\ datos} \times 100\% \quad (5)$$



Fig. 5. Imágenes de muestra de la base de datos.

Algunos ejemplos de los resultados obtenidos se muestran a continuación. En la figura 6(a) se muestra del método por resustitución las respuestas 1, 2 y 4 son del mismo tipo de madera que la consulta. En la figura 6(b) las imágenes de respuesta 1 y 3, por el método LOO, son del mismo tipo que la de consulta y; en la figura 6(c) por el método de CV la imagen de la respuesta 4 se encuentra en el mismo tipo de madera que la consultada. Estos resultados son los obtenidos con $K = 60$.

5. Resultados

En este trabajo se declara un acierto si una imagen o mas, de las primeras cinco obtenidas por la recuperación pertenecen a la clase de la consulta, ya que las maderas llegan a tener diferentes texturas dependiendo del corte realizado, como el ejemplo mostrado en la figura 7. Como se observa en la figura 6, tres de los elementos de recuperación pertenecen a la clase de la imagen de consulta, y las 2 imágenes faltantes no estarán en las 5 primeras imágenes de recuperación aun cuando son del mismo tipo de madera, ya que en estas se observan los poros de

Consulta	Res #1	Res #2	Res #3	Res #4	Res #5	
						(a)
						(b)
						(c)

Fig. 6. Resultados de la recuperación de 3 imágenes diferentes en los tres tipos de métodos de recuperación: (a) por resustitución, (b) por LOO y (c) por CV.




Fig. 7. Ejemplo de los cortes de las fotografías de muestras.

la madera que son típicos en cortes radiales, y en la imagen de consulta los poros son líneas o rayas como los observados en cortes longitudinales o tangenciales.

En la gráfica de la figura 8 se muestra la precisión obtenida de cada uno de los métodos. En las pruebas por resustitución los resultados que se obtienen aun con un número pequeño de centroides, $K = 5$, son de un 100 %; esto mismo sucede con LOO, donde el porcentaje de precisión es de 100 % en todos los casos. Y en CV la precisión varía significativamente, tal que con $K = 5$ la precisión es menor a al 50 % y con $K = 40$ se obtiene una precisión poco mayor al 80 %, siendo esta la mejor.

6. Conclusiones

Hemos presentado en este artículo la primera aproximación a clasificación e identificación de tipos de maderas mexicanas a partir de su imagen y textura de corte, haciendo uso de la técnica CBIR para poder generar un patrón descriptivo de su textura sin el uso de palabras o etiquetas asociadas a un lenguaje o idioma, teniendo como fuente directa de la información al contenido de la propia imagen de estudio, logrando una clasificación del 100 % con las condiciones de imágenes fijas y fotografiadas en ambiente de iluminación controlado.

También estamos compartiendo nuestra base de datos generada para este primer estudio, con la finalidad de que más estudiosos del tema, o personas interesadas en la preservación e identificación de patrones de adecuación de las especies arbóreas, deseen hacer en seguimiento de sus proyectos de investigación y estudios vinculados.

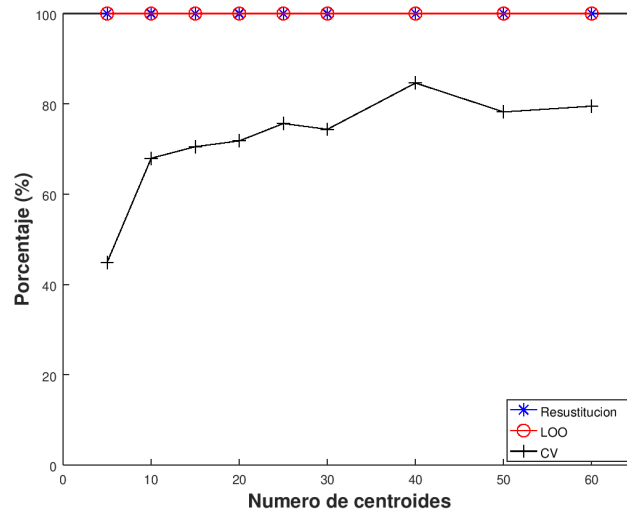


Fig. 8. Porcentaje de precisión en: Resustitución, LOO y CV.

En este primer trabajo de aplicación de visión por computadora apoyada en algoritmos de clasificación por auto agrupamiento y usando una métrica de distancia, consideramos que marca el siguiente paso hacia las vertientes de poder realizar la identificación de las maderas en ambientes no controlados, específicamente en imágenes con ruido, o bien tomadas en entornos laborales, tales como talleres, aserraderos, museos, etc.

Como parte del fortalecimiento de la implementación, también se considera poder aplicar otras metodologías más complejas de cómputo numérico, para comparar el rendimiento versus la simplicidad de la técnica CBIR reportada. En trabajos futuros se integrara más información que permitirá asociar la identificación de la especie y la usabilidad de la madera.

Agradecimientos. Este trabajo ha sido resultado del proyecto de investigación divisional CBI EL006-18 de la Universidad Autónoma Metropolitana unidad Azcapotzalco.

Referencias

1. Russell, S.J., Norvig, P.: Artificial Intelligence: A Modern Approach. Pearson Education, 2 ed. (2003)
2. Vignote-Peña, S., Morales-Peris, F.J., Morales-Mendez, E., Gómez-Pérez, C.: Tecnología de la madera en la construcción arquitectónica. Madrid: Ediciones Mundi-Prensa, 1 ed. (2000)
3. Echenique-Manrique, R.: Características de la madera y su uso en la construcción. México DF.: Lito Ediciones Olimpia, 1 ed. (1971)

4. Wang, H. et al: Wood Recognition Using Image Texture Features. PLoS One. 8, 10, 1–12 (2013)
5. Tyagi, V.: Content-Based Image Retrieval - Ideas, Influences, and Current Trends. Springer, (2017)
6. Serrano-Talamantes, J.F., Aviles-Cruz, C., Villegas-Cortez, J., Sossa-Azuola, J.H.: Self organizing natural scene image retrieval, Expert Systems with Applications, no. 0 (2012)
7. Benavides Alvarez, C., Villegas Cortez, J., Román Alonso, G., Aviles Cruz, C.: Face Classification by Local Texture Analysis through CBIR and SURF Points. Revista IEEE América Latina, Vol. 14, Issue: 5, pp. 2418–2424 (2016)
8. Villegas-Cortez, J., Pérez-Pimentel, Y., Osuma-Galán I.: Implementación de un sistema de reconocimiento de imágenes por contenido usando algoritmos genéticos. México DF. Departamento de electrónica, Universidad Autónoma Metropolitana (2014)
9. Gonzalez R.C., Woods, R.E.: Digital Image Processing. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA (1992)
10. Presutti, M.: La matriz de co-ocurrencia en la clasificación multispectral: Tutorial para la enseñanza de medidas texturales en cursos de grado universitario. La Plata. Departamento de ambiente y recursos naturales, Universidad Nacional de La Plata, Facultad de Ciencias Agrarias y Forestales (2004)
11. Benavides-Alvares, C., Villegas-Cortez, J., Román-Alonso, G., Avilés-Cruz, C.: Reconocimientos de rostros a partir de la propia imagen usando técnica CBIR. México DF. Departamento de Ing. Eléctrica, Universidad Autónoma Metropolitana, Iztapalapa (2015)