





Segmentación de Análisis de Movimiento Mediante Clustering.

Motion Analysis Segmentation using Clustering.

-  **Bernardo David Nolasco-Vargas** es estudiante en la Universidad Autónoma de Querétaro, Facultad de Informática (México) (bnolasco04@alumnos.uaq.mx), (<https://orcid.org/0009-0009-1507-7530>), Estudiante.
-  **Adrián García-López** es estudiante en la Universidad Autónoma de Querétaro, Facultad de Informática (México) (agarcia446@alumnos.uaq.mx), (<https://orcid.org/0009-0004-8244-0321>), Estudiante.
-  **Jorge Luis Pérez-Ramos** es docente en la Universidad Autónoma de Querétaro, Facultad de Informática (México) (jorge.luis.perez@uaq.mx), (<https://orcid.org/0000-0002-0444-9230>), Doctor.
-  **Selene Ramírez-Rosales** es docente en la Universidad Autónoma de Querétaro, Facultad de Informática (México) (selene.ramirez@uaq.mx), (<https://orcid.org/0000-0001-6635-5427>), Maestra.

Resumen: En la actualidad, los sistemas de vigilancia juegan un papel fundamental en la identificación y análisis de zonas de interés en grabaciones de video, jugando un rol esencial en la seguridad, mejorando la optimización del monitoreo de infraestructuras y contribuyendo a la planificación urbana. No obstante, el volumen masivo de datos generados por estos sistemas representa un desafío considerable para los operadores humanos, quienes deben identificar patrones de comportamiento relevantes en tiempo real. Esta sobrecarga de información ha motivado el desarrollo de técnicas automatizadas avanzadas basadas en algoritmos de *clustering*, como DBSCAN y *K-means*, que permiten agrupar y analizar grandes volúmenes de datos visuales, facilitando así la localización de áreas críticas de interés. Este estudio tiene como objetivo principal identificar y evaluar zonas de mayor relevancia mediante la extracción y análisis de datos de movimiento registrados en sistemas de vigilancia. La investigación adopta un enfoque experimental y se apoya en técnicas de procesamiento de imágenes y la aplicación de operaciones de morfología matemática para resaltar los objetos en movimiento. Posteriormente, se utilizan DBSCAN y *K-means* para la agrupación de los datos en *clusters* basados en características de similitud. No obstante, la efectividad de estos algoritmos puede variar dependiendo de factores como el ruido en las imágenes, la densidad de los datos y las características específicas de cada escenario de vigilancia, lo que plantea la necesidad de evaluar y comparar su rendimiento en diferentes contextos.

Palabras clave: Análisis de movimiento, clustering, zonas de interés, DBSCAN, K-means.

Cómo citar: Nolasco-Vargas, B.D., García-López, A., Pérez-Ramos, J.L. y Ramírez-Rosales, S. (2024). Segmentación de Análisis de Movimiento Mediante Clustering. *Tecnología, Ciencia y Estudios Organizacionales*, 6(12), pp. 119-128. <https://doi.org/10.56913/teceo.6.12.119-128>

Recepción: 30-09-2024
Aprobación: 23-10-2024

Abstract: Currently, surveillance systems play a fundamental role in identifying and analyzing areas of interest in video recordings, playing an essential role in security, improving infrastructure monitoring optimization, and contributing to urban planning. However, the massive volume of data these systems generate poses a significant challenge for human operators, who must identify relevant behavioral patterns. This information overload has driven the development of advanced automated techniques based on clustering algorithms, such as DBSCAN and K-means, which allow for the grouping and analysis of large volumes of visual data, thereby facilitating the localization of critical areas of interest. This study aims to identify and evaluate areas of higher relevance by extracting and analyzing movement data recorded by surveillance systems. The research adopts an experimental approach and relies on image processing techniques and the application of mathematical morphology operations to highlight moving objects. Subsequently, DBSCAN and K-means cluster the data based on similarity characteristics. However, the effectiveness of these algorithms may vary depending on factors such as image noise, data density, and specific characteristics of each surveillance scenario, highlighting the need to evaluate and compare their performance in different contexts.

Keywords: Motion analysis, clustering, areas of interest, DBSCAN, K-means.

Introducción

En la actualidad, los sistemas de vigilancia desempeñan un papel fundamental en la seguridad y el monitoreo de infraestructuras públicas y privadas. Contribuyen a la optimización de la gestión del tráfico, la protección de áreas sensibles y la planificación urbana. Sin embargo, estos sistemas generan un volumen masivo de datos visuales que resulta abrumador para los operadores humanos, quienes deben analizar estos datos en tiempo real para identificar comportamientos relevantes. Esta sobrecarga de información ha motivado el desarrollo de técnicas automatizadas que permiten extraer patrones significativos y detectar áreas críticas de interés de forma más eficiente (Shirbhate et al., 2012).

El análisis de movimiento es el procedimiento mediante el cual se detectan cambios en la posición de objetos en el transcurso de una grabación o vídeo a lo largo del tiempo. Dicho procedimiento puede ser usado en una gran variedad de aplicaciones, tales como sistemas de seguridad, monitoreo de tráfico, seguimiento de objetos, entre otros (Chong et al., 1992).

Para procesar y analizar grandes volúmenes de datos en estas aplicaciones, se emplea el *clustering*, una técnica de análisis de datos no supervisada que divide un conjunto de datos en subconjuntos homogéneos llamados *clusters*. Esta técnica facilita la identificación y agrupamiento de patrones y objetos en movimiento, optimizando así el análisis y la interpretación de la información recogida (Morris & Trivedi, 2009; Xu & Tian, 2015).

Los diversos *clusters* contienen elementos que comparten características similares entre sí, un ejemplo puede ser la proximidad entre los datos. Se utiliza principalmente en la minería de datos, la inteligencia artificial, y la identificación de patrones o tendencias de forma eficiente si (Sisodia, 2012; Xu & Tian, 2015).

Con el aumento de datos de sistemas de vigilancia generados por cámaras o sensores, la necesidad de analizar y entender estos movimientos de manera eficiente se ha vuelto más importante que nunca. El *clustering* ayuda a encontrar patrones y segmentar la información, siendo una herramienta crucial para el análisis de movimiento. Este trabajo tiene como objetivo desarrollar,

evaluar y comparar un método de segmentación de análisis de movimiento utilizando técnicas de *clustering* para la obtención de datos relevantes en áreas de interés.

Para la detección de objetos o movimiento en imágenes se utilizaron varias técnicas entre ellas sustracción de fondo y morfología matemáticas (Chong et al., 1992; Ge et al., 2011; González García, 2016). También se emplean algoritmos de *clustering* como DBSCAN (Density-Based Spatial Clustering of Applications with Noise) y *K-Means* para segmentar y analizar el movimiento en video.

Trabajos relacionados de técnicas de segmentación

Mediante la extracción de información de sistemas vigilancia y el procesamiento de video se espera identificar áreas de interés mediante algoritmos de *clustering* DBSCAN y *K-Means*, para la comparación y evaluación de los resultados, obteniendo así las áreas de mayor relevancia actividad para sistemas de monitoreo y vigilancia (Sisodia, 2012).

La segmentación de movimiento es una técnica utilizada para la visión por computadora esta sirve para detectar y seguir objetos en movimiento en una secuencia de imágenes. Los algoritmos de *clustering* como DBSCAN (Density-Based Spatial Clustering of Applications with Noise) y *K-Means*, son algoritmos para agrupar datos en *clusters* basados en características de similitud.

Para la detección de movimiento, se empleó una técnica basada en la acumulación de diferencias binarias entre fotogramas consecutivos de imágenes en escala de grises. Este método permite resaltar las áreas de cambio en una secuencia determinada de imágenes, permitiendo identificar las regiones donde se produce movimiento (Hossen & Tuli, 2016). Estas diferencias se calculan sumando cada fotograma, generando una matriz binaria en la que los *píxeles* con valor de 1 indican un cambio y los *píxeles* con valor de 0 son áreas sin algún cambio.

La morfología matemática ha demostrado ser una herramienta importante en el análisis de imágenes cuando la topología y la estructura geométrica de los objetos presentes en ellas son los parámetros claves para su caracterización, Un componente fundamental de la morfología matemática son los elementos estructurantes, los cuales son matrices que únicamente admite valores binarios, donde un “1” (true) indica la presencia de un objeto o una característica, y un “0” (false) indica su ausencia. Los elementos estructurantes definen la forma y el tamaño utilizados para examinar las estructuras dentro de una imagen, funcionando como una referencia para aplicar las operaciones morfológicas (La et al., 2010; Pierre, 2016).

La morfología matemática tiene dos operaciones principales:

- La erosión destaca las zonas oscuras presentes en una imagen.

$$\varepsilon_B(f)(x) = f(x + b)$$

- La dilatación permite destacar zonas claras en la imagen.

$$\delta_B(f)(x) = f(x + b)$$

Por otro lado, el *clustering* es una tarea de aprendizaje no supervisado en la que se busca identificar un conjunto finito de categorías llamadas clústeres para describir los datos (Morris & Trivedi, 2009).

El algoritmo DBSCAN (Density-Based Spatial Clustering of Applications with Noise) es un algoritmo de *clustering* que define los *clusters* mediante la estimación de la densidad, este algoritmo solo requiere de 2 parámetros (Li et al., 2019):

- Épsilon (eps): Este parámetro especifica lo cerca que deben estar los puntos entre sí para ser considerado parte de un cluster
- Puntos mínimos (min_samples): Este parámetro es el mínimo de puntos para formar una región.

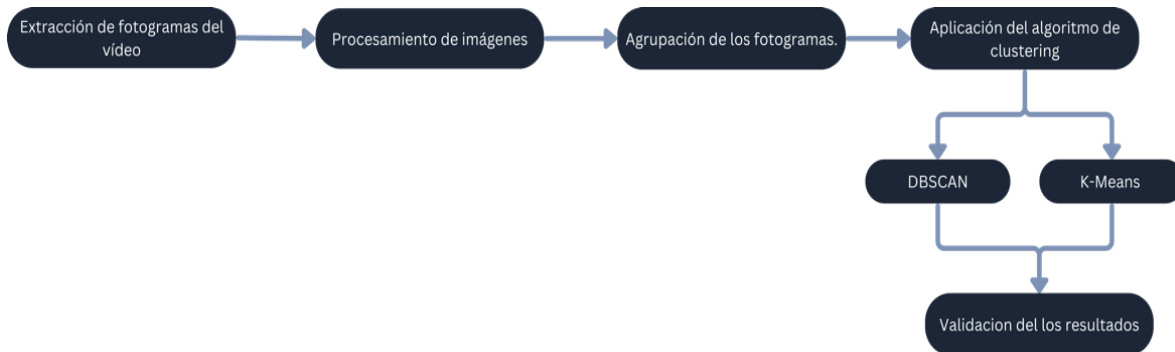
El algoritmo *K-Means* tiene como objetivo dividir un segmento de datos entre un número determinado de *clusters* basados en su similitud, se le pide al usuario que especifique el número de clusters para así agrupar los datos, este algoritmo solo requiere de 2 parámetros

- Numero de *clusters* (*n_clusters*): Este parámetro especifica el número de clusters a dividir los datos.
- Aleatoriedad (*Random_state*): Este parámetro es el control de aleatoriedad en el algoritmo para la creación de los centroides (centros del *clúster*).

Método

El proceso realizado se dividió en cinco etapas, ver Figura 1:

Figura 1. Metodología propuesta.



Extracción de fotogramas del video

Primero, se selecciona un vídeo para su análisis. A partir de este, se compararán los fotogramas en diferentes momentos. El intervalo entre fotogramas debe ser lo suficientemente grande para captar el movimiento de manera efectiva, lo cual puede variar según las características del escenario, pero sin exceder un límite que podría resultar en una pérdida de precisión en la detección.

Procesamiento de fotograma

El procesamiento de imágenes es una técnica computacional que manipula y mejora imágenes digitales para extraer información útil y facilitar su análisis. Utiliza algoritmos para mejorar la calidad de la imagen y transformarla según necesidades específicas, y se aplica en una variedad de campos, como la visión por computadora, el análisis médico, la fotografía digital y la vigilancia (Shirbhate et al., 2012; Wang et al., 2003).

El análisis de fotogramas es crucial para extraer información significativa de las secuencias de vídeo, especialmente en aplicación de detección de movimientos (Shirbhate et al., 2012). En este proceso, los fotogramas son inicialmente convertidos a escala de grises para simplificar el análisis y minimizar el ruido de color.

Después, se aplica un desenfoque gaussiano para suavizar la imagen y reducir el ruido y al final la aplicación de operaciones morfológicas como la erosión y dilatación se utilizan para mejorar la definición de los contornos de los objetos en movimiento (Pierre, 2016). Este enfoque sistemático de procesamiento de imágenes no solo clarifica las áreas de interés, sino que también facilita una agrupación efectiva en las etapas siguientes.

Figura 2. *Proceso de manipulación de fotogramas*



a) *Fotograma original*



b) *Fotograma en escala de grises*



c) *Fotograma con erosión*




d) *Fotograma con dilatación*

En este contexto, se presentará una visión general de las técnicas aplicadas y cómo contribuyen a un análisis detallado y preciso, en la Figura 2 se muestra el procesamiento que se realiza de los fotogramas.

Agrupación de los fotogramas:

Para analizar el movimiento en una secuencia de vídeo, cada fotograma se convierte en una matriz binaria, donde los píxeles en movimiento se representan como 1 y las áreas estáticas como 0. Las matrices binarias se suman para generar un mapa de calor que ilustra la intensidad del movimiento a lo largo del tiempo. Esta suma acumulativa de los píxeles permite identificar áreas de alta actividad variando en los intervalos de fotogramas analizados, ver Figura 3.

Figura 3. Agrupación de fotogramas



a) Intervalo cada 300 frames.


b) Intervalo cada 600 frames

c) Intervalo cada 900 frames.

Aplicación del algoritmo de clustering

Para identificar y agrupar las áreas de movimiento en los fotogramas procesados, se aplican algoritmos de *clustering*. Se implementaron técnicas como DBSCAN (Density-Based Spatial Clustering of Applications with Noise) con los parámetros $eps = 5$ y $min_samples = 10$, así como *K-Means* con los parámetros $random_state = 10$ (para garantizar la reproducibilidad de los resultados) y $n_clusters$ definido por el usuario. Estos algoritmos se utilizan para agrupar los píxeles en movimiento y destacar las áreas de interés. A continuación, se presentarán los resultados obtenidos con cada uno de los algoritmos en la Figura 4.

Figura 4. Aplicación del algoritmo de clustering.




a) Resultado aplicando DBSCAN

b) Resultado aplicando K-Means

Validación de resultados

Para la validación de los resultados, se llevaron a cabo diversas pruebas utilizando distintos intervalos de tiempo, con el fin de identificar el más adecuado para el marcado de *clusters*. Los ensayos demostraron que el procesamiento *frame a frame* no ofrecía una precisión suficiente debido al ruido presente. No obstante, al aplicar el marcado cada 300 o 600 *frames*, los resultados obtenidos fueron significativamente más precisos, como se detalla en la Figura 5.

Figura 5. Validación de resultados.



a) Resultado agrupación frame por frame.

b) Resultado agrupación cada 300 frames



c) Resultado agrupación cada 600 frames.

A continuación, se mostrará una comparación entre los algoritmos de *clustering* mediante varias pruebas con distintos intervalos, ver Tabla 1. Como se puede observar, en un intervalo demasiado grande se marcan el mismo número de *clusterings*, pero a medida que va disminuyendo el intervalo el algoritmo *K-means* suele ofrecer un número de conjuntos mayor a comparación de DBSCAN. También vale recalcar que, en intervalo muy pequeño, elevando así el número de *frames* (3200 *frames*), el número de *clusterings* disminuye considerablemente, esto a consecuencia de la gran cantidad de información continua en las comparaciones.

Tabla 1.


Datos generales de las experimentaciones.

Intervalo	Clusters con DBSCAN	Clusters con K-Means
60 Frames	1	1
600 Frames	3	4
1200 Frames	10	15
3200 Frames	3	4

Resultados

Los resultados obtenidos mostraron que los algoritmos de *clustering* pueden identificar efectivamente las áreas de interés más relevantes en una secuencia de video. La aplicación del algoritmo DBSCAN permitió identificar las regiones con mayor densidad de movimiento, ayudando a controlar el ruido en el proceso como se muestran en las Figuras 6 y 7 que es la suma de los fotogramas cada segundo, y el marcado de *clusters* con cada algoritmo; mientras que, el algoritmo de *K-Means* dividió el espacio de manera efectiva en *clusters* bien definidos los cuales se basan en la similitud del movimiento, como se observa en las imágenes los resultados son parecidos y en algunos casos puede variar la posición de los *clusters* por cuestiones de ruido.

Figura 6. Resultado Experimento 1



a) Resultado agrupación cada segundo b) Marcado de clusters con DBSCAN c) Marcado de clusters con K-Means

Figura 7. Resultado Experimento 2



a) Resultado agrupación cada segundo b) Marcado de clusters con DBSCAN c) Marcado de clusters con K-Means

Discusión

Al analizar los resultados obtenidos, se concluye que el uso de algoritmos de *clustering* como DBSCAN y *K-Means* es altamente efectivo para identificar áreas de interés en secuencias de vídeo. DBSCAN demostró una mayor sensibilidad a la densidad, permitiendo detectar áreas con agrupaciones densas de píxeles en movimiento, lo cual es útil para identificar objetos o eventos que ocurren en regiones concentradas. Por otro lado, *K-Means* ofreció una segmentación más uniforme, proporcionando una visión clara y estructurada de las áreas de movimiento a lo largo de la secuencia de vídeo. Esta capacidad de *K-Means* para definir clústeres con un número específico de grupos facilita el análisis comparativo y la interpretación de los patrones de movimiento.

Además, la incorporación de técnicas de morfología matemática, como la erosión y la dilatación, contribuyó significativamente a la precisión del análisis de movimiento. Estas técnicas mejoraron la calidad de los fotogramas procesados, al resaltar los contornos y eliminar el ruido, lo que a su vez optimizó el rendimiento de los algoritmos de *clustering* utilizado.

El soporte proporcionado por la morfología matemática refuerza la eficacia de los algoritmos de *clustering* en la segmentación de áreas de interés, demostrando su importancia en el análisis detallado de vídeos y la identificación precisa de objetos o eventos relevantes.

Sin embargo, ambos métodos presentan limitaciones, DBSCAN aunque es sensible a la densidad puede tener dificultades para distinguir entre grupos de movimientos cuando los objetos se dispersan de manera más uniforme o presentan variaciones sutiles en su densidad. Asimismo, su rendimiento depende significativamente de la selección adecuada de los parámetros de distancia y densidad mínima, lo que puede afectar la precisión del análisis. *K-Means*, por su parte, requiere que se especifique el número de clústeres de antemano, lo cual no siempre es adecuado para situaciones donde el número de objetos o eventos no es conocido previamente. Además, *K-Means* puede ser influenciado por puntos atípicos, lo que puede resultar en una segmentación menos precisa en ciertos casos.

Conclusión

En conclusión, los algoritmos de clustering como DBSCAN y *K-Means*, apoyados por técnicas de morfología matemática, son herramientas útiles para la identificación y segmentación de áreas de interés en secuencias de vídeo. Aunque, presentan limitaciones en cuanto a su sensibilidad a los parámetros y la dependencia de información previa, lo que podría reducir su efectividad en escenarios complejos o no estructurados. Su capacidad para analizar patrones de movimiento y su flexibilidad en diferentes contextos les otorgan un valor significativo en el análisis de vídeo.

Para trabajos futuros se podrían explorar la combinación de los algoritmos de DBSCAN y *K-Means* junto con algoritmos más avanzados de aprendizaje profundo (Deep Learning), como redes neuronales, para así poder mejorar la detección automática de objetos y patrones sin la necesidad de ajustarlos manualmente. Además, se podría investigar la optimización con la morfología matemática para reducir su impacto computacional, permitiendo su implementación en sistemas de análisis de vídeo en tiempo real. Al igual se podría investigar el desarrollo de métodos adaptativos que determinen de manera automática el número óptimo de clústeres en *K-Means* o los parámetros en DBSCAN, para así mejorar la versatilidad de estos algoritmos en escenarios más dinámicos.

Referencias

- Chong, C. P., Salama, C. A. T., & Smith, K. C. (1992). Image-motion detection using analog VLSI. *IEEE Journal of Solid-State Circuits*, 27(1), 93–96. <https://doi.org/10.1109/4.109560>
- Ge, R., Shan, Z., & Kou, H. (2011). An intelligent surveillance system based on motion detection. 2011 4th IEEE International Conference on Broadband Network and Multimedia Technology, 306–309. <https://doi.org/10.1109/ICBNMT.2011.6155946>
- González García, M. V. (2016). Análisis del movimiento en secuencias de imágenes. <https://eprints.ucm.es/id/eprint/38462/>
- Hossen, M. K., & Tuli, S. H. (2016). A surveillance system based on motion detection and motion estimation using optical flow. 2016 5th International Conference on Informatics, Electronics and Vision (ICIEV), 646–651. <https://doi.org/10.1109/ICIEV.2016.7760081>
- La, N., Palomino, S., & Concepción, L. P. (2010). Watershed: un algoritmo eficiente y flexible para segmentación de imágenes de geles 2-DE Watershed: an algorithm efficient and flexible segmentation of footage gels 2-OF.
- Li, H., Zhang, A., & Pei, X. (2019). Research on Thermal Error of CNC Machine Tool Based on DBSCAN Clustering and BP Neural Network Algorithm. 2019 IEEE International Conference of Intelligent Applied Systems on Engineering (ICIASE), 294–296. <https://doi.org/10.1109/ICIASE45644.2019.9074094>
- Morris, B., & Trivedi, M. (2009). Learning trajectory patterns by clustering: Experimental studies and comparative evaluation. 2009 IEEE Conference on Computer Vision and Pattern Recognition, 312–319. <https://doi.org/10.1109/CVPR.2009.5206559>
- Pierre, S. (2016). *Morphological Image Analysis: Principles and Application*. Springer Science & Business Media.
- Shirbhate, R. S., Mishra, N. D., & Pande, R. P. (2012). Video Surveillance System Using Motion Detection-A Survey.
- Sisodia, D. (2012). Clustering Techniques: A Brief Survey of Different Clustering Algorithms.
- Wang, L., Hu, W., & Tan, T. (2003). Recent developments in human motion analysis. *Pattern Recognition*, 36(3), 585–601. [https://doi.org/10.1016/S0031-3203\(02\)00100-0](https://doi.org/10.1016/S0031-3203(02)00100-0)
- Xu, D., & Tian, Y. (2015). A Comprehensive Survey of Clustering Algorithms. *Annals of Data Science*, 2(2), 165–193. <https://doi.org/10.1007/s40745-015-0040-1>