

Recuperación de escenarios naturales por contenido por medio de la causalidad de Wiener-Granger: metodología auto-organizante

Cesar Benavides-Álvarez, Carlos Avilés-Cruz, Arturo Zúñiga-López,
Andrés Ferreyra-Ramírez, Eduardo Rodríguez-Martínez

Universidad Autónoma Metropolitana,
Departamento de Electrónica, División de Ciencias Básicas e Ingeniería,
México

cesarbenavides32@gmail.com,
{caviles, azl, fra, erm}@azc.uam.mx

Resumen. La organización, clasificación y recuperación de imágenes digitales son hoy en día una de las áreas más aplicadas dentro de la ciencia de datos, minería de datos o búsqueda de información en internet. Por otro lado, la búsqueda de imágenes por su contenido o una zona de la misma, es el interés actual en la web. En el presente artículo se hace uso de la teoría de causalidad de Wiener-Granger, en un sistema auto-organizante de escenarios naturales. La metodología propuesta comprende una etapa de extracción de características en puntos aleatorios dentro de la imagen, después estas características son organizadas en forma de series temporales posteriormente, se realiza la estimación de causalidad Wiener-Granger. Una vez obtenidas las causalidades, se aplica el algoritmo k-means para lograr la auto-organización de atributos. En cuanto a la clasificación, se hace uso del algoritmo de clasificación de distancia k-NN para encontrar las imágenes más parecida que comparta las relaciones causales entre los elementos de los escenarios. Nuestra metodología se valida con 2 bases de imágenes públicas, obteniendo resultados de 100 % de recuperación.

Palabras clave: Clasificación de imágenes, recuperación de imágenes por contenido, causalidad de Wiener-Granger.

Content-based Natural Scenario Retrieval by Wiener Granger Causality: Self-Organizing Methodology

Abstract. The organization, classification, and retrieval of digital images are nowadays one of the most applied areas within data science, data mining, or information search on the Internet. On the other hand, the search of images by their content or an area of it is the current interest in the web. In this paper, we make use of the Wiener-Granger causality theory in a self-organizing system of natural scenarios. The proposed methodology comprises a stage of feature extraction at random points within the image, then these features are organized in the form of time series, and Wiener-Granger causality estimation is

performed. Once the causalities are obtained, the k-means algorithm is applied to achieve attribute self-organization. As for classification, the k-NN distance classification algorithm is used to find the most similar images that share the causal relationships between the elements of the scenarios. Our methodology is validated with two public image bases, obtaining results of 100%.

Keywords: Classification, content-based image retrieval, image retrieval, image classification, Wiener-Granger causality.

1. Introducción

Con el desarrollo del Internet y el uso masivo de dispositivos digitales, la recuperación de imágenes basada en su contenido (CBIR) ha tenido importante desarrollo y muchas aplicaciones, particularmente, a la visión artificial e inteligencia artificial [20].

Actualmente, se han realizado avances en nuevas teorías y modelos de CBIR y se han establecido muchos algoritmos CBIR eficaces que permiten buscar y recuperar imágenes (por su contenido) a partir de una imagen de entrada; entre los campos de aplicación se tiene: moda, identificación de personas, recuperación de productos de comercio electrónico, recuperación de imágenes de tele-detección, recuperación de imágenes de marcas, recuperación de escenarios naturales, entre otros [15, 12].

En el campo de la visión por computadora o visión artificial, lo que se busca es emular el sistema visual humano, con las capacidades y habilidades como lo hacen nuestros ojos. Así, el objetivo que persigue la visión artificial, es dotar a las computadoras de nuestras capacidades visuales de un mundo tridimensional, partiendo, generalmente, de imágenes bi-dimensionales [2].

Dado que no existe un algoritmo eficaz que pueda reconocer completamente cualquier objeto o escenario, la visión por computadora se considera un problema abierto, en donde se conjugan áreas como el procesamiento digital de imágenes, reconocimiento de patrones, aprendizaje de máquina, etc.

Una de las tareas de los sistemas automatizados de reconocimiento de imágenes es clasificar e identificar con éxito las imágenes de paisajes naturales¹, que con el aumento exponencial en la generación de imágenes de escenarios naturales ha tenido la web. Se estima que, más de la mitad de la información en Internet son imágenes, de las cuales el 85 % fueron tomadas a través de dispositivos móviles, y se consideró una estimación final de 5 billones de imágenes hasta este año 2018 [22].

Para utilizar esta información de manera eficiente, es necesario un sistema CBIR, ayudando a los usuarios a encontrar imágenes relevantes en función de sus características de auto-contenido o de las que se “ven” relacionadas con ellas, a partir de nuestra percepción visual, incluso cuando no existe un conocimiento previo de la base de datos, como el etiquetado manual sobre las imágenes.

¹ Se dice que un paisaje es natural si la imagen no tiene ninguna intervención o alteración de la mano del hombre.

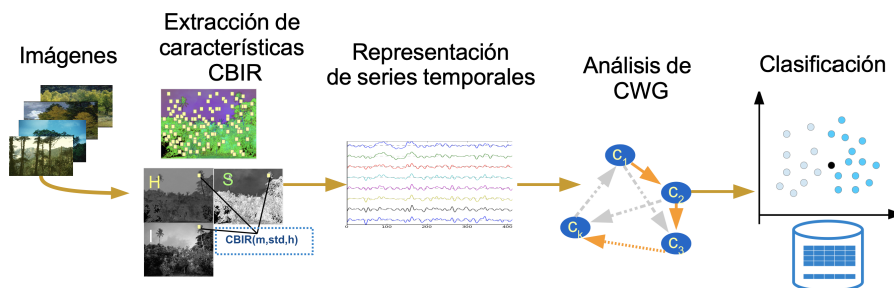


Fig. 1. Metodología general propuesta.

En este trabajo se desarrolla un sistema de recuperación de imágenes de paisajes naturales aplicando la teoría de la causalidad de Wiener-Granger (WGC) [11] como herramienta de análisis de imágenes a través de la información auto-organizada. Se identificaron las relaciones de causalidad entre las texturas locales contenidas en una imagen, lo que lleva a caracterizar un patrón descriptivo de un conjunto de paisajes dentro de un conjunto de datos de imágenes. Las principales etapas involucradas en el sistema desarrollado son las siguientes (Ver Fig. 1):

1. Lectura de imágenes: En primer lugar, se leen las imágenes del conjunto de datos y, a continuación, se aplica un cambio de formato de color del espacio Rojo-Verde-Azul RGB a Tono-Saturación-Intensidad HSB.
2. Extracción de características: La extracción estadística de características CBIR se genera aleatoriamente sobre 300 puntos de la imagen.
3. Conformación de series temporales: Las características de textura se organizan como una serie temporal para cada imagen.
4. Análisis de causalidad: El análisis WGC se aplica para calcular la matriz de relación causal entre las diferentes texturas.
5. Aplicación de clasificación: Se usa el algoritmo de clasificación a k-próximos vecinos KNN, para encontrar las texturas más próximas o similares a la de búsqueda.

El trabajo propone un análisis de causalidad de las clases de paisaje natural basado en un diccionario de texturas preestablecido y el análisis WGC de la metodología CBIR [21, 7] para proporcionar la caracterización del conjunto de datos. La metodología actual se probó con dos bases de datos de paisajes naturales:

- Vogel y Shiele (V_S) [23]. con 700 Imágenes clasificadas como: 144 costa, 103 bosque, 179 montaña, 131 pradera, 111 río/lago y 32 cielo/nube.
- Oliva y Torralba (O_T) [18]. 1472 Imágenes clasificadas como: 360 costa, 328 bosque, 374 montaña y 410 pradera.

Finalmente, se reporta una mejora en la precisión de la clasificación obtenida por nuestra estrategia propuesta, obteniendo un 100 % en la re-sustitución y hasta un 96 % para las metodologías de validación cruzada.

Visualizando en el futuro implementar un sistema autónomo de reconocimiento de escenas naturales montado en un coche, que será gestionado por nuestra propuesta como sistema autónomo [4, 5, 1]. El hecho de reconocer escenarios naturales en la navegación de un coche autónomo o posiblemente un dron, con un 100 % de certeza, este sistema propuesto será un elemento importante en la seguridad de los vehículos autónomos.

El resto del trabajo se organiza como sigue. En la sección 2 se presenta el soporte teórico del modelo WGC a aplicar. En la sección 3, se presenta la metodología. Los resultados se presentan en la sección 4. Finalmente, las conclusiones y perspectivas se presentan en la sección 5.

2. Fundamentos de la teoría de causalidad de Wiener-Granger

El paradigma de la inferencia causal se ha utilizado en diferentes campos de la ciencia, por ejemplo, en neurología se utiliza la teoría WGC [6] para examinar áreas del cerebro y las relaciones causales entre ellas. El análisis de la WGC se realizó mediante sensores [17, 16], y, últimamente en imágenes de resonancia magnética [26, 10, 13], la teoría de la WGC se está utilizando para el estudio de las relaciones causales entre las áreas que realizan actividades del cerebro.

Otros campos de la ciencia donde se ha aplicado la teoría WGC es en el procesamiento de vídeo para la indexación y recuperación [8]. El procesamiento de vídeo para la identificación masiva de personas y vehículos [14, 19, 25] y el análisis de escenarios complejos [9]. En esta propuesta, por primera vez, se aplica la teoría WGC a la recuperación de elementos naturales y escenas naturales.

En esta sección se establece el marco teórico del WGC. Por simplicidad y para evitar extendernos matemáticamente, la teoría se presenta sólo para dos procesos aleatorios, siendo extensible a n -procesos. En nuestro enfoque, un proceso aleatorio corresponde a una lectura de señal asociada a un tipo de textura dentro de un escenario natural. Así, para el presente análisis, cada lectura de textura corresponde a un proceso estocástico representado por C_i , siendo i la i -ésima textura que tiene un comportamiento estocástico dentro de un escenario.

2.1. Stochastic autoregressive model

Asumimos que cada textura puede ser representada por un modelo autorregresivo en series temporales. En el presente análisis y por simplicidad didáctica, sólo lo llevaremos a cabo con dos señales, $\{C_1$ y $C_2\}$, siendo fácilmente extensible a n señales-texturas. Cada proceso estacionario representa una textura del escenario y, puede representarse mediante un modelo autorregresivo de la siguiente manera:

$$C_1(t) = \sum_{k=1}^{\infty} K_{C_1}^1(k) \cdot C_1(t-k) + \eta_{C_1}^1, \quad \text{con} \quad \sum_{C_1}^1 = \text{var}(\eta_{C_1}^1), \quad (1)$$

$$C_2(t) = \sum_{k=1}^{\infty} K_{C_2}^1(k) \cdot C_2(t-k) + \eta_{C_2}^1, \quad \text{con} \quad \sum_{C_2}^1 = \text{var}(\eta_{C_2}^1), \quad (2)$$

siendo η_{C1}^1 y η_{C2}^1 ruido aleatorio Gaussian a valor media cero y desviación estándar unitaria; $K_{C1}^1(k)$ y $K_{C2}^1(k)$ son los coeficientes del modelo de regresión para la texturas $C1$ y $C2$, respectivamente. El modelo autorregresivo conjunto para las dos texturas está definido por las ecuaciones 3 y 4:

$$C1(t) = \sum_{k=1}^{\infty} K_{C1}^{1,1}(k) \cdot C1(t-k) + \sum_{k=1}^{\infty} K_{C2}^{1,2}(k) \cdot C2(t-k) + \eta_{C1}^2, \quad \text{con } \sum_{C1}^2 = \text{var}(\eta_{C1}^2), \quad (3)$$

$$C2(t) = \sum_{k=1}^{\infty} K_{C1}^{2,1}(k) \cdot C1(t-k) + \sum_{k=1}^{\infty} K_{C2}^{2,2}(k) \cdot C2(t-k) + \eta_{C2}^2, \quad \text{con } \sum_{C2}^2 = \text{var}(\eta_{C2}^2), \quad (4)$$

donde \sum_{C1}^2 y \sum_{C2}^2 son las varianzas de los términos residuales; η_{C1}^2 y η_{C2}^2 , respectivamente. Por otro lado, los términos $K_{C1}^{i,j}(k) \forall i, j, l \in [1, 2]$, son los coeficientes de la regresión para las regiones texturadas $C1(t)$ and $C2(t)$, respectivamente. Ahora analicemos las varianzas/covarianzas de los términos residuales $\eta_{C_i}^2$ mediante la siguiente ecuación de forma matricial Σ (5):

$$\Sigma = \begin{pmatrix} \Sigma_{C1}^2 & \Upsilon_{1,2} \\ \Upsilon_{2,1} & \Sigma_{C2}^2 \end{pmatrix}, \quad (5)$$

donde $\Upsilon_{1,2}$ es la covarianza entre η_{C1}^2 and η_{C2}^2 , definida como $\Upsilon_{1,2} = \text{cov}(\eta_{C1}^2, \eta_{C2}^2)$. A partir de las condiciones anteriores, y utilizando el concepto de independencia estadística entre dos procesos aleatorios al mismo tiempo (por parejas), se puede definir la causalidad en el tiempo. Un ejemplo de la causalidad entre $C1$ y $C2$ es la expresión dada por la ecuación 6:

$$F_{C2, C1} = \ln \left[\frac{\Sigma_{C1}^1 \times \Sigma_{C2}^1}{\Sigma_{C1}^2 \times \Sigma_{C2}^2} \right]. \quad (6)$$

La ecuación 6 se conoce comúnmente como la causalidad en el dominio del tiempo. A partir de esta ecuación, si los procesos aleatorios $C1(t)$ y $C2(t)$ son estadísticamente independientes, entonces $F_{C1, C2} = 0$; en caso contrario habrá causalidad de uno a otro. En la ecuación (1), Σ_{C1}^1 mide la precisión del modelo autorregresivo para predecir $C1(t)$, establecido en las muestras pasadas.

A su vez, Σ_{C1}^2 en la expresión 3 mide la precisión para predecir $C1(t)$ basándose en los valores anteriores de $C1(t)$ y $C2(t)$ al mismo tiempo. Volviendo al caso de tomar sólo 2 texturas al mismo tiempo $C1(t)$ y $C2(t)$ y según [24] y [11], si $\Sigma_{C2}^2 < \Sigma_{C1}^1$ entonces se dice que $C2(t)$ tiene una influencia causal sobre $C1(t)$. La causalidad se define por la ecuación 7:




Fig. 2. Ejemplo de una segmentación de zonas texturadas en un escenario natural para $k=4$ en el algoritmo k -Medias.

$$F_{C2 \rightarrow C1} = \ln \left[\frac{\Sigma_{C1}^1}{\Sigma_{C1}^2} \right], \quad (7)$$

Es relativamente fácil ver que si $F_{C2 \rightarrow C1} = 0$ entonces no hay influencia causal de $C2(t)$ hacia $C1(t)$, en cualquier otro valor, el resultado será diferente de cero. Por otro lado, la influencia causal de $C1(t)$ hacia $C2(t)$ se establece mediante la ecuación 8:

$$F_{C1 \rightarrow C2} = \ln \left[\frac{\Sigma_{C2}^1}{\Sigma_{C2}^2} \right]. \quad (8)$$

3. Metodología

En esta sección describimos la metodología diseñada para el sistema de auto organización de imágenes naturales usando la CWG. Para el uso del CBIR existen diferentes factores determinantes que se deben tener en cuenta a la hora de extraer la información de las imágenes, como la luminosidad, orientación, escala, homogeneidad, etc. Por lo que, la característica principal en los patrones propuestos de cada escena natural, es la textura.

La metodología propuesta, para la etapa de entrenamiento, se presenta en la Figura 3. Comprende desde la lectura de la base de imágenes, el cambio de formato de color, el sembrado de puntos aleatorios, la extracción de atributos, el auto-agrupamiento, la generación de series temporales, el cálculo de causalidad, la clasificación-recuperación de las k -imágenes próximas, y finalmente, el despliegado de las escenas naturales más parecidas.




Fig. 3. Arquitectura de entrenamiento y prueba para el sistema de clasificación.

La hipótesis principal de la metodología propuesta es la generación de un diccionario automático de texturas, las cuales representan elementos propios contenidos en las escenas como son, agua, vegetación, nubes, rocas, arena, etc. (ver Figura 2), depende de la auto-organización de la información por medio del algoritmo de agrupamiento k-means. A continuación se describe en detalle cada bloque comprendido en la metodología.

1. **BD.** Contiene el conjunto de imágenes de escenarios naturales.
2. **Preprocesamiento.** Carga la imagen de la base de datos, se realiza un ecualizado al histograma en las tres capas y finalmente se pasa del espacio de color RGB al HSB (Hue, Saturation, Brightness – Matiz, Saturación, Brillo), el cual proporciona la información relacionada a la textura.
3. **Sembrado de puntos aleatorios.** Se hace un sembrado aleatorio uniforme de 300 puntos aleatorios dentro de la imagen.
4. **Extracción de características.** Esta sección se realiza en dos partes principales y para tener varias muestras de la imagen se repite el proceso un numero r de veces:
 - **Generalización de la vecindad.** Para cada punto aleatorio se crea una ventana de tamaño $p \times p$ pixeles comenzando con el punto de interés en la esquina superior derecha, como se muestra en la Figura 4, en donde $p < \text{image_rows}$ y $p < \text{image_columns}$.
 - **CBIR feature extraction.** Para cada vecindad se extraen tres características de textura como son, la media, la desviación estándar y la homogeneidad en las tres capas del espacio de color HSB. Esto da como resultado un vector de 1×9 características de textura, para una imagen se crea una matriz de tamaño $N_P \times 9$. Donde N_P es el número de puntos aleatorios y F_{CBIR} son las características CBIR extraídas.




Fig. 4. Imagen con puntos aleatorios, cada punto aleatorio genera una vecindad de tamaño 10×10 píxeles.

5. **Agrupación de texturas CBIR.** Una vez que se extraen las características de textura CBIR de cada imagen en la base de datos, se genera una matriz F_{CBIR} de tamaño $(r * N_I * N_P) \times 9$, donde r es el número de repeticiones, N_I es el número de imágenes en la base de datos, N_P es el número de puntos aleatorios y finalmente, F_{CBIR} las características CBIR en cada punto para cada capa de color HSB.

Por medio del algoritmo K-means se agrupan las características CBIR en k clusters, estos representan las k texturas más representativas de la base de datos, generando una matriz CM_k .

6. **Generación de series de tiempo.** De la matriz F_{CBIR} del paso anterior, cada entrada de la matriz se compara con las entradas de la matriz MC_k del diccionario automático para construir una señal discreta como serie temporal T_S la cual tiene un tamaño de $k \times r \times N_I$. Donde k es el número de texturas automáticas del algoritmo k-means, r el número de repeticiones del experimento y N_I el número de imágenes en la base de datos.

7. **Análisis de causalidad de Wiener-Granger.** Una entrada de la matriz T_S tiene un tamaño de $k \times r$ para cada imagen en la base de datos. Esta entrada será la que alimenta el análisis de CWG, como se ve en la Figura 5. El análisis de causalidad se calculó con el toolbox de causalidad MVGC [3].

Una vez realizado el análisis de causalidad para cada una de las imágenes en la base de datos, obtenemos una matriz de relaciones de causalidad η_I de tamaño $k \times k$. La matriz F_{C_i, C_j} representa la matriz de relaciones causales para cada imagen I , en donde $C_i \rightarrow C_j$ representan las relaciones causales de las k variables entre ellas mismas, (como se ve en la Ecuación (9)), de forma que si un valor de $F_{C_i, C_j} = 0$ significa que no hay relación causal de la textura $i \rightarrow j$, y en la medida en que el valor aumenta con respecto a otros valores η_I , decimos que la relación causal es significativa con respecto a otras:




Fig. 5. Generación de la matriz de relaciones causales, η_I , usando el análisis de CWG.

$$\eta_I = \begin{bmatrix} F_{C_1, C_1} & F_{C_1, C_2} & \dots & F_{C_1, C_k} \\ F_{C_2, C_1} & F_{C_2, C_2} & \dots & F_{C_2, C_k} \\ \vdots & \vdots & \vdots & \vdots \\ F_{C_k, C_1} & F_{C_k, C_2} & \dots & F_{C_k, C_k} \end{bmatrix}. \quad (9)$$

Las matrices de causalidad η_I se convierten en vector concatenando sus renglones, en el mismo paso se eliminan los elementos de la diagonal principal debido a que no existe relación causal de una variable con ella misma, como se observa en la teoría. Cada elemento convertido en vector es ahora un patrón representativo de la imagen en la base de datos, dentro de una matriz a la que se le da el nombre de Γ , de tamaño $N_I \times (k * k) - k$, donde N_I es el numero de imágenes, k el número de texturas automáticas del diccionario.

8. Finalmente se realiza una nueva agrupación de la matriz Γ por medio del algoritmo k-medias, para crear un conjunto de clases a las cuales cada patrón de causalidad se puede ver representado por medio de un valor promedio. El valor de k para crear el numero de clases es $k = N_c$. Con esto se busca tener N_c clases dentro de los patrones en la matriz Γ . Por lo tanto la matriz de clases generada tiene un tamaño de $N_c \times (r * r) - r$ elementos.

4. Resultados experimentales

La evaluación de la propuesta se generó utilizando la potencia de un cluster de 19 procesadores de doble núcleo. Cada procesador es un Intel®Xeon®CPU E5-2670 v3 2.30GHz, y 74 GB de RAM. La metodología actual se probó con dos bases de datos de paisajes naturales:

- Vogel y Shiele (V_S) [23]. con 700 Imágenes clasificadas como: 144 costa, 103 bosque, 179 montaña, 131 pradera, 111 río/lago y 32 cielo/nube.
- Oliva y Torralba (O_T) [18]. 1472 Imágenes clasificadas como: 360 costa, 328 bosque, 374 montaña y 410 pradera.

De las dos bases de imágenes anteriormente citadas, se concatenaron, obteniendo una sola base de imágenes amplia. Las escenas naturales son: bosques, cielos, costas, montañas, praderas y ríos.

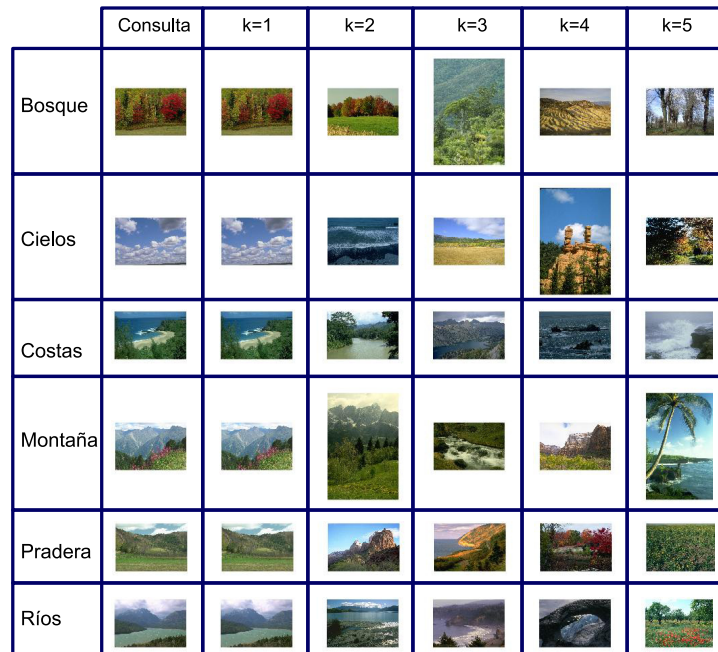


Fig. 6. Prueba con resubstitución sobre toda la base de imágenes.

Tabla 1. Matriz de confusión usando toda la base de imágenes.

Escena _i / Escena _j	Bosques	Cielos	Costas	Montañas	Praderas	Ríos
Bosques	100	0	0	0	0	0
Cielos	0	100	0	0	0	0
Costas	0	0	100	0	0	0
Montañas	0	0	0	100	0	0
Praderas	0	0	0	0	100	0
Ríos	0	0	0	0	0	100

Los resultados se tomaron de acuerdo a dos métodos de evaluación de desempeño, por un lado, en resubstitución (ver Fig. 6) y por el otro, en validación cruzada al 70/30 % (ver Fig. 7). En cuanto al número de centros en el algoritmo k-means, se utilizó un valor de $K = 9$, en virtud que proporcionó los mejores resultados.

Como se puede apreciar en las figuras 6 y 7, se recupera la imagen de búsqueda o consulta y, otras 4 imágenes más parecidas. Si se toma en cuenta el recuperar la imagen más parecida en el método de resubstitución, el presente sistema funciona la 100 %. En cambio, para el método de validación cruzada, las 5 imágenes recuperadas pertenecen al mismo tipo de escena natural.

Finalmente, la Tabla 1 muestra la cuantificación del desempeño del sistema propuesto, vía la matriz de confusión. En la tabla 1 se aprecia una recuperación al 100 % para cada una de los escenarios naturales.





































	Consulta	k=1	k=2	k=3	k=4	k=5
Bosque						
Cielos						
Costas						
Montaña						
Pradera						
Ríos						

Fig. 7. Prueba con validación cruzada 70/30 % sobre toda la base de imágenes.

5. Conclusiones y perspectivas

En este trabajo se presentó una novedosa propuesta de uso de la teoría de causalidad de Wiener-Granger, junto con el análisis de auto-organización CBIR, aplicada para la identificación y clasificación de 6 escenarios naturales: costa, bosque, montaña, pradera, río/lago y cielo/nube. Considerando la nueva formulación fue posible encontrar un conjunto de descriptores a partir de las matrices de causalidad para representar una clase de paisaje, a partir de un conjunto automático de texturas de referencia, proponiendo una caracterización de las imágenes basada en la apariencia continua de las texturas dentro de ellas.

Con este enfoque tenemos un 100 % de clasificación de imágenes para todo el conjunto de datos. Se tiene la ventaja de que no se requiere etiquetado previo ni conocimiento alguno sobre el contenido de las escenas naturales. El trabajo futuro se implementaran las pruebas de rotación, ruido y escala en las imágenes de la base de datos.

Por otro lado, se buscará la implementación de toda la metodología en cómputo paralelo; usando CPUs, la tecnología GPU, las cuales podría rendir eficientemente para la etapa de extracción de características de las imágenes. así como la implementación algoritmos evolutivos, para analizar en conjunto las texturas de la imagen buscando caracterizar el escenario y sus asociaciones con el paradigma de la comprensión visual.

Referencias

1. Alam, A., Jaffery, Z. A.: A vision-based system for traffic light detection. *Applications of Artificial Intelligence Techniques in Engineering. Advances in Intelligent Systems and Computing*, vol. 698, pp. 333–343 (2016) doi: 10.1007/978-981-13-1819-1_32
2. Ansari, M. A., Singh, D. K.: Human detection techniques for real time surveillance: A comprehensive survey. *Multimedia Tools and Applications*, vol. 80, no. 6, pp. 8759–8808 (2021) doi: 10.1007/s11042-020-10103-4
3. Barnett, L., Seth, A. K.: The MVGC multivariate granger causality toolbox: A new approach to granger-causal inference. *Journal of Neuroscience Methods*, vol. 223, pp. 50–68 (2014) doi: 10.1016/j.jneumeth.2013.10.018
4. Begum, R., Halse, S. V.: The smart car parking system using GSM and LabVIEW. *Journal of Computer and Mathematical Sciences*, vol. 9, no. 2, pp. 135–142 (2018) doi: 10.29055/jcms/740
5. Blaifi, S., Moulahoum, S., Colak, I., Merrouche, W.: Monitoring and enhanced dynamic modeling of battery by genetic algorithm using LabVIEW applied in photovoltaic system. *Electrical Engineering*, vol. 100, no. 2, pp. 1021–1038 (2017) doi: 10.1007/s00202-017-0567-6
6. Bressler, S. L., Seth, A. K.: Wiener-granger causality: A well established methodology. *NeuroImage*, vol. 58, no. 2., pp. 323–329 (2011) doi: 10.1016/j.neuroimage.2010.02.059
7. Cortez, J. V., Alvarez, C. B., Alonso, G. R., Cruz, C. A.: Reconocimiento de rostros a partir de la propia imagen usando técnica CBIR. In: *Congreso Español sobre Metaheurísticas, Algoritmos Evolutivos y Bioinspirados*, pp. 733–740 (2015)
8. Fablet, R., Boutheymy, P., Perez, P.: Nonparametric motion characterization using causal probabilistic models for video indexing and retrieval. *IEEE Transactions on Image Processing*, vol. 11, no. 4 (2022) doi: 10.1109/tip.2002.999674
9. Fan, Y., Yang, H., Zheng, S., Su, H., Wu, S.: Video Sensor-Based Complex Scene Analysis with Granger Causality. *Sensors*, vol. 13, no. 10, pp. 13685–13707 (2013) doi: 10.3390/s131013685
10. Friston, K.: Causal modelling and brain connectivity in functional magnetic resonance imaging. *Public Library of Science Biology*, vol. 7, no. 2, (2009) doi: 10.1371/journal.pbio.1000033
11. Granger, C. W.: Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, vol. 37, no. 3, pp. 424–438 (1969)
12. Jena, B., Nayak, G. K., Saxena, S.: Survey and analysis of content-based image retrieval systems. *Control Applications in Modern Power System, Lecture Notes in Electrical Engineering*, vol 710, pp. 427–433 (2021) doi: 10.1007/978-981-15-8815-0_37
13. Kim, E., Kim, D. S., Ahmad, F., Park, H.: Pattern-Based Granger Causality Mapping in fMRI. *Brain Connectivity*, vol. 3, no. 6, pp. 569–577 (2013) doi: 10.1089/brain.2013.0148
14. Kular, D., Ribeiro, E.: Analyzing activities in videos using latent dirichlet allocation and granger causality. *Advances in Visual Computing, Springer International Publishing*, pp. 647–656 (2015) doi: 10.1007/978-3-319-27857-5_58
15. Li, X., Yang, J., Ma, J.: Recent developments of content-based image retrieval. *Neurocomputing*, vol. 452, pp. 675–689 (2021) doi: 10.1016/j.neucom.2020.07.139
16. Mannino, M., Bressler, S. L.: Foundational perspectives on causality in large-scale brain networks. *Physics of Life Reviews*, vol. 15, pp. 107–123 (2015) doi: 10.1016/j.plrev.2015.09.002
17. Matias, F. S., Gollo, L. L., Carelli, P. V., Bressler, S. L., Copelli, M., Mirasso, C. R.: Modeling positive granger causality and negative phase lag between cortical areas. *NeuroImage*, vol. 99, pp. 411–418 (2014) doi: 10.1016/j.neuroimage.2014.05.063

18. Oliva, A., Torralba, A.: Modeling the shape of the scene: A holistic representation of the spatial envelope. *International Journal of Computer Vision*, vol. 42, no. 3, pp. 145–175 (2001) doi: 10.1023/A:1011139631724
19. Prabhakar, K., Oh, S., Wang, P., Abowd, G. D., Rehg, J. M.: Temporal causality for the analysis of visual events. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (2010) doi: 10.1109/cvpr.2010.5539871
20. Sampath, V., Maurtua, I., Aguilar Martín, J. J., Gutierrez, A.: A survey on generative adversarial networks for imbalance problems in computer vision tasks. *Journal of Big Data*, vol. 8, no. 1 (2021) doi: 10.1186/s40537-021-00414-0
21. Serrano-Talamantes, J. F., Avilés-Cruz, C., Villegas-Cortez, J., Sossa-Azuela, J. H.: Self organizing natural scene image retrieval. *Expert Systems with Applications: An International Journal*, vol. 40, no. 7, pp. 2398–2409 (2012) doi: 10.1016/j.eswa.2012.10.064
22. Tyagi, V.: *Content-based image retrieval: Ideas, influences, and current trends*. Springer Publishing Company, Incorporated (2017)
23. Vogel, J., Schiele, B.: Performance evaluation and optimization for content-based image retrieval. *Pattern Recognition*, vol. 39, no. 5, pp. 897–909 (2006) doi: 10.1016/j.patcog.2005.10.024
24. Wiener, N., Masani, P.: The prediction theory of multivariate stochastic processes: I. The regularity condition. *Acta Mathematica*. International Press of Boston, vol. 98, pp. 111–150 (1957) doi: 10.1007/bf02404472
25. Zhang, C., Yang, X., Lin, W., Zhu, J.: Recognizing human group behaviors with multi-group causalities. In: *Proceedings of the 2012 IEEE/WIC/ACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology*, vol. 3, pp. 44–48 (2012) doi: 10.1109/WI-IAT.2012.162
26. Zhang, H., Li, X.: Effective connectivity of facial expression network by using Granger causality analysis. *Society of Photo-Optical Instrumentation Engineers*, vol. 8920 (2013) doi: 10.1117/12.2030912