

**Tecnológico Nacional de México  
Centro Nacional de Investigación y Desarrollo  
Tecnológico**

Tesis de maestría

**Revisión sistemática de mejoras en la  
inicialización del algoritmo Fuzzy C-Means**

Presentada por:

**Lic. Yanelin Abarca Ponce**

Como requisito para la obtención del grado de:  
**Maestra en Ciencias de la Computación**

Director de tesis:

**Dr. Javier Ortiz Hernández**

Codirectores:

**Dra. María Yasmín Hernández Pérez**  
**Dr. Joaquín Pérez Ortega**



# Educación

Secretaría de Educación Pública



TECNOLÓGICO  
NACIONAL DE MÉXICO

SEP TecNM CENTRO NACIONAL DE INVESTIGACIÓN  
Y DESARROLLO TECNOLÓGICO

RECIBIDO  
10 FEB 2025 CMZ  
REQUERIMIENTO  
SUBDIRECCIÓN ACADÉMICA



Centro Nacional de Investigación y Desarrollo tecnológico  
Departamento de Ciencias Computacionales

Cuernavaca, Mor., 05/Febrero/2025  
OFICIO No. DCC/045/2025

**Asunto:** Aceptación de documento de tesis  
CENIDET-AC-004-M14-OFICIO

CARLOS MANUEL ASTORGA ZARAGOZA  
SUBDIRECTOR ACADÉMICO  
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de **YANELIN ABARCA PONCE** con número de control M21CE051, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado "**Revisión sistemática de mejoras en la inicialización del algoritmo Fuzzy C-Means**" y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

ATENTAMENTE

*Excellencia en Educación Tecnológica®  
"Conocimiento y Tecnología al Servicio de México"*

Dr. Javier Ortiz Hernández  
Director de tesis

Dr. Joaquín Pérez Ortega  
Codirector de tesis

Dra. María Yasmín Hernández Pérez  
Codirectora de tesis

Dra. Alicia Martínez Rebollar  
Revisor 1

Dr. José Alberto Hernández Aguilar  
Revisor 2



cenidet



Interior Internado Palmira S/N, Col. Palmira,  
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 3201,  
e-mail: [dcc\\_cenidet@tecnm.mx](mailto:dcc_cenidet@tecnm.mx) | [tecnm.mx](http://tecnm.mx) | [cenidet.tecnm.mx](http://cenidet.tecnm.mx)



2025  
Año de  
La Mujer  
Indígena



Centro Nacional de Investigación y Desarrollo tecnológico  
Subdirección Académica

Cuernavaca Mor, 10/febrero/2025

Oficio No. SAC/058/2025

Asunto: Autorización de impresión de tesis

**YANELIN ABARCA PONCE**  
**CANDIDATA AL GRADO DE MAESTRA**  
**EN CIENCIAS DE LA COMPUTACIÓN**  
**P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "**Revisión sistemática de mejoras en la inicialización del algoritmo Fuzzy C-Means**", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

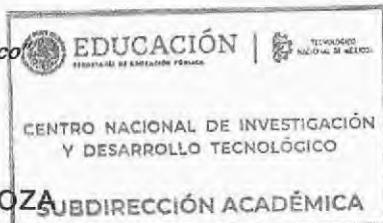
Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**A T E N T A M E N T E**

*Excelencia en Educación Tecnológica®*

*"Conocimiento y Tecnología al Servicio de México"*

**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**



c.c.p. Departamento de Ciencias Computacionales  
Departamento de Servicios Escolares

CMAZ/lmz



**2025**  
Año de  
La Mujer  
Indígena

Interior Internado Palmira S/N, Col. Palmira,  
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4104,  
e-mail: [acad\\_cenidet@tecnm.mx](mailto:acad_cenidet@tecnm.mx) [technm.mx](http://technm.mx) | [cenidet.tecnm.mx](http://cenidet.tecnm.mx)

**cenidet**  
Centro Nacional de Investigación  
y Desarrollo Tecnológico



# Dedicatoria

*Con mucho amor para mi familia y en especial para José Octavio Estrada Angelino, Santiago Magallón Zapata y la familia Avonce Peralta, porque este trabajo es el reflejo de la confianza y el apoyo incondicional que me han brindado.*

# Agradecimientos

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por la beca otorgada, la cual fue fundamental para la realización de mis estudios de maestría.

Al Tecnológico Nacional de México (TecNM) por facilitar sus instalaciones y proporcionar un entorno propicio para el aprendizaje y para la construcción de esta investigación.

Al Dr. Javier Ortiz Hernández, le agradezco profundamente sus aportaciones. Enriquecieron este trabajo y me permitieron explorar nuevas perspectivas sobre el tema. Su compromiso con la excelencia y los procesos siempre fue una inspiración constante durante mi carrera.

A la Dra. Yasmín Hernández Pérez, le manifiesto mi más profundo respeto y admiración por su destacada trayectoria. Sus aportaciones no solo fortalecieron esta tesis, sino que también me demostraron la importancia de abordar la investigación con rigor y organización.

A la Dra. Alicia Martínez Rebollar, le extiendo mi gratitud por sus observaciones orientadas al detalle. Sus aportaciones durante mi estancia ayudaron a consolidar una visión más robusta en este estudio.

Al Dr. Joaquín Pérez Ortega, mi reconocimiento y agradecimiento por su manera para señalar aspectos clave de este trabajo. Su trayectoria en el campo es un ejemplo para futuros investigadores.

Al Dr. José Alberto Hernández Aguilar, le expreso mi más sincero agradecimiento por su amabilidad y entusiasmo en todo momento. Su perspectiva y apoyo me impulsaron a seguir avanzando con confianza y determinación.

Al Mtro. Juan Antonio Miguel Ruiz, por su tiempo y compromiso al brindarme las ideas que fortalecieron el desarrollo y cierre de esta investigación. Su orientación fue clave en la consolidación de este trabajo.

# Resumen

La tesis presenta una revisión sistemática exhaustiva sobre mejoras relacionadas con la inicialización del algoritmo Fuzzy C-Means (FCM). A lo largo de esta tesis nos referimos a este algoritmo como FCM por sus siglas en inglés. Se describen los objetivos de la investigación, que incluyen una búsqueda exhaustiva de las distintas versiones, clasificar y analizar las tendencias relevantes para facilitar a los investigadores la selección del método que más se adecue a su problema concreto. La metodología se dividió en cuatro macroprocesos: conocimiento del algoritmo, diseño del protocolo, desarrollo de la revisión sistemática y presentación de resultados. Estas etapas se fundamentaron en metodologías como PRISMA 2020, PICO y 5W's+1H, las cuales garantizaron un enfoque riguroso y replicable, facilitando la respuesta a las preguntas de investigación planteadas. Se llevó a cabo una búsqueda exhaustiva en ocho repositorios diferentes, incluyendo PubMed, IEEE Xplore, Springer, Google Scholar, PLOS ONE, ACM Digital Library, MDPI y Science Direct, abarcando publicaciones desde 1981 hasta 2024. Esto resultó en la identificación inicial de más de 39,000 artículos relacionados con el algoritmo FCM, los cuales fueron filtrados y analizados. Después, siguiendo los criterios predefinidos, se incluyeron 108 artículos y se describieron de manera individual de acuerdo con su año de publicación. Se compararon las mejoras de acuerdo al dominio, tipo de datos utilizados, método implementado para la inicialización de FCM y la métrica de evaluación aplicada. Así, se identificaron 95 métodos diferentes para mejorar la inicialización de FCM, 39 dominios de aplicación y más de 150 métricas de evaluación. Por último, la investigación sugiere la aplicación de estas mejoras en diversas áreas, la exploración de mejoras para la resolución de problemas menos estudiados, la evaluación del impacto del uso de diferentes métodos en contextos específicos y el desarrollo de revisiones sistemáticas del algoritmo FCM aplicado en algún dominio.

Palabras clave: Fuzzy C-Means, revisión sistemática, inicialización, técnicas de agrupamiento.

# Abstract

The thesis presents a comprehensive systematic review on improvements related to the initialization of the Fuzzy C-Means (FCM) algorithm. Throughout this thesis we refer to this algorithm as FCM. The objectives of the research are described, which include a thorough search of the different versions, classifying and analyzing relevant trends to facilitate researchers in selecting the method that best suits their specific problem. The methodology was divided into four macro-processes: knowledge of the algorithm, design of the protocol, development of the systematic review and presentation of results. These stages were based on methodologies such as PRISMA 2020, PICO and 5W's+1H, which guaranteed a rigorous and replicable approach, facilitating the response to the research questions posed. A comprehensive search was conducted across eight different repositories, including PubMed, IEEE Xplore, Springer, Google Scholar, PLOS ONE, ACM Digital Library, MDPI and Science Direct, covering publications from 1981 to 2024. This resulted in the initial identification of more than 39,000 articles related to the FCM algorithm, which were filtered and analyzed. Then, following the predefined criteria, 108 articles were included and individually described according to their year of publication. The improvements were compared according to the domain, type of data used, method implemented for FCM initialization and the evaluation metric applied. Thus, 95 different methods to improve FCM initialization, 39 application domains, and more than 150 evaluation metrics were identified. Finally, the research suggests the application of these improvements in various areas, the exploration of improvements for the resolution of less studied problems, the evaluation of the impact of the use of different methods in specific contexts and the development of systematic reviews of the FCM algorithm applied in some domain.

Keywords: Fuzzy C-Means, systematic review, initialization, clustering techniques.

# Contenido

<b>Dedicatoria.....</b>	<b>I</b>
<b>Agradecimientos.....</b>	<b>II</b>
<b>Resumen .....</b>	<b>III</b>
<b>Abstract.....</b>	<b>IV</b>
<b>Lista de figuras .....</b>	<b>VII</b>
<b>Lista de tablas .....</b>	<b>VIII</b>
<b>Capítulo 1 Introducción.....</b>	<b>1</b>
1.1.    Planteamiento del problema .....	2
1.2.    Objetivos.....	3
1.2.1.    Objetivo general .....	3
1.2.2.    Objetivos específicos.....	3
1.3.    Metodología para la solución de la tesis .....	4
1.4.    Organización del documento .....	6
<b>Capítulo 2 Marco teórico.....</b>	<b>6</b>
2.1.    Métodos aplicados en la tesis.....	8
2.2.    Herramientas empleadas en la tesis .....	8
2.3.    Definición del algoritmo FCM .....	9
2.4.    Función objetivo de FCM.....	9
2.5.    Restricciones del algoritmo FCM.....	10
2.6.    Fases del algoritmo FCM .....	11
2.6.1.    Fase de inicialización:.....	11
2.6.2.    Fase del cálculo de centroides .....	11
2.6.3.    Fase de actualización de la matriz de membresías .....	11
2.6.4.    Fase de convergencia.....	12
2.7.    Notación de FCM .....	12
<b>Capítulo 3 Trabajo relacionado.....</b>	<b>11</b>
3.1.    Estudios relacionados .....	14
3.2.    Investigación relacionada en CENIDET .....	17

<b>Capítulo 4 Desarrollo de la revisión .....</b>	<b>1</b>
4.1.    Descripción de los métodos PRISMA, PICO y 5W's+1H aplicados a la tesis .....	19
4.2.    Preguntas de investigación .....	20
4.3.    Palabras clave .....	20
4.4.    Criterios de inclusión y exclusión .....	21
4.4.1.    Criterios de inclusión .....	21
4.4.2.    Criterios de exclusión .....	21
4.5.    Cadenas de búsqueda .....	21
4.6.    Diagrama de flujo PRISMA .....	23
<b>Capítulo 5 Resultados de la revisión .....</b>	<b>1</b>
5.1.    Respuesta a la Pregunta 1 de la revisión sistemática .....	25
5.1.1.    Descripción de mejoras publicadas en los años 1983-2009 .....	25
5.1.2.    Descripción de mejoras publicadas en los años 2010-2014 .....	27
5.1.3.    Descripción de mejoras publicadas en los años 2015-2019 .....	29
5.1.4.    Descripción de mejoras publicadas en los años 2020-2024 .....	33
5.2.    Respuesta a la Pregunta 2 de la revisión sistemática.....	38
5.3.    Respuesta a la Pregunta 3 de la revisión sistemática.....	54
5.4.    Respuesta a la Pregunta 4 de la revisión sistemática.....	57
<b>Capítulo 6 Discusión de los resultados .....</b>	<b>58</b>
6.1.    Otros hallazgos .....	59
<b>Capítulo 7 Conclusiones .....</b>	<b>60</b>
7.1.    Conclusiones.....	61
7.2.    Trabajos futuros.....	61
<b>Referencias .....</b>	<b>63</b>
<b>Anexo A: Publicaciones derivadas de la investigación .....</b>	<b>85</b>

# **Lista de figuras**

Figura 1. Búsqueda del término “Fuzzy C-Means” de artículos publicados en IEEE.....	2
Figura 2. Representación de la literatura vital para un investigador a través del principio de Pareto.....	2
Figura 3. Metodología de solución para resolver el problema de tesis.....	5
Figura 4. Diagrama PRISMA del filtrado de estudios.....	23
Figura 5. Tipo de datos utilizados en las mejoras de FCM.....	55
Figura 6. Métodos con mayor recurrencia en las mejoras de FCM.....	56
Figura 7. Tendencia de los elementos en FCM con mayor recurrencia de modificación.....	59

# **Lista de tablas**

Tabla 1. Artículos estudiados para la construcción de la revisión de la literatura.....	14
Tabla 2. Investigaciones relacionadas con el algoritmo FCM desarrolladas en CENIDET. ....	17
Tabla 3. Elementos de la investigación relacionados con los términos PICO. .....	19
Tabla 4. 5W's+1H y las interrogantes implementadas en la revisión sistemática.....	20
Tabla 5. Términos PICO y las palabras clave seleccionadas para la revisión sistemática. ....	20
Tabla 6. Cadenas de búsqueda.....	21
Tabla 7. Análisis comparativo de las mejoras en la inicialización de FCM localizadas en la revisión.....	38
Tabla 8. Tendencias de dominios de las mejoras de FCM.....	54
Tabla 9. Métodos más recurrentes en la literatura para mejorar la inicialización de FCM. ....	55
Tabla 10. Artículos de las mejoras de FCM con mayor número de citas.....	57
Tabla 11. Número de ocurrencias de las métricas de evaluación. ....	59

## Capítulo 1

# Introducción

La aplicación del algoritmo FCM ha desempeñado un papel crucial en múltiples disciplinas científicas y tecnológicas. Sin embargo, su implementación presenta desafíos, como la sensibilidad a la inicialización del algoritmo, lo que ha motivado el desarrollo de numerosas mejoras a lo largo de las últimas décadas. Este trabajo aborda el estudio de los métodos aplicados para inicializar FCM mediante una revisión sistemática que explora las modificaciones propuestas para mejorar su desempeño.

## 1.1. Planteamiento del problema

El algoritmo FCM ha sido ampliamente estudiado desde que se originó y se han desarrollado múltiples modificaciones para su aplicación para resolver problemas en dominios específicos. Actualmente, el número de artículos publicados referentes al algoritmo FCM en los diferentes repositorios es gradual. De hecho, como ejemplo de este crecimiento, la búsqueda del término “Fuzzy C-Means” en IEEE Xplore representa una cantidad inmensa de estudios (Figura 1).

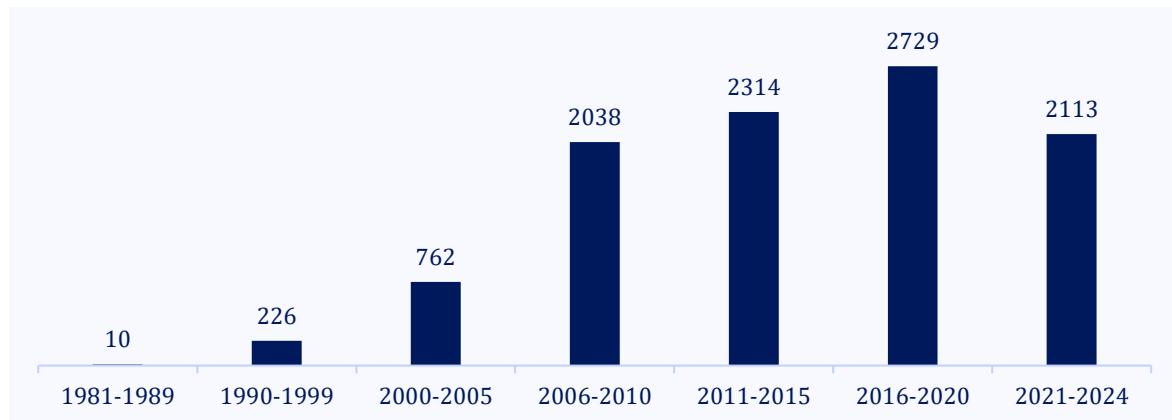


Figura 1. Búsqueda del término “Fuzzy C-Means” de artículos publicados en IEEE.

Considerando lo anterior, es posible observar que el uso de FCM ha sido un tema recurrente en la literatura. De hecho, según (Pérez Rave, 2019), en toda investigación, existe un subconjunto de artículos de menor frecuencia en toda la literatura, pero es vital para el investigador. Además, el autor menciona que este subconjunto se puede representar con base en un diagrama de Pareto (Figura 2).

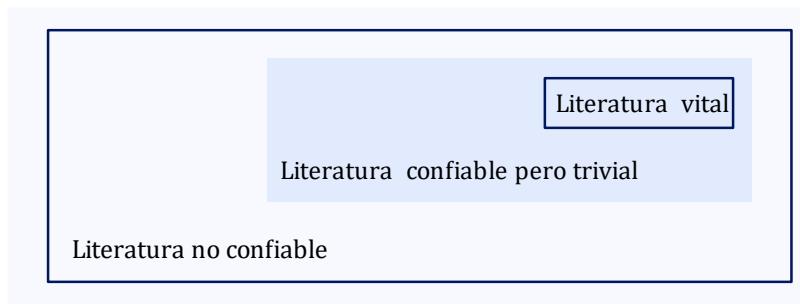


Figura 2. Representación de la literatura vital para un investigador a través del principio de Pareto.

Sin embargo, a pesar del volumen de investigaciones existentes a lo largo de las últimas décadas, no se ha realizado una revisión sistemática exhaustiva sobre el algoritmo FCM que compile, organice y clasifique de manera clara las mejoras desarrolladas. Por lo tanto, existe una gran incertidumbre de qué publicaciones son las relevantes para resolver un problema de investigación debido a la cantidad de información existente. Y, al no disponer de un estudio que sintetice la información de las mejoras de FCM, existe la necesidad de desarrollar una

investigación exhaustiva que permita identificar las características de los diferentes enfoques implementados para mejorar el algoritmo y proporcionar una visión global de su tendencia a lo largo del tiempo para fortalecer la investigación futura.

En particular, una de las etapas clave en el rendimiento del algoritmo FCM y en donde se han propuesto diversas estrategias para optimizar sus resultados es la inicialización, ya que una selección inadecuada de los valores iniciales puede derivar en resultados subóptimos o en una convergencia lenta. Por ello, la presente revisión sistemática se enfocará en analizar y clasificar las mejoras relacionadas con la inicialización del algoritmo, identificando los diferentes métodos utilizados en esta etapa y evaluando su impacto en los resultados obtenidos.

## 1.2. Objetivos

Se presenta el objetivo general y los objetivos específicos de la tesis que guiaron el proceso de la revisión sistemática sobre las mejoras en la inicialización de FCM.

### 1.2.1. Objetivo general

Realizar una revisión sistemática exhaustiva que compile, clasifique y analice las mejoras desarrolladas en la inicialización del algoritmo FCM para comprender las tendencias actuales y facilitar la selección del método que más se adecue en aplicaciones específicas.

### 1.2.2. Objetivos específicos

- Identificar las mejoras del algoritmo FCM en su inicialización para la compilación de las distintas versiones desarrolladas a lo largo del tiempo.
- Describir las mejoras desarrolladas en la inicialización de FCM para proporcionar una visión integral de las características de los métodos que las componen.
- Clasificar las mejoras del algoritmo FCM para la detección de patrones en sus enfoques implementados.
- Analizar las tendencias en las mejoras en la inicialización del algoritmo FCM para la identificación de los estudios con mayor relevancia.

### 1.3. Metodología para la solución de la tesis

La metodología de la tesis se desarrolló utilizando un diagrama de bloques (Ilustración 1) para expresar el proceso, las actividades realizadas, los métodos utilizados, los productos obtenidos y las herramientas empleadas. La estructura se dividió en cuatro macroprocesos fundamentales que guiaron el estudio para alcanzar los objetivos propuestos, donde cada uno de ellos consistió en:

1. Conocimiento del algoritmo FCM: Este macroproceso buscó establecer una base teórica sólida del algoritmo FCM y su estructura para identificar los diferentes elementos clave que influyen en su desempeño, con especial énfasis en su inicialización. Las actividades incluyeron el análisis de información teórica sobre FCM, estudio de las fases del algoritmo para el entendimiento del tema de investigación y la exploración de estudios parecidos a esta tesis para reconocer los desafíos asociados al tema.
2. Diseño del protocolo: En este macroproceso se buscó la definición de las directrices que guiaron el desarrollo de la revisión sistemática. Este proceso fue clave para definir actividades, métodos y las herramientas que ayudarían a identificar las mejoras en la inicialización de FCM. Se integraron la metodología PRISMA y el método PICO para la formulación de las preguntas de investigación, selección de palabras clave y la determinación de los criterios para la selección de artículos. Las 8 fuentes de información seleccionadas fueron PubMed, IEEE Xplore, Springer y Google Scholar para abordar la búsqueda de manera exhaustiva.
3. Desarrollo de la revisión sistemática: En esta fase se ejecutó la revisión sistemática conforme a las directrices establecidas en el protocolo. Se recopilaron, filtraron y analizaron artículos relevantes, centrándose en identificar mejoras en la inicialización de FCM. Este macroproceso permitió organizar la información y establecer una clasificación de los métodos encontrados, proporcionando una visión estructurada sobre cómo ha evolucionado esta área del algoritmo. Las actividades incluidas fueron la extracción y filtrado de artículos. Se construyó el diagrama de flujo PRISMA, se analizaron los artículos y se clasificaron los artículos incluidos en la revisión sistemática con base en el año de publicación, los métodos empleados, el dominio de aplicación y el tipo de datos utilizados.
4. Presentación de resultados: Este macroproceso es crucial para sintetizar el conocimiento generado de la revisión sistemática y estructurar los hallazgos en función de los criterios del protocolo establecido. En particular, se desarrolla la divulgación de la revisión sistemática a través de productos como artículos o productos académicos.

## 1 Conocimiento del algoritmo FCM

- Revisión teórica sobre el algoritmo FCM
- Estudio sobre las fases del algoritmo
- Marco teórico sobre FCM y las fases del algoritmo
- Método para revisión de la literatura

## 2 Diseño del protocolo

- Desarrollo de las preguntas de investigación
- Selección de las palabras clave para la investigación
- Selección de los criterios de inclusión/exclusión
- Método para revisión sistemática
- Método para formular preguntas de investigación
- Preguntas de investigación
- Cadenas de búsqueda
- Criterios de inclusión y exclusión

## 3 Desarrollo de la revisión sistemática

- Extracción de información y filtrado de artículos sobre las mejoras de FCM
- Flujo PRISMA
- Clasificación de artículos y análisis
- Resumen de artículos
- Tabla comparativa de las mejoras de FCM para su inicialización

## 4 Presentación de los resultados

- Redacción de los resultados de la investigación
- 5W's+1H
- Producto de divulgación
- Resultado de revisión sistemática

### Simbología:

Macroprocesos

Actividades

Métodos

Productos

Figura 3. Metodología de solución para resolver el problema de tesis.

## **1.4. Organización del documento**

La presente tesis está estructurada en siete capítulos, los cuales abordan el desarrollo de la revisión sistemática de mejoras en la inicialización del algoritmo Fuzzy C-Means (FCM), desde el planteamiento del problema, marco teórico, el desarrollo del protocolo, desarrollo, hallazgos y futuras líneas de investigación.

El Capítulo 1 introduce el problema de investigación, los objetivos generales, objetivos específicos y la metodología aplicada. En este apartado se justifica la necesidad de una revisión sistemática sobre la inicialización de FCM y se define el enfoque metodológico utilizado para garantizar la validez del estudio.

El Capítulo 2 trata de un marco teórico de la tesis. Esta sección detalla los métodos aplicados en la revisión sistemática, las herramientas, así como una descripción del algoritmo FCM, sus fases, restricciones y notación matemática. Este capítulo proporciona la base teórica necesaria para comprender la importancia de las mejoras en su inicialización.

El Capítulo 3 presenta un análisis de estudios previos relacionados con modificaciones de FCM, incluyendo investigaciones relevantes realizadas en el CENIDET. Esta sección permite contextualizar el tipo de investigación desarrollado sobre FCM y destacar las contribuciones que tengan mayor relación con esta tesis.

El Capítulo 4 describe la aplicación de los métodos PRISMA, PICO y el método de las 5W's+1H para la construcción del protocolo de la revisión. Se detallan las preguntas de investigación, las palabras clave empleadas, los criterios de inclusión y exclusión, las estrategias de búsqueda en bases de datos y el diagrama de flujo PRISMA.

El Capítulo 5 expone los resultados obtenidos en la revisión sistemática. Se presentan las respuestas a cada una de las preguntas de investigación y un análisis detallado de las mejoras propuestas para la inicialización de FCM en diferentes períodos de tiempo, su impacto en la precisión y eficiencia del algoritmo, así como su aplicación en diversos dominios.

El Capítulo 6 destaca otros hallazgos relevantes identificados durante la revisión, como tendencias emergentes en la modificación del algoritmo y patrones en el uso de métodos específicos para su inicialización.

Finalmente, el Capítulo 7 presenta las conclusiones generales de la investigación y las posibles direcciones para futuros estudios. Se analizan las implicaciones de los hallazgos y se proponen áreas donde nuevas mejoras podrían seguir optimizando el rendimiento de FCM.

El documento concluye con la lista de referencias utilizadas y un anexo que incluye publicaciones derivadas de la investigación.

## Capítulo 2

# Marco teórico

Este capítulo aborda definiciones clave y conceptos referentes a revisiones sistemáticas, revisión de la literatura, metodología PRISMA, PICO y 5W's+1H. Además, se presentan los principios básicos del algoritmo FCM, su origen como un problema de optimización. Se describen sus elementos, las restricciones y las cuatro fases fundamentales de FCM: inicialización, cálculo de centroides, actualización de membresías y convergencia. Por último, se presenta la notación de FCM.

## 2.1. Métodos aplicados en la tesis

En esta tesis, se utilizó una metodología que se apoya en distintas herramientas y marcos metodológicos para garantizar la exhaustividad y fiabilidad de los resultados. Por lo tanto, se describen los métodos aplicados que guiaron la investigación y organización de la revisión sistemática:

- Tipos de revisiones: Los autores (Grant & Booth, 2009) mencionan más de 10 tipos de revisiones, como la revisión crítica, revisión de la literatura, revisión de mapeo, revisión de estudios mixtos, revisión de la literatura, revisión rápida, revisión de alcance, revisión del estado del arte, revisión sistemática y revisión de paraguas, por mencionar algunas.
- Revisión sistemática y de la literatura: Según (MacDonell et al., 2010) una revisión sistemática es un método de investigación utilizado para identificar, evaluar y sintetizar todos los estudios primarios relevantes que satisfacen criterios de inclusión específicos para responder a una pregunta de investigación en particular. Y, a diferencia de este tipo de revisión, la literaria no sigue protocolos y tiene como objetivo proporcionar una visión general y comprensiva de un tema.
- PRISMA: La metodología por sus siglas en inglés (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) se compone de una serie de directrices que proporciona un marco riguroso y estructurado para llevar a cabo revisiones sistemáticas y facilitar su reproducción en futuras investigaciones (Page et al., 2021).
- PICO: Es una herramienta que relaciona sus términos con elementos clave de la investigación para guiar y delimitar el espacio de búsqueda (X. Huang et al., 2006; Schardt et al., 2007).
- 5W's+1H: La herramienta mencionada por el autor (Pérez Rave, 2019) representa cinco palabras en inglés (*What, Why, Who, When, Where*) y por una H (*How*).

## 2.2. Herramientas empleadas en la tesis

Para la gestión de los resultados de la búsqueda en las diferentes fuentes de información, se utilizaron herramientas como Zotero y Rayyan. Estas se describen a continuación:

- Zotero: Software gratuito y de código abierto utilizado para la gestión de referencias bibliográficas mediante la extracción de información. Fue utilizado para la extracción de información de cada artículo y la gestión de referencias de forma eficiente, optimizando el manejo de las fuentes consultadas durante la investigación.
- Rayyan: Plataforma en línea diseñada específicamente para apoyar al desarrollo de revisiones. Esta herramienta se conectó con los datos de Zotero para el filtrado de los estudios de las mejoras de FCM. Se utilizó para la detección de duplicados, incluir y excluir estudios con base en los criterios y organización de los estudios seleccionados.

### 2.3. Definición del algoritmo FCM

FCM es un algoritmo de agrupamiento que permite que un punto pertenezca a múltiples grupos, asignando a cada punto de datos un grado de pertenencia a cada grupo en función de qué tan cerca está del centro de ese clúster. Esto se logra mediante la minimización de la función objetivo  $J_m$ , durante cada iteración. Esta función de costo o función objetivo, mide qué tan bien están agrupados los puntos.

El algoritmo FCM fue desarrollado poco después de que surgiera la teoría de conjuntos difusos (Zadeh, 1965). Aunque hubo aplicaciones de manera temprana (Bellman et al., 1966), fue hasta el año de 1969 que Ruspini (E. H. Ruspini, 1969) formuló un método de agrupación difusa como un problema de optimización. En su artículo menciona distintas técnicas enfocadas a la reducción de datos como las de Watanabe (Watanabe, 1965), Wallace and Boulton (Wallace & Boulton, 1968), así como de procesos de recolocación y corrección mencionados por Lance y Willians (Lance & Williams, 1967) y Ball (Ball, 1965).

En 1970, Ruspini (E. H. Ruspini, 1970) continuó sus investigaciones, pero fue el autor (Dunn, 1973) quien presentó dos versiones con errores de mínimos cuadrados basados en el proceso ISODATA (Ball & Hall, 1965). En sus métodos, utilizó los multiplicadores de Lagrange para la solución de las pruebas realizadas.

Dunn continuó sus estudios (Dunn, 1974), pero fue Bezdek (Bezdek, 1973) quien explicó que las condiciones necesarias vinculadas con el coeficiente de partición y que un único criterio de clasificación para una amplia variedad de patrones no es suficiente.

Siguiendo con esta línea, el autor (Bezdek, 1981) realizó la generalización de FCM, que hoy en día se conoce como el método tradicional y uno de los algoritmos representativos de los métodos basados en una función objetivo y con diversas restricciones (Expresiones 1-9). Consiste en identificar la partición óptima en el conjunto dado (Algoritmo 1).

### 2.4. Función objetivo de FCM

La función objetivo del algoritmo FCM busca minimizar la dispersión de los puntos respecto a los centroides mediante una medida de distancia ponderada (Ecuación 1). A continuación, se describen en detalle algunos de los elementos que la componen (Ecuaciones 2-5), incluyendo la matriz de pertenencia, los centroides, la distancia euclídea y el factor de ponderación. La función objetivo del algoritmo FCM tradicional  $J_m$  es:

$$J_m(U, v) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m (d_{ik})^2 \quad (1)$$

Donde:

$$U \in M_{fc} \quad (2)$$

Denota que el conjunto  $U$  es una partición  $c$  difusa;

$$\nu = (\nu_1, \nu_2, \dots, \nu_c) \in \mathbb{R}^{cp} \text{ con } \nu_i \in \mathbb{R}^p \quad (3)$$

Es el centro o prototipo del grupo de  $u_i$ , y  $1 \leq i \leq c$ ;

$$(d_{ik})^2 = \|x_k - \nu_i\|^2 \text{ y } |\cdot| \quad (4)$$

Denota que  $(d_{ik})^2$  es un producto inducido por una norma en  $\mathbb{R}^2$ ; y

$$m \in [1, \infty) \quad (5)$$

Equivale al valor del exponente de ponderación y denota que su valor está entre 1 al  $\infty$ .

## 2.5. Restricciones del algoritmo FCM

Al ser un algoritmo desarrollado para resolver problemas de optimización, FCM cuenta con distintas restricciones (Ecuación 6-9), siendo que:

$$u_{ik} \in [0,1] \forall i, k; \quad (6)$$

$$\sum_{i=1}^c u_{ik} = 1 \forall k; \quad (7)$$

$$u_{ik} = 1 \text{ si } x_i = \nu_k; \quad (8)$$

$$0 < \sum_{i=1}^n u_{ik} < n \forall i. \quad (9)$$

Las restricciones (Ecuación 6-9) indican que el grado de pertenencia del objeto  $i$  al clúster  $k$  debe tener un valor entre 0 y 1. La suma de los grados de pertenencia de cualquier objeto  $i$  a todos los clústeres debe ser igual a 1. El valor del grado de pertenencia  $u_{ik}$  de un objeto  $i$  a un clúster es igual a 1, si y solo si el objeto se encuentra en la misma posición del clúster  $k$ , además, la suma de los grados de pertenencia de todos los objetos al clúster  $k$  debe ser mayor a 0.

## 2.6. Fases del algoritmo FCM

El algoritmo FCM (Algoritmo 1) mencionado por el mismo autor, (Bezdek et al., 1984) tiene cuatro fases: 1) inicialización, 2) cálculo de los centroides, 3) actualización de membresías, y 4) convergencia. El proceso consiste en realizar el cálculo de las expresiones alternativamente, hasta que se satisfaga un criterio de convergencia.

### Algoritmo 1

- 1 **Fase de inicialización:** Elegir el número de  $c$ ,  $2 \leq c < n$ ; métrica de distancia; el valor del exponente de ponderación  $m$ ,  $1 \leq m < \infty$  y la matriz inicial  $U^{(0)} \in M_{fc}$  y número de iteraciones.
- 2 **Fase del cálculo de centroides:** Calcula el valor de los centros usando la Ecuación (10).
- 3 **Fase de actualización de membresía:** Actualiza el valor de membresías con Ecuación (11).
- 4 **Fase de convergencia:** Compara el valor de  $U^{(l)}$  con  $U^{(l-1)}$  si  $\|U^{(l-1)} - U^{(l)}\| \leq \varepsilon_L$  parar; de otra manera, regresar a la fase 2.

### 2.6.1. Fase de inicialización:

En esta fase se eligen los parámetros que conformarán el algoritmo: el número de  $c$ , el tipo de métrica de distancia, el valor de  $m$ , el valor de  $U^{(0)}$  y el número de iteraciones  $\varepsilon_L$  para la convergencia de FCM.

### 2.6.2. Fase del cálculo de centroides

Se calculan los centros a partir de los parámetros iniciales (Ecuación 10):

$$v_j = \frac{\sum_{i=1}^n u_{ik}^m x_k}{\sum_{i=1}^n u_{ik}^m} \quad (10)$$

Donde  $u_{ik}$  es el grado de pertenencia del  $i$ -ésimo dato al  $k$ -ésimo grupo,  $x_k$  es el  $k$ -ésimo punto de datos,  $v_j$  es el centro del  $j$ -ésimo grupo,  $c$  es el número de grupos, y  $m$  es el factor de ponderación.

### 2.6.3. Fase de actualización de la matriz de membresías

Se actualiza la matriz de membresías  $U^{(l)}$  (Ecuación 11) con base en los valores de distancias de los datos hacia los nuevos centros generados:

$$u_{ik} = \frac{1}{\left[ \sum_{j=1}^c \left( \frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{m-1}} \right]} \quad (11)$$

### 2.6.4. Fase de convergencia

En esta fase, se comparan los valores de  $U^{(l)}$  con  $U^{(-l)}$  que sean menores del umbral predefinido. Si se cumple esta condición (Ecuación 12), el algoritmo converge y se detiene. De lo contrario, se vuelve a la fase 2 y se repiten los pasos iterativamente hasta que se alcanza la convergencia.

$$\text{Si } \left| \left| U^{(l)} - U^{(l-1)} \right| \right| \leq \varepsilon_L \text{ parar.} \quad (12)$$

### 2.7. Notación de FCM

A continuación, se describe la notación de la función presentada en (Bezdek, 1981):

$m$ : Exponente de ponderación, en donde  $m > 1$ ;

$c$ : Número de clústeres en  $X$ ;

$n$ : Número de objetos en  $X$ ;

$i$ : Índice de objetos;

$j$ : Índice de agrupaciones;

$X$  ó  $\{x_1, x_2, \dots, x_n\}$ : conjunto de  $n$  objetos a particionar de acuerdo al criterio seleccionado;

$U$  ó  $\{u_{ik}\}$ : grado de membresía del objeto  $i$  al clúster  $k$ ;

$V$  ó  $\{v_1, v_2, \dots, v_n\}$ : centro del clúster  $i$ ;

$(d_{ik})^2$ : Distancia del objeto  $x_i$  al centroide  $v_k$  usando la norma euclíadiana.

### Capítulo 3

## Trabajo relacionado

Las revisiones de la literatura que se han desarrollado a lo largo de las décadas sobre los algoritmos de agrupamiento difuso, han desempeñado un papel crucial. Este capítulo aborda la construcción del estado actual de las revisiones publicadas que exploran los estudios relacionados con el algoritmo FCM en distintos contextos y dominios.

### 3.1. Estudios relacionados

El análisis del estado sobre la investigación de FCM se construyó a partir de la revisión de 20 artículos que analizan su desarrollo, estudios sobre algoritmos de agrupamiento y de tipo difusos. En cada uno, se buscaron características como el enfoque de investigación, referencias de los artículos relacionados con FCM identificados, el total de artículos que los autores reportan y las áreas de aplicación (Tabla 1).

Tabla 1. Artículos estudiados para la construcción de la revisión de la literatura.

Ref.	Enfoque	Dominios	Referencias reportadas	Total
(Nayak et al., 2023)	Revisión de mejoras de FCM desarrolladas de 2015 al 2019	Redes neuronales, segmentación de imágenes, agrupamiento, clasificación y sistemas de detección de intrusos	(Ahmed & Hossain, 2016; Alsmirat et al., 2017; Azzaoui et al., 2019; Bai et al., 2016; Chattaraj & Das, 2016; Ding & Fu, 2016; Fatehi & Asadi, 2017; Fathabadi, 2016; Jahangoshai Rezaee et al., 2018; Keskin, 2015; Kisi & Zounemat-Kermani, 2016; A. Kumar et al., 2017; D. h. i. r. e. n. d. r. a. Kumar, 2019; Nayak et al., 2017, 2016; Ouma & Hahn, 2017; Rubio et al., 2017; Sun et al., 2024; T. o. n. g. Wu, 2019; Zeraatpisheh, 2019; M. i. n. x. i. a. Zhang, 2019; A. Alam et al., 2023; Mai & Ngo, 2015; J. i. n. j. u. n. Tang, 2015; D. Gupta et al., 2015; Parveen & Singh, 2015; Izakian et al., 2015; Filho & Telmo, 2015; Mekhmoukh & Mokrani, 2015; A. Gupta et al., 2015; Stetco et al., 2015a; Son, 2015; Z. Wang et al., 2014; Kaushal et al., 2024; Wei et al., 2021; Namburu et al., 2017; Balasubramaniam & Ananthi, 2016; Gomathi & Thangaraj, 2010; Ganesan & Rajini, 2010; <i>Kalam, Rehma, Ciza Thomas, and M. Abdul Rahiman. “GAUSSIAN KERNEL BASED FUZZY CMeans CLUSTERING ALGORITHM FOR IMAGE SEGMENTATION.” Comput. Sci. Inf. Technol. (2016): 47–56, s/f; Q. Wang et al., 2017; Pedrycz &amp; Waletzky, 1997; Davé &amp; Sen, 2002; Dang et al., 2015</i> )	51
(Raj & Nath, 2020)	Un estudio comparativo sobre diferentes técnicas de agrupamiento difuso	Segmentación de imágenes para la detección de cáncer de mama	(Al-Zoubi et al., 2007; Cannon et al., 1986; Duan et al., 2016a; Fu & Elmesiry, 2005; Havens et al., 2012; M.-C. Hung & Yang, 2001a; Kolen & Hutcheson, 2002; Pal et al., 2005; W. Wang et al., 2006a)	9
(S. Deng, 2020)	Revisión de mejoras de FCM	Problemas con ruido, tiempo de operación y sesgo inicial	(Pal et al., 2005; Forghani et al., 2007; Dave, 1991; Pappas, 1992; W. Cai et al., 2007; Tolias & Panas, 1998; Sen & Dave, 1998; Pham & Prince, 1999; Pham et al., 1999; Krishnapuram & Keller, 1993; Pal et al., 1997; Cannon et al., 1986; W. Cai et al., 2007; Kamel & Selim, 1994; M.-C. Hung & Yang, 2001a; Pal & Bezdek, 2002; Eschrich et al., 2001; W. Wang et al., 2006a; Krinidis & Chatzis, 2010; Gath & Geva, 1989; Jain & Moreau, 1987; Tan, Lim, et al., 2013a)	24
(C. Li et al., 2019)	Revisión sistemática de algoritmos difusos para la detección de fallas maquinarias rotativas	Diagnósticos de fallas industriales y de maquinaria rotativa	(Cao et al., 2012; Farajzadeh-Zanjani et al., 2015; Jiang et al., 2010; C. Li et al., 2016; Wentao et al., 2008; Z. Xu et al., 2016; K. Yu et al., 2017; Y. Zhang et al., 2009)	8
(Arora et al., 2019)	Ánalysis comparativo de diferentes métricas de distancia en FCM	Reconocimiento de patrones	(Bezdek et al., 1981a; Grabursts, 2015; Groenen et al., 2007; H.-C. Liu et al., 2009)	4

(E. H. Ruspini et al., 2019)	Estudio histórico de los algoritmos de agrupamiento difuso	Reconocimiento de patrones, análisis de imágenes, sistemas de recuperación de información, modelado de sistemas difusos, descripción de secuencias biológicas, regulación genética y anotación de genes	(Babuška & Verbruggen, 1996, 1997; Bezdek et al., 1981a, 1981b, 1995; Bobrowski & Bezdek, 1991; Chiu, 1994a; Coray, 1981; Dave, 1990; Frigui & Krishnapuram, 1996; Gunderson, 1983a; Gustafson & Kessel, 1978; Hathaway & Bezdek, 1993; Kaymak & Babuska, 1995; T. Kim et al., 1988; Krishnapuram et al., 1992; Krishnapuram & Keller, 1993; Pal et al., 2005; Selim & Ismail, 1986; Setnes, 2000; Sugeno & Yasukawa, 1993; Yoshinari et al., 1993)	22
(Domingo, s/f)	Estudio comparativo de FCM y otros algoritmos	Segmentación de imágenes y análisis de datos	(A. Ali et al., 2004; J.-L. Fan et al., 2003; Gustafson & Kessel, 1978; Krishnapuram & Keller, 1993; Siddique, 2023; Stetco et al., 2015a)	6
(Rihova & Malec, 2018)	Estudio descriptivo del algoritmo FCM	Biología marina, diagnóstico médico, reconocimiento de voz y segmentación de mercados	(Dave & Bhaswan, 1992; Höppner, 1999; Krishnapuram et al., 1992; Oliveira et al., 2007; Pal & Bezdek, 1995; Rezankova & Husek, 2012; W. Wang & Zhang, 2007; Xie & Beni, 1991)	8
(Saxena et al., 2017)	Revisión sobre técnicas de agrupamiento y sus desarrollos	Reconocimiento de patrones, datos incompletos o ruidosos	(Hathaway et al., 2000; Krishnapuram & Keller, 1993; Pal et al., 1997; R. Xu & WunschII, 2005; Yager & Filev, 1994a)	5
(Prabhakar & Sandeep, 2017)	Una revisión del algoritmo FCM, su enfoque y las limitaciones	Ingeniería agrícola, astronomía, química, geología, análisis de imágenes, diagnóstico médico, análisis de formas y reconocimiento de objetivos	(Al-Zoubi et al., 2007; Bach et al., 2004; L. Chen et al., 2010; Jahanbakhsh Pourjabari & Seyedzadegan, 2016a; H. Li et al., 2013; J. Lin & Zheng, 2009; Q.-K. Pan et al., 2014; W.-T. Pan, 2012; L. Wang et al., 2013, 2015)	10
(Nayak et al., 2015)	Revisión del algoritmo FCM del año 2000 al 2014	Redes neuronales, análisis de imágenes, segmentación de video, retornos de sonar, agrupamiento de colores, aplicaciones en tiempo real, análisis de señales, portal de internet, detección arritmias, detección de picos en densidades, biología, detección de daños, expresión génica, pronóstico, reconocimiento de voz, detección de incendios forestales, frecuencia de carga, gestión de la cadena de suministro, análisis de documentos y análisis de enfermedades	(Ahmed et al., 2002; Aydilek & Arslan, 2013; Bezdek, 1981; Bharill & Tiwari, 2014a; W. Cai et al., 2007; Cannon et al., 1986; S. Chen & Zhang, 2004; Chuang et al., 2006; Y. Dong et al., 2006; Dovžan & Škrjanc, 2011; Dunn, 1973; J. Fan & Li, 2014; J.-L. Fan et al., 2003; Fritz et al., 2013; Geweniger et al., 2010; Halberstadt & Douglas, 2008; Hassen et al., 2014; Horta et al., 2011; W.-L. Hung et al., 2006; Z. Ji et al., 2012; Z.-X. Ji et al., 2011; Kamel & Selim, 1994; Kannan et al., 2012a; D.-W. Kim et al., 2004a; Kong et al., 2002; Kühne et al., 2010; Lai et al., 2013; K. Li & Li, 2014; X. Li et al., 2012; Li-mei, 2000; P.-L. Lin et al., 2014; Maraziotis, 2012; J.-P. Mei & Chen, 2013; Mingoti & Lima, 2006; Mitra et al., 2010; Mukhopadhyay & Maulik, 2009; Nayak et al., 2014a; Noordam et al., 2002; Özbay et al., 2006; Park & Dagher, 1994; Pedrycz, 2004; Pedrycz & Vukovich, 2004; Pei et al., 1998; Pianykh, 2006; Qiu et al., 2013; E. H. Ruspini, 1969; Sanchez et al., 2014; Shamshirband et al., 2014; Staiano et al., 2006; Su et al., 2014; Tsekouras & Tsimikas, 2013; Visalakshi et al., 2014; W. X. & J. Z., 1991; X. Wang et al., 2004; K.-L. Wu & Yang, 2002; C. Xu et al., 2013; Z. Xu, 2012; Xue et al., 2010; M.-S. Yang & Tsai, 2008; Zadeh, 1965)	60

(Abdu et al., 2014)	Revisión de diferentes técnicas para mejorar FCM	Segmentación de imágenes	(Hasanzadeh & Kasaei, 2008, 2010; Xiong et al., 2006; J. Yan, 2014a; C. Yang et al., 2010; Y. Yang et al., 2004)	6
(Grover, 2014)	Estudio comparativo de algoritmos de agrupamiento	Minería de datos, procesamiento de datos geográficos, medicina y clasificación de hallazgos estadísticos en estudios sociales	(Correa et al., 2011; Fadhel & Adel, 2009; Krishnapuram & Keller, 1993; Ojeda-Magana et al., 2006; Pal et al., 2005; Zarandi et al., 2009)	6
(Sivanandini & Raj, 2013)	Revisión comparativa de algoritmos de agrupamiento basados en técnicas difusas.	Bioinformática, reconocimiento de patrones y análisis de imágenes	(R. Cai & Yu, 2009; Celikyilmaz & Burhan Turksen, 2008; Chatzis & Varvarigou, 2009; Cominetti et al., 2010a; J. Deng et al., 2010a; Sato-Ilic et al., 2009; J. Yu & Yang, 2007; Y. Zhang et al., 2010)	8
(Suganya & Shanthi, 2012)	Revisión del algoritmo FCM	Imágenes médicas, detección de patrones, minería de datos y bioinformática	(Bezdek, 1981; Fadhel & Adel, 2009; Krishnapuram & Keller, 1993; Pal et al., 2005)	4
(Türkşen, 2011)	Descripción y evaluación de distintos modelos difusos	No menciona	(Celikyilmaz & Burhan Turksen, 2008; Celikyilmaz & Turksen, 2008; Celikyilmaz & Türkşen, 2009; Hathaway & Bezdek, 1993; Hoppner & Klawonn, 2003; Türkşen, 2008, 2009)	7
(Z. Wang, 2010)	Estudio comparativo de algoritmos de FCM	Modelado de posturas para el reconocimiento de acciones humanas	(Corsini et al., 2005; Hathaway et al., 1989; Hathaway & Bezdek, 1994; Setnes & Babuska, 1999)	4
(M. A. Ali et al., 2008)	Revisión de diferentes algoritmos difusos para el procesamiento de imágenes	Procesamiento de imágenes	(A. Ali et al., 2005; M. A. Ali et al., 2006; Babuka et al., 2002; Bezdek, 1981; J.-L. Fan et al., 2003; Flores-Sintas et al., 1999; Gath & Hoory, 1995; Gustafson & Kessel, 1978; J.-J. Huang et al., 2003; Krishnapuram & Keller, 1993; Krishnapuram & Kim, 1999; Li-me, 2000; Man & Gath, 1994; E. H. Ruspini, 1969)	14
(M.-S. Yang, 1993)	Estudios de algoritmos de agrupamiento difuso	Taxonomía, medicina, geología, negocios, sistemas de ingeniería y procesamiento de imágenes	(Bezdek, 1981; Bezdek et al., 1981a, 1981b; BEZDEK & HATHAWAY, 1990; Bloomfield & Steiger, 1983; Bobrowski & Bezdek, 1991; Bobrowski & Niemiro, 1984; Dave, 1990, 1992; Dunn, 1973; Gustafson & Kessel, 1978; Hathaway et al., 1989; Jajuga, 1991; Libert & Roubens, 1982; E. Ruspini, 1973; E. H. Ruspini, 1969, 1970; Trauwaert et al., 1991; Windham, 1985; M.-S. Yang, 1994; M.-S. Yang & Yu, 1990, 1992)	22
(Hohle, s/f)	Enfoque descriptivo de agrupamiento difuso	No menciona	(Mostowski, 1948; Zadeh, 1965)	2

Inicialmente, los estudios tratan sobre algoritmos de agrupación. Pero, fue hasta el año 2010 que se publicó una revisión sobre el algoritmo FCM y su desarrollo. Su estudio fue abarcando temas comparativos, análisis de las limitaciones del algoritmo, análisis variantes con distintas métricas de distancias, estudios sobre algún dominio en específico y revisiones que centran su estudio en mejoras de FCM localizadas en un lapso de tiempo determinado.

Los artículos que más destacan por la cantidad de artículos reportados son los de (Nayak et al., 2023) con un total de 51 modificaciones a FCM reportadas. (Nayak et al., 2015) en su revisión, realizó un resumen de 60 mejoras de FCM reportadas en estudios anteriores. En su estudio hace un resumen de modificaciones de FCM desarrolladas para resolver problemas en dominios como: redes neuronales, agrupamiento, clasificación, análisis de imágenes y análisis estructural de los algoritmos. Y, el autor (S. Deng, 2020) reportó 24 artículos de mejoras de FCM para resolver problemas como el ruido, el tiempo de operación y el sesgo inicial. (E. H. Ruspini et al., 2019) reportó 22 mejoras de FCM de manera histórica. Y (M.-S. Yang, 1993) reportó 22 artículos de algoritmos de agrupamiento.

### 3.2. Investigación relacionada en CENIDET

Por otro lado, en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), el algoritmo FCM ha sido objeto de investigación en diversas áreas, como la mejora de la convergencia del algoritmo, su aplicación en Big Data, el uso de sistemas paralelos, y su implementación en el ámbito de la segmentación de imágenes (Tabla 2).

Tabla 2. Investigaciones relacionadas con el algoritmo FCM desarrolladas en CENIDET.

Referencia	Título	Enfoque
(Pérez-Ortega et al., 2024)	A New Criterion for Improving Convergence of Fuzzy C-Means Clustering. Axioms,	Mejora en la fase de convergencia (Paso 4 del algoritmo FCM)
(Pérez-Ortega et al., 2022)	Hybrid Fuzzy C-Means Clustering Algorithm Oriented to Big Data Realms.	Big Data
(Pérez-Ortega et al., 2023)	POFCM: A Parallel Fuzzy Clustering Algorithm for Large Datasets.	Sistemas en Paralelo
(Mújica-Vargas et al., 2011)	Segmentation of Noisy Images Using the Rank M-type L-filter and the Fuzzy C-Means Clustering Algorithm.	Segmentación de imágenes
(Gamino-Sánchez et al., 2018)	Block-Matching Fuzzy C-Means clustering algorithm for segmentation of color images degraded with Gaussian noise	Segmentación de imágenes

Considerando lo anterior, es posible observar que el uso de FCM ha sido un tema recurrente en la literatura y que muchos estudios han analizado cierto número de mejoras de FCM. Por lo tanto, persiste la necesidad de llevar a cabo una revisión sistemática enfocadas al algoritmo FCM, en particular para el conocimiento de los métodos aplicados para mejorar la inicialización y extraer información que describa las tendencias actuales.

## Capítulo 4

# Desarrollo de la revisión

En este capítulo se describen los métodos aplicados para el proceso de la revisión sistemática que se desarrolló sobre las mejoras de FCM para su inicialización. Se describen las preguntas de investigación, las palabras clave, los criterios de inclusión y exclusión aplicados para asegurar la calidad de los estudios seleccionados y el filtrado de artículos. Este proceso, con el diagrama PRISMA ilustra cómo fue la selección de los 108 estudios incluidos en la revisión.

## 4.1. Descripción de los métodos PRISMA, PICO y 5W's+1H aplicados a la tesis

La revisión sistemática integró 3 métodos: PRISMA, PICO y 5W's+1H. El objetivo fue establecer una metodología que permitiera descubrir las condiciones sobre el tema de tesis, y que, a su vez, posibilitara la identificación de la literatura relevante, garantizara la replicabilidad de los resultados y propiciara la formación eficiente de investigación.

Inicialmente, la revisión sistemática se realizó con base en la metodología PRISMA con el objetivo de seguir un proceso sistemático, fiable y replicable. Además, esta metodología sirvió como marco para el filtrado de artículos, aplicando los criterios de inclusión y exclusión de forma coherente y sistemática.

En segundo lugar, se utilizó el método PICO para localizar los elementos que comprenden esta tesis como la población, con el fin de desarrollar las preguntas de investigación y las palabras clave para el protocolo de investigación.

No obstante, para esta tesis se identificó a la población (*Population*), como el total de artículos relacionados con mejoras en la inicialización de FCM, mientras que la intervención (*Intervention*) se centra en los métodos. Comparación (*Comparison*) en las características individuales de las mejoras propuestas, incluyendo el dominio de aplicación, los elementos modificados, tipo de datos y los resultados (*Outcomes*) explora las tendencias generales identificadas a lo largo del tiempo (Tabla 3).

Tabla 3. Elementos de la investigación relacionados con los términos PICO.

PICO	Elementos relacionados con los términos PICO
<i>Population</i>	Total de artículos relacionados con las mejoras del algoritmo FCM para su inicialización.
<i>Intervention</i>	Elemento modificado para la inicialización del algoritmo FCM.
<i>Comparison</i>	Características de las mejoras desarrolladas para la inicialización del algoritmo FCM.
<i>Outcomes</i>	Tendencias generales observadas sobre las mejoras de FCM para su inicialización.

Por otro lado, el método de las 5W's+1H se integró para desarrollar distintas interrogantes que facilitaran la extracción de información y organización de los resultados de la tesis (Tabla 4).

Tabla 4. 5W's+1H y las interrogantes implementadas en la revisión sistemática.

5W's+1H	Interrogantes para la extracción de información individual
What	¿Qué mejora se desarrolló? (Nombre de la implementación)
Why	Elemento modificado para la inicialización del algoritmo FCM.
Who	¿Cuáles son los tipos de datos utilizados en la investigación?
When	Fecha de implementación.
Where	¿Dónde se hizo? (Dominio de aplicación)
How	¿Cómo se hizo? (Métodos)

## 4.2. Preguntas de investigación

De acuerdo a la incógnita general de investigación (¿Cuáles son las condiciones actuales que presentan las mejoras desarrolladas para inicializar el algoritmo FCM?) se realizaron cuatro preguntas para la revisión sistemática siguiendo el enfoque de los elementos PICO (Tabla 3):

- **Pregunta 1:** ¿Cuáles son los artículos que se han publicado sobre mejoras para inicializar el algoritmo FCM?
- **Pregunta 2:** ¿Cuáles son métodos o enfoques utilizados para mejorar la inicialización de FCM?
- **Pregunta 3:** ¿Cuáles son las características de las mejoras del algoritmo FCM para su inicialización? Por ejemplo: dominio, elementos modificados, tipo de datos, métricas.
- **Pregunta 4:** ¿Cuáles son los artículos de las mejoras para inicializar FCM con mayor relevancia en investigación?

## 4.3. Palabras clave

Las palabras clave se seleccionaron con base en los elementos PICO (Tabla 3) con el objetivo de representar lo mejor posible los elementos que constituyen el estudio sobre las mejoras para inicializar el algoritmo FCM. El enfoque permitió garantizar que se abordaran todos los aspectos relevantes relacionados con la tesis (Tabla 5).

Tabla 5. Términos PICO y las palabras clave seleccionadas para la revisión sistemática.

Término	Palabras clave
P	Mejoras, Modificaciones, Enfoques
I	Centros iniciales, matriz inicial, factor de ponderación, número de clústeres, número de iteraciones y el umbral de paro
C	Métodos, dominio, datos, métricas,
O	Rendimiento, convergencia, tiempo de ejecución, precisión, Impacto

## 4.4. Criterios de inclusión y exclusión

Los criterios de inclusión y exclusión se ajustaron según las características de la investigación. Su objetivo fue garantizar la calidad y relevancia de los artículos incluidos en la revisión sistemática.

### 4.4.1. Criterios de inclusión

- Estudios que describen modificaciones de FCM para la inicialización del algoritmo.
- Estudios de mejoras para inicializar FCM comprendidos entre el año de 1981 al 2024.

### 4.4.2. Criterios de exclusión

- Artículos que no traten sobre una mejora del algoritmo FCM.
- Artículos que modifiquen únicamente la fase 2, fase 3 y fase 4 (cálculo de centroides, actualización de membresías y convergencia) del algoritmo FCM.
- Híbridos del algoritmo FCM con algún otro método.
- Artículos en un idioma diferente del inglés y español.

## 4.5. Cadenas de búsqueda

Los términos y operadores booleanos empleados para la búsqueda de artículos en las 8 fuentes de información se ajustaron según las necesidades de la revisión. Se buscaron artículos a partir de la cadena general y se limitó la búsqueda entre los años de 1981 al 20 de octubre del 2024:

- ("Fuzzy C-Means" OR FCM) AND ("Improvement" OR "Enhancement" OR "Modification") [Año de publicación: 1981-2024].

Tabla 6. Cadenas de búsqueda.

Repository	Código booleano	Resultados
PubMed	("Fuzzy C-Means" OR FCM) AND ("Improvement" OR "Enhancement" OR "Modification")	1093
IEEE Xplore	("All Metadata":Fuzzy C-Means) OR ("All Metadata":FCM) AND ("All Metadata":Enhancement) OR ("All Metadata":Improvement) AND ("All Metadata":Improved) AND ("All Metadata":Modification)	10,516
Google Scholar	["Fuzzy C-Means" OR "FCM algorithm"] AND ["Improvement" OR "Enhancement" OR "Modification" OR "Modified" OR "Approach"]	2061

Science Direct	Title, abstract, keywords: ("Fuzzy C-Means" OR FCM) AND (Novel OR Modification OR Modified OR Enhancement OR Approach OR Improved OR Improvement)	3037
Springer	"Fuzzy C-Means" OR FCM AND (Novel OR Approach OR Modified OR Enhanced OR Enhancement OR Modification OR Approached)	19,003
ACM Digital Library	[[All: "Fuzzy C-Means"] OR [All: FCM]] AND [[All: "Improvement"] OR [All: "Enhancement"] OR [All: "Modification"]]	833
MDPI	("Fuzzy C-Means" OR FCM) AND ("Improvement" OR "Enhancement" OR "Modification")	1,122
PLOS ONE	("Fuzzy C-Means" OR FCM) AND ("Improvement" OR "Enhancement" OR "Modification")	393

Los resultados obtenidos muestran un gran volumen de artículos recuperados. Por ejemplo, bases de datos especializadas como IEEE Xplore y Springer produjeron el mayor número de resultados iniciales, con un total de 12,619 y 19,075 publicaciones, respectivamente. En contraste, hubo fuentes de información como PLOS ONE y MDPI, que generaron resultados limitados, pero permitieron identificar artículos en dominios específicos. En total, la búsqueda abarcó más de 38,000 publicaciones.

## 4.6. Diagrama de flujo PRISMA

Como parte de la metodología de la revisión sistemática, se elaboró un diagrama de flujo PRISMA. Este diagrama muestra cómo se gestionaron los estudios identificados, permitiendo comprender cómo se llegaron a los 108 estudios finalmente incluidos en la revisión.

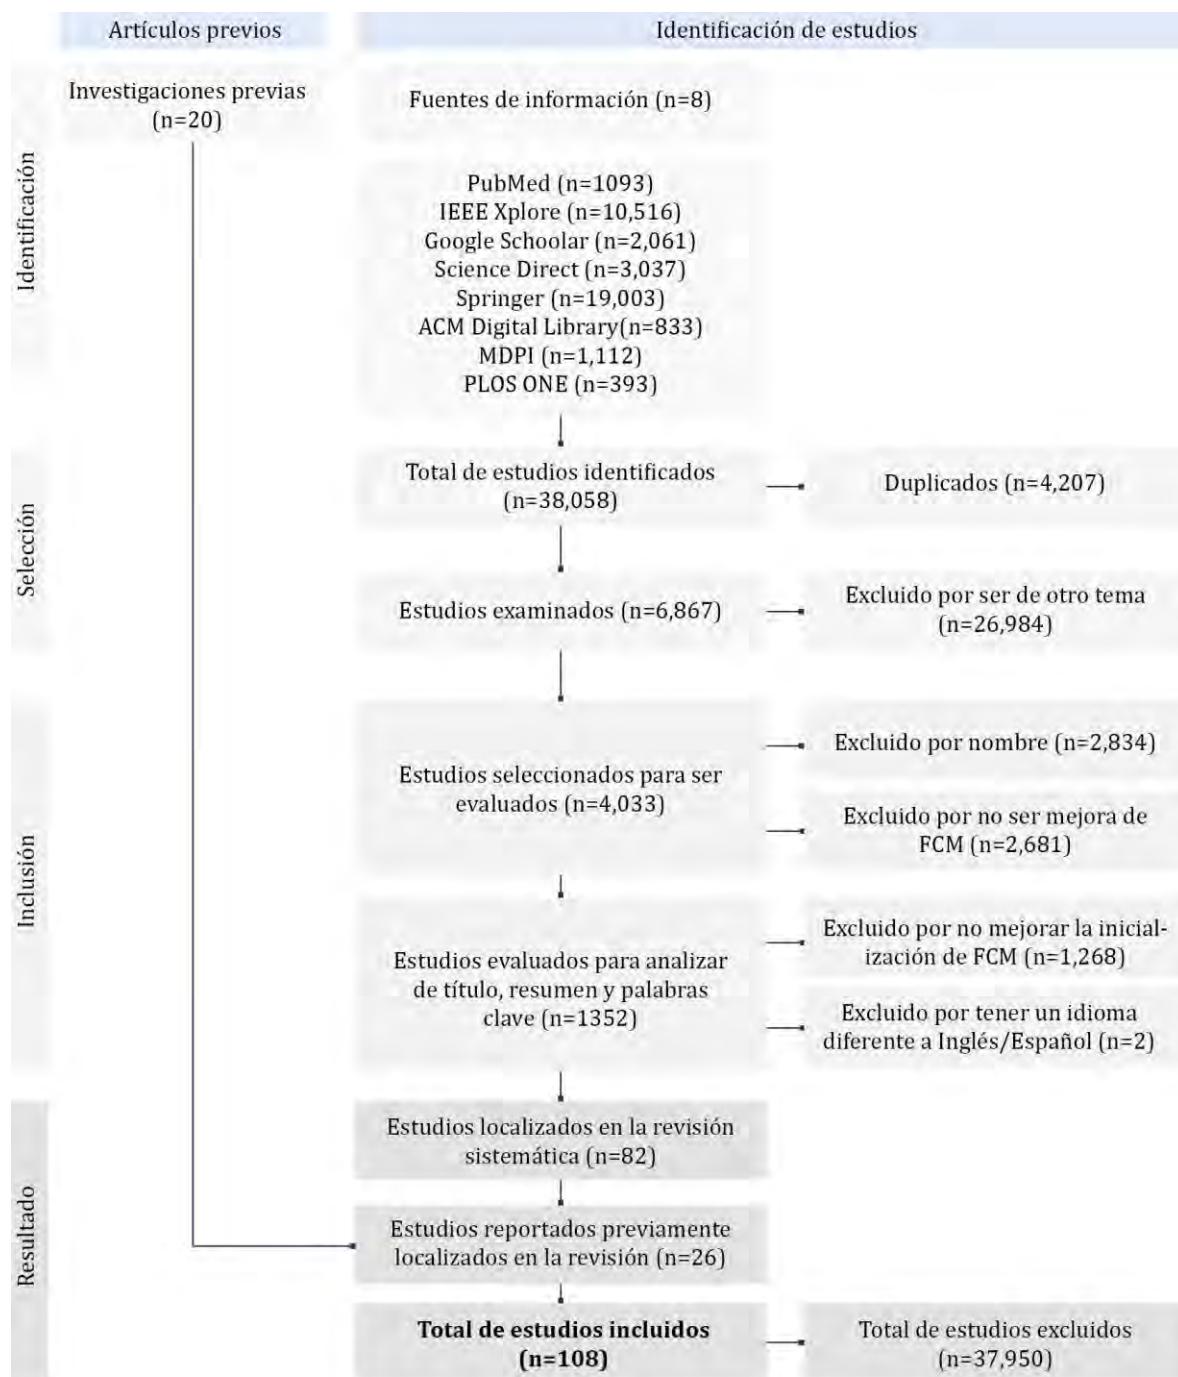


Figura 4. Diagrama PRISMA del filtrado de estudios.

## Capítulo 5

# Resultados de la revisión

En este capítulo se presentan las respuestas a las preguntas de investigación como resultado de la revisión sistemática.

## 5.1. Respuesta a la Pregunta 1 de la revisión sistemática

En primer lugar, para responder la Pregunta 1 de la revisión sistemática (¿Cuáles son los artículos que se han publicado sobre mejoras para inicializar el algoritmo FCM?), se desarrolló la descripción individual de los 108 artículos localizados. Y, para identificar su evolución histórica, se agruparon en cuatro ciclos temporales: 1983-2009, 2010-2014, 2015-2019 y 2020-2024.

### 5.1.1. Descripción de mejoras publicadas en los años 1983-2009

#### Año 1983

1. Fue desarrollado *Fuzzy C-Varieties* (FCV), una mejora que permite detectar grupos de diferentes formas aplicando el método *Ward* para obtener la matriz de pertenencias inicial (Gunderson, 1983b). Este proceso hace que se obtenga una partición inicial con la varianza minimizada y que FCV pueda converger con mayor rapidez.

#### Año 1994

2. Se desarrolló la mejora de FCM con la integración de *Mountain Method* (MM), un enfoque aplicado para la estimación aproximada de los centros de clústeres (Yager & Filev, 1994b). Se puede utilizar de dos maneras: a) como técnica independiente de agrupamiento y b) como herramienta complementaria de FCM para proporcionar los valores iniciales de los centros de los clústeres.
3. Se mejoró FCM integrando *Modified Mountain Method* (MMM) para su inicialización (Chiu, 1994b). A diferencia de MM desarrollado anteriormente, este método considera cada punto de datos como un posible centro de clúster, eliminando la necesidad de especificar una resolución de grilla haciendo que el método sea más eficiente computacionalmente.

#### Año 1998

4. Se implementó el algoritmo *Multistage Random Sampling FCM* (mrFCM) el cual utiliza un método de muestreo aleatorio para la inicialización de FCM (Cheng et al., 1998). Su principal aportación es que, mrFCM comienza con un pequeño subconjunto representativo de los datos. Luego, añadieron otro pequeño subconjunto de datos no procesados y se recalculan los centros de los clústeres hasta converger.

#### Año 2001

5. *K-Nearest Neighbors - One Iteration FCM* (KNN-1FCM) fue implementado para encontrar una mejor aproximación inicial de los centros de clústeres (Zahid et al., 2001). El algoritmo utiliza las reglas del método de *K-Nearest Neighbors* para encontrar una buena aproximación inicial de los centros de los clústeres.
6. Fue desarrollado *Partition simplification FCM* (psFCM) para refinar la selección de los centros de los clústeres iniciales (M.-C. Hung & Yang, 2001b)). La mejora divide el conjunto de datos original en bloques unitarios y se reemplazan los patrones por su centroide para tomarlos como conjunto de datos simplificado.

## Año 2004

7. Se desarrolló un esquema novedoso de selección de los centros de clústeres iniciales de FCM basándose en colores más vivos en una imagen por los autores (D.-W. Kim et al., 2004b). Esta mejora utiliza el espacio de color CIELAB para representar los colores principales en escenas naturales. Estos colores de referencia se utilizan para comparar y medir similitudes con los puntos de color.

## Año 2006

8. Fue desarrollado *Global Fuzzy C-Means* (GFCM) para la selección de los centros de clústeres de FCM y mejorar su inicialización por (W. Wang et al., 2006b). En lugar de seleccionar todos los centros de manera aleatoria, el método comienza con un solo clúster y añade nuevos centros de manera óptima en cada iteración. El primer centroide se calcula como el centroide de todo el conjunto de datos. Y, una vez que se ha determinado, el algoritmo añade nuevos clústeres de manera incremental.

## Año 2007

9. Se combinó un algoritmo genético para dar lugar al algoritmo denominado *Genetic Fuzzy Clustering Algorithm* (GFCA) para mejorar la precisión y la velocidad de la segmentación de tejidos cerebrales por (Nie et al., 2007). El método se utiliza para determinar los centros de los clústeres iniciales y luego realizar la segmentación con FCM en una sola iteración.

10. Se implementó *Kernelized Fuzzy C-Means* (KFCM) para la inicialización de FCM por (Kawa & Pietka, 2007). El método agrega una matriz de Kernel para transformar los datos y realizar el agrupamiento en un espacio con una mejor detección de clústeres y una mayor robustez frente al ruido en las imágenes.

## Año 2008

11. Se desarrolló *Conditionally Posittive Definite kernel* (CPD Kernel) para mejorar la inicialización FCM por (W. Li & Yang, 2008). El método reemplaza la métrica de distancia por una métrica basada en un núcleo CPD, por sus siglas en inglés.

## Año 2009

12. *Single-Point Mutation Evolutionary Programming* (SPMEP) se desarrolló para optimizar la búsqueda adecuada de clústeres y reducir la dependencia de la elección inicial de los centros de clústeres (H. Dong et al., 2009). La mejora aplica un método de programación evolutiva.

13. *Single Point Iterative Weighted Fuzzy C-Means* (SWFCM) fue desarrollado (J. Fan et al., 2009). El método utiliza un ajuste iterativo de un solo punto para encontrar los centros iniciales más adecuados, lo que mejora la velocidad de convergencia y la precisión del algoritmo.

### 5.1.2. Descripción de mejoras publicadas en los años 2010-2014

#### Año 2010

14. Se desarrolló *Fast and robust image segmentation using FCM with spatial information* (FRIS-FCM) para una mejor inicialización de FCM (X. Y. Wang & Bu, 2010). El método incorpora información espacial local y la alta correlación entre píxeles adyacentes, lo que permite una inicialización más precisa y robusta.
15. Se implementó un método *Ant Colony Fuzzy C-Means Hybrid Algorithm* (AFHA) para la inicialización de FCM (Z. Yu et al., 2010). El proceso incluye el método de *Ant Colony Optimization* (ACO) para seleccionar los centros iniciales de los clústeres de manera eficiente y adaptativa en comparación con la inicialización aleatoria tradicional de FCM.
16. Se mejoró la inicialización de FCM con el método *Mountain C-Regression Clustering Method* (MCR) (K.-L. Wu et al., 2010). Este enfoque identifica los valores más altos en las densidades como centros de clústeres iniciales para reducir la dependencia de los valores iniciales y mejorar la robustez del algoritmo frente al ruido y los valores atípicos.
17. Se implementó *Diffusion-based Fuzzy Clustering Algorithm* (DifFUZZY) para la selección de los centros iniciales y el número de clústeres (Cominetti et al., 2010b). La propuesta de los autores introduce un método basado en la identificación de los "núcleos" utilizando un gráfico de vecindad y procesos de difusión.
18. Se propuso *Improved Fuzzy C-Means Clustering Algorithm* (IFCM) (J. Deng et al., 2010b). El método utiliza conjuntos de puntos de muestra de alta potencia denominados para la selección de los centros para inicializar FCM.

#### Año 2011

19. Se desarrolló *Possibilistic C-Means with Mahalanobis Distance and Particle Swarm Optimization* (PCM-MD-PSO) por los autores (Y. Zhang et al., 2011)
20. Se desarrolló *Modified Robust Fuzzy C-Means with weight Bias Estimation* (MRFCM-wBE) para la selección de los centros iniciales de FCM (Ramathilagam et al., 2011). El método aplica la distancia máxima de los puntos.

#### Año 2012

21. Se desarrolló *Fuzzy C-Means with Teaching Learning Based Optimization* (FCM/TLBO) para la selección de los centros de FCM para su inicialización (Naik et al., 2012). El método combina un algoritmo basado en el comportamiento humano, inspirado en el proceso de aprendizaje colectivo para la selección de los centros iniciales de FCM.
22. Se mejoró *Kernelized Fuzzy C-Means* con la implementación de *Hybrid Ant Colony Optimization* (KFCM-HACO) (Doğan & Korürek, 2012). El método intenta superar las limitaciones que tiene el algoritmo *Kernelized Fuzzy C-Means*, optimizando la selección de los centros y parámetros del *Kernel* para inicializar FCM con el método de *Hybrid Ant Colony Optimization* (HACO).

23. *Dynamic Fuzzy -Means Clustering* (DFCM) fue desarrollado para la selección de los centros de FCM para su inicialización (Z. Wang et al., 2012). El método fue utilizado para la detección de la temporada de lluvias con datos de series temporales de alta dimensión.

24. Se desarrollaron dos mejoras de FCM denominadas *Robust Fuzzy C-Means based on Kernel Function* (RFCMK) y *Tsallis Entropy based Fuzzy C-Means* (TEFCM) para la selección de los centros de FCM para su inicialización (Kannan et al., 2012b). Los métodos fueron utilizados para mejorar la segmentación de imágenes médicas de Resonancia magnética de mama y cerebro.

25. *Semi-Supervised Fuzzy Clustering Algorithm* (SSFCA) fue desarrollado para la selección del número de clústeres (Maraziotis, 2012). La mejora incorpora información supervisada en forma de restricciones de pares (*Must-link* y *Don't Link*).

## Año 2013

26. Se desarrolló *Region Splitting and Merging- Fuzzy C-Means Hybrid Algorithm* (RFHA) para la selección de los centros de FCM para su inicialización (Tan, Isa, et al., 2013). La mejora aplica un enfoque jerárquico mediante el método de *Region Splitting and Merging* (RSM). Este método utiliza un análisis jerárquico del histograma de cada canal de color para identificar picos que representan regiones homogéneas.

27. *Stem Cells and Fuzzy C-Means algorithm* (SC-FCM) fue desarrollado para mejorar la selección de los centros de clústeres de FCM para su inicialización (Taherdangkoo & Bagheri, 2013). El método se basa en un algoritmo denominado *Stem Cells Algorithm* (SCA).

28. Fue desarrollada la mejora denominada *Adaptative Fuzzy C-Means* (AFCM) para la selección de los centros de clústeres y el número de clústeres (Han et al., 2013). El método se diseñó para generar reglas en sistemas neuro-difusos. El objetivo de AFCM fue determinar el número de reglas para su modelo con un método de un solo clúster. Así, el proceso se repite hasta que la fuerza de disparo mínima de todas las reglas satisfaga el umbral preespecificado.

29. *Fuzzy C-Means with Hierarchical Approach* (FCM-HA) fue desarrollado para mejorar la segmentación de imágenes en color (Tan, Lim, et al., 2013b). Este esquema tuvo como objetivo determinar automáticamente el número de clústeres y sus centros iniciales del algoritmo FCM. El esquema se diseñó con dos módulos principales: el módulo de división y el módulo de fusión

30. Fue desarrollado *Improved Spatial Fuzzy C-Means* (IFCMS) para la inicialización de FCM (Benaichouche et al., 2013). El esquema utiliza el método de *Particle Swarm Optimization* (PSO) para mejorar la selección de los centros iniciales.

31. Se mejoró la forma en cómo se determinan los centros de los clústeres de FCM (HongLei et al., 2013). El esquema propuesto selecciona centros de manera aleatoria utilizando la transformación de componentes principales y la estimación de densidad del *Kernel* en la primera componente principal. Este enfoque permite identificar el número de clases y los centros iniciales basándose en los picos de la función de densidad de probabilidad.

## Año 2014

32. Se desarrolló *Ant Colony Optimized Fuzzy C-Means* (ACO-FCM) para la selección del número de clústeres y centros de FCM (J. Yan, 2014b). El esquema emplea el algoritmo de *Ant Colony Optimization* (ACO) para mejorar la inicialización del agrupamiento.

33. *Random Sampling Iterative Optimization Fuzzy C-Means* (RSIO-FCM) fue desarrollado para mejorar FCM (Bharill & Tiwari, 2014b). El proceso comienza dividiendo el conjunto de datos en subconjuntos. Los centros de los clústeres obtenidos de un subconjunto se utilizaron como puntos de partida para agrupar los siguientes subconjuntos. Con este enfoque de muestreo uniforme se asegura que los centros de los clústeres reflejaran mejor la distribución real de los datos, minimizando la función objetivo de manera más efectiva y mejorando la precisión de clasificación.

34. Se desarrolló el algoritmo *Improved Firefly Based Fuzzy C-Means Clustering* (Improved FAFCM) para la selección de los centros de clústeres de FCM (Nayak et al., 2014b). El esquema utiliza el algoritmo *Firefly Algorithm* (FA) para optimizar los centros de los clústeres iniciales de FCM. En el método, cada luciérnaga representa un conjunto y se mueve en el espacio de búsqueda basado en la intensidad de luz. Después, utilizaron los centros de clústeres obtenidos como puntos de partida para el algoritmo FCM.

35. *Genetic Fuzzy C-Means* (GFCM) fue desarrollado para la selección de los centros de clústeres de FCM (Niware & Chaturvedi, 2014). La mejora integra el algoritmo *Genetic Algorithm* (GA) para seleccionar los centros iniciales de los clústeres.

### 5.1.3. Descripción de mejoras publicadas en los años 2015-2019

## Año 2015

36. Se desarrolló un algoritmo mejorado denominado *Small targets based on improved Data Field and FCM* (SDF-FCM) para la selección de los centros de clústeres de FCM (J. Zhao & Jia, 2015). El método incluye una función de potencial que refleja las interacciones entre los píxeles de la imagen. Y, los "puntos de máximo potencial" se utilizan como los centros iniciales de agrupamiento en el algoritmo FCM.

37. Se implementó el algoritmo *Improved Kernel Possibilistic C-Means* (IKPCM) para la selección de los centros de clústeres de FCM (Mekhmoukh & Mokrani, 2015). El esquema utiliza el algoritmo *Particle Swarm Optimization* (PSO) para seleccionar de manera óptima los centros de los clústeres. PSO optimiza esta selección mediante un proceso iterativo en el que una población de partículas (posibles soluciones) se mueve en el espacio de búsqueda influenciada por su mejor posición conocida y la mejor posición conocida del enjambre.

38. *Fuzzy C-Means++* fue desarrollado para mejorar la inicialización de FCM (Stetco et al., 2015b). El método introduce una modificación en el mecanismo de la selección de los centros de los clústeres de FCM mediante la integración del método de inicialización *K-means++*.

39. Se implementó el algoritmo *Optimal Supervised Fuzzy C-Means* (OSFCM) para mejorar FCM (F. Li et al., 2015). La modificación cambia la forma de seleccionar los centros iniciales de FCM utilizando información de las muestras de entrenamiento. El método sigue un enfoque basado en probabilidades para inicializar la matriz de partición, lo que posteriormente permite determinar los centros de los clústeres de manera óptima.

40. Se desarrolló un método basado en la función de densidad de montaña denominado *Mountain Density Function based Fuzzy C-Means* (MDF-FCM) para mejorar la selección de los centros de clústeres de FCM (Ansari et al., 2015). El esquema incorpora un método denominado *Mountain Density Function* (MDF). Este método calcula valores de densidad para cada sesión de usuario y selecciona la sesión con el valor de densidad más alto como el primer centro de cluster.

41. Se implementó el algoritmo *Factorized Fuzzy C-Means* (F-FCM) para mejorar la forma en cómo se selecciona el valor del exponente de ponderación de FCM (Suleman, 2015). La propuesta elimina el parámetro del exponente de ponderación y utiliza una factorización de matriz no negativa convexa para determinar los centros de los clústeres.

42. Se implementó el algoritmo *Semi-Supervised Fuzzy C-Means* (SFCM) gracias a los autores (Y. Mei et al., 2015). El esquema se desarrolló para la selección de los centros iniciales con base en funciones de ponderación.

43. Fue desarrollado *Genetic Algorithm Kernel-Based Fuzzy C-Means* (GAKFCM) para mejorar la selección de los centros de clústeres y los parámetros del *Kernel* (Ding & Fu, 2016). El método combina un algoritmo genético mejorado con el algoritmo *Kernel-Based Fuzzy C-Means* (KFCM) para optimizar la selección de los centros iniciales y parámetros del *Kernel*.

## Año 2016

44. *Weighted Hue and Intensity Fuzzy C-Means* (WH-IFCM) fue desarrollado para mejorar la selección de los centros de FCM (Rajaby et al., 2016). En lugar de seleccionar aleatoriamente los centros iniciales, el esquema construye una tabla de frecuencias de intensidad para identificar los picos dominantes. Estos picos los utilizan para inicializar los centros de los clústeres.

45.(D. Wang et al., 2016) propusieron un método integrado de evaluación dinámica para el rendimiento de recuperación por agotamiento en reservorios carbonatados naturalmente fracturados y rugosos (NFVCRs) utilizando un algoritmo llamado *Self Adaptive Particle Swarm optimization* (DPSO) combinado con FCM.

46. *Chaotic Quantum Particle Swarm Optimization Fuzzy C-Means* (CQPSO) fue desarrollado para mejorar la inicialización de FCM (L. Liu et al., 2016). El esquema combina el algoritmo *Chaotic Quantum Particle Swarm Optimization* (CQPSO) para identificar los centros de clústeres de FCM. El método fue aplicado para la identificación de fluidos en reservorios carbonatados, específicamente en la Cuenca de Tarim, China.

47. Se desarrolló *Improved Feature-Weighted Fuzzy C-Means* (IFW-FCM) para mejorar FCM (Jahanbakhsh Pourjabari & Seyedzadegan, 2016b). La mejora modifica la inicialización del algoritmo FCM utilizando el método de *Term Variance* para inicializar el vector de pesos de las características. El método calcula la varianza de cada característica en el conjunto de datos y asigna mayores pesos a aquellas características con mayor varianza.

48. Se desarrolló una mejora de FCM basada en supervisión parcial por (Duan et al., 2016b). La mejora reduce la sensibilidad a los valores iniciales. Primero, se realiza una iteración de FCM para obtener una partición preliminar. Luego, se identifican los clústeres cercanos analizando las diferencias en las membresías de los patrones. Los clústeres inapropiados se clasifican en tres tipos: absorbidos por múltiples clústeres, absorbidos por un solo clúster, y separados en varios clústeres.

49. El algoritmo *Elicit Teaching Learning Based Optimization with Fuzzy C-Means* (ETLBO-FCM) fue desarrollado para mejorar FCM (Nayak et al., 2016). El método combina la optimización basada en el aprendizaje y enseñanza (ETLBO). Primero, se inicializan la población de los centros de clústeres de manera aleatoria. Luego, calculan la media de los clústeres y se evalúa la aptitud de cada centro de clúster. A partir de estos valores, se selecciona el mejor centro de clúster como el "mejor maestro".

### Año 2017

50. Se implementó el algoritmo *Improved Self-Adaptive Cellular Genetic Algorithm for Fuzzy C-Means* (IDCGA-FCM) para la selección de los centros de clústeres de FCM (Jie et al., 2017). La mejora incorpora el mapa de Arnold para asegurar que los cromosomas iniciales aprovechen al máximo la información inherente del conjunto de datos.

51. Se desarrolló *Hybrid Chemical Reaction based Metaheuristic with Fuzzy C-Means* (CRO-FCM) para mejorar la inicialización de FCM (Nayak et al., 2017). El enfoque el método *Chemical Reaction Optimization* (CRO) con el algoritmo *Fuzzy C-Means* (FCM) para mejorar la selección de los centros de los clústeres y optimizar el proceso del agrupamiento. Comienzan inicializando una población de posibles centros de clústeres de manera aleatoria. Luego, iteran a través del proceso de CRO que incluye cuatro tipos de reacciones químicas. Y, las mejores soluciones se seleccionan para reemplazar las anteriores en la población.

52. Se implementó un nuevo enfoque denominado *Mahalanobis Distance based Improved Fuzzy C-Means* (FCM-M) para determinar los centros iniciales de FCM por (Haldar et al., 2017). El método utiliza datos de entrenamiento con el uso de la métrica de distancia de Mahalanobis.

53. Se desarrolló *Fuzzy C-Means Clustering with Mahalanobis and Minkowski Distance Metrics* (M&MFCM) para la selección del número de clústeres de FCM por (Gueorguieva et al., 2017). El método valida el resultado de cada métrica de distancia para obtener el óptimo.

54. El algoritmo *Deterministic Annealing Gustafson-Kessel fuzzy clustering algorithm* (DA-GK) fue desarrollado para mejorar la inicialización de FCM por (Chaomurilige et al., 2017). El método incorpora un método determinista para la el valor del exponente de ponderación.

### Año 2018

55. Se desarrolló *Chaotic Firefly Algorithm-Based Fuzzy C-Means* (C-FAFCM). Para la selección de los centros de clústeres de FCM por (Ghosh et al., 2018). El método incorpora el algoritmo *Chaotic Firefly* (CF) y fue aplicado para la segmentación de imágenes de resonancia magnética.

56. Se desarrollaron tres métodos diferentes para inicializar el algoritmo KIFCM: a) *Particle Swarm Optimization Kernel Intuitionistic Fuzzy C-Means*, b) *Genetic Algorithm Kernel Intuitionistic Fuzzy C-Means* y c) *Colonia de Abejas Artificial Kernel Intuitionistic Fuzzy C-Means* por (Kuo et al., 2018).

57. Se desarrolló una mejora para FCM gracias a los autores (H. Liu et al., 2018), La mejora integra un nuevo método para la inicialización del algoritmo FCM denominado *Multi-scale Just Noticeable Difference (JND) color histogram*. Este método se utiliza para proporcionar los centros de los clústeres iniciales de manera más efectiva.

58. Se desarrolló el algoritmo denominado *Mixing Matrix Estimation Based on Data Field and Improved Fuzzy C-Means Clustering* (MME-DF-IFCM) gracias a los autores (Q. Guo et al., 2018). El esquema aplica la teoría del campo de datos para estimar el número de centros del agrupamiento de antemano. Después, utilizaron *Particle Swarm Optimization* (PSO) para optimizar el proceso iterativo del agrupamiento de FCM.

## Año 2019

59. Se desarrolló el algoritmo *Fuzzy C-Means Global and Local Region-based Active Contour* (FCM-GLREAC) gracias a los autores (Soomro et al., 2019). El enfoque utiliza FCM para realizar una segmentación inicial que luego se utiliza para iniciar el método de contorno activo.

60. Se desarrolló la mejora llamada *Entropy-Based Weighted Semi-Supervised Fuzzy C-Means* (EWSS-FCM) por (C. L. Liu et al., 2019). El esquema desarrollado consiste en un mecanismo para calcular la entropía de cada objeto de datos, que mide la incertidumbre de su pertenencia a los clústeres.

61. Se mejoró FCM con métodos basados en ponderaciones gracias a los autores (Hashemzadeh et al., 2019). La mejora incorpora el algoritmo *Fuzzy C-Means* basado en *feature-weight* y *cluster-weight learning* (FWCW-FCM).

62. *Improved FCM Initialization Method* (IFIM) fue desarrollado por (B. Yan et al., 2019). El esquema modifica la inicialización del algoritmo FCM al introducir un método para eliminar las falsas alarmas. Utilizan una técnica de análisis del núcleo gaussiano.

63. Fue desarrollado el algoritmo *Community detection algorithm based on improved label propagation and Fuzzy C-Means* (LPA-FCM) por los autores (Z. H. Deng et al., 2019). El esquema se diseñó para mejorar el algoritmo FCM, integrando el uso del método de propagación de etiquetas (LPA) para mejorar la detección de comunidades en redes complejas. Primero, se asignan etiquetas iniciales de los vértices y sus vecinos. Después, los vértices con mayor diversidad se seleccionan y se ajustan sus etiquetas.

64. Se implementó el algoritmo *State Transition Algorithm-Based Fuzzy C-Means* (STAFCM) por los autores (X. Wang et al., 2019) para mejorar la precisión del agrupamiento de FCM, implementaron el algoritmo de Transición de Estado para mejorar la selección de los centros iniciales. Primero, STA realiza una búsqueda de los centros de los clústeres. Después, estos centros iniciales optimizados se pasan luego al FCM, que los utiliza como puntos de partida para su proceso iterativo.

65. *Improved Fuzzy Clustering* (IFC) fue desarrollado por (Qiao et al., 2019). La mejora utiliza el algoritmo K-Means y Comentropy para definir el número de clústeres y centros iniciales.

66. Se implementó el algoritmo FCM-GABPN por los autores (Lv et al., 2019). El esquema combina el método de *Genetic Algorithm* (GA) para mejorar la inicialización del algoritmo FCM.

67. El algoritmo *Adaptive Fuzzy C-Means Segmentation Image Algorithm based on Global Spatial Information* (AFCM\_GSI) fue desarrollado por los autores (M. Li et al., 2019). La mejora propone el uso del algoritmo de Optimización de Lobos Grises con Vuelo de Lévy (LGWO) para determinar los centros iniciales del agrupamiento de FCM.

68. Fue implementado el algoritmo *Robust Heterogeneous C-Means* (RHCM) por (Gharib et al., 2019). La mejora desarrollada se basa en la modificación del algoritmo FCM para su inicialización. La implementación utiliza la medida *Correntropy* como métrica de distancia. Además, RHCM utiliza el método de clustering directo (DC) para la inicialización de los centros iniciales.

69. *Greedy Snake Model and Fuzzy C-Means Optimization* fue desarrollado por (Sheela & Suganthi, 2019). La mejora modifica la inicialización de FCM. La matriz de membresías la obtienen utilizando el método *Greedy Snake* y los resultados se eligen como valores de entrada para FCM. Los centros iniciales de los clústeres se eligen calculando el centro de masa de las regiones segmentadas por el método *Greedy Snake*, lo que permite una mejor convergencia y precisión en la segmentación final.

#### 5.1.4. Descripción de mejoras publicadas en los años 2020-2024

##### Año 2020

70. Se implementó el algoritmo *Unsupervised Deep Fuzzy C-Means Clustering Network* (UDFCMN) por los autores (Z. Zhao et al., 2020). El esquema desarrollado modifica la inicialización del algoritmo FCM. El método que incluyen se llama *Winner-Take-All Deep Belief Network* (WTADBN). Este método se utiliza para pre entrenar un modelo para extraer características jerárquicas ocultas de cada imagen de entrenamiento, que luego se utilizan para generar las etiquetas iniciales de los clústeres mediante el algoritmo FCM.

71. *Partition Energy-Entropy Fuzzy C-Means* (PEHFCM) fue desarrollado por (Martino et al., 2020). La mejora presenta una variación del algoritmo FCM que incorpora un nuevo índice de validez basado en las medidas de energía y entropía difusas para mejorar la inicialización de los centros de los clústeres y determinar el número óptimo de clústeres. Este índice, denominado *Partition Energy-Entropy* (PEH), se calcula como la diferencia entre la energía difusa y la entropía difusa de los clústeres. La energía difusa mide la cantidad de información contenida en un cluster, mientras que la entropía difusa mide la difusidad o la calidad de la información.

72. *Fuzzy C-Means with InoFreq* (FCM-InoFreq) fue desarrollado por (Cebeci & Cebeci, 2020). La mejora incorpora el algoritmo *Initialization on Frequency Polygons* (InoFreq) para la selección de los centroides iniciales de FCM. El método utiliza los picos en los polígonos de frecuencia de la característica con el mayor número de picos en un conjunto de datos para determinar los centroides iniciales. La implementación del algoritmo se realizó en R y se comparó con otros métodos de inicialización comunes como K-means++.

73. *Entropy Weighted FCM* (EwFCM) fue implementado por (Qaiyum et al., 2020). La mejora utiliza el algoritmo *Ant Colony Optimization* (ACO) para mejorar la inicialización de FCM. Para ellos, cada punto de datos se considera como una hormiga, y su distribución en los clústeres se decide mediante una matriz de feromonas normalizada y perturbada con ruido gaussiano.

74. Se desarrolló el algoritmo *Entropy Weighted FCM* (EwFCM) gracias (Cardone et al., 2020). La mejora utiliza una función de entropía para calcular la media de cada objeto y asignan un peso inversamente proporcional a su difusidad. Utilizando estos pesos, aplicaron un algoritmo FCM ponderado para determinar los centros iniciales de los clústeres.

75. *Regional Hidden Markov Random Field - Fuzzy C-Means* (RHMRF-FCM) fue desarrollado por (W. Lin & Li, 2020). El esquema utiliza el método *Regional Hidden Markov Random Field*

(RHMRF) mejorar la inicialización del algoritmo FCM al dividir la imagen en regiones homogéneas utilizando la regla de heterogeneidad mínima (MHR) en paralelo y un modelo HMRF que considera tanto la informaciónpectral de cada región como la relación espacial entre regiones vecinas.

76. Se desarrolló *Artificial Bee Colony + Fuzzy C Means with Manhattan distance clustering* (ABC+FCMM) gracias a los autores (Mousavi et al., 2020). El esquema realiza una combinación del algoritmo *Artifitial Bee Colony* (ABC) y FCM. Su objetivo fue determinar los centros iniciales de una manera más precisa. Además, utilizaron la distancia de Manhattan para mejorar sus resultados.

## Año 2021

77. Fue implementado *Color Image Quick Fuzzy C-Means Clustering Algorithm* (CIQFCM) por (Z. Liu et al., 2021) para la selección de los centros iniciales.

78. Se desarrolló el algoritmo *Improved Fuzzy C-Means Clustering Algorithm* (Improved FCM) por los autores (M. Yang et al., 2021). La mejora utiliza el método de *Principle of minimum distance* para mejorar la inicialización de FCM seleccionando centros de clúster iniciales relativamente aproximados. Este proceso se llevó a cabo calculando la distancia entre muestras y generando una matriz de distancia.

79. Se implementó el algoritmo *Cooperative System Fuzzy C-Means* (CSFCM) por los autores (Abdellahoum et al., 2021). La mejora utiliza un enfoque cooperativo que utiliza tres métodos diferentes: *Genetic Algorithm* (GA), *Biogeography-Based Optimization* (BBO) y *Firefly Algorithm* (FA) para determinar automáticamente los parámetros iniciales.

80. *Cluster-Weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm* (CGFFCM) fue implementado por (Golzari Oskouei et al., 2021). El método propone una técnica de ponderación de clústeres (*Cluster weighting*) para reducir la sensibilidad de FCM a la selección de los centros iniciales.

81. Se implementó *Modified Local-Information Weighted Intuitionistic Fuzzy C-means Clustering and Gold-Panning Algorithm* (GPA-LWIFCM) por los autores (Wei et al., 2021). El esquema emplea el método *Gold-Panning Algorithm* (GPA) para mejorar la inicialización del algoritmo FCM mediante la optimización de los centros de clústeres iniciales y los parámetros clave del algoritmo. El GPA imita los comportamientos sociales de los buscadores de oro, donde cada individuo toma decisiones basadas en su riqueza y la distancia a otros individuos.

82. Se desarrolló el algoritmo *Improved Fuzzy C-means Clustering Algorithm based on t-SNE* (Yi et al., 2021) para mejorar la selección de los centros de clústeres de FCM.

83. Se desarrolló *Histogram based Fuzzy C-Means* (HBFCM) *improced with Randomly Attracted Rough Firefly Algorithm* por los autores (Dhal et al., 2021). El enfoque utiliza el algoritmo *Randomly Attracted Rough Firefly Algorithm* (RARFA) para mejorar la selección de los centros de clústeres iniciales de FCM.

84. *Kernel Time-Weighted Fuzzy C-Means* (KTFCM) fue implementado por los autores (S. Dong et al., 2021). La mejora incorpora el algoritmo *Kernel time-weighted Fuzzy C-Means* (KTFCM) para introducir una medida de disimilitud ponderada por tiempo.

85. Se implementó el algoritmo *Local Information Bi-directional Fuzzy C-Means* (LI\_BIFCM) por los autores (Ren & Sun, 2021).

86. Se implementó el *algoritmo Improved differential privacy Fuzzy C-Means clustering* (IDPFCM) por (Y. Zhang & Han, 2021). En lugar de inicializar aleatoriamente los centros de los clústeres, este método identifica dos puntos en el conjunto de datos que tienen la mayor distancia entre sí y los utiliza como los primeros centros de clúster. Luego, se seleccionan sucesivamente nuevos centros de clúster que maximicen la distancia mínima a los centros ya seleccionados.

## Año 2022

87. Se propuso una nueva variante del algoritmo FCM llamada HOFCM, que optimiza la matriz de membresía inicial para mejorar la convergencia del algoritmo desarrollada por los autores (Pérez-Ortega et al., 2022). La mejora se basa en una función de transformación "S" que genera los centroides iniciales, mediante una variante del algoritmo K-Means (O-K-Means) para generar una matriz de membresía inicial.

88. Se desarrolló *Fuzzy C-Means Clustering with Modified Cuckoo* (FCMCS) por (Chakraborty, 2024). El método combina el algoritmo de agrupamiento FCM con una versión modificada del algoritmo de búsqueda de Cuco (*Cuckoo Search*, CS) para mejorar la inicialización y la eficiencia del proceso de agrupamiento en la segmentación de imágenes biomédicas.

89. *Self-Organizing Maps - Fuzzy C-Means* (SOM-FCM) fue desarrollado por (Zhou & Zhao, 2022). La mejora utiliza *Self-Organizing Maps* (SOM) para realizar un paso de pre agrupamiento del sistema y mejorar la selección de los centros iniciales de FCM.

90. Se desarrolló *Adaptive Fuzzy C-Means* (A-FCM) por los autores (Anita Davamani et al., 2022). La mejora incorpora un modelo que utiliza el algoritmo *Best search-based Moth-Flame Optimization* (BS-MFO) para optimizar el número de iteraciones, el grado de difusidad y el umbral de convergencia del algoritmo FCM.

91. *Improved FCM algorithm* fue implementado por los autores (Y. Zhang et al., 2022). El enfoque integra el método de *Particle Swarm Optimization* (PSO) para obtener los centros iniciales óptimos del algoritmo FCM. PSO busca soluciones globales óptimas al tratar cada conjunto de centros del agrupamiento como una partícula en un espacio de búsqueda. Las partículas actualizan sus posiciones y velocidades basándose en su mejor posición histórica y la mejor posición global encontrada por el enjambre.

92. *Improved Possibilistic Fuzzy C-Means* (IPFCM) fue desarrollado por los autores (Saberi et al., 2022). La mejora calcula los centros de los clústeres del algoritmo FCM utilizando un método posibilista, que es menos sensible al ruido y a valores atípicos. Así, los valores se ajustan iterativamente hacia las regiones de alta densidad, maximizando el índice de validez.

93. Se desarrolló el algoritmo *Eagle Strategy with Stochastic Fractal Search based Fuzzy Clustering* (ES-SFSFC) por los autores (Das et al., 2022). El método integra *Eagle Strategy based on Stochastic Fractal Search* (SFS) una combinación de *Eagle Strategy* con *Stochastic Fractal Search* (SFS) para mejorar la inicialización de FCM.

94. Se desarrolló *Fuzzy Clustering Algorithm Based on Improved Global Best-Guided Artificial Bee Colony with New Search Probability* (PIABC-FCM) por los autores (Alomoush et al., 2022). El método incorpora *Artifitcial Bee Colony* (ABC) para la inicialización de FCM para mejorar sus resultados mediante la determinación de centros óptimos. Los autores utilizan las capacidades del algoritmo ABC para encontrar las mejores posiciones de los centroides de los clústeres, lo que ayuda a reducir la sensibilidad al ruido de FCM.

95. Se implementó el algoritmo *Cooperative Differential Evolution for Fuzzy C-Means* (CDE-FCM) por los autores (Banerjee & Abu-Mahfouz, 2022) en donde integraron *Cooperative Multi-Population Differential Evolution with Elitism* para la selección de los centros de clústeres y el número d clústeres.

96. Se implementó el modelo denominado *Kernel-based Picture Fuzzy C-Means clustering with Grey Wolf Optimizer* (KPFCM-GWO) por los autores (C.-M. Yang et al., 2022). El esquema implementa el algoritmo *Grey Wolf Optimizer* (GWO) para determinar los valores óptimos de los parámetros de FCM.

97. *Twice Grid Optimization and Sparrow Search Algorithm optimized Fuzzy C-Means* (TGO-SSA-FCM) fue implementado por los autores (P. Li et al., 2022). La mejora aplica el método *Twice Grid Optimization* (TGO) para mejorar los resultados de FCM. TGC se basa en la idea de que los centros deben tener una densidad alta y estar separados por distancias relativamente largas. Inicialmente, los datos se dividen en cuadrículas y luego se filtran según un umbral de densidad y dimensión.

98. El algoritmo *Fuzzy C-Means Grey Wolf Optimization* (FCMGWO) fue implementado por (Mohammidian-khoshnoud et al., 2022). La mejora utiliza el método *Grey Wolf Optimizer* (GWO) para optimizar los centros iniciales de FCM.

## Año 2023

99. *Density-Based Fuzzy C-Means* (DFCM) fue desarrollado por (Varshney et al., 2023). El esquema aplica el método *Density-based initialization technique* (DIF) para mejorar los resultados del agrupamiento de FCM. La técnica selecciona los centroides iniciales de los clústeres basándose en la densidad de los puntos de datos, en lugar de hacerlo de manera aleatoria. Al identificar los puntos de datos con alta densidad como centroides iniciales, se logra una mejor formación de los clústeres y una convergencia más rápida del algoritmo.

100. Se desarrolló el algoritmo *Modified FCM* por (C. Zhang et al., 2023). La mejora utiliza el método *Statistical Histogram Method* (SHM) para analizar la distribución de las coordenadas de la nube de puntos tridimensional, determinando así el número de clústeres y los centros iniciales de los clústeres.

101. *Density Peak Fuzzy C-Means* (DP-FCM) fue desarrollado por (Kuo et al., 2023). El esquema utiliza ron *Density Peak Clustering* (DPC) para la inicialización del algoritmo FCM para mejorar sus resultados. Utilizaron DPC para identificar los centros de los clústeres iniciales basándose en un gráfico de decisión, donde los puntos de datos con alta densidad local y gran distancia se seleccionaron como centros de los clústeres. Denominaron al algoritmo resultante

102. Se implementó el algoritmo *Adaptive Chaotic Annealing Particle Swarm Optimization Fuzzy C-Means Clustering Algorithm* (ACAPSO-FCM) por los autores (S. Wang et al., 2023). El

enfoque incorpora el método *Adaptive chaotic annealing particle swarm optimization* (ACAPSO) para la inicialización del algoritmo FCM y mejorar los resultados de convergencia.

103. *Viewpoint-Driven Subspace Fuzzy C-Means* (VSFCM) fue implementado por los autores (Y. Tang et al., 2023). El método aplica *Cut-off Distance-Induced Clustering Initialization* (CDCI) para la selección de puntos de alta densidad para lograr la inicialización de centros óptimos.

104. Se implementó el algoritmo denominado como *Hierarchical Clustering-Fuzzy C-Means* (HAC-FCM) por (F. Guo et al., 2023). El esquema integra el método *Hierarchical Agglomerative Clustering* (HAC) para la inicialización de FCM para mejorar la precisión del agrupamiento de desechos espaciales.

## Año 2024

105. Se desarrolló el algoritmo denominado como *Efficient Fuzzy C-Means* (EFCM) por los autores (Arakeri et al., 2024). El esquema aplica el método de *Intensity value* representado por picos de histogramas para a selección de los centros de FCM.

106. Se desarrolló un método llamado *Equidistance index IFCM* (EI-IFCM) por los autores (Ma et al., 2024). que combina *Equidistance Index* (EI) para seleccionar los centros iniciales de FCM, basados en densidad.

107. *Multi-Strategy Tuna Swarm Optimization-Fuzzy C-means* (MSTSO-FCM) fue desarrollado por (Sun et al., 2024). El método introduce una estrategia de búsqueda local caótica y una estrategia de estimación de distribución de desplazamiento para mejorar la capacidad de desarrollo del algoritmo y mantener la diversidad de la población.

108. Se desarrolló el método *Subtractive Clustering-Based Particle Swarm Optimization Fuzzy C-Means* (SC-PSO-FCM) para mejorar la selección de los centros de FCM por (Quan et al., 2024). El enfoque integra las ventajas del clustering sustractivo y la optimización por enjambre de partículas (PSO) la precisión del agrupamiento de señales.

## 5.2. Respuesta a la Pregunta 2 de la revisión sistemática

Para responder a la Pregunta 2 (¿Cuáles son métodos o enfoques utilizados para mejorar la inicialización de FCM?), se elaboró una tabla que clasifica los métodos implementados en las mejoras del algoritmo FCM para su inicialización, los cuales fueron localizados en la revisión sistemática. Esta tabla integra información detallada de los 108 artículos analizados como: a) nombre de la variante propuesta, b) dominio de aplicación, c) elemento modificado en la inicialización, d) tipo de datos utilizados, e) métodos aplicados y f) criterios de evaluación empleados.

Tabla 7. Análisis comparativo de las mejoras en la inicialización de FCM localizadas en la revisión.

#	Referencia	Nombre de la variante de FCM	Dominio	Elemento modificado	Tipo de datos	Métodos	Criterios de evaluación
1	(Gunderson, 1983b)	<i>Adaptive Fuzzy C-Varieties Clustering Algorithm (AFCV)</i>	Detección y caracterización de subestructuras	Matriz inicial	Datos sintéticos con formas esféricas y lineales	<i>Ward's method (WM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Number of Iterations (NoI)</i></li> <li>▪ <i>Precision (PR)</i></li> </ul>
2	(Yager & Filev, 1994b)	<i>Fuzzy C-Means with Mountain Method Initialization (FCM-MM)</i>	Visión por computadora	Centros iniciales	Datos $s$ -dimensionales sintéticos	<i>Mountain Method (MM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Precision (PR)</i></li> </ul>
3	(Chiu, 1994b)	<i>Mountain Method Fuzzy C-Means (MM-FCM)</i>	Gestión del transporte	Centros iniciales y número de clústeres	Datos demográficos reales de 100 zonas de análisis de tráfico en el condado de New Castle y datos sintéticos generados con <i>Mackey-Glass</i>	<i>Modified Mountain Method (MMM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Root Mean Squared (RMS)</i></li> </ul>
4	(Cheng et al., 1998)	<i>Multistage Random Sampling Fuzzy <math>e</math>-means Clustering Algorithm (mrFCM)</i>	Segmentación de imágenes	Centros iniciales	Imágenes de resonancia magnética (MRI)	<i>Multistage Random Sampling (MRS)</i>	<ul style="list-style-type: none"> <li>▪ <i>Average CPU time</i></li> <li>▪ <i>STFV of CPU time</i></li> </ul>
5	(Zahid et al., 2001)	<i>K-nearest-neighbours one iteration Fuzzy C-Means Algorithm (KNN-1FCMA)</i>	Clustering	Centros iniciales	Datos artificiales $s$ -dimensional	<i>K-Nearest Neighbours (KNN)</i>	<ul style="list-style-type: none"> <li>▪ <i>Classification Error (ME)</i></li> <li>▪ <i>Number of Iterations (NoI)</i></li> <li>▪ <i>Partition coefficient (PC)</i></li> </ul>

6	(M.-C. Hung & Yang, 2001b)	<i>Partition Simplification Fuzzy C-Means</i> (psFCM)	Clustering	Centros iniciales	Dos conjuntos de datos generados a partir de distribuciones normales y distribuciones uniformes	<i>K-d Tree method</i>	<ul style="list-style-type: none"> <li>▪ <i>Factor Reduction in Time</i> (FRT)</li> <li>▪ <i>Factor Reduction in Distance</i> (FRD)</li> </ul>
7	(D.-W. Kim et al., 2004b) -	<i>Novel Scheme for Fuzzy C-Means</i> (NS-FCM)	Segmentación de imágenes a color	Centroides iniciales	Datos de color de imágenes con ColorChecker de Munsell	Espacio de color CIELAB	<ul style="list-style-type: none"> <li>▪ Experimentos comparativos</li> </ul>
8	(W. Wang et al., 2006b)	<i>Global Fuzzy C-Means</i> (GFCM)	Clustering	Centros iniciales	2 conjuntos de datos sintéticos en un espacio bidimensional	<i>Incremental Global Search</i> (IGS)	<ul style="list-style-type: none"> <li>▪ <i>Clustering Error</i> (CE)</li> <li>▪ <i>Accuracy</i> (ACC)</li> </ul>
9	(Nie et al., 2007)	<i>Genetic Fuzzy Clustering Algorithm</i> (GFCA)	Segmentación de imágenes	Centros iniciales	Imágenes de resonancia magnética (MRI)	<i>Genetic Algorithm</i> (GA)	<ul style="list-style-type: none"> <li>▪ <i>Tanimoto Coefficient</i> (TCnt)</li> <li>▪ <i>Time Consumed</i> (TC)</li> </ul>
10	(Kawa & Pietka, 2007)	<i>Kernelized Fuzzy C-Means</i> (KFCM)	Segmentación de imágenes	Matriz de Kernel utilizando una función de Kernel gaussiana	Imágenes de resonancia magnética (MRI)	<i>Kernel trick</i>	<ul style="list-style-type: none"> <li>▪ <i>Intra-cluster Distance</i></li> <li>▪ <i>Inter-cluster Distance</i></li> <li>▪ <i>Time Consumed</i> (TC)</li> </ul>
11	(W. Li & Yang, 2008)	<i>Conditionally Positive Definite Kernel-based Fuzzy C-Means Clustering</i> (CPD-FCM)	Identificación de estructuras de los datos	Kernel para el cálculo de la distancia	Conjunto de datos del Horno de Gas de Box y Jenkins y Serie temporal sintética	<i>Conditionally Positve Definite kernel</i> (CPD Kernel)	<ul style="list-style-type: none"> <li>▪ <i>Root Mean Squared Error</i> (RMSE)</li> <li>▪ <i>Number of Fuzzy Rules</i> (NoOFR)</li> </ul>
12	(H. Dong et al., 2009)	<i>Evolutionary Programming-based Fuzzy C-Means</i> (EPFCM)	Clustering	Centros iniciales	Datos sintéticos y reales	<i>Single-Point Mutation Evolutionary Programming</i> (SPMEP)	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient</i> (PC)</li> <li>▪ <i>Partition Entropy</i> (PE)</li> <li>▪ <i>Fuzzy Hypervolume</i> (PBMF)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> </ul>
13	(J. Fan et al., 2009)	<i>Single Point Iterative Weighted Fuzzy C-Means</i> (SWFCM)	Segmentación de imágenes	Centros iniciales	Imágenes satelitales de áreas geográficas y de color naturales del conjunto de datos de Berkeley, Iris, Wine y Pima.	<i>Single Point Iterative Adjustment Method</i> (SPIAM)	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient</i> (PC)</li> <li>▪ <i>Partition Entropy</i> (PE)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> <li>▪ <i>Fukuyama-Sugeno Index</i> (FSI)</li> <li>▪ <i>Kwon Index</i> (KI)</li> </ul>
14	(X. Y. Wang & Bu, 2010)	<i>A fast and robust image segmentation using FCM with spatial information</i> (FRIS-FCM)	Segmentación de imágenes	Incorporación de información espacial	Imágenes en escala de grises de escenas naturales	<i>Spatial Relationship y Gray-level relationship</i>	<ul style="list-style-type: none"> <li>▪ <i>Region Consistency</i> (RCcy)</li> <li>▪ <i>Region Contrast</i> (RCst)</li> <li>▪ <i>Region Ambiguity</i> (RA)</li> <li>▪ <i>Comprehensive Evaluation Function</i> (CEF)</li> </ul>

15	(Z. Yu et al., 2010)	<i>Ant Colony Fuzzy C-Means Hybrid Algorithm</i> (AFHA)	Segmentación de imágenes a color	Centros iniciales	Imágenes representadas en el espacio de color RGB	<i>Ant Colony Optimization</i> (ACO)	<ul style="list-style-type: none"> <li>▪ <i>Mean Squared Error</i> (MSE)</li> <li>▪ <i>Partition Coefficient</i> (PC)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> </ul>
16	(K.-L. Wu et al., 2010)	<i>Mountain C-Regression Clustering Method</i> (MCR)	Clustering	Centros iniciales	Datos sintéticos	<i>Mountain C-Regressions</i> (MCR)	<ul style="list-style-type: none"> <li>▪ <i>Number of Inappropriate Results</i> (NIR)</li> <li>▪ <i>Mean Squared Error</i> (MSE)</li> <li>▪ <i>Robustness to noise and outliers</i> (RNO)</li> <li>▪ <i>Visual Comparisons</i> (VC)</li> </ul>
17	(Cominetti et al., 2010b)	<i>Diffusion-based Fuzzy Clustering Algorithm</i> (DifFUZZY)	Bioinformática	Centros iniciales y número de clústeres	Datos de microarrays de alta densidad con información genética de pacientes con diferentes tipos de leucemia	<i>Identification of the core of clusters</i>	<ul style="list-style-type: none"> <li>▪ <i>Receiver Operating Characteristic</i> (ROC)</li> </ul>
18	(J. Deng et al., 2010b)	<i>Improved Fuzzy C-Means Clustering Algorithm</i> (IFCM)	Minería de texto	Centros iniciales	Conjuntos de datos de 20 Newsgroups proporcionados por UCI	<i>High-Power Sample point set</i>	<ul style="list-style-type: none"> <li>▪ <i>Running Time</i> (RT)</li> <li>▪ <i>Accuracy</i> (ACC)</li> </ul>
19	(Ramathilagam et al., 2011)	<i>Modified Robust Fuzzy C-Means with weight Bias Estimation</i> (MRFCM-wBE)	Segmentación de imágenes	Centros iniciales	Imágenes de resonancia magnética (MRI)	<i>Dist-max initialization</i> (DMI)	<ul style="list-style-type: none"> <li>▪ <i>Running Time</i> (RT)</li> <li>▪ <i>Number of iterations</i> (NoI)</li> <li>▪ <i>Accuracy</i> (ACC)</li> <li>▪ <i>Silhouette Index</i> (SI)</li> </ul>
20	(Y. Zhang et al., 2011)	<i>Possibilistic C-Means with Mahalanobis Distance and Particle Swarm Optimization</i> (PCM-MD-PSO)	Segmentación de imágenes	Centros iniciales	3 imágenes reales	<i>Mahalanobis Distance</i> (MD)	<ul style="list-style-type: none"> <li>▪ <i>Fitness Function</i> (FF)</li> </ul>
21	(Naik et al., 2012)	<i>Teaching Learning Based Optimization con Fuzzy C-Means</i> (TLBO/FCM)	Clustering	Centros iniciales	Iris, Glass, Wisconsin, Breast Cancer, Wine, Vowel, Haberman's, Survival Data, Pima Indian Diabetes	<i>Teaching Learning Based Optimization</i> (TLBO)	<ul style="list-style-type: none"> <li>▪ <i>Number of Iterations</i> (NoI)</li> </ul>
22	(Doğan & Korürek, 2012)	<i>Kernelized Fuzzy C-Means con Hybrid Ant Colony Optimization</i> (KFCM-HACO)	Clasificación de señales	Centros iniciales y parámetros del kernel	Datos de arritmias MIT-BIH y de latidos de ECG	<i>Hybrid Ant Colony Optimization</i> (HACO)	<ul style="list-style-type: none"> <li>▪ <i>Sensitivity</i></li> <li>▪ <i>Specificity</i></li> </ul>
23	(Z. Wang et al., 2012)	<i>Dynamic Fuzzy C-Means Magn</i> (DFCM)	Optimización de sistemas hidráulicos	Centros iniciales	Datos de series temporales de alta dimensión relacionados con la precipitación y las	<i>Real Coding-based Accelerating Genetic Algorithm</i> (RAGA)	<ul style="list-style-type: none"> <li>▪ <i>Compact and Separation Function</i> (CSF)</li> </ul>

					inundaciones en la cuenca del lago Taihu		
24	(Kannan et al., 2012b)	<i>Robust Fuzzy C-Means based on Kernel Function (RFCMK) y Tsallis Entropy based Fuzzy C-Means (TEFCM)</i>	Segmentación de imágenes	Centros Iniciales	Imágenes de Resonancia Magnética (MRI)	Normed induced kernel function and Tsallis entropy	<ul style="list-style-type: none"> <li>▪ Number of Iterations (NoI)</li> <li>▪ Silhouette Width (SW)</li> </ul>
25	(Maraziotis, 2012)	<i>Semi-Supervised Fuzzy Clustering Algorithm (SSFCA)</i>	Bionformática	Número de clústeres	Datos de los niveles de expresión de 6000 genes en 17 puntos de tiempo por dos ciclos celulares de levadura y datos de 6400 genes en 7 puntos de tiempo durante la esporulación de la levadura	<i>Competitive agglomeration</i>	<ul style="list-style-type: none"> <li>▪ Normalized Mutual Information (NMI)</li> <li>▪ Rand Index (RI)</li> <li>▪ Silhouette Index (SI)</li> </ul>
26	(Tan, Isa, et al., 2013)	<i>Region Splitting and Merging- Fuzzy C-Means Hybrid Algorithm (RFHA)</i>	Segmentación de imágenes a color	Centros iniciales	Imágenes naturales obtenidas de bases de datos públicas de segmentación de imágenes	<i>Region Splitting and Merging (RSM)</i>	<ul style="list-style-type: none"> <li>▪ Mean Squared Error (MSE)</li> <li>▪ Homogeneity Values (HV)</li> </ul>
27	(Taherdangkoo & Bagheri, 2013)	<i>Stem Cells and Fuzzy C-Means Algorithm (SC-FCM)</i>	Clustering	Centros iniciales	Vowel, Iris, Crude Oil, Control Chart, Wood Defects, Wine, Nomoa, University y Seeds	<i>Stem Cells Algorithms (SCA)</i>	<ul style="list-style-type: none"> <li>▪ Objective Function Value (OFV)</li> <li>▪ Convergence Characteristics</li> <li>▪ Davies-Bouldin Index (DBI)</li> </ul>
28	(Han et al., 2013)	<i>Adaptive Fuzzy C-Means (AFCM)</i>	Sistemas Neuro Difusos (NFS)	Centros iniciales y número de clústeres	Series temporales de Mackey-Glass y datos sobre el consumo de combustible del repositorio KEEL	Statistical theory	<ul style="list-style-type: none"> <li>▪ Root Mean Squared Error (RMSE)</li> </ul>
29	(Tan, Lim, et al., 2013b)	<i>Fuzzy C-Means with Hierarchical Approach (FCM-HA)</i>	Segmentación de imágenes a color	Centros iniciales	Imágenes a color	<i>Hierarchical approach (HA)</i>	<ul style="list-style-type: none"> <li>▪ Mean Squared Error (MSE)</li> </ul>
30	(Benaichouche et al., 2013)	<i>Improved Spatial Fuzzy C-Means (IFCMS)</i>	Segmentación de imágenes	Centros iniciales	Imágenes sintéticas que contienen diferentes números de clústeres y están corrompidas con diferentes niveles y tipos de ruido	Particle Swarm Optimization (PSO)	<ul style="list-style-type: none"> <li>▪ Accuracy (ACC)</li> </ul>

31	(HongLei et al., 2013)	<i>Modified Fuzzy C-Means Clustering Algorithm with Spatial Constraints Based on Markov Random Field</i>	Teledetección (Remote sensing)	Centros iniciales	Imagen sintética de 512x512 píxeles e imagen del satélite QuickBird de 300x300 píxeles de Maricopa County, Arizona, USA	<i>Density function of the first principal component</i>	<ul style="list-style-type: none"> <li>▪ Overall Accuracy (OACC)</li> <li>▪ Kappa Coefficient (KC)</li> </ul>
32	(J. Yan, 2014b)	<i>Ant Colony Optimized Fuzzy C-Means (ACO-FCM)</i>	Teledetección (remote sensing)	Número de clústeres y centros iniciales	imágenes multi-espectrales de resolución espacial media obtenidas del satélite Landsat 7 TM	<i>Ant Colony Optimization (ACO)</i>	<ul style="list-style-type: none"> <li>▪ Experimentos comparativos</li> </ul>
33	(Bharill & Tiwari, 2014b)	<i>Random Sampling Iterative Optimization Fuzzy C-Means (RSIO-FCM)</i>	Big Data	Centros iniciales	Pen-Based Recognition of Handwritten Digits y Page Blocks Classification	<i>Random Sampling Iterative Optimization (RSIO)</i>	<ul style="list-style-type: none"> <li>▪ Objective Function Value (OFV)</li> <li>▪ Time Consumed (TC)</li> <li>▪ Accuracy (ACC)</li> </ul>
34	(Nayak et al., 2014b)	<i>Improved Firefly Based Fuzzy C-Means (Improved FAFCM)</i>	Clustering	Centros iniciales	Datos reales como Glass, Iris y Lung Cancer y un conjunto de datos artificial	<i>Firefly Algorithm (FA)</i>	<ul style="list-style-type: none"> <li>▪ Objective Function Value (OFV)</li> <li>▪ Number of iterations (NoI)</li> </ul>
35	(Niware & Chaturvedi, 2014)	<i>Genetic Fuzzy C-Means (GFCM)</i>	Minería de uso Web	Centros iniciales	Datos de registros web reales del servidor de Microsoft, que contiene 22 atributos	<i>Genetic Algorithm (GA)</i>	<ul style="list-style-type: none"> <li>▪ Error Rate (ER)</li> <li>▪ Time Consumed (TC)</li> <li>▪ Number of Iterations (NoI)</li> </ul>
36	(J. Zhao & Jia, 2015)	<i>Segmentation algorithm for small targets based on improved data field and Fuzzy C-Means clustering (SDF-FCM)</i>	Segmentación de imágenes	Centros iniciales	Imágenes en escala de grises	Función de potencial	<ul style="list-style-type: none"> <li>▪ Misclassification Error (ME)</li> <li>▪ Mean Structure Similarity (MSSIM)</li> </ul>
37	(Mekhmoukh & Mokrani, 2015)	<i>Improved Kernel Possibilistic C-Means (IKPCM)</i>	Segmentación de imágenes	Centros iniciales	Imágenes de Resonancia Magnética (MRI)	<i>Particle Swarm Optimization (PSO)</i>	<ul style="list-style-type: none"> <li>▪ Partition Entropy (PE)</li> <li>▪ Partition Coefficient (PC)</li> <li>▪ Xie-Beni Index (XBI)</li> <li>▪ DICE Index (DICE-I)</li> <li>▪ Jaccard Index (JI)</li> <li>▪ True Positive Fraction (TPF)</li> <li>▪ False Negative Fraction (FNF)</li> <li>▪ False Positive Fraction (FPF)</li> </ul>
38	(Stetco et al., 2015b)	<i>Fuzzy C-Means++</i>	Clustering	Centros iniciales	Iris, Spam y Wine	<i>Seeding mechanism of K-Means++</i>	<ul style="list-style-type: none"> <li>▪ Number of Iterations (NoI)</li> <li>▪ Objective Function Value (OFV)</li> <li>▪ Xie-Beni Index (XBI)</li> </ul>

39	(F. Li et al., 2015)	<i>Optimal Supervised Fuzzy C-Means Clusterin (OSFCM)</i>	Maquinaria Rotativa	Matriz inicial	datos de señales de vibración	Muestras de entrenamiento	<ul style="list-style-type: none"> <li>▪ Accuracy (ACC)</li> <li>▪ Time Consumed (TC)</li> </ul>
40	(Ansari et al., 2015)	<i>MDF based FCM (MDFCM)</i>	Minería de uso Web	Centros iniciales	Datos de sesiones de usuario extraídos de los registros web	<i>Mountain Density Function (MDF)</i>	<ul style="list-style-type: none"> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Fukuyama-Sugeno Index (FSI)</i></li> <li>▪ <i>Zahid SC Index</i></li> <li>▪ <i>Error Rate (ER)</i></li> </ul>
41	(Suleman, 2015)	<i>Factorised Fuzzy C-Means (F-FCM)</i>	Segmentación de imágenes	Exponente de ponderación	Conjuntos de datos reales descargados del UCI Machine Learning Repository	<i>Semi-nonnegative matrix factorisation (semi-NMF)</i>	<ul style="list-style-type: none"> <li>▪ <i>Xie-Beni Index (XBI)</i></li> </ul>
42	(Y. Mei et al., 2015)	<i>Semi-Supervised Fuzzy C-Means (SFCM)</i>	Control de Tráfico	Centros iniciales	Datos de GPS de vehículos de prueba, específicamente taxis equipados con GPS en Shanghai, China	<i>Weighted function of density and distance</i>	<ul style="list-style-type: none"> <li>▪ <i>Clustering Purity (CP)</i></li> <li>▪ <i>Normalized Mutual Information (NMI)</i></li> </ul>
43	(Ding & Fu, 2016)	<i>Genetic Algorithm Kernel-Based Fuzzy C-Means (GAKFCM)</i>	Clustering	Centros iniciales y parámetros del Kernel	Iris, Wine y ANC (American National Corpus) Database	<i>Genetic Algorithm (GA)</i>	<ul style="list-style-type: none"> <li>▪ <i>Precision (PR)</i></li> <li>▪ <i>Recall (RE)</i></li> <li>▪ <i>Correct Rate (CR)</i></li> <li>▪ <i>Running Time (RT)</i></li> </ul>
44	(Rajaby et al., 2016)	<i>Weighted Hue and Intensity Fuzzy C-Means</i>	Segmentación de imágenes a color	Centros iniciales	Conjunto de datos Berkeley Segmentation	<i>Table of intensity and hue value densities</i>	<ul style="list-style-type: none"> <li>▪ Accuracy (ACC)</li> </ul>
45	(D. Wang et al., 2016)	DPSO-FCM	Ingeniería de petróleo y gas	Centros iniciales	Datos de reservorios carbonatados naturalmente fracturados y yugosos (NFVCRs) en la Cuenca de Tarim, China	<i>Selfadaptiveparticle swarm optimization (DPSO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Squared Error (SE)</i></li> </ul>
46	(L. Liu et al., 2016)	<i>Chaotic Quantum Particle Swarm Optimization Fuzzy C-Means (CQPSO-FCM)</i>	Ingeniería de petróleo y gas	Centros iniciales	Datos sísmicos y datos de pozos perforados	<i>Chaotic Quantum Particle Swarm Optimization (CQPSO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Coincidence Rate (CR)</i></li> <li>▪ <i>Number of Iterations (NoI)</i></li> </ul>
47	(Jahanbakhsh Pourjabari & Seyedzadegan, 2016b)	<i>Improved Feature-Weighted Fuzzy C-Means</i>	Clustering	Centros iniciales	Iris, Crude oil y Bupa	<i>Term Variance</i>	<ul style="list-style-type: none"> <li>▪ <i>Error Rate (ER)</i></li> </ul>

48	(Duan et al., 2016b)	<i>An Improved Fuzzy C-Means Clustering Algorithm Based on Partial Supervision</i>	Clustering	Centros iniciales y número de clústeres	Iris de la base de datos UCI	Partially supervised fuzzy clustering	<ul style="list-style-type: none"> <li>▪ <i>Sensitivity</i></li> </ul>
49	(Nayak et al., 2016) REVISAR FECHA	<i>Elicit teaching learning based optimization with Fuzzy C-Means (ETLBO-FCM)</i>	Clustering	Centros iniciales	Iris, Lenses, Haberman, Balance scale, Wisconsin breast cancer, Contraceptive Method Choice, Hayesroth, Robot Navigation, Spect heart, Glass, Wine y Lung Cancer	<i>Elicit Teaching Learning Based Optimization (ETLBO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Rand Index (RI)</i></li> <li>▪ <i>Jaccard Index (JI)</i></li> <li>▪ <i>Fowlkes and Mallows Index (FMI)</i></li> <li>▪ <i>Hubert's Index (HI)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> </ul>
50	(Jie et al., 2017)	<i>Improved Self-Adaptive Cellular Genetic Algorithm for Fuzzy C-Means (IDCGA-FCM)</i>	Clustering	Centros iniciales	Ocho conjuntos de datos del UCI Machine Learning Repository: Iris, Wine, Glass, Heart Disease, Cancer, Prima Indians Diabetes, Image Segmentation y Landsat Satellite	<i>Arnold cat map (ACM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient (PC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Fukuyama-Sugeno Index (FSI)</i></li> <li>▪ <i>Pakhira-Bandyopadhyay-Maulik Fuzzy (PBMF)</i></li> <li>▪ <i>Silhouette Index (SI)</i></li> </ul>
51	(Nayak et al., 2017)	<i>Hybrid Chemical Reaction based Metaheuristic with Fuzzy C-Means Algorithm for Optimal Cluster Analysis (CRO-FCM)</i>	Clustering	Centros iniciales	Iris, Lenses, Haberman, Balance scale, Wisconsin breast cancer, Contraceptive Method Choice, Hayesroth, Robot Navigation, Spect heart, Glass, Wine y Lung Cancer	<i>Chemical Reaction Optimization (CRO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Fitness Function (FF)</i></li> <li>▪ <i>Intra-cluster Distance</i></li> <li>▪ <i>Inter-cluster Distance</i></li> <li>▪ <i>Error Rate (ER)</i></li> </ul>
52	(Haldar et al., 2017)	<i>Mahalanobis Distance based improved Fuzzy C-Means (FCM-M)</i>	Servicio Médico	Centros iniciales	Datos que provienen del MIT-BIH Arrhythmia Database, disponible en PhysioNet	<i>Training Data</i>	<ul style="list-style-type: none"> <li>▪ <i>Detection Rate (DR)</i></li> <li>▪ <i>False Rejection Rate (FRR)</i></li> </ul>
53	(Gueorguieva et al., 2017)	<i>Fuzzy C-Means Clustering with Mahalanobis and Minkowski Distance Metrics (M&amp;MFCM)</i>	Segmentación de imágenes	Número de clústeres	Dos datasets 3D: Seeds dataset y Housing Data set	<i>Validation Measures</i>	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient (PC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Compact and Separation Function (CSF)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Dunn's Index (DI)</i></li> <li>▪ <i>Alternative Dunn's Index (ADI)</i></li> </ul>
54	(Chaomurilige et al., 2017)	<i>Deterministic Annealing Gustafson-Kessel fuzzy (DA-GK)</i>	Clustering	Exponente de ponderación	Iris, Wine, Ionosphere, Waveform, Breast-Cancer-Wisconsin, Haberman's	<i>Deterministic annealing</i>	<ul style="list-style-type: none"> <li>▪ <i>Error Rate (ER)</i></li> <li>▪ <i>Average Error Count (AEC)</i></li> <li>▪ <i>Mean Squared Error (MSE)</i></li> <li>▪ <i>Running Time (RT)</i></li> </ul>

					Survival y Connectionist Bench		
55	(Ghosh et al., 2018)	<i>Chaotic Firefly Algorithm-Based Fuzzy C-Means (C-FAFCM)</i>	Segmentación de imágenes	Centros iniciales	Imágenes de Resonancia Magnética (MRI)	<i>Chaotic-Firefly Algorithm (C-FA)</i>	<ul style="list-style-type: none"> <li>▪ <i>DICE Index (DICE-I)</i></li> <li>▪ <i>Tanimoto Coefficient (TCnt)</i></li> <li>▪ <i>Under Segmentation (UnS)</i></li> <li>▪ <i>Over Segmentation (OvS)</i></li> <li>▪ <i>Correct Rate (CR)</i></li> </ul>
56	(Kuo et al., 2018)	<i>Particle Swarm Optimization Kernel Intuitionistic Fuzzy C-Means (PSO-KIFCM), Genetic Algorithm Kernel Intuitionistic Fuzzy C-Means (GA-IKFCM) y Artificial Bee Colony Kernel Intuitionistic Fuzzy C-Means (ABC-KIFCM)</i>	Negocios/Marketing	Centros iniciales	Iris, Wine, Tae, Flame, Glass y Wisconsin-Breast Cancer	<i>Particle Swarm Optimization (PSO), Genetic algorithm (GA), Artificial Bee Colony (ABC)</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Standard desviation (Desvst)</i></li> <li>▪ <i>Davies-Bouldin Index (DBI)</i></li> <li>▪ <i>Computation Time (CT)</i></li> </ul>
57	(H. Liu et al., 2018)	<i>Pareto-based interval type-2 Fuzzy C-Means with multi-scale just Noticeable Difference color histogram (PIT2FC-MJND)</i>	Segmentación de imágenes	Centros iniciales	Imágenes de la base de datos de Berkeley y Weizmann	<i>Multi-scale just noticeable difference (JND) color histogram</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> </ul>
58	(Q. Guo et al., 2018)	<i>Mixing Matrix Estimation Based on Data Field and Improved Fuzzy C-Means Clustering (MME-DF-IFCM)</i>	Procesamiento de señales	Número de clústeres	Señales de radar MIMO (Multiple Input, Multiple Output)	<i>Data field</i>	<ul style="list-style-type: none"> <li>▪ <i>Normalized mean Squared Error (NMSE)</i></li> </ul>
59	(Soomro et al., 2019)	<i>Fuzzy C-Means Global and Local Region-based Active Contour (FCM-GLREAC)</i>	Segmentación de imágenes	Matriz inicial	Datos de lesiones cutáneas públicas (PH2)	<i>Global and Local Region-based Active Contour</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Number of Iterations (NoI)</i></li> <li>▪ <i>Computation Time (CT)</i></li> </ul>
60	(C. L. Liu et al., 2019)	<i>Entropy-Based Weighted Semi-Supervised Fuzzy C-Means (EWSS-FCM)</i>	Clustering	Matriz inicial	20 Newsgroups y COREL Database	<i>Entropy function</i>	<ul style="list-style-type: none"> <li>▪ <i>F1-Score (F1)</i></li> <li>▪ <i>Jaccard Index (JI)</i></li> </ul>
61	(Hashemzadeh et al., 2019)	<i>Fuzzy C-Means clustering method based on feature-</i>	Clustering	Centros iniciales	Ecoli, Iris, Wine, Glass, Ionosphere, Heberman, Spectf heart, Vowel, Pima Indians	<i>Cluster weighting</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Normalized Mutual Information (NMI)</i></li> </ul>

		<i>weight and cluster-weight learning</i>			Diabetes, Breast Cancer Wisconsin, Dermatology, Zoo, Letter Recognition (A, B, C), Statlog, Balance y Breast Cancer Wisconsin		
62	(B. Yan et al., 2019)	<i>Improved FCM Initialization Method (IFIM)</i>	Vigilancia aérea y el seguimiento de aviones	Centros iniciales	Datos de un radar en el aeropuerto general de Shaanxi Pucheng Neifu	<i>Ellipsoid gating y predictive location of targets</i>	<ul style="list-style-type: none"> <li>▪ <i>Optimal sub-pattern assignment (OSPA)</i></li> <li>▪ <i>Computation Time (CT)</i></li> <li>▪ <i>F1-Score (F1)</i></li> </ul>
63	(Z. H. Deng et al., 2019)	<i>Community detection algorithm based on improved label propagation and Fuzzy C-Means (LPA-FCM)</i>	Redes complejas	Matriz inicial y etiquetas de vecindad	Karate, Dolphin, Football, Polbook, Email, Netscience y Power	<i>Neighbor Evaluation Method (NEM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Normalized Mutual Information (NMI)</i></li> <li>▪ <i>Modulation Recognition Rate (MRR)</i></li> </ul>
64	(X. Wang et al., 2019)	<i>State Transition Algorithm-based Fuzzy C-Means (STAFCM)</i>	Minería y procesamiento de minerales	Centros iniciales	330 conjuntos de datos históricos industriales de una planta de flotación de oro-antimoniio en China	<i>State Transition Algorithm (STA)</i>	<ul style="list-style-type: none"> <li>▪ <i>Computation Time (CT)</i></li> <li>▪ <i>Objective Function Value (OFV)</i></li> <li>▪ <i>Accuracy (ACC)</i></li> </ul>
65	(Qiao et al., 2019)	<i>Improved Fuzzy Clustering (IFC)</i>	Desulfuración húmeda de gases de combustión	Centros iniciales y número de clústeres	Datos históricos de operación de un sistema de desulfuración de gases de combustión húmeda (WFGD) de una unidad de 600 MW en una planta de energía	<i>Comentropy y K-means</i>	<ul style="list-style-type: none"> <li>▪ <i>Objective Function Value (OFV)</i></li> </ul>
66	(Lv et al., 2019)	FCM-GABPN	Compañía de producción de plantillas de PCB	Centros iniciales	Registros históricos de una empresa de producción de plantillas de PCB	<i>Genetic Algorithm (GA)</i>	<ul style="list-style-type: none"> <li>▪ <i>Mean Squared Error (MSE)</i></li> <li>▪ <i>Mean Absolute Error (MAE)</i></li> <li>▪ <i>Mean Absolute Percentage Error (MAPE)</i></li> <li>▪ <i>Predicted Surplus Rate (Surpr_Pd)</i></li> <li>▪ <i>Predicted Supplemental Feeding Rate (Supfr_Pd)</i></li> </ul>
67	(M. Li et al., 2019)	<i>Adaptive Fuzzy C-Means Segmentation Image Algorithm based on Global Spatial Information (AFCM_GSI)</i>	Imágenes de teledetección	Centros iniciales	2 imágenes sintéticas que son generadas artificialmente y luego contaminadas con diferentes tipos de ruido, 2 imágenes naturales y 6 imágenes de teledetección del	<i>Lévy grey wolf optimization algorithm (LGWO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Comparison Score (CS)</i></li> <li>▪ <i>Peak Signal to Noise Ratio (PSNR)</i></li> <li>▪ <i>Mean Structure Similarity (MSSIM)</i></li> </ul>

					USGS, National Map y Urban Area Imagery		
68	(Gharib et al., 2019)	<i>Robust Heterogeneous C-Means</i> (RHCM)	Análisis de imágenes	Centros iniciales	Datos de imágenes y sus etiquetas correspondientes de la red social de 500px, con información de latitud y longitud de cada imagen	<i>Direct Clustering</i> (DC)	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient</i> (PC)</li> <li>▪ <i>Partition Entropy</i> (PE)</li> <li>▪ <i>Partition Index</i> (PI)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> <li>▪ <i>Dunn's Index</i> (DI)</li> <li>▪ <i>Rand Index</i> (RI)</li> </ul>
69	(Sheela & Suganthi, 2019)	<i>Greedy Snake Model and Fuzzy CMeans optimization</i>	Segmentación de imágenes	Matriz inicial y centros iniciales	Imágenes de resonancia magnética (MRI) de pacientes con tumores cerebrales	<i>Greedy Snake Model</i>	<ul style="list-style-type: none"> <li>▪ <i>DICE Index</i> (DICE-I)</li> <li>▪ <i>Sensitivity</i></li> <li>▪ <i>Specificity</i></li> <li>▪ <i>Probabilistic Rand Index</i> (PRI)</li> <li>▪ <i>Hausdorff Distance</i> (HD)</li> </ul>
70	(Z. Zhao et al., 2020)	<i>Unsupervised Deep Fuzzy C-Means clustering Network</i> (UDFCMN)	Segmentación de imágenes	Centros iniciales	Imágenes médicas de los pulmones, secuencias de imágenes de CT, datos de expresión génica, metilación de ADN y mutaciones genéticas de 372 pacientes del Hospital colaborador	<i>Winner-Take-All Deep Belief Network</i> (WTADBN)	<ul style="list-style-type: none"> <li>▪ <i>Davies–Bouldin Index</i> (DBI)</li> <li>▪ <i>Silhouette Index</i> (SI)</li> </ul>
71	(Martino et al., 2020)	<i>Partition Energy-Entropy Fuzzy C-Means</i> (PEHFCM)	Clustering	Centros iniciales y número de clústeres	Iris, Wine, Breast Cancer, Glass, Seeds, Sonar y Vehicle	<i>Partition Energy-Entropy</i> (PEH)	<ul style="list-style-type: none"> <li>▪ <i>Number of Iterations</i> (NoI)</li> <li>▪ <i>Running Time</i> (RT)</li> <li>▪ <i>Partition Coefficient</i> (PC)</li> <li>▪ <i>Partition Entropy</i> (PE)</li> <li>▪ <i>Fukuyama-Sugeno Index</i> (FSI)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> <li>▪ <i>Partition Coefficient and Exponential Separation</i> (PCAES)</li> <li>▪ <i>Accuracy</i> (ACC)</li> <li>▪ <i>Precision</i> (PR)</li> <li>▪ <i>Recall</i> (RE)</li> <li>▪ <i>F1-Score</i> (F1)</li> </ul>
72	(Cebeci & Cebeci, 2020)	<i>Fuzzy C-Means with InoFreq</i> (FCM-InoFreq)	Segmentación de imágenes	Centros iniciales	Conjunto de datos sintéticos generado utilizando la función rnorm de R y seis conjuntos de datos reales:	<i>Initialization on Frequency Polygons</i> (InoFreq)	<ul style="list-style-type: none"> <li>▪ <i>Number of Iterations</i> (NoI)</li> <li>▪ <i>Computation Time</i> (CT)</li> <li>▪ <i>Initialization Time</i> (IT)</li> <li>▪ <i>Partition Entropy</i> (PE)</li> <li>▪ <i>Modified Partition Coefficient</i> (MPC)</li> </ul>

					Iris, Forest, Wine, Glass, Waveform y Wilt train			<ul style="list-style-type: none"> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Kwon Index (KI)</i></li> <li>▪ <i>Partition Coefficient and Bhattacharyya Measure Fuzzy Index (PBMF-I)</i></li> </ul>
73	(Qaiyum et al., 2020)	<i>Ant Colony Optimization of Interval Type-2 Fuzzy C-Means (IT2FCM-ACO)</i>	Big data	Centros iniciales	Airlines, Forest, Sea, Poker, Electricity y KDD Cup	<i>Ant Colony Optimization (ACO)</i>		<ul style="list-style-type: none"> <li>▪ <i>Silhouette Index (SI)</i></li> <li>▪ <i>Fuzzy Rand Index (FRI)</i></li> <li>▪ <i>Error Rate (ER)</i></li> <li>▪ <i>Running Time (RT)</i></li> <li>▪ <i>Speedup (SU)</i></li> </ul>
74	(Cardone et al., 2020)	<i>Entropy Weighted FCM (EwFCM)</i>	Clustering	Centros iniciales	Iris y Wine	<i>Entropy Weighted</i>		<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Precision (PR)</i></li> <li>▪ <i>Recall (RE)</i></li> <li>▪ <i>F1-Score (F1)</i></li> </ul>
75	(W. Lin & Li, 2020)	<i>Regional Hidden Markov Random Field - Fuzzy C-Means (RHMRF-FCM)</i>	Segmentación de imágenes	Centros iniciales y número de clústeres	Especificamente, se utilizan imágenes de satélites como WorldView-3	<i>Regional Hidden Markov Random Field</i>		<ul style="list-style-type: none"> <li>▪ <i>User's Accuracy (UACC)</i></li> <li>▪ <i>Producer's Accuracy (PACC)</i></li> <li>▪ <i>Overall Accuracy (OACC)</i></li> <li>▪ <i>Kappa Coefficient (KC)</i></li> </ul>
76	(Mousavi et al., 2020)	<i>Artificial Bee Colony + Fuzzy C Means with Manhattan distance clustering (ABC+FCMM)</i>	Big Data	Centros iniciales y métrica de distancia	Fisher's, Iris, EEG Eye State, Wine, Haberman's Survival, User Knowledge, Modeling, Ionosphere, Blood Transfusion	<i>Artificial Bee Colony (ABC) y Manhattan Distance (MD)</i>		<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Runtime Speed (RTS)</i></li> <li>▪ <i>Receiver Operating Characteristic (ROC)</i></li> <li>▪ <i>Confusion Matrix (CM)</i></li> <li>▪ <i>Error Rate (ER)</i></li> </ul>
77	(Z. Liu et al., 2021)	<i>Color Image Quick Fuzzy C-Means Clustering Algorithm (CIQFCM)</i>	Extracción de colores dominantes	Centros iniciales	Imágenes reales	<i>Improved pedigree clustering algorithm</i>		<ul style="list-style-type: none"> <li>▪ <i>Number of Quantized Colors (Nc)</i></li> <li>▪ <i>Time Consumed (TC)</i></li> <li>▪ <i>Differences of Average Colors</i></li> </ul>
78	(M. Yang et al., 2021)	<i>Improved Fuzzy C-Means Clustering Algorithm (Improved FCM)</i>	Energía eólica	Centros iniciales y número de clústeres	Datos históricos de velocidad del viento y potencia de salida de turbinas eólicas	<i>Principle of minimum distance</i>		<ul style="list-style-type: none"> <li>▪ <i>Root Mean Squared Error (RMSE)</i></li> <li>▪ <i>Mean Absolute Error (MAE)</i></li> <li>▪ <i>Sum of Squares due to Error (SSE)</i></li> <li>▪ <i>Coefficient of Determination (CD)</i></li> <li>▪ <i>Compact and Separation Function (CSF)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> </ul>
79	(Abdellahoum et al., 2021)	<i>Cooperative System Fuzzy C-Means (CSFCM)</i>	Segmentación de imágenes	Centros iniciales y número de clústeres	Imágenes de resonancia magnética (MRI)	<i>Genetic Algorithm (GA), Biogeography-Based Optimization (BBO) y Firefly Algorithm (FA)</i>		<ul style="list-style-type: none"> <li>▪ <i>Peak Signal to Noise Ratio (PSNR)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Subarea Coefficient (SC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> </ul>

							<ul style="list-style-type: none"><li>▪ Partition Coefficient (PC)</li></ul>
80	(Golzari Oskouei et al., 2021)	<i>Cluster-weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm (CGFFCM)</i>	Segmentación de imágenes	Centros iniciales y métrica de distancia	Datos de Benchmark Berkeley	<i>Cluster-weight and Group-local Feature-weight learning (CGFFCM)</i>	<ul style="list-style-type: none"><li>▪ Accuracy (ACC)</li><li>▪ Normalized Mutual Information (NMI)</li><li>▪ F1-Score (F1)</li></ul>
81	(Wei et al., 2021)	<i>Modified Local-Information Weighted Intuitionistic Fuzzy C-means Clustering and Gold-Panning Algorithm (GPA-LWIFCM)</i>	Segmentación de imágenes	Centros iniciales	Imágenes sintéticas con diferentes tipos de ruido, multigrises y reales térmicas infrarrojas	<i>Gold-Panning Algorithm (GPA)</i>	<ul style="list-style-type: none"><li>▪ Similarity Index (SI)</li><li>▪ Optimal Similarity Index (Opt SI)</li><li>▪ Average Similarity Index (Avg SI)</li></ul>
82	(Yi et al., 2021)	<i>Improved Fuzzy C-Means clustering algorithm based on t-SNE</i>	Espectroscopía de terahercios (THz)	Centros iniciales	Datos espectrales de terahercios	<i>T-distributed Stochastic Neighbor Embedding (t-SNE)</i>	<ul style="list-style-type: none"><li>▪ Correct Rate (CR)</li></ul>
83	(Dhal et al., 2021)	<i>Histogram based Fuzzy C-Means (HBFCM) improved with Randomly Attracted Rough Firefly Algorithm</i>	Segmentación de imágenes	Centros iniciales	Imágenes en escala de grises de leucemia aguda linfoblástica (ALL) de la base de datos ALL-IDB2	<i>Randomly Attracted Rough Firefly Algorithm (RARFA)</i>	<ul style="list-style-type: none"><li>▪ Feature Similarity Index (FSIM)</li><li>▪ Root Mean Squared Error (RMSE)</li><li>▪ Peak Signal to Noise Ratio (PSNR)</li><li>▪ Structural Similarity Index (SSIM)</li><li>▪ Normalized Cross-Correlation (NCC)</li><li>▪ Average Difference (AD)</li><li>▪ Maximum Difference (MD)</li><li>▪ Normalized Absolute Error (NAE)</li><li>▪ Accuracy (ACC)</li><li>▪ Precision (PR)</li><li>▪ Recall (RE)</li><li>▪ F1-Score (F1)</li></ul>
84	(S. Dong et al., 2021)	<i>Kernel Time-Weighted Fuzzy C-Means (KTFCM)</i>	Mercado de valores	Métrica de distancia y parámetros del Kernel	Series temporales financieras	<i>Time Weight (TW)</i>	<ul style="list-style-type: none"><li>▪ Accuracy (ACC)</li><li>▪ Annual Return (AR)</li><li>▪ Maximum Drawdown (MDD)</li><li>▪ Annual Volatility (V)</li><li>▪ Total Return (R)</li><li>▪ Average Return (AR)</li></ul>
85	(Ren & Sun, 2021)	<i>Local Information Bi-directional Fuzzy C-Means (LI_BIFCM)</i>	Clustering	Centros iniciales	Datos Sintéticos: S1, S2, S3 y datos reales: WDBC, Wine, Segmentation, Seeds,	<i>Vertical ensemble y Horizontal ensemble</i>	<ul style="list-style-type: none"><li>▪ Accuracy (ACC)</li><li>▪ Adjusted Rand Index (ARI)</li><li>▪ Adjusted Mutual Information (AMI)</li></ul>

					Dermatology, Parkinsons, Pima, Iris y Ionosphere.		
86	(Y. Zhang & Han, 2021)	<i>Improved differential privacy Fuzzy C-Means clustering</i> (IDPFCM)	Protección de la privacidad	Matriz de membresías y centros iniciales	Iris, Seeds, Trial, S1 y datos sintéticos (D1)	<i>Maximum distance method</i>	<ul style="list-style-type: none"> <li>▪ <i>F1-Score</i> (F1)</li> <li>▪ <i>Adjusted Rand Index</i> (ARI)</li> </ul>
87	(Pérez-Ortega et al., 2022)	<i>Hybrid OK-Means Fuzzy C-Means</i> (HOFCM)	Clustering	Matriz inicial	WDBC, Abalone, SPAM, Urban y 1m2d	<i>S Function</i> (SF)	<ul style="list-style-type: none"> <li>▪ <i>Execution Time</i> (ET)</li> <li>▪ <i>Objective Function Value</i> (OFV)</li> <li>▪ <i>Percentage of Time Reduction</i> (PTR)</li> <li>▪ <i>Percentage Gain in Objective Function</i> (PGOF)</li> </ul>
88	(Chakraborty, 2024)	CFCM	Segmentación de imágenes	Centros iniciales	Imágenes X-ray, de resonancia magnética, tomografías computarizadas y ultrasonidos a escala de grises y a color	<i>Cuckoo search</i> (CS)	<ul style="list-style-type: none"> <li>▪ <i>Davies-Bouldin Index</i> (DBI)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> <li>▪ <i>Dunn's Index</i> (DI)</li> <li>▪ <math>\beta</math> Index</li> <li>▪ <i>Sensitivity</i></li> <li>▪ <i>Specificity</i></li> <li>▪ <i>Jaccard Index</i> (JI)</li> <li>▪ <i>DICE Index</i> (DICE-I)</li> <li>▪ <i>Pixelwise Accuracy</i> (PACC)</li> </ul>
89	(Zhou & Zhao, 2022)	<i>Self-Organizing Maps - Fuzzy C-Means</i> (SOM-FCM)	Industria Automotriz	Centros iniciales	Modelo de simulación de una línea de ensamblaje de automóviles real en Plant Simulation 15	<i>Self-Organizing Maps</i> (SOM)	<ul style="list-style-type: none"> <li>▪ <i>Throughput</i> (P)</li> <li>▪ <i>Total Travel Distance of AGVs</i> (D)</li> <li>▪ <i>Objective Function Value</i> (OFV)</li> <li>▪ <i>Gap</i> (GAP)</li> </ul>
90	(Anita Davamani et al., 2022)	<i>Adaptive Fuzzy C-Means</i> (A-FCM)	Biomedicina	Número de iteraciones, exponente de ponderación y Umbral de convergencia	Blood Cell Count and Detection (BCCD): Incluye imágenes de diferentes tipos de células sanguíneas como glóbulos rojos (RBC), glóbulos blancos (WBC) y plaquetas	<i>Best search-based Moth-Flame Optimization</i> (BS-MFO)	<ul style="list-style-type: none"> <li>▪ <i>Accuracy</i> (ACC)</li> <li>▪ <i>Sensitivity</i></li> <li>▪ <i>Specificity</i></li> <li>▪ <i>Precision</i> (PR)</li> <li>▪ <i>False Positive Rate</i> (FPR)</li> <li>▪ <i>False Negative Rate</i> (FNR)</li> <li>▪ <i>Negative Predictive Value</i> (NPV)</li> <li>▪ <i>False Discovery Rate</i> (FDR)</li> <li>▪ <i>F1-Score</i> (F1)</li> <li>▪ <i>Matthews Correlation Coefficient</i> (MCC)</li> </ul>

91	(Y. Zhang et al., 2022)	Improved FCM algorithm	Tomografía de Capacitancia Eléctrica	Centros iniciales	Utilizan un instrumento de medición de imagen capacitiva de matriz plana (Planar capacitance sensor)	<i>Particle swarm optimization algorithm (PSO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Relative Image Error (RIE)</i></li> <li>▪ <i>Image Correlation Coefficient (ICC)</i></li> <li>▪ <i>Positional Error (PE)</i></li> </ul>
92	(Saberi et al., 2022)	<i>Improved Possibilistic Fuzzy C-Means</i> (IPFCM)	Movimientos sísmicos	Centros iniciales	Balance Scale, Breast Cancer, High Time Resolution Universe Survey (HTRU2), Fisher's Iris y New Thyroid	<i>Possibilistic Fuzzy C-Means</i> (PFCM)	<ul style="list-style-type: none"> <li>▪ <i>Dunn's Index (DI)</i></li> <li>▪ <i>Silhouette Index (SI)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Davies-Bouldin Index (DBI)</i></li> </ul>
93	(Das et al., 2022)	Eagle Strategy with Stochastic Fractal Search based Fuzzy Clustering with Morphological Reconstruction (SFSFCMR)	Segmentación de imágenes	Centros iniciales	Imágenes microscópicas de leucemia linfoblástica aguda (ALL)	<i>Eagle Strategy based on Stochastic Fractal Search (SFS) y Morphological Reconstruction (MR)</i>	<ul style="list-style-type: none"> <li>▪ <i>Peak Signal to Noise Ratio (PSNR)</i></li> <li>▪ <i>Quality Index based on Local Variance (QILV)</i></li> <li>▪ <i>Feature Similarity Index (FSIM)</i></li> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Precision (PR)</i></li> <li>▪ <i>Recall (RE)</i></li> <li>▪ <i>F1-Score (F1)</i></li> </ul>
94	(Alomoush et al., 2022)	<i>Fuzzy Clustering Algorithm Based on Improved Global Best-Guided Artificial Bee Colony with New Search Probability</i> (PIABC-FCM)	Segmentación de imágenes	Centros iniciales	Datos provenientes del Berkeley Segmentation Dataset: Lena, Baboon, Pepper, Airplane y Cameraman	<i>Improved Global Best-Guided Artificial Bee Colony</i> (PIABC)	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient (PC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Subarea Coefficient (SC)</i></li> <li>▪ <i>Separation Index (SI)</i></li> </ul>
95	(Banerjee & Abu-Mahfouz, 2022)	<i>Cooperative Differential Evolution for Fuzzy C-Means</i> (CDE-FCM)	Detección de fallas	Centros iniciales y número de clústeres	Data1 y Data2: Datos sintéticos generados, datos obtenidos del repositorio UCI Machine y datos obtenidos de un experimento de monitoreo de salud de máquinas en tiempo real	<i>Cooperative Multi-Population Differential Evolution with Elitism</i>	<ul style="list-style-type: none"> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>Bensaid Index (VB)</i></li> <li>▪ <i>Tang Index (TI)</i></li> <li>▪ <i>Modified Kwon Index (VK2)</i></li> <li>▪ <i>Ren Index (VR)</i></li> <li>▪ <i>Fukuyama-Sugeno Index (FSI)</i></li> <li>▪ <i>Partition Coefficient (PC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Precision (PR)</i></li> <li>▪ <i>Recall (RE)</i></li> <li>▪ <i>Rand Index (RI)</i></li> <li>▪ <i>F1-Score (F1)</i></li> </ul>

96	(C.-M. Yang et al., 2022)	<i>Kernel-based Picture Fuzzy C-Means clustering with Grey Wolf Optimizer (KPFM-GWO)</i>	Segmentación de mercados	Métrica de distancia y centros iniciales	Iris, Wine, Glass, Wisconsin Diagnostic Breast Cancer y Airline	<i>Grey Wolf Optimizer (GWO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Silhouette Index (SI)</i></li> <li>▪ <i>Calinski-Harabasz Index (CHI)</i></li> <li>▪ <i>Adjusted Rand Index (ARI)</i></li> <li>▪ <i>Accuracy (ACC)</i></li> </ul>
97	(P. Li et al., 2022)	<i>Twice Grid Optimization and Sparrow Search Algorithm optimized Fuzzy C-Means (TGO-SSA-FCM)</i>	Control de tráfico	Centros iniciales, Número de clústeres y Exponente de ponderación	Los datos de sensores de tráfico en el Distrito de Shunyi, Beijing, China.	<i>Twice Grid Optimization (TGO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Root Mean Squared Error (RMSE)</i></li> <li>▪ <i>Relative Accuracy (RACC)</i></li> <li>▪ <i>Mean Absolute Error (MAE)</i></li> </ul>
98	(Mohammadian-khosnoud et al., 2022)	<i>Fuzzy C-Means Gray Wolf Optimization (FCMGWO)</i>	Segmentación de imágenes	Centros iniciales	Imágenes de citología de mama generadas por una cámara echo-LAB montada en un microscopio echoLAB con un aumento de 400x	<i>Gray Wolf Optimization (GWO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Partition Coefficient (PC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Davies-Bouldin Index (DBI)</i></li> <li>▪ <i>Calinski-Harabasz Index (CHI)</i></li> </ul>
99	(Varshney et al., 2023)	<i>Density based Intuitionistic Fuzzy C-Means (DIFCM)</i>	Clustering	Centros iniciales y número clústeres	Balance scale, Breast cancer, Car evaluation, Dermatology, Ecoli, Glass, Image segmentation, Iris, Ionosphere, Seeds, Wine y Zoo	<i>Density-based initialization technique (DIF)</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Partition Entropy (PE)</i></li> <li>▪ <i>Partition Coefficient (PC)</i></li> </ul>
100	(C. Zhang et al., 2023)	<i>Modified Fuzzy C-Means Clustering Algorithm with Statistical Histogram Initialization (MFCM-SHI)</i>	Simplificación de nubes de puntos 3D	Centros iniciales y número de clústeres	Datos de CSDN: Satélite, Conejo (Bunny), Caballo (Horse) y Pala de turbina (Turbine blade)	<i>Statistical Histogram Method (SHM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Execution Time (ET)</i></li> <li>▪ <i>Simplification Quality (SQ)</i></li> </ul>
101	(Kuo et al., 2023)	<i>Density Peak Genetic Algorithm Possibilistic Fuzzy C-Means (DP-GA-PFCM)</i>	Segmentación de mercados	Centros iniciales y número de clústeres	Iris Flame, Jain, Wine, Glass, Ecoli, Compound, Seed, Breast Tissue, Aggregation, Pima, Room Occupancy, Rice y Wifi	<i>Density Peak Clustering (DPC) y Elbow Method (EM)</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy (ACC)</i></li> <li>▪ <i>Adjusted Rand Index (ARI)</i></li> <li>▪ <i>Normalized Mutual Information (NMI)</i></li> </ul>
102	(S. Wang et al., 2023)	<i>Adaptive Chaotic Annealing Particle Swarm Optimization Fuzzy C-Means Clustering Algorithm (ACAPSO-FCM)</i>	Ingeniería geotécnica	Centros iniciales	Datos de un túnel en Huayang, Chongqing, China	<i>Adaptive chaotic annealing particle swarm optimization (ACAPSO)</i>	<ul style="list-style-type: none"> <li>▪ <i>Separation Capacity (Vpc)</i></li> <li>▪ <i>Separation Entropy (Vpe)</i></li> <li>▪ <i>Xie-Beni Index (XBI)</i></li> <li>▪ <i>F1-Score (F1)</i></li> </ul>

103	(Y. Tang et al., 2023)	<i>Viewpoint-Driven Subspace Fuzzy C-Means</i> (VSFCM)	Clustering	Centros iniciales	Iris, Wireless Indoor, Localization, Wine, Breast Cancer Wisconsin, Seeds, Letter Recognition (A, B), Ionosphere SPECT heart data, Aggregation, Zoo, DATA1 (Datos Sintéticos) y DATA2 (Datos Sintéticos)	<i>Cut-off Distance-Induced Clustering Initialization</i> (CDCI)	<ul style="list-style-type: none"> <li>▪ <i>Partition Index</i> (PI)</li> <li>▪ <i>Normalized Mutual Information</i> (NMI)</li> <li>▪ <i>Calinski-Harabasz Index</i> (CHI)</li> <li>▪ <i>Extended Adjusted Rand Index</i> (EARI)</li> <li>▪ <i>Xie-Beni Index</i> (XBI)</li> </ul>
104	(F. Guo et al., 2023)	<i>Hierarchical Clustering-Fuzzy C-Means</i> (HAC-FCM)	Detección y clasificación de desechos espaciales	Centros iniciales y número de clústeres	Datos de muestras de desechos espaciales en un entorno de laboratorio	<i>Hierarchical Agglomerative Clustering</i> (HAC)	<ul style="list-style-type: none"> <li>▪ <i>Degree of Polarization</i> (DOLP)</li> <li>▪ <i>Polarimetric Bidirectional Reflectance Distribution Function</i> (pBRDF)</li> <li>▪ <i>Polarization State Analyzer</i> (PSA)</li> <li>▪ <i>Full Average Filter</i> (FAF)</li> </ul>
105	(Arakeri et al., 2024)	<i>Efficient Fuzzy C-Means</i> (EFCM)	Segmentación de imágenes	Centros iniciales	Imágenes de tomografía computarizada (CT) del abdomen del Shirdi Sai Cancer Hospital y Bapuji Cancer Hospital de la India y el conjunto de datos 3D-ircadb	<i>Intensity value represented by the histogram peaks</i>	<ul style="list-style-type: none"> <li>▪ <i>Accuracy</i> (ACC)</li> <li>▪ <i>Silhouette Index</i> (SI)</li> <li>▪ <i>Davies-Bouldin Index</i> (DBI)</li> <li>▪ <i>Area Under Curve</i> (AUC)</li> </ul>
106	(Ma et al., 2024)	<i>Equidistance index IFCM</i> (EI-IFCM)	Clustering	Centros iniciales y número de clústeres	Iris, Wine, Cancer, Satimage, Heart, Seeds, Abalone, Avila y Shuttle	<i>Equidistance Index</i> (EI)	<ul style="list-style-type: none"> <li>▪ <i>Rand Index</i> (RI)</li> <li>▪ <i>Adjusted Rand Index</i> (ARI)</li> <li>▪ <i>Adjusted Mutual Information</i> (AMI)</li> <li>▪ <i>Fowlkes and Mallows Index</i> (FMI)</li> <li>▪ <i>Execution Time</i> (ET)</li> <li>▪ <i>Number of Iterations</i> (NoI)</li> </ul>
107	(Sun et al., 2024)	<i>Multi-Strategy Tuna Swarm Optimization- Fuzzy C-Means</i> (MSTSO-FCM)	Segmentación de imágenes	Matriz inicial	Iris, Liver, Heart, Pima y Waveform	<i>Multi-Strategy Tuna Swarm Optimization</i> (MSTSO)	<ul style="list-style-type: none"> <li>▪ <i>Accuracy</i> (ACC)</li> <li>▪ <i>Silhouette Index</i> (SI)</li> <li>▪ <i>Davies-Bouldin Index</i> (DBI)</li> <li>▪ <i>Area Under Curve</i> (AUC)</li> </ul>
108	(Quan et al., 2024)	<i>Subtractive Clustering-Based Particle Swarm Optimization Fuzzy C-Means</i> (SC-PSO-FCM)	Sistemas de comunicación	Centros iniciales	Datos de señales moduladas digitalmente	<i>Subtractive clustering</i> (SC) y algorithm based on the signal-to-noise ratio (SN-SC)	<ul style="list-style-type: none"> <li>▪ <i>Modulation Recognition Rate</i> (MRR)</li> <li>▪ <i>Number of Local Optima</i> (NLO)</li> <li>▪ <i>Objective Function Value</i> (OFV)</li> </ul>

### 5.3. Respuesta a la Pregunta 3 de la revisión sistemática

Para dar respuesta a la Pregunta 3 (¿Cuáles son las características de las mejoras del algoritmo FCM para su inicialización?, por ejemplo: dominio, métodos utilizados, tipo de datos y métricas), se presenta una lista de los 39 dominios localizados, en donde fueron aplicadas las mejoras del algoritmo FCM (Tabla 8).

Tabla 8. Tendencias de dominios de las mejoras de FCM.

#	Dominio	Tendencia	#	Dominio	Tendencia
1	Segmentación de imágenes	34	21	Ingeniería geotécnica	1
2	Clustering	25	22	Servicio médico	1
3	Big Data	3	23	Mercado de valores	1
4	Bioinformática	3	24	Minería de texto	1
5	Teledetección (Remote sensing)	3	25	Minería y procesamiento de minerales	1
6	Clasificación de señales	2	26	Movimientos sísmicos	1
7	Control de tráfico	2	27	Optimización de sistemas hidráulicos	1
8	ingeniería de petróleo y gas	2	28	Producción de plantillas de PCB	1
9	Negocios/Marketing	2	29	Protección de la privacidad	1
10	Minería de uso de la Web	2	30	Maquinaria rotativa	1
11	Redes complejas	1	31	Segmentación de imágenes	1
12	Detección de fallas	1	32	Segmentación de mercados	1
13	Detección y caracterización de sub estructuras	1	33	Simplificación de nubes de puntos 3D	1
14	Detección y clasificación de desechos espaciales	1	34	Sistemas de comunicación	1
15	Extracción de colores dominantes	1	35	Sistemas Neuro Difusos	1
16	Tomografía de capacitancia eléctrica	1	36	Vigilancia aérea y el seguimiento de aviones	1
17	Espectroscopía de terahercios (THz)	1	37	Visión por computadora	1
18	Gestión del transporte	1	38	Desulfuración húmeda de gases de combustión	1
19	Identificación de estructuras de modelos difusos	1	39	Energía Eólica	1
20	Industria Automotriz	1			

También, se presentan los métodos utilizados en más de una investigación (Tabla 9). Y, por otro lado, se presenta una gráfica para representar los tipos de datos utilizados en los estudios (Ilustración 4). Y, una gráfica de las categorías del tipo de métodos con mayor recurrencia (Ilustración 5).

Tabla 9. Métodos más recurrentes en la literatura para mejorar la inicialización de FCM.

Métodos	Apariciones Métodos
<i>Genetic Algorithm (GA)</i>	6
<i>Particle Swarm Optimization (PSO)</i>	4
<i>Ant Colony Optimization (ACO)</i>	3
<i>K-means</i>	2
<i>Entropy</i>	2
<i>Cluster weighting</i>	2
<i>Firefly Algorithm (FA)</i>	2
<i>Grey Wolf Optimizer (GWO)</i>	2

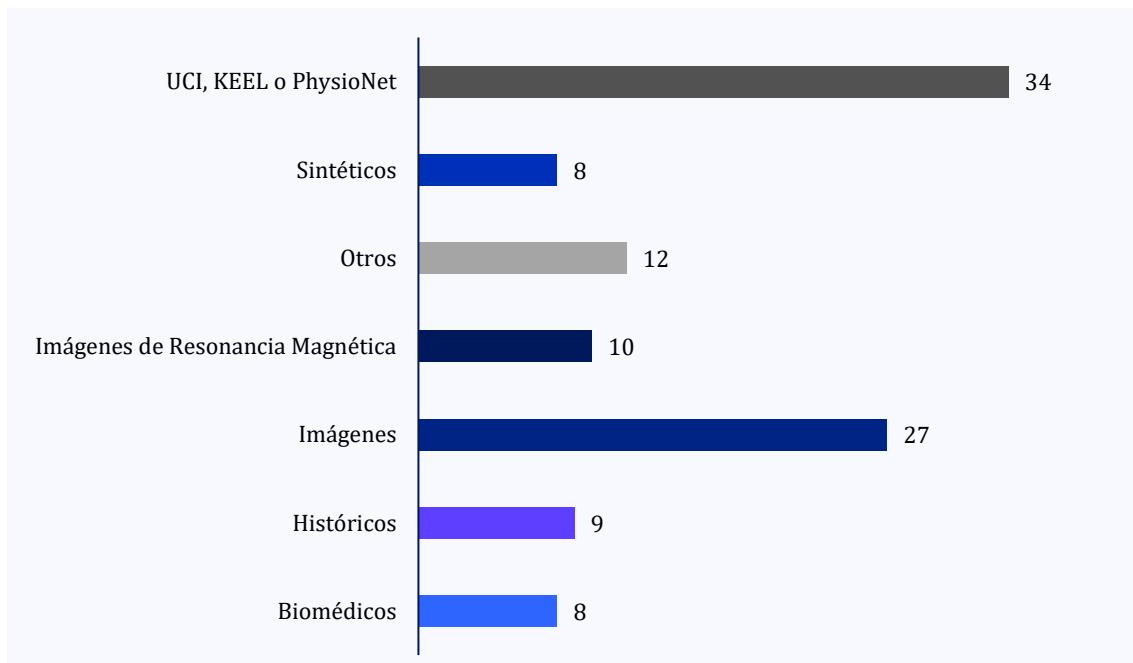


Figura 5. Tipo de datos utilizados en las mejoras de FCM.

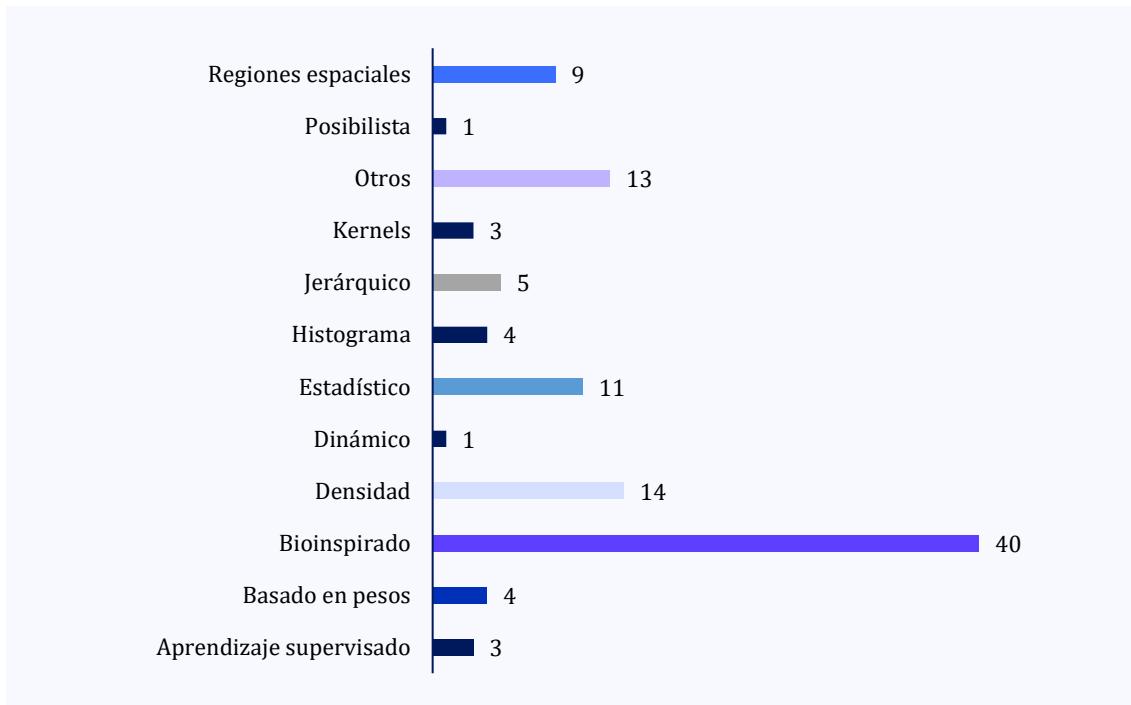


Figura 6. Métodos con mayor recurrencia en las mejoras de FCM.

## 5.4. Respuesta a la Pregunta 4 de la revisión sistemática

Finalmente, en respuesta a la Pregunta 4 (*¿Cuáles son los artículos de las mejoras para inicializar FCM con mayor relevancia en investigación?*) se destacan los artículos más citados y su dominio de aplicación. De este modo, fue posible proporcionar un punto de referencia de los estudios más influyentes para investigaciones futuras. El número de citas se tomó de *Google Scholar* (Tabla 9).

Tabla 10. Artículos de las mejoras de FCM con mayor número de citas.

Referencia	Dominio	Citas en Google
(Gunderson, 1983)	Detección y caracterización de subestructuras	4,141
(Yager & Filev, 1994)	Visión por computadora	918
(Hung & Yang, 2001)	Agrupamiento en general	262
(Ding & Fu, 2016)	Agrupamiento en general	250
(Benaichouche et al., 2013)	Segmentación de imágenes	205
(X. Y. Wang & Bu, 2010)	Segmentación de imágenes	200
(Cheng et al., 1998)	Segmentación de imágenes	197
(J. Fan et al., 2009)	Agrupamiento en general	170
(Yu et al., 2010)	Segmentación de imágenes	166
(W. Wang et al., 2006)	Agrupamiento en general	154
(D.-W. Kim et al., 2004) -	Segmentación de imágenes	140
(Stetco et al., 2015)	Agrupamiento en general	130
(Mekhmoukh & Mokrani, 2015)	Segmentación de imágenes	126
(Zhang et al., 2011)	Segmentación de imágenes	125
(Yang et al., 2021)	Parques Eólicos	120
(Kuo et al., 2018)	Negocios/Marketing	96
(Maraziotis, 2012)	Bioinformática	90
(Hashemzadeh et al., 2019)	Agrupamiento en general	89
(Haldar et al., 2017)	Datos médicos	86
(L. Liu et al., 2016)	Ingeniería de petróleo y gas	80

## Capítulo 6

# Discusión de los resultados

En este capítulo se presenta una discusión de hallazgos con relevancia para investigación. Estas tendencias fueron observadas a partir de la revisión sistemática realizada sobre las mejoras para la inicialización de FCM.

## 6.1. Otros hallazgos

En primer lugar, se encontró la que hubo modificaciones en 6 elementos diferentes como: 1) centros iniciales, 2) matriz inicial, 3) número de clústeres, 4) número de iteraciones, 5) exponente de ponderación, 6) métrica de distancia y 7) el umbral de convergencia (Ilustración 7).

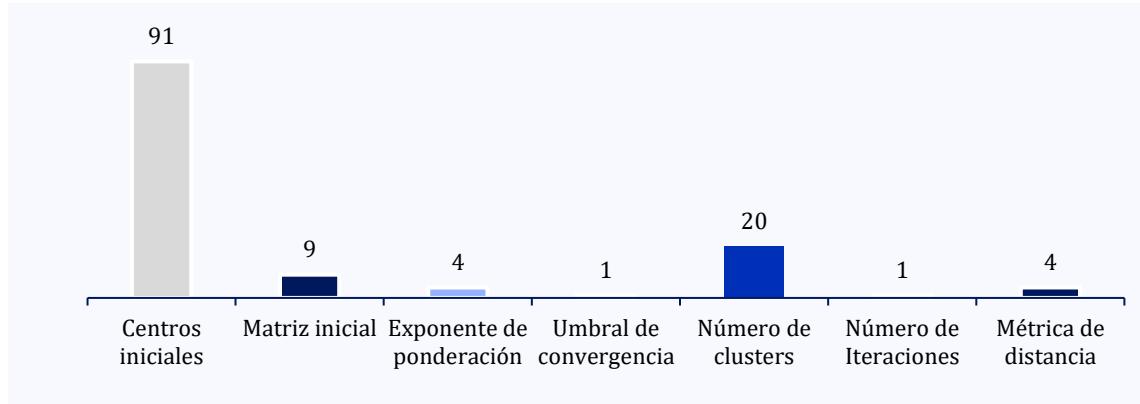


Figura 7. Tendencia de los elementos en FCM con mayor recurrencia de modificación.

Después, fue posible observar una gran cantidad de métricas de evaluación utilizadas para distintos contextos: para medir el error de agrupamiento, para evaluar el tiempo, para evaluar carga computacional, por mencionar algunos (Tabla 11).

Tabla 11. Número de ocurrencias de las métricas de evaluación.

Top de métricas localizadas en la revisión	Total	Top de métricas localizadas en la revisión	Total
Accuracy (ACC)	27	Mean Squared Error (MSE)	6
Partition Coefficient (PC)	14	Computation Time (CT)	5
Partition Entropy (PE)	14	Adjusted Rand Index (ARI)	5
Number of Iterations (NoI)	13	Root Mean Squared Error (RMSE)	5
F1-Score (F1)	11	Sensitivity	5
Objective Function Value (OFV)	9	Fukuyama-Sugeno Index (FSI)	5
Precision (PR)	9	Rand Index (RI)	5
Silhouette Index (SI)	9	Time Consumed (TC)	5
Xie-Beni Index (XBI)	9	Dunn's Index (DI)	4
Davies-Bouldin Index (DBI)	8	Peak Signal to Noise Ratio (PSNR)	4
Error Rate (ER)	7	Specificity	4
Normalized Mutual Information (NMI)	7	DICE Index (DICE-I)	4
Xie-Beni Index (XBI)	7	Jaccard Index (JI)	4
Recall (RE)	6	Execution Time (ET)	3
Running Time (RT)	6	Compact and Separation Function (CSF)	3

## Capítulo 7

# Conclusiones

Este capítulo se presenta las conclusiones obtenidas a partir de la revisión sistemática de las mejoras propuestas para la inicialización del algoritmo Fuzzy C-Means (FCM). Además, se exponen los aportes de la investigación y se plantean posibles líneas de trabajo futuro, con el objetivo de orientar investigaciones posteriores en la optimización de FCM.

## 7.1. Conclusiones

La investigación de tesis permitió la elaboración de una revisión sistemática basada en la metodología PRISMA, PICO y el método de las 5W's+1H para la búsqueda exhaustiva de las mejoras del algoritmo FCM para su inicialización. El desarrollo de este marco metodológico permitió alcanzar los objetivos planteados y proporcionó una comprensión integral de las tendencias actuales, reflejando hallazgos relevantes:

- Se identificaron 108 mejoras con 95 métodos diferentes utilizados para mejorar la inicialización del algoritmo FCM aplicadas en más de 30 dominios diferentes. Además, se encontró el uso de datos de tipo históricos, sintéticos y reales descargados desde: UC Irvine Machine Learning Repository, Keel o PhysioNet. Y, se localizaron más de 150 métricas de evaluación empleadas para medir aspectos como el error de agrupamiento, los tiempos de ejecución y la calidad de la agrupación (por ejemplo, exactitud y sensibilidad).
- Las mejoras identificadas se describieron de manera individual, lo que proporcionó una visión integral de las características de los métodos implementados a lo largo del tiempo.
- La clasificación de las mejoras implementadas en diferentes categorías, por el tipo de método implementado, elemento modificado, tipo de datos utilizados, tipo de métrica y dominio de aplicación, permitió detectar patrones en los enfoques implementados.
- Y, fue posible hacer una discusión de los hallazgos como la tendencia de los elementos modificados de FCM para mejorar su inicialización, los dominios de aplicación con mayor relevancia y los métodos que más se han utilizado para modificar el algoritmo.

De este modo, con la compilación, descripción y clasificación de las mejoras fue posible reflejar la evolución del algoritmo y su adaptación a diversas necesidades en diferentes dominios de aplicación, el tipo de datos utilizados y la variedad de métricas existentes para evaluar las mejoras implementadas. Esta información representa una herramienta valiosa para investigadores interesados en algoritmos de agrupamiento, ya que les permite seleccionar la mejora del algoritmo FCM más adecuada a sus necesidades específicas.

## 7.2. Trabajos futuros

Por último, las tendencias observadas en los métodos y dominios analizados sugieren varias direcciones para futuras investigaciones. Estas incluyen:

- Desarrollo de nuevas estrategias de inicialización de FCM: Incorporación de métodos que no se hayan aplicado para mejorar la inicialización de FCM.
- Estudios comparativos de variantes de FCM: Evaluación de las mejoras de FCM aplicado en contextos diferentes para analizar su desempeño.
- Extensión de las mejoras de FCM: Adaptación de las mejoras de FCM hacia diversos dominios para inferir en dominios poco explorados.

- Optimización de los métodos existentes: Desarrollo de mejoras para optimizar los resultados, reducir el tiempo de cómputo y mejorar el algoritmo ante los valores iniciales.
- Revisiones sobre FCM: Exploración del algoritmo en dominios específicos, estudio sobre otro tipo de mejoras realizadas a FCM, estudios comparativos y la exploración de enfoques híbridos de FCM, el estudio de la aplicación del algoritmo en dominios específicos, evaluar la aplicación de distintas mejoras de FCM y el desarrollo de nuevas mejoras con métodos que no se hayan implementado.

## Referencias

- A-Alam, N., Khan, M. S. I., & Nasir, M. K. (2023). Using fused Contourlet transform and neural features to spot COVID19 infections in CT scan images. *Intelligent Systems with Applications*, 17. <https://doi.org/10.1016/J.ISWA.2023.200182>
- Abdellahoum, H., Mokhtari, N., Brahim, A., & Boukra, A. (2021). CSFCM: An improved fuzzy C-Means image segmentation algorithm using a cooperative approach. *Expert Systems with Applications*, 166. <https://doi.org/10.1016/J.ESWA.2020.114063>
- Abdu, K. K., Faiza, B., & Alias, R. A. (2014). A review and analysis of fuzzy-c means clustering techniques. *International Journal of Scientific & Engineering Research*, 5(11).
- Ahmed, M. N., Yamany, S. M., Mohamed, N., Farag, A. A., & Moriarty, T. (2002). A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data. *IEEE Transactions on Medical Imaging*, 21(3), 193–199. <https://doi.org/10.1109/42.996338>
- Ahmmmed, R., & Hossain, Md. F. (2016). Tumor detection in brain MRI image using template based K-means and Fuzzy C-means clustering algorithm. *2016 International Conference on Computer Communication and Informatics (ICCCI)*, 1–6. <https://doi.org/10.1109/ICCCI.2016.7479972>
- Ali, A., Dooley, L. S., & Karmakar, G. C. (2005). AUTOMATIC FEATURE SET SELECTION FOR MERGING IMAGE SEGMENTATION RESULTS USING FUZZY CLUSTERING.
- Ali, A., Karmakar, G., & Dooley, L. (2004). Fuzzy Image Segmentation using Suppressed Fuzzy C-Means Clustering (SFCM).
- Ali, M. A., Dooley, L. S., & Karmakar, G. C. (2006). Object Based Image Segmentation Using Fuzzy Clustering. *2006 IEEE International Conference on Acoustics Speed and Signal Processing*, 2, II-105-II-108. <https://doi.org/10.1109/ICASSP.2006.1660290>
- Ali, M. A., Karmakar, G. C., & Dooley, L. S. (2008). Review on Fuzzy Clustering Algorithms. *Journal of Advanced Computations*, 2, 169–181.
- Alomoush, W., Khashan, O. A., Alrosan, A., Houssein, E. H., Attar, H., Alweshah, M., & Alhosban, F. (2022). Fuzzy Clustering Algorithm Based on Improved Global Best-Guided Artificial Bee Colony with New Search Probability Model for Image Segmentation. *Sensors*, 22(22), Article 22. <https://doi.org/10.3390/s22228956>
- Alsmirat, M. A., Jararweh, Y., Al-Ayyoub, M., Shehab, M. A., & Gupta, B. B. (2017). Accelerating compute intensive medical imaging segmentation algorithms using hybrid CPU-GPU implementations. *Multimedia Tools and Applications*, 76(3), 3537–3555. <https://doi.org/10.1007/s11042-016-3884-2>
- Al-Zoubi, M. B., Hudaib, A., & Al-Shboul, B. (2007). A fast fuzzy clustering algorithm. *6th WSEAS Int. Conf. on Artificial Intelligence, Knowledge Engineering and Data Bases*, 6, 28–32.
- Anita Davamani, K., Rene Robin, C. R., Doreen Robin, D., & Jani Anbarasi, L. (2022). Adaptive blood cell segmentation and hybrid Learning-based blood cell classification: A Meta-heuristic-based model. *Biomedical Signal Processing and Control*, 75. <https://doi.org/10.1016/J.BSPC.2022.103570>
- Ansari, Z., Sattar, S. A., Babu, A. V., & Azeem, M. F. (2015). Mountain density-based fuzzy approach for discovering web usage clusters from web log data. *Fuzzy Sets and Systems*, 279, 40–63. <https://doi.org/10.1016/j.fss.2015.01.021>
- Arakeri, M., Lakshmana, Reddy, R., Ravishankar, H., & Deepa, K. R. (2024). An Enhanced Approach to Intelligent Computer-Assisted Localization of Liver Tumor on Computed Tomography Images. *SN Computer Science*, 5(7), 809. <https://doi.org/10.1007/s42979-024-03145-0>
- Arora, J., Khatter, K., & Tushir, M. (2019). *Fuzzy c-Means Clustering Strategies: A Review of Distance Measures* (pp. 153–162). [https://doi.org/10.1007/978-981-10-8848-3\\_15](https://doi.org/10.1007/978-981-10-8848-3_15)

- Aydilek, I. B., & Arslan, A. (2013). A hybrid method for imputation of missing values using optimized fuzzy c-means with support vector regression and a genetic algorithm. *Information Sciences*, 233, 25–35. <https://doi.org/10.1016/j.ins.2013.01.021>
- Azzaoui, H., Mansouri, I., & Elkhiel, B. (2019). Methylcyclohexane Continuous Distillation Column Fault Detection Using Stationary Wavelet Transform & Fuzzy C-means. *Materials Today: Proceedings*, 13.
- Babuka, R., Van Der Veen, P. J., & Kaymak, U. (2002). Improved covariance estimation for Gustafson-Kessel clustering. *2002 IEEE World Congress on Computational Intelligence. 2002 IEEE International Conference on Fuzzy Systems. FUZZ-IEEE'02*, 2, 1081–1085. <https://doi.org/10.1109/FUZZ.2002.1006654>
- Babuška, R., & Verbruggen, H. B. (1996). An overview of fuzzy modeling for control. *Control Engineering Practice*, 4(11), 1593–1606. [https://doi.org/10.1016/0967-0661\(96\)00175-X](https://doi.org/10.1016/0967-0661(96)00175-X)
- Babuška, R., & Verbruggen, H. B. (1997). Constructing Fuzzy Models by Product Space Clustering. *Fuzzy Model Identification*, 53–90.
- Bach, F. R., Lanckriet, G. R. G., & Jordan, M. I. (2004). Multiple kernel learning, conic duality, and the SMO algorithm. *Twenty-First International Conference*, 6. <https://doi.org/10.1145/1015330.1015424>
- Bai, C., Dhavale, D., & Sarkis, J. (2016). Complex investment decisions using rough set and fuzzy c-means: An example of investment in green supply chains. *European Journal of Operational Research*, 248(2), 507–521. <https://doi.org/10.1016/j.ejor.2015.07.059>
- Balasubramaniam, P., & Ananthi, V. P. (2016). Segmentation of nutrient deficiency in incomplete crop images using intuitionistic fuzzy C-means clustering algorithm. *Nonlinear Dynamics*, 83.
- Ball, G. H. (1965). *Data analysis in the social sciences: What about the details?* 533–559.
- Ball, G. H., & Hall, D. J. (1965). *ISODATA, A NOVEL METHOD OF DATA ANALYSIS AND PATTERN CLASSIFICATION*. <https://api.semanticscholar.org/CorpusID:53887616>
- Banerjee, A., & Abu-Mahfouz, I. (2022). A Novel Adaptive FCM with Cooperative Multi-Population Differential Evolution Optimization. *Algorithms*, 15(10), Article 10. <https://doi.org/10.3390/a15100380>
- Bellman, R., Kalaba, R., & Zadeh, L. (1966). Abstraction and pattern classification. *Journal of Mathematical Analysis and Applications*, 13(1), 1–7. [https://doi.org/10.1016/0022-247X\(66\)90071-0](https://doi.org/10.1016/0022-247X(66)90071-0)
- Bezdek, J. C. (1973). *Fuzzy Mathematics in Pattern Classification*.
- Bezdek, J. C. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*. <https://doi.org/10.1007/978-1-4757-0450-1>
- Bezdek, J. C., Coray, C., Gunderson, R., & Watson, J. (1981a). Detection and Characterization of Cluster Substructure I. Linear Structure: Fuzzy  $c$ -Lines. *SIAM Journal on Applied Mathematics*, 40(2), 339–357. <https://doi.org/10.1137/0140029>
- Bezdek, J. C., Coray, C., Gunderson, R., & Watson, J. (1981b). Detection and Characterization of Cluster Substructure II. Fuzzy  $c$ -Varieties and Convex Combinations Thereof. *SIAM Journal on Applied Mathematics*, 40(2), 358–372. <https://doi.org/10.1137/0140030>
- Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10(2–3), 191–203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
- BEZDEK, J. C., & HATHAWAY, R. J. (1990). DUAL OBJECT-RELATION CLUSTERING MODELS. *International Journal of General Systems*, 16(4), 385–396. <https://doi.org/10.1080/03081079008935090>
- Bezdek, J. C., Hathaway, R. J., & Nikhil, R. P. L. (1995). Norm-induced shell-prototypes (NISP) clustering. 3(4), 431–449.

- Bharill, N., & Tiwari, A. (2014a). Handling Big Data with Fuzzy Based Classification Approach. *Advance Trends in Soft Computing*, 312, 219–227.
- Bharill, N., & Tiwari, A. (2014b). Handling Big Data with Fuzzy Based Classification Approach. *Advance Trends in Soft Computing*, 312, 219–227.
- Bloomfield, P., & Steiger, W. L. (1983). Least absolute deviations: Theory, applications, and algorithms. *Progress in probability and statistics*, 349.
- Bobrowski, L., & Bezdek, J. C. (1991). C-means clustering with the  $l_1$  and  $l_\infty$  norms. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 545–554. <https://doi.org/10.1109/21.97475>
- Bobrowski, L., & Niemiro, W. (1984). A method of synthesis of linear discriminant function in the case of nonseparability. *Pattern Recognition*, 17(2), 205–210. [https://doi.org/10.1016/0031-3203\(84\)90059-1](https://doi.org/10.1016/0031-3203(84)90059-1)
- Cai, R., & Yu, F. (2009). Fuzzy Temporal Constraints Based Fuzzy Clustering Algorithm for Temporal Dadaset. *2009 Sixth International Conference on Fuzzy Systems and Knowledge Discovery*, 480–484. <https://doi.org/10.1109/FSKD.2009.461>
- Cai, W., Chen, S., & Zhang, D. (2007). Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation. *Pattern Recognition*, 40(3), 825–838. <https://doi.org/10.1016/j.patcog.2006.07.011>
- Cannon, R. L., Dave, J. V., & Bezdek, J. C. (1986). Efficient Implementation of the Fuzzy c-Means Clustering Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2, 248–255. <https://doi.org/10.1109/TPAMI.1986.4767778>
- Cao, S. Q., Zuo, X. M., Tao, A. X., Wang, J. M., & Chen, X. Z. (2012). A Bearing Intelligent Fault Diagnosis Method Based on Cluster Analysis. *Applied Mechanics and Materials*, 152, 1628–1633. <https://doi.org/10.4028/www.scientific.net/AMM.152-154.1628>
- Cardone, B., Di Martino, F., & o. (2020). A Novel Fuzzy Entropy-Based Method to Improve the Performance of the Fuzzy C-Means Algorithm. *Electronics*, 9(4), 554. <https://doi.org/10.3390/electronics9040554>
- Cebeci, Z., & Cebeci, C. (2020). A Fast Algorithm to Initialize Cluster Centroids in Fuzzy Clustering Applications. *Information*, 11(9), Article 9. <https://doi.org/10.3390/info11090446>
- Celikyilmaz, A., & Burhan Turksen, I. (2008). Enhanced Fuzzy System Models With Improved Fuzzy Clustering Algorithm. *IEEE Transactions on Fuzzy Systems*, 16(3), 779–794. <https://doi.org/10.1109/TFUZZ.2007.905919>
- Celikyilmaz, A., & Turksen, I. B. (2008). Uncertainty Modeling of Improved Fuzzy Functions With Evolutionary Systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 38(4), 1098–1110. <https://doi.org/10.1109/TSMCB.2008.924587>
- Celikyilmaz, A., & Türksen, I. B. (2009). Modeling Uncertainty with Fuzzy Logic. *Studies in Fuzziness and Soft Computing*, 240. <http://link.springer.com/10.1007/978-3-540-89924-2>
- Chakraborty, S. (2024). FMCSSE: Fuzzy modified cuckoo search with spatial exploration for biomedical image segmentation. *Soft Computing*. <https://doi.org/10.1007/s00500-024-09905-7>
- Chaomurilige, Yu, J., & Yang, M. S. (2017). Deterministic annealing Gustafson-Kessel fuzzy clustering algorithm. *Information Sciences*, 417, 435–453. <https://doi.org/10.1016/J.INS.2017.07.005>
- Chattaraj, A., & Das, A. (2016). Mammographie image segmentation using kernel based FCM clustering approach. *2016 International Conference on Computer, Electrical & Communication Engineering (ICCECE)*, 1–6. <https://doi.org/10.1109/ICCECE.2016.8009576>

- Chatzis, S., & Varvarigou, T. (2009). Factor Analysis Latent Subspace Modeling and Robust Fuzzy Clustering Using t-Distributions. *IEEE Transactions on Fuzzy Systems*, 17(3), 505–517. <https://doi.org/10.1109/TFUZZ.2008.924317>
- Chen, L., Lu, M., & Chen, C. L. P. (2010). Multiple kernel fuzzy C-means based image segmentation. *2010 IEEE International Conference on Systems, Man and Cybernetics - SMC*, 4123–4129. <https://doi.org/10.1109/ICSMC.2010.5641782>
- Chen, S., & Zhang, D. (2004). Robust Image Segmentation Using FCM With Spatial Constraints Based on New Kernel-Induced Distance Measure. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 34(4), 1907–1916. <https://doi.org/10.1109/TSMCB.2004.831165>
- Cheng, T. W., Goldgof, D. B., & Hall, L. O. (1998). Fast fuzzy clustering. *Fuzzy Sets and Systems*, 93(1), 49–56. [https://doi.org/10.1016/S0165-0114\(96\)00232-1](https://doi.org/10.1016/S0165-0114(96)00232-1)
- Chiu, S. L. (1994a). Fuzzy Model Identification Based on Cluster Estimation. *Journal of Intelligent and Fuzzy Systems*, 2(3), 267–278. <https://doi.org/10.3233/IFS-1994-2306>
- Chiu, S. L. (1994b). Fuzzy Model Identification Based on Cluster Estimation. *Journal of Intelligent and Fuzzy Systems*, 2(3), 267–278. <https://doi.org/10.3233/IFS-1994-2306>
- Chuang, K.-S., Tzeng, H.-L., Chen, S., Wu, J., & Chen, T.-J. (2006). Fuzzy c-means clustering with spatial information for image segmentation. *Computerized Medical Imaging and Graphics*, 30(1), 9–15. <https://doi.org/10.1016/j.compmedimag.2005.10.001>
- Cominetti, O., Matzavinos, A., Samarasinghe, S., Kulasiri, D., Liu, S., Maini, P. K., & Erban, R. (2010a). DifFUZZY: a fuzzy clustering algorithm for complex datasets. *International Journal of Computational Intelligence in Bioinformatics and Systems Biology*, 1(4), 402. <https://doi.org/10.1504/IJCIBSB.2010.038222>
- Cominetti, O., Matzavinos, A., Samarasinghe, S., Kulasiri, D., Liu, S., Maini, P. K., & Erban, R. (2010b). DifFUZZY: a fuzzy clustering algorithm for complex datasets. *International Journal of Computational Intelligence in Bioinformatics and Systems Biology*, 1(4), 402. <https://doi.org/10.1504/IJCIBSB.2010.038222>
- Coray, C. (1981). *Clustering algorithms with prototype selection*. 945–955.
- Correa, C., Valero, C., Barreiro, P., Diago, M.-P., & Tardaguila, J. (2011). A Comparison of Fuzzy Clustering Algorithms Applied to Feature Extraction on Vineyard. *Inteligencia artificial revista iberoamericana de inteligencia artificial*, 1, 778.
- Corsini, P., Lazzerini, B., & Marcelloni, F. (2005). A new fuzzy relational clustering algorithm based on the fuzzy C-means algorithm. *Soft Computing*, 9(6), 439–447. <https://doi.org/10.1007/s00500-004-0359-6>
- Dang, T. H., Ngo, L. T., & Pedrycz, W. (2015). Interval Type-2 fuzzy C-Means approach to collaborative clustering. *2015 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 1–7. <https://doi.org/10.1109/FUZZ-IEEE.2015.7337932>
- Das, A., Namtirtha, A., & Dutta, A. (2022). Fuzzy clustering of Acute Lymphoblastic Leukemia images assisted by Eagle strategy and morphological reconstruction. *Knowledge-Based Systems*, 239. <https://doi.org/10.1016/J.KNOSYS.2021.108008>
- Davé, R. a. j. e. s. h. N., & Sen, S. u. m. i. t. (2002). Robust fuzzy clustering of relational data. *IEEE Transactions on Fuzzy Systems*, 10.
- Dave, R. N. (1990). FUZZY SHELL-CLUSTERING AND APPLICATIONS TO CIRCLE DETECTION IN DIGITAL IMAGES. *International Journal of General Systems*, 16(4), 343–355. <https://doi.org/10.1080/03081079008935087>
- Dave, R. N. (1991). Characterization and detection of noise in clustering. *Pattern Recognition Letters*, 12(11), 657–664. [https://doi.org/10.1016/0167-8655\(91\)90002-4](https://doi.org/10.1016/0167-8655(91)90002-4)
- Dave, R. N. (1992). Generalized fuzzy c-shells clustering and detection of circular and elliptical boundaries. *Pattern Recognition*, 25(7), 713–721. [https://doi.org/10.1016/0031-3203\(92\)90134-5](https://doi.org/10.1016/0031-3203(92)90134-5)

- Dave, R. N., & Bhaswan, K. (1992). Adaptive fuzzy c-shells clustering and detection of ellipses. *IEEE Transactions on Neural Networks*, 3(5), 643–662. <https://doi.org/10.1109/72.159055>
- Deng, J., Hu, J., Chi, H., & Wu, J. (2010a). An Improved Fuzzy Clustering Method for Text Mining. *2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing*, 65–69. <https://doi.org/10.1109/NSWCTC.2010.23>
- Deng, J., Hu, J., Chi, H., & Wu, J. (2010b). An Improved Fuzzy Clustering Method for Text Mining. *2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing*, 65–69. <https://doi.org/10.1109/NSWCTC.2010.23>
- Deng, S. (2020). Clustering with Fuzzy C-means and Common Challenges. *Journal of Physics: Conference Series*, 1453(1), 012137. <https://doi.org/10.1088/1742-6596/1453/1/012137>
- Deng, Z. H., Qiao, H. H., Song, Q., & Gao, L. (2019). A complex network community detection algorithm based on label propagation and fuzzy C-means. *Physica A: Statistical Mechanics and its Applications*, 519, 217–226. <https://doi.org/10.1016/J.PHYSA.2018.12.024>
- Dhal, K. G., Das, A., Ray, S., & Gálvez, J. (2021). Randomly Attracted Rough Firefly Algorithm for histogram based fuzzy image clustering. *Knowledge-Based Systems*, 216, 106814. <https://doi.org/10.1016/j.knosys.2021.106814>
- Ding, Y., & Fu, X. (2016). Kernel-based fuzzy c-means clustering algorithm based on genetic algorithm. *Neurocomputing*, 188, 233–238. <https://doi.org/10.1016/j.neucom.2015.01.106>
- Doğan, B., & Korürek, M. (2012). A new ECG beat clustering method based on kernelized fuzzy c-means and hybrid ant colony optimization for continuous domains. *Applied Soft Computing Journal*, 12(11), 3442–3451. <https://doi.org/10.1016/J.ASOC.2012.07.007>
- Domingo, V. G. (s/f). *Fuzzy C-means and clustering algorithms: A comparative study*. <http://hdl.handle.net/10609/97627>
- Dong, H., Dong, Y., Zhou, C., Yin, G., & Hou, W. (2009). A fuzzy clustering algorithm based on evolutionary programming. *Expert Systems with Applications*, 36(9), 11792–11800. <https://doi.org/10.1016/J.ESWA.2009.04.031>
- Dong, S., Wang, J., Luo, H., Wang, H., & Wu, F.-X. (2021). A dynamic predictor selection algorithm for predicting stock market movement. *Expert Systems with Applications*, 186, 115836. <https://doi.org/10.1016/j.eswa.2021.115836>
- Dong, Y., Zhuang, Y., Chen, K., & Tai, X. (2006). A hierarchical clustering algorithm based on fuzzy graph connectedness. *Fuzzy Sets and Systems*, 157(13), 1760–1774. <https://doi.org/10.1016/j.fss.2006.01.001>
- Dovžan, D., & Škrjanc, I. (2011). Recursive fuzzy c-means clustering for recursive fuzzy identification of time-varying processes. *ISA Transactions*, 50(2), 159–169. <https://doi.org/10.1016/j.isatra.2011.01.004>
- Duan, L., Yu, F., & Zhan, L. (2016a). An improved fuzzy C-means clustering algorithm. *2016 12th International Conference on Natural Computation and 13th Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 1199–1204. <https://doi.org/10.1109/FSKD.2016.7603349>
- Duan, L., Yu, F., & Zhan, L. (2016b). An improved fuzzy C-means clustering algorithm. *2016 12th International Conference on Natural Computation and 13th Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 1199–1204. <https://doi.org/10.1109/FSKD.2016.7603349>
- Dunn, J. C. (1973). A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters. *Journal of Cybernetics*, 3(3), 32–57. <https://doi.org/10.1080/01969727308546046>

- Dunn, J. C. (1974). A Graph Theoretic Analysis of Pattern Classification via Tamura's Fuzzy Relation. *IEEE Transactions on Systems, Man, and Cybernetics*, 3, 310–313. <https://doi.org/10.1109/TSMC.1974.5409141>
- Eschrich, S., Ke, J., Hall, L. O., & Goldgof, D. B. (2001). Fast fuzzy clustering of infrared images. *Joint 9th IFSA World Congress and 20th NAFIPS International Conference*, 2, 1145–1150. <https://doi.org/10.1109/NAFIPS.2001.944766>
- Fadhel, S. M., & Adel, A. (2009). *Modified Fuzzy Possibilistic C-means*. 2174.
- Fan, J., Han, M., & Wang, J. (2009). Single point iterative weighted fuzzy C-means clustering algorithm for remote sensing image segmentation. *Pattern Recognition*, 42(11), 2527–2540. <https://doi.org/10.1016/J.PATCOG.2009.04.013>
- Fan, J., & Li, J. (2014). A Fixed Suppressed Rate Selection Method for Suppressed Fuzzy C-Means Clustering Algorithm. *Applied Mathematics*, 5(8), 1275–1283. <https://doi.org/10.4236/am.2014.58119>
- Fan, J.-L., Zhen, W.-Z., & Xie, W.-X. (2003). Suppressed fuzzy c-means clustering algorithm. *Pattern Recognition Letters*, 24(9), 1607–1612. [https://doi.org/10.1016/S0167-8655\(02\)00401-4](https://doi.org/10.1016/S0167-8655(02)00401-4)
- Farajzadeh-Zanjani, M., Razavi-Far, R., Saif, M., Zarei, J., & Palade, V. (2015). Diagnosis of Bearing Defects in Induction Motors by Fuzzy-Neighborhood Density-Based Clustering. *2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*, 935–940. <https://doi.org/10.1109/ICMLA.2015.114>
- Fatehi, M., & Asadi, H. H. (2017). Application of semi-supervised fuzzy c-means method in clustering multivariate geochemical data, a case study from the Dalli Cu-Au porphyry deposit in central Iran. *Ore Geology Reviews*, 81, 245–255. <https://doi.org/10.1016/J.OREGOREV.2016.10.002>
- Fathabadi, H. a. s. s. a. n. (2016). Power distribution network reconfiguration for power loss minimization using novel dynamic fuzzy c-means (dFCM) clustering based ANN approach. *International Journal of Electrical Power & Energy Systems*, 78.
- Filho, S. i. l. v. a., & Telmo, M. (2015). Hybrid methods for fuzzy clustering based on fuzzy c-means and improved particle swarm optimization. *Expert Systems with Applications*, 42.
- Flores-Sintas, A., Cadenas, JoséM., & Martin, F. (1999). Membership functions in the fuzzy C-means algorithm. *Fuzzy Sets and Systems*, 101(1), 49–58. [https://doi.org/10.1016/S0165-0114\(97\)00062-6](https://doi.org/10.1016/S0165-0114(97)00062-6)
- Forghani, N., Forouzanfar, M., & Forouzanfar, E. (2007). MRI fuzzy segmentation of brain tissue using IFCM algorithm with particle swarm optimization. *2007 22nd international symposium on computer and information sciences*, 1–4. <https://doi.org/10.1109/ISCIS.2007.4456869>
- Frigui, H., & Krishnapuram, R. (1996). A comparison of fuzzy shell-clustering methods for the detection of ellipses. *IEEE Transactions on Fuzzy Systems*, 4(2), 193–199. <https://doi.org/10.1109/91.493912>
- Fritz, H., García-Escudero, L. A., & Mayo-Iscar, A. (2013). Robust constrained fuzzy clustering. *Information Sciences*, 245, 38–52. <https://doi.org/10.1016/j.ins.2013.03.056>
- Fu, H., & Elmesiry, A. (2005). A new feature weighted fuzzy C-means clustering algorithm. 11–18.
- Gamino-Sánchez, F., Hernández-Gutiérrez, I. V., Rosales-Silva, A. J., Gallegos-Funes, F. J., Mújica-Vargas, D., Ramos-Díaz, E., Carvajal-Gámez, B. E., & Kinani, J. M. V. (2018). Block-Matching Fuzzy C-Means clustering algorithm for segmentation of color images degraded with Gaussian noise. *Engineering Applications of Artificial Intelligence*, 73, 31–49. <https://doi.org/10.1016/j.engappai.2018.04.026>
- Ganesan, P., & Rajini, V. (2010). A method to segment color images based on modified Fuzzy-Possibilistic-C-Means clustering algorithm. *Recent Advances in Space Technology*

- Services and Climate Change 2010 (RSTS & CC-2010)*, 157–163.  
<https://doi.org/10.1109/RSTSCC.2010.5712837>
- Gath, I., & Geva, A. B. (1989). Unsupervised optimal fuzzy clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 773–780.  
<https://doi.org/10.1109/34.192473>
- Gath, I., & Hoory, D. (1995). Fuzzy clustering of elliptic ring-shaped clusters. *Pattern Recognition Letters*, 16(7), 727–741. [https://doi.org/10.1016/0167-8655\(95\)00030-K](https://doi.org/10.1016/0167-8655(95)00030-K)
- Geweniger, T., Zülke, D., Hammer, B., & Villmann, T. (2010). Median fuzzy c-means for clustering dissimilarity data. *Neurocomputing*, 73(7), 1109–1116.  
<https://doi.org/10.1016/j.neucom.2009.11.020>
- Gharib, A., Sadoghi-Yazdi, H., & Taherinia, A. hossein. (2019). Robust Heterogeneous C-means. *Applied Soft Computing Journal*, 86. <https://doi.org/10.1016/J.ASOC.2019.105885>
- Ghosh, P., Mali, K., & Das, S. K. (2018). Chaotic firefly algorithm-based fuzzy C-means algorithm for segmentation of brain tissues in magnetic resonance images. *Journal of Visual Communication and Image Representation*, 54, 63–79.  
<https://doi.org/10.1016/J.JVCIR.2018.04.007>
- Golzari Oskouei, A., Hashemzadeh, M., Asheghi, B., & Balafar, M. A. (2021). CGFFCM: Cluster-weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm for color image segmentation [Formula presented]. *Applied Soft Computing*, 113. <https://doi.org/10.1016/J.ASOC.2021.108005>
- Gomathi, M., & Thangaraj, P. (2010). A Parameter Based Modified Fuzzy Possibilistic C-Means Clustering Algorithm for Lung Image Segmentation. *Global journal of computer science and technology*, 10. <https://api.semanticscholar.org/CorpusID:45454928>
- Grabusts, P. (2015). The Choice of Metrics for Clustering Algorithms. *Environment. Technology. Resources. Proceedings of the International Scientific and Practical Conference*, 2, 70.  
<https://doi.org/10.17770/etr2011vol2.973>
- Grant, M. J., & Booth, A. (2009). A typology of reviews: An analysis of 14 review types and associated methodologies. *Health Information & Libraries Journal*, 26(2), 91–108.  
<https://doi.org/10.1111/j.1471-1842.2009.00848.x>
- Groenen, P. J. F., Kaymak, U., & Van Rosmalen, J. (2007). Fuzzy Clustering with Minkowski Distance Functions. *Advances in Fuzzy Clustering and Its Applications*, 53–68.
- Grover, N. (2014). A study of various Fuzzy Clustering Algorithms. *International Journal of Engineering Research*, 3(3), 177–181. <https://doi.org/10.17950/ijer/v3s3/310>
- Gueorguieva, N., Valova, I., & Georgiev, G. (2017). M&MFCM: Fuzzy C-means Clustering with Mahalanobis and Minkowski Distance Metrics. *Procedia Computer Science*, 114, 224–233. <https://doi.org/10.1016/J.PROCS.2017.09.064>
- Gunderson, R. W. (1983a). An adaptive FCV clustering algorithm. *International Journal of Man-Machine Studies*, 19(1), 97–104. [https://doi.org/10.1016/S0020-7373\(83\)80044-3](https://doi.org/10.1016/S0020-7373(83)80044-3)
- Gunderson, R. W. (1983b). An adaptive FCV clustering algorithm. *International Journal of Man-Machine Studies*, 19(1), 97–104. [https://doi.org/10.1016/S0020-7373\(83\)80044-3](https://doi.org/10.1016/S0020-7373(83)80044-3)
- Guo, F., Zhu, J., Huang, L., Li, H., Deng, J., Jiang, H., & Hou, X. (2023). Enhancing Spatial Debris Material Classifying through a Hierarchical Clustering-Fuzzy C-Means Integration Approach. *Applied Sciences*, 13(8), Article 8. <https://doi.org/10.3390/app13084754>
- Guo, Q., Li, C., & Ruan, G. (2018). Mixing Matrix Estimation of Underdetermined Blind Source Separation Based on Data Field and Improved FCM Clustering. *Symmetry*, 10(1), Article 1. <https://doi.org/10.3390/sym10010021>
- Gupta, A., Shihhare, H., & Sharma, S. (2015). Recommender system using fuzzy c-means clustering and genetic algorithm based weighted similarity measure. *2015 International Conference on Computer, Communication and Control (IC4)*, 1–8. <https://doi.org/10.1109/IC4.2015.7375707>

- Gupta, D., An, R. S., & Tyagi, B. (2015). A hybrid segmentation method based on Gaussian kernel fuzzy clustering and region based active contour model for ultrasound medical images. *Biomedical Signal Processing and Control*, 16, 98–112. <https://doi.org/10.1016/J.BSPC.2014.09.013>
- Gustafson, D., & Kessel, W. (1978). Fuzzy clustering with a fuzzy covariance matrix. *1978 IEEE Conference on Decision and Control including the 17th Symposium on Adaptive Processes*, 761–766. <https://doi.org/10.1109/CDC.1978.268028>
- Halberstadt, W., & Douglas, T. S. (2008). Fuzzy clustering to detect tuberculous meningitis-associated hyperdensity in CT images. *Computers in Biology and Medicine*, 38(2), 165–170. <https://doi.org/10.1016/j.combiomed.2007.09.002>
- Haldar, N. A. H., Khan, F. A., Ali, A., & Abbas, H. (2017). Arrhythmia classification using Mahalanobis distance based improved Fuzzy C-Means clustering for mobile health monitoring systems. *Neurocomputing*, 220, 221–235. <https://doi.org/10.1016/J.NEUCOM.2016.08.042>
- Han, M.-F., Lin, C.-T., & Chang, J.-Y. (2013). Differential evolution with local information for neuro-fuzzy systems optimisation. *Knowledge-Based Systems*, 44, 78–89. <https://doi.org/10.1016/j.knosys.2013.01.023>
- Hasanzadeh, M., & Kasaei, S. (2008). Fuzzy Image Segmentation Using Membership Connectedness. *EURASIP Journal on Advances in Signal Processing*, 2008(1), 417293. <https://doi.org/10.1155/2008/417293>
- Hasanzadeh, M., & Kasaei, S. (2010). A Multispectral Image Segmentation Method Using Size-Weighted Fuzzy Clustering and Membership Connectedness. *IEEE Geoscience and Remote Sensing Letters*, 7(3), 520–524. <https://doi.org/10.1109/LGRS.2010.2040800>
- Hashemzadeh, M., Golzari Oskouei, A., & Farajzadeh, N. (2019). New fuzzy C-means clustering method based on feature-weight and cluster-weight learning. *Applied Soft Computing Journal*, 78, 324–345. <https://doi.org/10.1016/J.ASOC.2019.02.038>
- Hassen, D. B., Taleb, H., Yaacoub, I. B., & Mnif, N. (2014). Classification of Chest Lesions with Using Fuzzy C-Means Algorithm and Support Vector Machines. *International Joint Conference SOCO'13-CISIS'13-ICEUTE'13*, 239, 319–328.
- Hathaway, R. J., & Bezdek, J. C. (1993). Switching regression models and fuzzy clustering. *IEEE Transactions on Fuzzy Systems*, 1(3), 195–204. <https://doi.org/10.1109/91.236552>
- Hathaway, R. J., & Bezdek, J. C. (1994). Nerf c-means: Non-Euclidean relational fuzzy clustering. *Pattern Recognition*, 27(3), 429–437. [https://doi.org/10.1016/0031-3203\(94\)90119-8](https://doi.org/10.1016/0031-3203(94)90119-8)
- Hathaway, R. J., Bezdek, J. C., & Hu, Y. (2000). Generalized fuzzy c-means clustering strategies using L/sub p/ norm distances. *IEEE Transactions on Fuzzy Systems*, 8(5), 576–582. <https://doi.org/10.1109/91.873580>
- Hathaway, R. J., Davenport, J. W., & Bezdek, J. C. (1989). Relational duals of the c-means clustering algorithms. *Pattern Recognition*, 22(2), 205–212. [https://doi.org/10.1016/0031-3203\(89\)90066-6](https://doi.org/10.1016/0031-3203(89)90066-6)
- Havens, T. C., Bezdek, J. C., Leckie, C., Hall, L. O., & Palaniswami, M. (2012). Fuzzy c-Means Algorithms for Very Large Data. *IEEE Transactions on Fuzzy Systems*, 20(6), 1130–1146. <https://doi.org/10.1109/TFUZZ.2012.2201485>
- Hohle, U. (s/f). A survey on mathematical aspects of fuzzy set theory. *[1992 Proceedings] IEEE International Conference on Fuzzy Systems*, 869–872. <https://doi.org/10.1109/FUZZY.1992.258772>
- HongLei, Y., JunHuan, P., BaiRu, X., & DingXuan, Z. (2013). Remote Sensing Classification Using Fuzzy C-means Clustering with Spatial Constraints Based on Markov Random Field. *European Journal of Remote Sensing*, 46(1), 305–316. <https://doi.org/10.5721/EuJRS20134617>

- Höppner, F. (1999). *Fuzzy cluster analysis: Methods for classification, data analysis, and image recognition*. 289.
- Hoppner, F., & Klawonn, F. (2003). A contribution to convergence theory of fuzzy c-means and derivatives. *IEEE Transactions on Fuzzy Systems*, 11(5), 682–694. <https://doi.org/10.1109/TFUZZ.2003.817858>
- Horta, D., De Andrade, I. C., & Campello, R. J. G. B. (2011). Evolutionary fuzzy clustering of relational data. *Theoretical Computer Science*, 412(42), 5854–5870. <https://doi.org/10.1016/j.tcs.2011.05.039>
- Huang, J.-J., Li, S.-Y., & Ban, X.-J. (2003). A fast approach to building rough data model through G-K fuzzy clustering. *Proceedings of the 2003 International Conference on Machine Learning and Cybernetics (IEEE Cat. No.03EX693)*, 1559–1564. <https://doi.org/10.1109/ICMLC.2003.1259743>
- Huang, X., Lin, J., & Demner-Fushman, D. (2006). Evaluation of PICO as a knowledge representation for clinical questions. *AMIA ... Annual Symposium Proceedings. AMIA Symposium, 2006*, 359–363.
- Hung, M.-C., & Yang, D.-L. (2001a). An efficient Fuzzy C-Means clustering algorithm. *2001 IEEE International Conference on Data Mining*, 225–232. <https://doi.org/10.1109/ICDM.2001.989523>
- Hung, M.-C., & Yang, D.-L. (2001b). An efficient Fuzzy C-Means clustering algorithm. *2001 IEEE International Conference on Data Mining*, 225–232. <https://doi.org/10.1109/ICDM.2001.989523>
- Hung, W.-L., Yang, M.-S., & Chen, D.-H. (2006). Parameter selection for suppressed fuzzy c-means with an application to MRI segmentation. *Pattern Recognition Letters*, 27(5), 424–438. <https://doi.org/10.1016/j.patrec.2005.09.005>
- Izakian, H., Pedrycz, W., & Jamal, I. (2015). Fuzzy clustering of time series data using dynamic time warping distance. *Engineering Applications of Artificial Intelligence*, 39, 235–244. <https://doi.org/10.1016/J.ENGAPPAL.2014.12.015>
- Jahanbakhsh Pourjabari, A., & Seyedzadegan, M. S. (2016a). *An improved method of fuzzy c-means clustering by using feature selection and weighting*. 16(10), 64–69.
- Jahanbakhsh Pourjabari, A., & Seyedzadegan, M. S. (2016b). *An improved method of fuzzy c-means clustering by using feature selection and weighting*. 16(10), 64–69.
- Jahangoshai Rezaee, M., Jozmaleki, M., & Valipour, M. (2018). Integrating dynamic fuzzy C-means, data envelopment analysis and artificial neural network to online prediction performance of companies in stock exchange. *Physica A: Statistical Mechanics and Its Applications*, 489, 78–93. <https://doi.org/10.1016/j.physa.2017.07.017>
- Jain, A. K., & Moreau, J. V. (1987). Bootstrap technique in cluster analysis. *Pattern Recognition*, 20(5), 547–568. [https://doi.org/10.1016/0031-3203\(87\)90081-1](https://doi.org/10.1016/0031-3203(87)90081-1)
- Jajuga, K. (1991). L1-norm based fuzzy clustering. *Fuzzy Sets and Systems*, 39(1), 43–50. [https://doi.org/10.1016/0165-0114\(91\)90064-W](https://doi.org/10.1016/0165-0114(91)90064-W)
- Ji, Z., Sun, Q., Xia, Y., Chen, Q., Xia, D., & Feng, D. (2012). Generalized rough fuzzy c-means algorithm for brain MR image segmentation. *Computer Methods and Programs in Biomedicine*, 108(2), 644–655. <https://doi.org/10.1016/j.cmpb.2011.10.010>
- Ji, Z.-X., Sun, Q.-S., & Xia, D.-S. (2011). A modified possibilistic fuzzy c-means clustering algorithm for bias field estimation and segmentation of brain MR image. *Computerized Medical Imaging and Graphics*, 35(5), 383–397. <https://doi.org/10.1016/j.compmedimag.2010.12.001>
- Jiang, L. L., Liu, Y. L., Li, X. J., & Chen, A. (2010). Fault Diagnosis of Roller Bearing Based on Bispectrum Estimation and Fuzzy Cluster Analysis. *Applied Mechanics and Materials*, 36, 129–134. <https://doi.org/10.4028/www.scientific.net/AMM.36.129>

- Jie, L., Liu, W., Sun, Z., & Teng, S. (2017). Hybrid fuzzy clustering methods based on improved self-adaptive cellular genetic algorithm and optimal-selection-based fuzzy c-means. *Neurocomputing*, 249, 140–156. <https://doi.org/10.1016/J.NEUCOM.2017.03.068>
- Kalam, Rehma, Ciza Thomas, and M. Abdul Rahiman. "GAUSSIAN KERNEL BASED FUZZY CMeans CLUSTERING ALGORITHM FOR IMAGE SEGMENTATION." *Comput. Sci. Inf. Technol* (2016): 47–56. (s/f).
- Kamel, M. S., & Selim, S. Z. (1994). New algorithms for solving the fuzzy clustering problem. *Pattern Recognition*, 27(3), 421–428. [https://doi.org/10.1016/0031-3203\(94\)90118-X](https://doi.org/10.1016/0031-3203(94)90118-X)
- Kannan, S. R., Ramathilagam, S., Devi, R., & Hines, E. (2012a). Strong fuzzy c-means in medical image data analysis. *Journal of Systems and Software*, 85(11), 2425–2438. <https://doi.org/10.1016/j.jss.2011.12.020>
- Kannan, S. R., Ramathilagam, S., Devi, R., & Hines, E. (2012b). Strong fuzzy c-means in medical image data analysis. *Journal of Systems and Software*, 85(11), 2425–2438. <https://doi.org/10.1016/j.jss.2011.12.020>
- Kaushal, M., Danish Lohani, Q. M., & Castillo, O. (2024). Weighted Intuitionistic Fuzzy C-Means Clustering Algorithms. *International Journal of Fuzzy Systems*, 26(3), 943–977. <https://doi.org/10.1007/s40815-023-01644-5>
- Kawa, J., & Pietka, E. (2007). Kernelized Fuzzy c-means Method in Fast Segmentation of Demyelination Plaques in Multiple Sclerosis. *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5616–5619. <https://doi.org/10.1109/IEMBS.2007.4353620>
- Kaymak, U., & Babuska, R. (1995). Compatible cluster merging for fuzzy modelling. *1995 IEEE International Conference on Fuzzy Systems. The International Joint Conference of the Fourth IEEE International Conference on Fuzzy Systems and The Second International Fuzzy Engineering Symposium*, 2, 897–904. <https://doi.org/10.1109/FUZZY.1995.409789>
- Keskin, G. A. (2015). Using integrated fuzzy DEMATEL and fuzzy C: Means algorithm for supplier evaluation and selection. *International Journal of Production Research*, 53(12), 3586–3602. <https://doi.org/10.1080/00207543.2014.980461>
- Kim, D.-W., Lee, K. H., & Lee, D. (2004a). A novel initialization scheme for the fuzzy c-means algorithm for color clustering. *Pattern Recognition Letters*, 25(2), 227–237. <https://doi.org/10.1016/j.patrec.2003.10.004>
- Kim, D.-W., Lee, K. H., & Lee, D. (2004b). A novel initialization scheme for the fuzzy c-means algorithm for color clustering. *Pattern Recognition Letters*, 25(2), 227–237. <https://doi.org/10.1016/j.patrec.2003.10.004>
- Kim, T., Bezdek, J. C., & Hathaway, R. J. (1988). Optimality tests for fixed points of the fuzzy c-means algorithm. *Pattern Recognition*, 21(6), 651–663. [https://doi.org/10.1016/0031-3203\(88\)90037-4](https://doi.org/10.1016/0031-3203(88)90037-4)
- Kisi, O., & Zounemat-Kermani, M. (2016). Suspended Sediment Modeling Using Neuro-Fuzzy Embedded Fuzzy c-Means Clustering Technique. *Water Resources Management*, 30(11), 3979–3994. <https://doi.org/10.1007/s11269-016-1405-8>
- Kolen, J. F., & Hutcheson, T. (2002). Reducing the time complexity of the fuzzy c-means algorithm. *IEEE Transactions on Fuzzy Systems*, 10(2), 263–267. <https://doi.org/10.1109/91.995126>
- Kong, X., Wang, R., & Li, G. (2002). Fuzzy clustering algorithms based on resolution and their application in image compression. *Pattern Recognition*, 35(11), 2439–2444. [https://doi.org/10.1016/S0031-3203\(01\)00216-3](https://doi.org/10.1016/S0031-3203(01)00216-3)

- Krinidis, S., & Chatzis, V. (2010). A Robust Fuzzy Local Information C-Means Clustering Algorithm. *IEEE Transactions on Image Processing*, 19(5), 1328–1337. <https://doi.org/10.1109/TIP.2010.2040763>
- Krishnapuram, R., & Keller, J. M. (1993). A possibilistic approach to clustering. *IEEE Transactions on Fuzzy Systems*, 1(2), 98–110. <https://doi.org/10.1109/91.227387>
- Krishnapuram, R., & Kim, J. (1999). A note on the Gustafson-Kessel and adaptive fuzzy clustering algorithms. *IEEE Transactions on Fuzzy Systems*, 7(4), 453–461. <https://doi.org/10.1109/91.784208>
- Krishnapuram, R., Nasraoui, O., & Frigui, H. (1992). The fuzzy c spherical shells algorithm: A new approach. *IEEE Transactions on Neural Networks*, 3(5), 663–671. <https://doi.org/10.1109/72.159056>
- Kühne, M., Tognari, R., & Nordholm, S. (2010). A novel fuzzy clustering algorithm using observation weighting and context information for reverberant blind speech separation. *Signal Processing*, 90(2), 653–669. <https://doi.org/10.1016/j.sigpro.2009.08.005>
- Kumar, A., Kumar, D., & Jarial, S. K. (2017). A hybrid clustering method based on improved artificial bee colony and fuzzy C-means algorithm. *International Journal of Artificial Intelligence*, 15, 40–60.
- Kumar, D. h. i. r. e. n. d. r. a. (2019). A modified intuitionistic fuzzy c-means clustering approach to segment human brain MRI image. *Multimedia Tools and Applications*, 78.
- Kuo, R. J., Alfarez, M. N., & Nguyen, T. P. Q. (2023). Genetic based density peak possibilistic fuzzy c-means algorithms to cluster analysis- a case study on customer segmentation. *Engineering Science and Technology, an International Journal*, 47, 101525. <https://doi.org/10.1016/j.estch.2023.101525>
- Kuo, R. J., Lin, T. C., Zulvia, F. E., & Tsai, C. Y. (2018). A hybrid metaheuristic and kernel intuitionistic fuzzy c-means algorithm for cluster analysis. *Applied Soft Computing Journal*, 67, 299–308. <https://doi.org/10.1016/J.ASOC.2018.02.039>
- Lai, J. Z. C., Juan, E. Y. T., & Lai, F. J. C. (2013). Rough clustering using generalized fuzzy clustering algorithm. *Pattern Recognition*, 46(9), 2538–2547. <https://doi.org/10.1016/j.patcog.2013.02.003>
- Lance, G. N., & Williams, W. T. (1967). A general theory of classificatory sorting strategies: 1. Hierarchical systems. *The computer journal*, 9(4), 373–380.
- Li, C., De Oliveira, J. V., Cerrada, M., Cabrera, D., Sanchez, R. V., & Zurita, G. (2019). A Systematic Review of Fuzzy Formalisms for Bearing Fault Diagnosis. *IEEE Transactions on Fuzzy Systems*, 27(7), 1362–1382. <https://doi.org/10.1109/TFUZZ.2018.2878200>
- Li, C., Valente de Oliveira, J., Cerrada, M., Pacheco, F., Cabrera, D., Sanchez, V., & Zurita, G. (2016). Observer-biased bearing condition monitoring: From fault detection to multi-fault classification. *Engineering Applications of Artificial Intelligence*, 50, 287–301. <https://doi.org/10.1016/j.engappai.2016.01.038>
- Li, F., Chyu, M. K., Wang, J., & Tang, B. (2015). Life grade recognition of rotating machinery based on Supervised Orthogonal Linear Local Tangent Space Alignment and Optimal Supervised Fuzzy C-Means Clustering. *Measurement: Journal of the International Measurement Confederation*, 73, 384–400. <https://doi.org/10.1016/J.MEASUREMENT.2015.05.025>
- Li, H., Guo, S., Li, C., & Sun, J. (2013). A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm. *Knowledge-Based Systems*, 37, 378–387. <https://doi.org/10.1016/j.knosys.2012.08.015>
- Li, K., & Li, P. (2014). Fuzzy Clustering with Generalized Entropy Based on Neural Network. *Unifying Electrical Engineering and Electronics Engineering*, 238, 2085–2091.

- Li, M., Xu, L., Gao, S., Xu, N., & Yan, B. (2019). Adaptive Segmentation of Remote Sensing Images Based on Global Spatial Information. *Sensors*, 19(10), Article 10. <https://doi.org/10.3390/s19102385>
- Li, P., Dong, B., Li, S., & Chu, R. (2022). A Repair Method for Missing Traffic Data Based on FCM, Optimized by the Twice Grid Optimization and Sparrow Search Algorithms. *Sensors*, 22(11), 4304. <https://doi.org/10.3390/s22114304>
- Li, W., & Yang, Y. (2008). A new approach to TS fuzzy modeling using dual kernel-based learning machines. *Neurocomputing*, 71(16–18), 3660–3665. <https://doi.org/10.1016/j.neucom.2008.03.002>
- Li, X., Wong, H.-S., & Wu, S. (2012). A fuzzy minimax clustering model and its applications. *Information Sciences*, 186(1), 114–125. <https://doi.org/10.1016/j.ins.2011.09.032>
- Libert, G., & Roubens, M. (1982). Non-metric fuzzy clustering algorithms and their cluster validity. *Fuzzy Information and Decision processes*, (Edited by M. Gupta and E. Sanchez), 417–425.
- Li-me, W. (2000). *Rival Checked Fuzzy C-Means Algorithm*. <https://api.semanticscholar.org/CorpusID:123852327>
- Lin, J., & Zheng, S. (2009). An Optimizing Search Based on Kernel-Based Fuzzy C-Means Clustering. *2009 International Conference on Computational Intelligence and Software Engineering*, 1–3. <https://doi.org/10.1109/CISE.2009.5365934>
- Lin, P.-L., Huang, P.-W., Kuo, C. H., & Lai, Y. H. (2014). A size-insensitive integrity-based fuzzy c-means method for data clustering. *Pattern Recognition*, 47(5), 2042–2056. <https://doi.org/10.1016/j.patcog.2013.11.031>
- Lin, W., & Li, Y. (2020). Parallel Regional Segmentation Method of High-Resolution Remote Sensing Image Based on Minimum Spanning Tree. *Remote Sensing*, 12(5), Article 5. <https://doi.org/10.3390/rs12050783>
- Liu, C. L., Hsiao, W. H., Chang, T. H., & Li, H. H. (2019). Clustering data with partial background information. *International Journal of Machine Learning and Cybernetics*, 10(5), 1123–1138. <https://doi.org/10.1007/S13042-018-0790-0>
- Liu, H., Zhao, F., & Chaudhary, V. (2018). Pareto-based interval type-2 fuzzy c-means with multi-scale JND color histogram for image segmentation. *Digital Signal Processing: A Review Journal*, 76, 75–83. <https://doi.org/10.1016/J.DSP.2018.02.005>
- Liu, H.-C., Jeng, B.-C., Yih, J.-M., & Yu, Y.-K. (2009). Fuzzy C-means algorithm based on standard mahalanobis distances. *Proceedings of the 2009 International Symposium on Information Processing (ISIP'09)*.
- Liu, L., Sun, S. Z., ong, Yu, H., Yue, X., & Zhang, D. (2016). A modified Fuzzy C-Means (FCM) Clustering algorithm and its application on carbonate fluid identification. *Journal of Applied Geophysics*, 129, 28–35. <https://doi.org/10.1016/J.JAPPGEO.2016.03.027>
- Liu, Z., Ding, F., Xu, Y., & Han, X. (2021). Background dominant colors extraction method based on color image quick fuzzy c-means clustering algorithm. *Defence Technology*, 17(5), 1782–1790. <https://doi.org/10.1016/j.dt.2020.10.002>
- Lv, S., Xian, R., Li, D., Zheng, B., & Jin, H. (2019). An FCM-GABPN Ensemble Approach for Material Feeding Prediction of Printed Circuit Board Template. *Applied Sciences*, 9(20), Article 20. <https://doi.org/10.3390/app9204455>
- Ma, Q., Zhu, X., Zhao, X., Zhao, B., Fu, G., & Zhang, R. (2024). An equidistance index intuitionistic fuzzy c-means clustering algorithm based on local density and membership degree boundary. *Applied Intelligence*, 54(4), 3205–3221. <https://doi.org/10.1007/s10489-024-05297-1>
- MacDonell, S., Shepperd, M., Kitchenham, B., & Mendes, E. (2010). How Reliable Are Systematic Reviews in Empirical Software Engineering? *IEEE Transactions on Software Engineering*, 36(5), 676–687. <https://doi.org/10.1109/TSE.2010.28>

- Mai, S. D., & Ngo, L. T. (2015). Interval Type-2 Fuzzy C-Means Clustering with Spatial Information for Land-Cover Classification. En N. T. Nguyen, B. Trawiński, & R. Kosala (Eds.), *Intelligent Information and Database Systems* (Vol. 9011, pp. 387–397). Springer International Publishing. [https://doi.org/10.1007/978-3-319-15702-3\\_38](https://doi.org/10.1007/978-3-319-15702-3_38)
- Man, Y. H., & Gath, I. (1994). Detection and separation of ring-shaped clusters using fuzzy clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(8), 855–861. <https://doi.org/10.1109/34.308484>
- Maraziotis, I. A. (2012). A semi-supervised fuzzy clustering algorithm applied to gene expression data. *Pattern Recognition*, 45(1), 637–648. <https://doi.org/10.1016/j.patcog.2011.05.007>
- Martino, F., Di, o, & Sessa, S. (2020). A New Validity Index Based on Fuzzy Energy and Fuzzy Entropy Measures in Fuzzy Clustering Problems. *Entropy*, 22(11), 1200. <https://doi.org/10.3390/e22111200>
- Mei, J.-P., & Chen, L. (2013). LinkFCM: Relation integrated fuzzy c-means. *Pattern Recognition*, 46(1), 272–283. <https://doi.org/10.1016/j.patcog.2012.06.012>
- Mei, Y., Tang, K., & Li, K. (2015). Real-time identification of probe vehicle trajectories in the mixed traffic corridor. *Transportation Research Part C: Emerging Technologies*, 57, 55–67. <https://doi.org/10.1016/j.trc.2015.06.008>
- Mekhmoukh, A., & Mokrani, K. (2015). Improved Fuzzy C-Means based Particle Swarm Optimization (PSO) initialization and outlier rejection with level set methods for MR brain image segmentation. *Computer Methods and Programs in Biomedicine*, 122(2), 266–281. <https://doi.org/10.1016/J.CMPB.2015.08.001>
- Mingoti, S. A., & Lima, J. O. (2006). Comparing SOM neural network with Fuzzy c-means, K-means and traditional hierarchical clustering algorithms. *European Journal of Operational Research*, 174(3), 1742–1759. <https://doi.org/10.1016/j.ejor.2005.03.039>
- Mitra, S., Pedrycz, W., & Barman, B. (2010). Shadowed c-means: Integrating fuzzy and rough clustering. *Pattern Recognition*, 43(4), 1282–1291. <https://doi.org/10.1016/j.patcog.2009.09.029>
- Mohammadian-khoshnoud, M., Soltanian, A. R., Dehghan, A., & Farhadian, M. (2022). Optimization of fuzzy c-means (FCM) clustering in cytology image segmentation using the gray wolf algorithm. *BMC Molecular and Cell Biology*, 23(1), 9. <https://doi.org/10.1186/s12860-022-00408-7>
- Mostowski, A. (1948). Proofs of non-deducibility in intuitionistic functional calculus. *Journal of Symbolic Logic*, 13(4), 204–207. <https://doi.org/10.2307/2267135>
- Mousavi, S. M. H., Charles, V., & Gherman, T. (2020). An evolutionary Pentagon Support Vector finder method. *Expert Systems with Applications*, 150, 113284. <https://doi.org/10.1016/j.eswa.2020.113284>
- Mújica-Vargas, D., Gallegos-Funes, F. J., & Cruz-Santiago, R. (2011). Segmentation of Noisy Images Using the Rank M-type L-filter and the Fuzzy C-Means Clustering Algorithm. En J. F. Martínez-Trinidad, J. A. Carrasco-Ochoa, C. Ben-Youssef Brants, & E. R. Hancock (Eds.), *Pattern Recognition* (Vol. 6718, pp. 184–193). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-21587-2\\_20](https://doi.org/10.1007/978-3-642-21587-2_20)
- Mukhopadhyay, A., & Maulik, U. (2009). Towards improving fuzzy clustering using support vector machine: Application to gene expression data. *Pattern Recognition*, 42(11), 2744–2763. <https://doi.org/10.1016/j.patcog.2009.04.018>
- Naik, A., Satapathy, S. C., ra, & Parvathi, K. (2012). Improvement of Initial Cluster Center of C-means using Teaching Learning based Optimization. *Procedia Technology*, 6, 428–435. <https://doi.org/10.1016/J.PROTCY.2012.10.051>

- Namburu, A. n. u. p. a. m. a., Samayamantula, S. r. i. n. i. v. a. s. K. u. m. a. r., & Edara, S. r. i. n. i. v. a. s. a. R. e. d. d. y. (2017). Generalised rough intuitionistic fuzzy c-means for magnetic resonance brain image segmentation. *IET Image Processing*, 11.
- Nayak, J., Naik, B., & Behera, H. S. (2015). *Fuzzy C-Means (FCM) Clustering Algorithm: A Decade Review from 2000 to 2014* (pp. 133–149). [https://doi.org/10.1007/978-81-322-2208-8\\_14](https://doi.org/10.1007/978-81-322-2208-8_14)
- Nayak, J., Naik, B., Behera, H. S., & Abraham, A. (2017). Hybrid chemical reaction based metaheuristic with fuzzy c-means algorithm for optimal cluster analysis. *Expert Systems with Applications*, 79, 282–295. <https://doi.org/10.1016/J.ESWA.2017.02.037>
- Nayak, J., Naik, B., Kanungo, D. P., & Behera, H. S. (2016). A hybrid elicit teaching learning based optimization with fuzzy c-means (ETLBO-FCM) algorithm for data clustering. *Ain Shams Engineering Journal*, 9(3), 379–393. <https://doi.org/10.1016/J.ASEJ.2016.01.010>
- Nayak, J., Nanda, M., Nayak, K., Naik, B., & Behera, H. S. (2014a). An Improved Firefly Fuzzy C-Means (FAFCM) Algorithm for Clustering Real World Data Sets. *Advanced Computing, Networking and Informatics- Volume 1*, 27, 339–348.
- Nayak, J., Nanda, M., Nayak, K., Naik, B., & Behera, H. S. (2014b). An Improved Firefly Fuzzy C-Means (FAFCM) Algorithm for Clustering Real World Data Sets. *Advanced Computing, Networking and Informatics- Volume 1*, 27, 339–348.
- Nayak, J., Rekha, H. S., & Naik, B. (2023). Fuzzy C-Means Clustering: Advances and Challenges (Part II). En L. Rokach, O. Maimon, & E. Shmueli (Eds.), *Machine Learning for Data Science Handbook: Data Mining and Knowledge Discovery Handbook* (pp. 239–269). Springer International Publishing. [https://doi.org/10.1007/978-3-031-24628-9\\_12](https://doi.org/10.1007/978-3-031-24628-9_12)
- Nie, S., Zhang, Y., Li, W., & Chen, Z. (2007). A Fast and Automatic Segmentation Method of MR Brain Images Based on Genetic Fuzzy Clustering Algorithm. *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 5628–5633. <https://doi.org/10.1109/IEMBS.2007.4353623>
- Niware, D. K., & Chaturvedi, S. K. (2014). Web Usage Mining through Efficient Genetic Fuzzy C-Means. *IJCSNS International Journal of Computer Science and Network Security*, 14(6).
- Noordam, J. C., Van Den Broek, W. H. A. M., & Buydens, L. M. C. (2002). Multivariate image segmentation with cluster size insensitive Fuzzy C-means. *Chemometrics and Intelligent Laboratory Systems*, 64(1), 65–78. [https://doi.org/10.1016/S0169-7439\(02\)00052-7](https://doi.org/10.1016/S0169-7439(02)00052-7)
- Ojeda-Magana, B., Ruelas, R., Corona-Nakamura, M. A., & Andina, D. (2006). An Improvement to the Possibilistic Fuzzy c-Means Clustering Algorithm. *World Automation Congress (WAC) 2006*, 1–8. <https://doi.org/10.1109/WAC.2006.376056>
- Oliveira, J. V. de, Pedrycz, W., & Oliveira, J. V. de. (2007). *Advances in fuzzy clustering and its applications*. 434.
- Ouma, Y. O., & Hahn, M. (2017). Pothole detection on asphalt pavements from 2D-colour pothole images using fuzzy c-means clustering and morphological reconstruction. *Automation in Construction*, 83, 196–211. <https://doi.org/10.1016/J.AUTCON.2017.08.017>
- Özbay, Y., Ceylan, R., & Karlik, B. (2006). A fuzzy clustering neural network architecture for classification of ECG arrhythmias. *Computers in Biology and Medicine*, 36(4), 376–388. <https://doi.org/10.1016/j.combiomed.2005.01.006>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Alonso-Fernández, S. (2021). Declaración PRISMA 2020: Una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, 74(9), 790–799. <https://doi.org/10.1016/j.recesp.2021.06.016>
- Pal, N. R., & Bezdek, J. C. (1995). On cluster validity for the fuzzy c-means model. *IEEE Transactions on Fuzzy Systems*, 3(3), 370–379. <https://doi.org/10.1109/91.413225>

- Pal, N. R., & Bezdek, J. C. (2002). Complexity reduction for “large image” processing. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 32(5), 598–611. <https://doi.org/10.1109/TSMCB.2002.1033179>
- Pal, N. R., Pal, K., & Bezdek, J. C. (1997). A mixed c-means clustering model. *6th International Fuzzy Systems Conference*, 1, 11–21. <https://doi.org/10.1109/FUZZY.1997.616338>
- Pal, N. R., Pal, K., Keller, J. M., & Bezdek, J. C. (2005). A possibilistic fuzzy c-means clustering algorithm. *IEEE Transactions on Fuzzy Systems*, 13(4), 517–530. <https://doi.org/10.1109/TFUZZ.2004.840099>
- Pan, Q.-K., Sang, H.-Y., Duan, J.-H., & Gao, L. (2014). An improved fruit fly optimization algorithm for continuous function optimization problems. *Knowledge-Based Systems*, 62, 69–83. <https://doi.org/10.1016/j.knosys.2014.02.021>
- Pan, W.-T. (2012). A new Fruit Fly Optimization Algorithm: Taking the financial distress model as an example. *Knowledge-Based Systems*, 26, 69–74. <https://doi.org/10.1016/j.knosys.2011.07.001>
- Pappas, T. N. (1992). An adaptive clustering algorithm for image segmentation. *IEEE Transactions on Signal Processing*, 40(4), 901–914. <https://doi.org/10.1109/78.127962>
- Park, D. C., & Dagher, I. (1994). Gradient based fuzzy c-means (GBFCM) algorithm. *1994 IEEE International Conference on Neural Networks (ICNN'94)*, 3, 1626–1631. <https://doi.org/10.1109/ICNN.1994.374399>
- Parveen, & Singh, A. (2015). Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. *2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)*, 98–102. <https://doi.org/10.1109/SPIN.2015.7095308>
- Pedrycz, W. (2004). Fuzzy clustering with a knowledge-based guidance. *Pattern Recognition Letters*, 25(4), 469–480. <https://doi.org/10.1016/j.patrec.2003.12.010>
- Pedrycz, W., & Vukovich, G. (2004). Fuzzy clustering with supervision. *Pattern Recognition*, 37(7), 1339–1349. <https://doi.org/10.1016/j.patcog.2003.11.005>
- Pedrycz, W., & Waletzky, J. (1997). Fuzzy clustering with partial supervision. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 27(5), 787–795. <https://doi.org/10.1109/3477.623232>
- Pei, J. H., Fan, J. L., & Xie, W. X. (1998). A new efficient fuzzy clustering method: Cutset of fuzzy c-means algorithm}. *Acta Electronica Sinica*, 26(2), 83–86.
- Pérez Rave, J. (2019). *Revisión sistemática de literatura en ingeniería. 2a. Edición (ampliada y actualizada)*.
- Pérez-Ortega, J., Moreno-Calderón, C. F., Roblero-Aguilar, S. S., Almanza-Ortega, N. N., Frausto-Solís, J., Pazos-Rangel, R., & Rodríguez-Lelis, J. M. (2024). A New Criterion for Improving Convergence of Fuzzy C-Means Clustering. *Axioms*, 13(1), 35. <https://doi.org/10.3390/axioms13010035>
- Pérez-Ortega, J., Rey-Figueroa, C. D., Roblero-Aguilar, S. S., Almanza-Ortega, N. N., Zavala-Díaz, C., García-Paredes, S., & Landero-Nájera, V. (2023). POFCM: A Parallel Fuzzy Clustering Algorithm for Large Datasets. *Mathematics*, 11(8), Article 8. <https://doi.org/10.3390/math11081920>
- Pérez-Ortega, J., Roblero-Aguilar, S., Silvia, ra, Almanza-Ortega, N. N., Solís, J. F., Zavala-Díaz, C., Hernández, Y., L, & ero-Nájera, V. (2022). Hybrid Fuzzy C-Means Clustering Algorithm Oriented to Big Data Realms. *Axioms*, 11(8), 377. <https://doi.org/10.3390/axioms11080377>
- Pham, D. L., & Prince, J. L. (1999). An adaptive fuzzy C-means algorithm for image segmentation in the presence of intensity inhomogeneities. *Pattern Recognition Letters*, 20(1), 57–68. [https://doi.org/10.1016/S0167-8655\(98\)00121-4](https://doi.org/10.1016/S0167-8655(98)00121-4)

- Pham, D. L., Prince, J. L., Goos, G., Hartmanis, J., & Van Leeuwen, J. (1999). An Adaptive Fuzzy Segmentation Algorithm for Three-Dimensional Magnetic Resonance Images. *Information Processing in Medical Imaging*, 1613, 140–153.
- Pianykh, O. S. (2006). Analytically tractable case of fuzzy c-means clustering. *Pattern Recognition*, 39(1), 35–46. <https://doi.org/10.1016/j.patcog.2005.06.005>
- Prabhakar, S., & Sandeep, P. (2017). A Survey on Fuzzy C-means Clustering Techniques. *International Journal of Engineering Development and Research*, 5(4), 1151–1155.
- Qaiyum, S., Aziz, I., Hasan, M. H., Khan, A. I., & Almalawi, A. (2020). Incremental Interval Type-2 Fuzzy Clustering of Data Streams using Single Pass Method. *Sensors*, 20(11), Article 11. <https://doi.org/10.3390/s20113210>
- Qiao, Z., Wang, X., Gu, H., Tang, Y., Si, F., Romero, C. E., & Yao, X. Z. (2019). An investigation on data mining and operating optimization for wet flue gas desulfurization systems. *Fuel*, 258. <https://doi.org/10.1016/J.FUEL.2019.116178>
- Qiu, C., Xiao, J., Yu, L., Han, L., & Iqbal, M. N. (2013). A modified interval type-2 fuzzy C-means algorithm with application in MR image segmentation. *Pattern Recognition Letters*, 34(12), 1329–1338. <https://doi.org/10.1016/j.patrec.2013.04.021>
- Quan, Z., Zhang, H., Luo, J., & Sun, H. (2024). Simulation-Enhanced MQAM Modulation Identification in Communication Systems: A Subtractive Clustering-Based PSO-FCM Algorithm Study. *Information*, 15(1), Article 1. <https://doi.org/10.3390/info15010042>
- Raj, S., & Nath, K. (2020). A SURVEY PAPER ON IMPROVING FUZZY C-MEANS CLUSTERING TECHNIQUES. *INTERNATIONAL JOURNAL OF INNOVATIVE RESEARCH IN TECHNOLOGY & SCIENCE*, 13–17.
- Rajaby, E., Ahadi, S. M., & Aghaeinia, H. (2016). Robust color image segmentation using fuzzy c-means with weighted hue and intensity. *Digital Signal Processing: A Review Journal*, 51, 170–183. <https://doi.org/10.1016/J.DSP.2016.01.010>
- Ramathilagam, S., P, iyarajan, R., Sathy, A., Devi, R., & Kannan, S. R. (2011). Modified fuzzy c-means algorithm for segmentation of T1T2-weighted brain MRI. *Journal of Computational and Applied Mathematics*, 235(6), 1578–1586. <https://doi.org/10.1016/J.CAM.2010.08.033>
- Ren, C., & Sun, L. (2021). A Bi-directional Fuzzy C-Means Clustering Ensemble Algorithm Considering Local Information. *International Journal of Computational Intelligence Systems*, 14(1), 171. <https://doi.org/10.1007/s44196-021-00014-z>
- Rezankova, H., & Husek, D. (2012). Fuzzy clustering: Determining the number of clusters. *2012 Fourth International Conference on Computational Aspects of Social Networks (CASoN)*, 277–282. <https://doi.org/10.1109/CASoN.2012.6412415>
- Rihova, E., & Malec, M. (2018). *Fuzzy C-Means clustering. Technique and evaluating results*.
- Rubio, E., Castillo, O., Valdez, F., Melin, P., Gonzalez, C. I., & Martinez, G. (2017). An Extension of the Fuzzy Possibilistic Clustering Algorithm Using Type-2 Fuzzy Logic Techniques. *Advances in Fuzzy Systems*, 2017, 1–23. <https://doi.org/10.1155/2017/7094046>
- Ruspini, E. (1973). New experimental results in fuzzy clustering. *Information Sciences*, 6, 273–284. [https://doi.org/10.1016/0020-0255\(73\)90043-1](https://doi.org/10.1016/0020-0255(73)90043-1)
- Ruspini, E. H. (1969). A new approach to clustering. *Information and Control*, 15(1), 22–32. [https://doi.org/10.1016/S0019-9958\(69\)90591-9](https://doi.org/10.1016/S0019-9958(69)90591-9)
- Ruspini, E. H. (1970). Numerical methods for fuzzy clustering. *Information Sciences*, 2(3), 319–350. [https://doi.org/10.1016/S0020-0255\(70\)80056-1](https://doi.org/10.1016/S0020-0255(70)80056-1)
- Ruspini, E. H., Bezdek, J. C., & Keller, J. M. (2019). Fuzzy Clustering: A Historical Perspective. *IEEE Computational Intelligence Magazine*, 14(1), 45–55. <https://doi.org/10.1109/MCI.2018.2881643>

- Saberi, H., Sharbati, R., & Farzanegan, B. (2022). A gradient ascent algorithm based on possibilistic fuzzy C-Means for clustering noisy data. *Expert Systems with Applications*, 191. <https://doi.org/10.1016/J.ESWA.2021.116153>
- Sanchez, M. A., Castillo, O., Castro, J. R., & Melin, P. (2014). Fuzzy granular gravitational clustering algorithm for multivariate data. *Information Sciences*, 279, 498–511. <https://doi.org/10.1016/j.ins.2014.04.005>
- Sato-Ilic, M., Ito, S., & Takahashi, S. (2009). Generalized kernel fuzzy clustering model. *2009 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, 421–426. <https://doi.org/10.1109/FUZZY.2009.5276876>
- Saxena, A., Prasad, M., Gupta, A., Bharill, N., Patel, O. P., Tiwari, A., Er, M. J., Ding, W., & Lin, C.-T. (2017). A review of clustering techniques and developments. *Neurocomputing*, 267, 664–681. <https://doi.org/10.1016/j.neucom.2017.06.053>
- Schardt, C., Adams, M. B., Owens, T., Keitz, S., & Fontelo, P. (2007). Utilization of the PICO framework to improve searching PubMed for clinical questions. *BMC Medical Informatics and Decision Making*, 7(1), 16. <https://doi.org/10.1186/1472-6947-7-16>
- Selim, S. Z., & Ismail, M. A. (1986). On the Local Optimality of the Fuzzy Isodata Clustering Algorithm. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2, 284–288. <https://doi.org/10.1109/TPAMI.1986.4767783>
- Sen, S., & Dave, R. N. (1998). Clustering of relational data containing noise and outliers. *1998 IEEE International Conference on Fuzzy Systems IEEE World Congress on Computational Intelligence*, 2, 1411–1416. <https://doi.org/10.1109/FUZZY.1998.686326>
- Setnes, M. (2000). Supervised fuzzy clustering for rule extraction. *IEEE Transactions on Fuzzy Systems*, 8(4), 416–424. <https://doi.org/10.1109/91.868948>
- Setnes, M., & Babuska, R. (1999). Fuzzy relational classifier trained by fuzzy clustering. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 29(5), 619–625. <https://doi.org/10.1109/3477.790444>
- Shamshirband, S., Amini, A., Anuar, N. B., Kiah, M. L. M., Teh, Y. W., & Furnell, S. (2014). D-FICCA: A density-based fuzzy imperialist competitive clustering algorithm for intrusion detection in wireless sensor networks. *Measurement*, 55, 212–226. <https://doi.org/10.1016/j.measurement.2014.04.034>
- Sheela, C. J. J., & Suganthi, G. (2019). Automatic Brain Tumor Segmentation from MRI using Greedy Snake Model and Fuzzy C-Means Optimization. *Journal of King Saud University - Computer and Information Sciences*, 34(3), 557–566. <https://doi.org/10.1016/j.jksuci.2019.04.006>
- Siddique, A. (2023). *IMPLEMENTING BIG DATA ANALYTICS APPROACHES TO IMPROVE FOOD QUALITY AND MINIMIZE FOOD WASTE AND LOSS.* <https://etd.auburn.edu/handle/10415/8709>
- Sivanandini, L. D., & Raj, M. M. (2013). A Survey on Data Clustering Algorithms based on Fuzzy Techniques. *International Journal of Science and Research (IJSR)*, 2(4). <https://www.ijsr.net/archive/v2i4/IJSRON2013704.pdf>
- Son, L. e. H. o. a. n. g. (2015). DPFCM. *Expert Systems with Applications: An International Journal*, 42.
- Soomro, S., Munir, A., & Choi, K. N. (2019). Fuzzy c-means clustering based active contour model driven by edge scaled region information. *Expert Systems with Applications*, 120, 387–396. <https://doi.org/10.1016/J.ESWA.2018.10.052>
- Staiano, A., Tagliaferri, R., & Pedrycz, W. (2006). Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering. *Neurocomputing*, 69(13), 1570–1581. <https://doi.org/10.1016/j.neucom.2005.06.014>

- Stetco, A., Zeng, X.-J., & Keane, J. (2015a). Fuzzy C-means++: Fuzzy C-means with effective seeding initialization. *Expert Systems with Applications*, 42(21), 7541–7548. <https://doi.org/10.1016/j.eswa.2015.05.014>
- Stetco, A., Zeng, X.-J., & Keane, J. (2015b). Fuzzy C-means++: Fuzzy C-means with effective seeding initialization. *Expert Systems with Applications*, 42(21), 7541–7548. <https://doi.org/10.1016/j.eswa.2015.05.014>
- Su, M.-S., Chia, C.-C., Chen, C.-Y., & Chen, J.-F. (2014). Classification of partial discharge events in GILBS using probabilistic neural networks and the fuzzy c-means clustering approach. *International Journal of Electrical Power & Energy Systems*, 61, 173–179. <https://doi.org/10.1016/j.ijepes.2014.03.054>
- Suganya, R., & Shanthi, R. M. (2012). Fuzzy C-Means Algorithm- A Review. *International Journal of Scientific and Research Publications*, 2(11).
- Sugeno, M., & Yasukawa, T. (1993). A fuzzy-logic-based approach to qualitative modeling. *IEEE Transactions on Fuzzy Systems*, 1(1), 7. <https://doi.org/10.1109/TFUZZ.1993.390281>
- Suleman, A. (2015). A convex semi-nonnegative matrix factorisation approach to fuzzy c-means clustering. *Fuzzy Sets and Systems*, 270, 90–110. <https://doi.org/10.1016/j.fss.2014.07.021>
- Sun, C., Shao, Q., Zhou, Z., & Zhang, J. (2024). An Enhanced FCM Clustering Method Based on Multi-Strategy Tuna Swarm Optimization. *Mathematics*, 12(3), Article 3. <https://doi.org/10.3390/math12030453>
- Taherdangkoo, M., & Bagheri, M. H. (2013). A powerful hybrid clustering method based on modified stem cells and Fuzzy C-means algorithms. *Engineering Applications of Artificial Intelligence*, 26(5), 1493–1502. <https://doi.org/10.1016/J.ENGAPPAI.2013.03.002>
- Tan, K. S., Isa, N. A. M., & Lim, W. H. (2013). Color image segmentation using adaptive unsupervised clustering approach. *Applied Soft Computing Journal*, 13(4), 2017–2036. <https://doi.org/10.1016/J.ASOC.2012.11.038>
- Tan, K. S., Lim, W. H., & Isa, N. A. M. (2013a). Novel initialization scheme for Fuzzy C-Means algorithm on color image segmentation. *Applied Soft Computing*, 13(4), 1832–1852. <https://doi.org/10.1016/j.asoc.2012.12.022>
- Tan, K. S., Lim, W. H., & Isa, N. A. M. (2013b). Novel initialization scheme for Fuzzy C-Means algorithm on color image segmentation. *Applied Soft Computing Journal*, 13(4), 1832–1852. <https://doi.org/10.1016/J.ASOC.2012.12.022>
- Tang, J. i. n. j. u. n. (2015). A hybrid approach to integrate fuzzy C-means based imputation method with genetic algorithm for missing traffic volume data estimation. *Transportation Research Part C: Emerging Technologies*, 51.
- Tang, Y., Chen, R., & Xia, B. (2023). VSFCM: A Novel Viewpoint-Driven Subspace Fuzzy C-Means Algorithm. *Applied Sciences*, 13(10), Article 10. <https://doi.org/10.3390/app13106342>
- Tolias, Y. A., & Panas, S. M. (1998). On applying spatial constraints in fuzzy image clustering using a fuzzy rule-based system. *IEEE Signal Processing Letters*, 5(10), 245–247. <https://doi.org/10.1109/97.720555>
- Trauwaert, E., Kaufman, L., & Rousseeuw, P. (1991). Fuzzy clustering algorithms based on the maximum likelihood principle. *Fuzzy Sets and Systems*, 42(2), 213–227. [https://doi.org/10.1016/0165-0114\(91\)90147-I](https://doi.org/10.1016/0165-0114(91)90147-I)
- Tsekouras, G. E., & Tsimikas, J. (2013). On training RBF neural networks using input-output fuzzy clustering and particle swarm optimization. *Fuzzy Sets and Systems*, 221, 65–89. <https://doi.org/10.1016/j.fss.2012.10.004>
- Türkşen, I. B. (2008). Fuzzy functions with LSE. *Applied Soft Computing*, 8(3), 1178–1188. <https://doi.org/10.1016/j.asoc.2007.12.004>
- Türkşen, I. B. (2009). Fuzzy System Models Evolution from Fuzzy Rulebases to Fuzzy Functions. *Encyclopedia of Complexity and Systems Science*, 4080–4094.

- Türkşen, I. B. (2011). A review of developments in fuzzy system models: Fuzzy rule bases to fuzzy functions. *Scientia Iranica*, 18(3), 522–527. <https://doi.org/10.1016/j.scient.2011.04.001>
- Varshney, A. K., Muhuri, P. K., & Lohani, Q. M. D. (2023). Density-based IFCM along with its interval valued and probabilistic extensions, and a review of intuitionistic fuzzy clustering methods. *Artificial Intelligence Review*, 56(4), 3755–3795. <https://doi.org/10.1007/s10462-022-10236-y>
- Visalakshi, N. K., Parvathavarthini, S., & Thangavel, K. (2014). *An Intuitionistic Fuzzy Approach to Fuzzy Clustering of Numerical Dataset* (pp. 79–87). [https://doi.org/10.1007/978-81-322-1680-3\\_9](https://doi.org/10.1007/978-81-322-1680-3_9)
- W. X., X., & J. Z., X. (1991). A combine hard clustering algorithm and fuzzy clustering algorithm—Fuzzy c-means clustering algotihm with two layers. *Fuzzy Syst. Math.*, 2(6), 77–85.
- Wallace, C. S., & Boulton, D. M. (1968). An information measure for classification. *The Computer Journal*, 11(2), 185–194.
- Wang, D., Li, Y., Hu, Y., Li, B., Deng, X., & Liu, Z. (2016). Integrated dynamic evaluation of depletion-drive performance in naturally fractured-vuggy carbonate reservoirs using DPSO-FCM clustering. *Fuel*, 181, 996–1010. <https://doi.org/10.1016/J.FUEL.2016.05.009>
- Wang, L., Shi, Y., & Liu, S. (2015). An improved fruit fly optimization algorithm and its application to joint replenishment problems. *Expert Systems with Applications*, 42(9), 4310–4323. <https://doi.org/10.1016/j.eswa.2015.01.048>
- Wang, L., Zheng, X., & Wang, S. (2013). A novel binary fruit fly optimization algorithm for solving the multidimensional knapsack problem. *Knowledge-Based Systems*, 48, 17–23. <https://doi.org/10.1016/j.knosys.2013.04.003>
- Wang, Q., Zhang, Y., Xiao, Y., & Li, J. (2017). Kernel-based fuzzy C-means clustering based on fruit fly optimization algorithm. *2017 International Conference on Grey Systems and Intelligent Services (GSIS)*, 251–256. <https://doi.org/10.1109/GSIS.2017.8077713>
- Wang, S., Dong, F., Zhang, Z., Yang, B., & Hou, Q. (2023). Multi-index dominant grouping of rock mass discontinuities based on the combined weighting method: A case study for the Huayang tunnel. *Tunnelling and Underground Space Technology*, 139. <https://doi.org/10.1016/J.TUST.2023.105211>
- Wang, W., & Zhang, Y. (2007). On fuzzy cluster validity indices. *Fuzzy Sets and Systems*, 158(19), 2095–2117. <https://doi.org/10.1016/j.fss.2007.03.004>
- Wang, W., Zhang, Y., Li, Y., & Zhang, X. (2006a). The Global Fuzzy C-Means Clustering Algorithm. *2006 6th World Congress on Intelligent Control and Automation*, 3604–3607. <https://doi.org/10.1109/WCICA.2006.1713041>
- Wang, W., Zhang, Y., Li, Y., & Zhang, X. (2006b). The Global Fuzzy C-Means Clustering Algorithm. *2006 6th World Congress on Intelligent Control and Automation*, 3604–3607. <https://doi.org/10.1109/WCICA.2006.1713041>
- Wang, X., Lv, X., & Yang, C. (2019). Data-driven Extraction Method of Belief Rule for Reagent Addition in Antimony Rougher Flotation. *IFAC-PapersOnLine*, 52(14), 72–77. <https://doi.org/10.1016/j.ifacol.2019.09.166>
- Wang, X., Wang, Y., & Wang, L. (2004). Improving fuzzy c-means clustering based on feature-weight learning. *Pattern Recognition Letters*, 25(10), 1123–1132. <https://doi.org/10.1016/j.patrec.2004.03.008>
- Wang, X. Y., & Bu, J. (2010). A fast and robust image segmentation using FCM with spatial information. *Digital Signal Processing: A Review Journal*, 20(4), 1173–1182. <https://doi.org/10.1016/j.dsp.2009.11.007>

- Wang, Z. (2010). Comparison of Four Kinds of Fuzzy C-Means Clustering Methods. *2010 Third International Symposium on Information Processing*, 563–566. <https://doi.org/10.1109/ISIP.2010.133>
- Wang, Z., Cui, T., Wang, Y., & Yu, Z. (2012). Flood Season Division with an Improved Fuzzy C-mean Clustering Method in the Taihu Lake Basin in China. *Procedia Engineering*, 28, 66–74. <https://doi.org/10.1016/j.proeng.2012.01.684>
- Wang, Z., Xu, Z., Liu, S., & Yao, Z. (2014). Direct clustering analysis based on intuitionistic fuzzy implication. *Appl. Soft Comput.*, 23.
- Watanabe, S. (1965). *Une explication mathématique du classement d'objets*. na.
- Wei, D., Wang, Z., Si, L., Tan, C., & Lu, X. (2021). An image segmentation method based on a modified local-information weighted intuitionistic Fuzzy C-means clustering and Goldpanning Algorithm. *Engineering Applications of Artificial Intelligence*, 101, 104209. <https://doi.org/10.1016/j.engappai.2021.104209>
- Wentao, S., Changhou, L., & Dan, Z. (2008). Bearing Fault Diagnosis Based on Feature Weighted FCM Cluster Analysis. *2008 International Conference on Computer Science and Software Engineering*, 518–521. <https://doi.org/10.1109/CSSE.2008.289>
- Windham, M. P. (1985). Numerical classification of proximity data with assignment measures. *Journal of Classification*, 2(1), 157–172. <https://doi.org/10.1007/BF01908073>
- Wu, K.-L., & Yang, M.-S. (2002). Alternative c-means clustering algorithms. *Pattern Recognition*, 35(10), 2267–2278. [https://doi.org/10.1016/S0031-3203\(01\)00197-2](https://doi.org/10.1016/S0031-3203(01)00197-2)
- Wu, K.-L., Yang, M.-S., & Hsieh, J.-N. (2010). Mountain c-regressions method. *Pattern Recognition*, 43(1), 86–98. <https://doi.org/10.1016/j.patcog.2009.06.008>
- Wu, T. o. n. g. (2019). Modified fuzzy clustering with segregated cluster centroids. *Neurocomputing*, 361.
- Xie, X. L., & Beni, G. (1991). A validity measure for fuzzy clustering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(8), 841–847. <https://doi.org/10.1109/34.85677>
- Xiong, G., Zhou, X., & Ji, L. (2006). Automated Segmentation of Drosophila RNAi Fluorescence Cellular Images Using Deformable Models. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 53(11), 2415–2424. <https://doi.org/10.1109/TCSI.2006.884461>
- Xu, C., Zhang, P., Li, B., Wu, D., & Fan, H. (2013). Vague C-means clustering algorithm. *Pattern Recognition Letters*, 34(5), 505–510. <https://doi.org/10.1016/j.patrec.2012.12.001>
- Xu, R., & WunschII, D. (2005). Survey of Clustering Algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645–678. <https://doi.org/10.1109/TNN.2005.845141>
- Xu, Z. (2012). *Intuitionistic fuzzy hierarchical clustering algorithms*. 20, 90–97.
- Xu, Z., Li, Y., Wang, Z., & Xuan, J. (2016). A Novel Clustering Method Combining ART with Yu's Norm for Fault Diagnosis of Bearings. *Shock and Vibration*, 2016, 1–10. <https://doi.org/10.1155/2016/5468716>
- Xue, Z., Shang, Y., & Feng, A. (2010). Semi-supervised outlier detection based on fuzzy rough C-means clustering. *Mathematics and Computers in Simulation*, 80(9), 1911–1921. <https://doi.org/10.1016/j.matcom.2010.02.007>
- Yager, R. R., & Filev, D. P. (1994a). Approximate clustering via the mountain method. *IEEE Transactions on Systems, Man, and Cybernetics*, 24(8), 1279–1284. <https://doi.org/10.1109/21.299710>
- Yager, R. R., & Filev, D. P. (1994b). Approximate clustering via the mountain method. *IEEE Transactions on Systems, Man, and Cybernetics*, 24(8), 1279–1284. <https://doi.org/10.1109/21.299710>
- Yan, B., Xu, N., Xu, L. P., Li, M. Q., & Cheng, P. (2019). An improved partitioning algorithm based on FCM algorithm for extended target tracking in PHD filter. *Digital Signal Processing: A Review Journal*, 90, 54–70. <https://doi.org/10.1016/J.DSP.2019.04.002>

- Yan, J. (2014a). *Remote sensing image segmentation based on ant colony optimized fuzzy C-means clustering*. 6(6), 2675–2679.
- Yan, J. (2014b). *Remote sensing image segmentation based on ant colony optimized fuzzy C-means clustering*. 6(6), 2675–2679.
- Yang, C., Bruzzone, L., Sun, F., Lu, L., Guan, R., & Liang, Y. (2010). A Fuzzy-Statistics-Based Affinity Propagation Technique for Clustering in Multispectral Images. *IEEE Transactions on Geoscience and Remote Sensing*, 48(6), 2647–2659. <https://doi.org/10.1109/TGRS.2010.2040035>
- Yang, C.-M., Liu, Y., Wang, Y.-T., Li, Y.-P., Hou, W.-H., Duan, S., & Wang, J.-Q. (2022). A Novel Adaptive Kernel Picture Fuzzy C-Means Clustering Algorithm Based on Grey Wolf Optimizer Algorithm. *Symmetry*, 14(7), 1442. <https://doi.org/10.3390/sym14071442>
- Yang, M., Shi, C., & Liu, H. (2021). Day-ahead wind power forecasting based on the clustering of equivalent power curves. *Energy*, 218, 119515. <https://doi.org/10.1016/j.energy.2020.119515>
- Yang, M.-S. (1993). A survey of fuzzy clustering. *Mathematical and Computer Modelling*, 18(11), 1–16. [https://doi.org/10.1016/0895-7177\(93\)90202-A](https://doi.org/10.1016/0895-7177(93)90202-A)
- Yang, M.-S. (1994). ON ASYMPTOTIC NORMALITY OF A CLASS OF FUZZY C-MEANS CLUSTERING PROCEDURES. *International Journal of General Systems*, 22(4), 391–403. <https://doi.org/10.1080/03081079408935224>
- Yang, M.-S., & Tsai, H.-S. (2008). A Gaussian kernel-based fuzzy c-means algorithm with a spatial bias correction. *Pattern Recognition Letters*, 29(12), 1713–1725. <https://doi.org/10.1016/j.patrec.2008.04.016>
- Yang, M.-S., & Yu, K. F. (1990). ON STOCHASTIC CONVERGENCE THEOREMS FOR THE FUZZY C-MEANS CLUSTERING PROCEDURE\*. *International Journal of General Systems*, 16(4), 397–411. <https://doi.org/10.1080/03081079008935091>
- Yang, M.-S., & Yu, K. F. (1992). ON EXISTENCE AND STRONG CONSISTENCY OF A CLASS OF FUZZY C-MEANS CLUSTERING PROCEDURES. *Cybernetics and Systems*, 23(6), 583–602. <https://doi.org/10.1080/01969729208927483>
- Yang, Y., Chongxun, Z., & Lin, P. (2004). *A Novel Fuzzy C-Means Clustering Algorithm for Image Thresholding*. 4.
- Yi, C., Tuo, S., Tu, S., & Zhang, W. (2021). Improved fuzzy C-means clustering algorithm based on t-SNE for terahertz spectral recognition. *Infrared Physics & Technology*, 117, 103856. <https://doi.org/10.1016/j.infrared.2021.103856>
- Yoshinari, Y., Pedrycz, W., & Hirota, K. (1993). Construction of fuzzy models through clustering techniques. *Fuzzy Sets and Systems*, 54(2), 157–165. [https://doi.org/10.1016/0165-0114\(93\)90273-K](https://doi.org/10.1016/0165-0114(93)90273-K)
- Yu, J., & Yang, M.-S. (2007). A Generalized Fuzzy Clustering Regularization Model With Optimality Tests and Model Complexity Analysis. *IEEE Transactions on Fuzzy Systems*, 15(5), 904–915. <https://doi.org/10.1109/TFUZZ.2006.889957>
- Yu, K., Lin, T. R., & Tan, J. W. (2017). A bearing fault diagnosis technique based on singular values of EEMD spatial condition matrix and Gath-Geva clustering. *Applied Acoustics*, 121, 33–45. <https://doi.org/10.1016/j.apacoust.2017.01.023>
- Yu, Z., Au, O. C., Zou, R., Yu, W., & Tian, J. (2010). An adaptive unsupervised approach toward pixel clustering and color image segmentation. *Pattern Recognition*, 43(5), 1889–1906. <https://doi.org/10.1016/j.patcog.2009.11.015>
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
- Zahid, N., Abouelala, O., Limouri, M., & Essaid, A. (2001). Fuzzy clustering based on K-nearest-neighbours rule. *Fuzzy Sets and Systems*, 120(2), 239–247. [https://doi.org/10.1016/S0165-0114\(99\)00074-3](https://doi.org/10.1016/S0165-0114(99)00074-3)

- Zarandi, M., Zarinbal, M., & Turksen, I. B. (2009). *Type-II Fuzzy Possibilistic C-Mean Clustering*. 30–35.
- Zeraatpisheh, M. o. j. t. a. b. a. (2019). Disaggregating and updating a legacy soil map using DSMART, fuzzy c-means and k-means clustering algorithms in Central Iran. *Geoderma*, 340.
- Zhang, C., Zhou, H., Chen, B., Peng, Y., & Duan, J. (2023). Hybrid simplification algorithm for unorganized point cloud based on two-level fuzzy decision making. *Optik*, 276. <https://doi.org/10.1016/J.IJLEO.2023.170642>
- Zhang, M. i. n. x. i. a. (2019). A hybrid biogeography-based optimization and fuzzy C-means algorithm for image segmentation. *Soft computing*, 23.
- Zhang, Y., & Han, J. (2021). Differential privacy fuzzy C-means clustering algorithm based on gaussian kernel function. *PLOS ONE*, 16(3), e0248737. <https://doi.org/10.1371/journal.pone.0248737>
- Zhang, Y., Huang, D., Ji, M., & Xie, F. (2011). Image segmentation using PSO and PCM with Mahalanobis distance. *Expert Systems with Applications*, 38(7), 9036–9040. <https://doi.org/10.1016/J.ESWA.2011.01.041>
- Zhang, Y., Liu, X.-D., Xie, F.-D., & Li, K.-Q. (2009). Fault classifier of rotating machinery based on weighted support vector data description. *Expert Systems with Applications*, 36(4), 7928–7932. <https://doi.org/10.1016/j.eswa.2008.10.062>
- Zhang, Y., Xu, X., & Ye, Y. (2010). NSS-AKmeans: An Agglomerative Fuzzy K-means clustering method with automatic selection of cluster number. *2010 2nd International Conference on Advanced Computer Control*, 32–38. <https://doi.org/10.1109/ICACC.2010.5487179>
- Zhang, Y., Zhao, Z., Yao, X., Wen, Y., & Luo, X. (2022). Planar array capacitive imaging method based on data optimization. *Sensors and Actuators A: Physical*, 347, 113941. <https://doi.org/10.1016/j.sna.2022.113941>
- Zhao, J., & Jia, M. (2015). Segmentation algorithm for small targets based on improved data field and fuzzy c-means clustering. *Optik*, 126(23), 4330–4336. <https://doi.org/10.1016/j.ijleo.2015.08.037>
- Zhao, Z., Zhao, J., Song, K., Hussain, A., Du, Q., Dong, Y., Liu, J., & Yang, X. (2020). Joint DBN and Fuzzy C-Means unsupervised deep clustering for lung cancer patient stratification. *Engineering Applications of Artificial Intelligence*, 91, 103571. <https://doi.org/10.1016/j.engappai.2020.103571>
- Zhou, B., & Zhao, Z. (2022). A hybrid fuzzy-neural-based dynamic scheduling method for part feeding of mixed-model assembly lines. *Computers and Industrial Engineering*, 163. <https://doi.org/10.1016/J.CIE.2021.107794>

## Anexo A: Publicaciones derivadas de la investigación

