



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Doctorado

Agrupamiento Difuso Intuitivo Robusto para
Delimitación de Lesiones de la Piel

presentada por
MC. Celia Ramos Palencia

como requisito para la obtención del grado de
Doctora en Ciencias de la Computación

Director de tesis
Dr. Dante Mújica Vargas

Cuernavaca, Morelos, México. Febrero de 2024.



Cuernavaca, Mor.,

No. De Oficio:

Asunto:

24/enero/2024

SAC/009/2024

**Autorización de
impresión de tesis**


**CELIA RAMOS PALENCIA
CANDIDATA AL GRADO DE DOCTORA
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 **“AGRUPAMIENTO DIFUSO INTUITIVO ROBUSTO PARA DELIMITACIÓN DE LESIONES DE LA PIEL”**, 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”*




**CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO**

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

CMAZ/lmz



 Centro Nacional de Investigación y Desarrollo Tecnológico	ACEPTACIÓN DE IMPRESIÓN DEL DOCUMENTO DE TESIS DOCTORAL	Código: CENIDET-AC-006-D20
		Revisión: 0
	Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4	Página 1 de 1

Cuernavaca, Mor., a 22 de enero de 2024

CARLOS MANUEL ASTORGA ZARAGOZA
 SUBDIRECTOR ACADÉMICO
 PRESENTE

ATn: **JUAN GABRIEL GONZÁLEZ SERNA**
 PRESIDENTE DEL CLAUSTRO DOCTORAL

Los abajo firmantes, miembros del Comité Tutorial de la estudiante **CELIA RAMOS PALENCIA** manifiestan que después de haber revisado el documento de tesis titulado **"AGRUPAMIENTO DIFUSO INTUITIVO ROBUSTO PARA DELIMITACIÓN DE LESIONES DE LA PIEL"**, realizado bajo la dirección de Dante Mújica Vargas, el trabajo se **ACEPTA** para proceder a su impresión.

ATENTAMENTE



DANTE MÚJICA VARGAS
 TecNM/CAMPUS CENIDET



NOÉ ALEJANDRO CASTRO SÁNCHEZ
 TecNM/CAMPUS CENIDET




NIMROD GONZÁLEZ FRANCO
 TecNM/CAMPUS CENIDET



ALICIA MARTÍNEZ REBOLLAR
 TecNM/CAMPUS CENIDET



JEAN MARIE VIANNEY KINANI
 INST. POLITECNICO NACIONAL UPIIH-HIDALGO



c.c.p: María Elena Gómez Torres / Jefa del Departamento de Servicios Escolares
 c.c.p: María Yasmín Hernández Pérez / Jefa del Departamento C. Computacionales
 c.c.p: Expediente



Dedicatoria

A mis padres, por ser el empuje y la confianza para hacer posible lo que creía imposible.

A mi hermana, por su apoyo incondicional y por ser mi mayor fan.

A Jonathan, por su paciencia. Este será el primero de nuestros comienzos.

A mis tres amigos. Gracias por acompañarme, que las aventuras nunca falten.

A Dios...promesa cumplida.

Gracias

Agradecimientos

Agradezco al Centro Nacional de Investigación y Desarrollo Tecnológico CENIDET por la oportunidad de desarrollo durante mis estudios de doctorado.

De igual modo, agradezco al Consejo Nacional de Humanidades, Ciencias y Tecnologías CONAHCYT por el apoyo económico, para mis estudios de doctorado.

Al Dr. Dante Mújica Vargas, quién además de fungir como mi director de tesis, fue una ayuda inapreciable, gracias por su paciencia, tiempo, enseñanzas y motivación para formarme realmente como investigadora.

A todos y cada uno de los miembros del comité tutorial que se me asignó para esta tesis: Dr. Noé Alejandro Castro Sánchez, Dr. Nimrod González Franco, Dra. Alicia Martínez Rebollar y Dr. Jean Marie Vianney Kinani, por cada una de sus observaciones, sugerencias y consejos a lo largo de mi estadía en esta institución.

A mis compañeros de CENIDET, en especial a Antonio y Arturo, quienes además de que iniciamos juntos, fueron de gran ayuda durante el desarrollo de mi tema doctoral. Gracias por sus consejos y los buenos momentos. A Andrés, Alexis y Christian por estar siempre presente en mis evaluaciones, las hicieron más llevaderas. Que tengan éxito en todo.

A mi familia, por cada una de sus muestras de afecto y porque siempre me han hecho sentir cobijada y perteneciente. A Elenita y Roberto, por ser mi otra mamá y el hermano de otro vientre; ejemplo perfecto de que cuando se quiere todo se puede.

¡GRACIAS!

Resumen

El *clustering* o agrupamiento, permite agrupar los objetos que son similares entre sí para que su análisis pueda ser más rápido y certero. Existe el agrupamiento difuso, el cual permite que todos los objetos de un conjunto de datos pertenezcan en cierta medida a los grupos que se formen; dentro de esta rama se encuentra el algoritmo difuso intuitivo, que además de un grado de pertenencia, agrega dos parámetros más, convirtiéndolo así en un método más eficiente que el tradicional difuso. En esta investigación se presenta la formulación del algoritmo de agrupamiento difuso intuitivo para ser robusto ante datos atípicos presentes en imágenes dermatoscópicas y realizar la delimitación de la zona afectada. Este algoritmo es formulado a partir de la derivación de la función objetivo para la actualización de pertenencias, para integrar una función de influencia de un estimador m-redescendente. La experimentación demuestra una precisión del 95% con el uso del algoritmo propuesto con respecto a otros algoritmos de agrupamiento para realizar delimitaciones, además se reduce considerablemente el número de iteraciones.

Palabras clave: Agrupamiento difuso, Conjuntos difusos, Conjuntos difusos intuitivos, Estimadores robustos, Segmentación de Imágenes, Imágenes Dermatoscópicas.

Abstract

Clustering allows grouping objects that are similar to each other so that their analysis can be faster and accurate. There is fuzzy clustering, which allows all objects in a dataset to belong to some extent to the groups formed. This work presents the formulation of the intuitive fuzzy clustering algorithm to be robust to atypical data present in dermoscopic images and to delimit the affected area. This algorithm is formulated from the objective function derivation for memberships update, to integrate an m-re-descending estimator influence function. Experimentation shows an accuracy of 95% with the proposal algorithm with respect to other clustering algorithms to perform delimitations, in addition the iterations number is considerably reduced.

Keywords: Clustering, Fuzzy clustering, Intuitionistic fuzzy clustering, Robust estimators, Pattern recognition, Image segmentation.

Índice

1. Introducción	1
1.1. Planteamiento del problema	2
1.1.1. Delimitación del problema	2
1.1.2. Complejidad del problema	2
1.2. Objetivos	3
1.2.1. Objetivo general	3
1.2.2. Objetivos específicos	3
1.3. Alcances y limitaciones	3
1.3.1. Alcances	3
1.3.2. Limitaciones	3
1.4. Justificación	4
1.4.1. Beneficios e importancia	4
1.5. Aportaciones científicas	5
1.6. Organización de la tesis	5
2. Marco teórico	6
2.1. Imágenes médicas	6
2.1.1. Tipos de imágenes médicas	6
2.1.2. Imágenes dermatoscópicas	9
2.2. Segmentación de imágenes	10
2.3. Agrupamiento de datos	12
2.4. Agrupamiento difuso	14
2.5. Conjuntos difusos	14
2.6. <i>Fuzzy C-Means</i>	15
2.7. Conjuntos difusos intuitivos	16
2.8. Distancias en conjuntos difusos y conjuntos difusos intuitivos	18
2.9. Algoritmo <i>Intuitionistic Fuzzy C-Means</i>	20
2.10. Estimadores robustos	20
3. Estado del arte	25
3.1. Discusión del estado del arte	34
3.2. Antecedentes	37
4. Metodología	38

4.1. Método tradicional	38
4.2. Método propuesto	39
4.3. Algoritmo <i>Redescending Intuitionistic Fuzzy C-Means</i> RIFCM	40
4.4. Estimador M-Redescendente	44
5. Experimentación y Resultados	47
5.1. Experimentación de RIFCM con bases de datos sintéticas	48
5.1.1. Métricas para evaluación de agrupamiento	49
5.1.2. Resultados de agrupamiento con RIFCM en base de datos sintéticas .	50
5.2. Experimentación de RIFCM con imágenes dermatoscópicas	57
5.2.1. Métricas para evaluación de segmentación	59
5.2.2. Resultados de segmentación con RIFCM en imágenes dermatoscópicas	60
5.3. Experimentos adicionales	67
5.4. Discusión de los resultados	71
6. Conclusiones	72
6.1. Productos de la investigación	72
6.2. Aportaciones de la investigación	73
6.3. Conclusiones	73
6.4. Objetivos y alcances logrados	74
6.4.1. Objetivos alcanzados	74
6.4.2. Alcances realizados	75
6.5. Trabajos Futuros	76
Referencias	77
Anexos	82

Índice de Tablas

3.1.	Discusión del Estado del Arte	35
5.1.	Métricas obtenidas de la experimentación sin presencia de datos atípicos	50
5.2.	Métricas obtenidas de la experimentación con datos atípicos	51
5.3.	Tiempo de ejecución e iteraciones en cada base de datos	56
5.4.	Vectores de prototipos obtenidos por cada algoritmo y distancia con respecto al <i>ground truth</i>	56
5.5.	Clasificación de imágenes para experimentación.	58
5.6.	Métricas obtenidas de la experimentación con datos atípicos para la segmentación de imágenes.	61
5.7.	Métricas obtenidas de la experimentación con datos atípicos para imágenes con tinta.	64
5.8.	Promedio de iteraciones y tiempo de ejecución segmentación de imágenes.	67
5.9.	Promedio de iteraciones y tiempo de ejecución experimentos adicionales.	70
5.10.	Métricas obtenidas de la experimentación con datos atípicos.	71
6.1.	Objetivos alcanzados.	74
6.2.	Alcances realizados.	75

Índice de Figuras

2.1.	Ejemplo de imagen por resonancia magnética	7
2.2.	Ejemplo de ecografía	7
2.3.	Ejemplo de radiografía	8
2.4.	Ejemplo de tomografía	8
2.5.	Representación de imágenes dermatoscópicas [2]	9
2.6.	Resultados de la segmentación de imágenes en ejemplos sencillos [3].	10
2.7.	Grupos de diferentes formas y tamaños [7].	12
2.8.	Agrupamiento en un conjunto de datos en $c = 5$ [7].	13
3.1.	Topología general de las redes neuronales de función de base radial con información auxiliar [25].	26
3.2.	Iteraciones contra Función objetivo [22].	27
3.3.	Segmentación de imágenes obtenidas usando RIFCM [22].	28
3.4.	Muestra de imágenes de un conjunto de datos [26].	28
3.5.	Segmentación de la muestra con RK-FCM [26].	29
3.6.	Obra de arte, ruido de Gauss y ruido de sal y pimienta [27].	29
3.7.	Resultados intermedios y resultados finales para la segmentación de mapas de sal y pimienta [27].	29
3.8.	Segmentación de imágenes en escala de grises con ruido sal y pimienta, (f) Segmentación con S-IFCM [28].	30
3.9.	Segmentación de imágenes con diversos algoritmos, (g) con S-IFCM [28].	30
3.10.	Proceso de minería de datos [32].	32
3.11.	Resultados del agrupamiento con la presencia de <i>outliers</i> [33]	32
3.12.	Visualización con mapa de calor usando diferentes algoritmos[33]	33
3.13.	Resultados de la segmentación de imágenes con información atípica[34]	33
3.14.	Imágenes de resonancias magnéticas comparando diversos métodos [4].	34
3.15.	Resultados de la segmentación con el método propuesto [35].	34
4.1.	Forma tradicional del proceso de agrupamiento de datos	39
4.2.	Propuesta de solución	40
4.3.	Formas de las funciones ρ y ψ del estimador Andrew's Sine	45
5.1.	Proceso de implementación computacional.	47
5.2.	Ejemplo de una base de datos simulada y su modificación para crear datos atípicos de forma simulada	48
5.3.	Base datos con $\sigma = 0.2$	49
5.4.	Desempeño de Hampel en el caso más sencillo y en la dispersión con $\sigma = 0.25$	52

5.5.	Caso de prueba con la base de datos original de 3 grupos.	53
5.6.	Caso de prueba base de datos de 3 grupos y variación $\sigma = 0.1$	54
5.7.	Resultados de las métricas para reconocimiento de patrones.	55
5.8.	Imágenes dermatoscópicas con diferentes artefactos.	58
5.9.	Clasificación de imágenes.	59
5.10.	Formas de las funciones ρ y ψ del estimador Andrew's Sine.	60
5.11.	Resultados de las métricas para segmentación de imágenes Clase 1.	62
5.12.	Resultados de las métricas para segmentación de imágenes Clase 1.	63
5.13.	Formas de las funciones ρ y ψ del estimador Andrew's Sine.	64
5.14.	Resultados de las métricas para segmentación de imágenes Clase 5.	65
5.15.	Resultados de las métricas para segmentación de imágenes Clase 5.	66
5.16.	Segmentación con diferentes estimadores con presencia de vello abundante. . .	68
5.17.	Segmentación con diferentes estimadores con presencia de dos artefactos diferentes, vello y electródo.	69
5.18.	Segmentación con diferentes estimadores en lesión con diferentes bordes y texturas.	70

Capítulo 1

Introducción

Las imágenes dermatoscópicas han sido de gran utilidad para el diagnóstico oportuno en la detección de melanoma, pero su interpretación toma tiempo y es subjetiva, incluso para dermatólogos expertos. Esta desventaja ha despertado interés dentro de la inteligencia artificial, lo que ha traído consigo el desarrollo de sistemas de diagnóstico asistidos por computadora, que ayudan a la evaluación clínica de los expertos en el área médica. El enfoque tradicional en el análisis automático de imágenes dermatoscópicas suele tener tres etapas: 1) Segmentación de la imagen; 2) extracción y selección de características y 3) clasificación de la lesión. La fase de segmentación es uno de los pasos más importantes ya que afecta la precisión de los pasos subsecuentes. Además de que también se vuelve difícil debido a la gran variedad de formas de lesiones, tamaño, coloración, tipo de piel y textura; sin mencionar que algunas lesiones tienen bordes irregulares y en algunos casos, existe una suave transición entre la piel y la lesión. Estos artefactos presentes en este tipo de imágenes no es considerado ruido, sino información atípica, la cual distorciona el resultado del análisis. Por esta razón debe identificarse y tratarse de una forma adecuada. Para abordar este problema han surgido diversos métodos o algoritmos dependiendo el resultado que se espera obtener. En ese contexto, las enfermedades de la piel han tenido un incremento importante en los últimos años. Debido a ello, el campo médico ha buscado apoyo en otras áreas del conocimiento para ayudar a la detección e identificación de lesiones cutáneas que permitan ofrecer un diagnóstico preciso y a la vez, proveer un tratamiento eficiente frente a estos padecimientos. Por lo tanto, los dermatólogos han recurrido al uso de herramientas tecnológicas que ayuden en el análisis de imágenes dermatoscópicas de lesiones cutáneas, las cuales son obtenidas a través de un proceso denominado dermatoscopia digital, que consiste en la toma de una fotografía digital utilizando una cámara especializada que atenúan problemas de iluminación, reflexión y refracción de la piel [1]; y al uso de modelos computacionales que permitan interpretar estas imágenes para una mayor confiabilidad en el diagnóstico médico. Estos modelos pueden estar basados en el uso de algoritmos de agrupamiento y segmentación de imágenes. Con esta tesis doctoral se introduce en el Estado del arte un algoritmo de agrupamiento difuso intuitivo robusto que es capaz de realizar tareas de Segmentación de Imágenes Dermatoscópicas con la presencia de información atípica y que ésta no afecte el resultado. Disminuyendo el número de iteraciones y mostrando mayor calidad de agrupamiento y segmentación que los métodos tradicionales.

1.1. Planteamiento del problema

El agrupamiento de objetos ha sido uno de los temas más estudiados debido a sus múltiples usos en diversas áreas del conocimiento, es por ello que se han creado y mejorado diferentes métodos para este propósito, por ejemplo, los algoritmos de agrupamiento. Dentro de esta clase, se encuentran los de agrupamiento difuso, que a diferencia de los algoritmos clásicos, como K-Means, que sólo permiten la pertenencia de un objeto a un solo grupo, otorgan la flexibilidad de tener cierto grado de pertenencia a todos los grupos (*Fuzzy C-Means*). De esta rama se derivan los IFS (*Intuitionistic Fuzzy Sets*) o conjuntos difusos intuitivos, los cuáles, agregan un grado de pertenencia, uno de no pertenencia y un grado de indecisión, lo que permite que este método sea más eficiente que el tradicional. Sin embargo, a pesar de mostrar resultados favorables, estos algoritmos tienen una limitación entre sí, y es que son basados en el cálculo de la media; lo que provoca que sean sensibles ante la presencia de información atípica.

Hipótesis: Un algoritmo de agrupamiento difuso intuitivo puede ser robustecido a través del uso de algunos estimadores robustos y la actualización de sus valores de pertenencia para ser tolerante a información atípica.

1.1.1. Delimitación del problema

En esta investigación se plantea de manera matemática el algoritmo IFCM de tal manera que pueda ser robusto con el uso de un estimador, a través de la derivación de su función objetivo; el cual será evaluado en términos de calidad de agrupamiento y convergencia, en tareas de Segmentación de Imágenes dermatoscópicas.

1.1.2. Complejidad del problema

La complejidad reside en que en los métodos clásicos de agrupamiento de datos es necesario un bloque de preprocesamiento, que filtre aquellos datos que se encuentran muy dispersos con respecto al resto. Estas técnicas constan, entre otras, en la eliminación, ponderación y normalización, lo cual puede generar alteraciones en la información y reducir la calidad del agrupamiento. Sin embargo al no realizar este preprocesamiento los algoritmos clásicos de agrupamiento como vecino más cercano, agrupamiento jerárquico y *k-means*, el rendimiento se ve afectado en gran medida.

1.2. Objetivos

1.2.1. Objetivo general

Proponer, formular y evaluar una estrategia que permita robustecer a un algoritmo de agrupamiento difuso intuitivo frente a datos atípicos para la delimitación de imágenes dermatoscópicas.

1.2.2. Objetivos específicos

- Proponer un estimador robusto que sea implementado dentro de un algoritmo difuso intuitivo
- Formular una versión robusta de un algoritmo difuso intuitivo.
- Evaluar el desempeño del algoritmo propuesto en bases de datos e imágenes dermatoscópicas con información atípica.
- Validar los resultados utilizando métricas de la literatura en el dominio del reconocimiento de patrones y la segmentación de imágenes médicas
- Comparar los resultados obtenidos con antecedentes de la literatura.

1.3. Alcances y limitaciones

1.3.1. Alcances

- Robustecer a un algoritmo de agrupamiento difuso intuitivo.
- Establecer las bases para que esta propuesta se puede extender a otras metodologías basadas en agrupamiento difuso.
- Proponer un esquema basado en agrupamiento difuso con aprendizaje aplicable a tareas de Segmentación de Imágenes Dermatoscópicas.
- Posicionarse en el Estado del Arte como un referente importante en proceso de robustecer a los algoritmos de agrupamiento difuso.

1.3.2. Limitaciones

- Se trabajó con imágenes dermatoscópicas.
- No se consideró la presencia de ruido en la segmentación de imágenes.
- La segmentación se realizó con sólo 5 tipos de artefactos: vellos, tinta, electrodos y color con abultamiento.
- Se hizo uso de 3 estimadores robustos para implementarse en un algoritmo de agrupamiento difuso.

1.4. Justificación

En los métodos clásicos de agrupamiento de datos es necesario un bloque de preprocesamiento, que filtre aquellos datos que se encuentran muy dispersos con respecto al resto. Estas técnicas constan, entre otras, en la eliminación, ponderación y normalización, lo cual puede generar alteraciones en la información y reducir la calidad del agrupamiento. Sin embargo al no realizar este preprocesamiento los algoritmos clásicos de agrupamiento como vecino más cercano, agrupamiento jerárquico y k-means, el rendimiento se ve afectado en gran medida. La investigación en el área de agrupamiento de datos ha producido una gran cantidad de diferentes paradigmas, enfoques y métodos; el algoritmo de agrupamiento difuso *Fuzzy C-Means* sobresale debido en gran medida a su simplicidad y eficiencia. Sin embargo, a pesar de las ventajas mencionadas anteriormente, este algoritmo en su forma convencional presenta una deficiencia importante, pues al estar basado en una función objetivo de mínimos cuadrados, se vuelve sumamente sensible a información atípica, lo que provoca resultados no satisfactorios. A partir de esta debilidad de los algoritmos de agrupamiento, en esta investigación se propone la reformulación del algoritmo de Agrupamiento Difuso Intuitivo IFCM incorporando la influencia de un estimador M-Redescendente sobre las funciones objetivo y de actualización del algoritmo, lo cual permite segmentar imágenes demartoscópicas con información atípica sin utilizar etapas de pre-procesamiento.

1.4.1. Beneficios e importancia

Los beneficios obtenidos de esta investigación son:

- Formulación matemática de un algoritmo de agrupamiento difuso intuitivo robusto aplicable a tareas de Reconocimiento de Patrones y Segmentación de Imágenes.
- Mejora en la calidad de agrupamiento y segmentación frente a otros métodos tradicionales.

En esta investigación se marca un referente dentro del estado de arte mediante la formulación de un algoritmo difuso intuitivo robusto capaz de agrupar datos y segmentar imágenes con información atípica.

1.5. Aportaciones científicas

Las aportaciones científicas que se obtuvieron durante la elaboración de esta tesis doctoral son:

- Algoritmo de Agrupamiento Difuso Intuitivo Robusto aplicable a tareas de Reconocimiento de Patrones.
- Algoritmo de Agrupamiento Difuso Intuitivo Robusto aplicable a la Segmentación de Imágenes Dermatoscópicas.
- Metodología capaz de ser replicada y usada con diversos tipos de estimadores robustos únicamente modificando los parámetros necesarios.

1.6. Organización de la tesis

El documento se encuentra compuesto por seis capítulos, incluyendo anexos y referencias. En el capítulo 2 se muestra el marco teórico donde se presentan los conceptos utilizados durante la investigación como por ejemplo, agrupamiento difuso, agrupamiento difuso intuitivo, segmentación de imágenes dermatoscópicas, estimadores robustos, etc. El capítulo 3 se describe el estudio del estado del arte, es decir, aquellas investigaciones que sirvieron como base y antecedentes para esta investigación. En el capítulo 4 se muestra la metodología utilizada en este trabajo. El capítulo 5 contiene la experimentación realizada en las diferentes tareas para las cuales se formuló un algoritmo difuso intuitivo robusto y los resultados que se obtuvieron. En el capítulo 6 se incluyen las conclusiones y los trabajos futuros que podrían realizarse usando como base esta investigación.

Capítulo 2

Marco teórico

En este capítulo se describen de manera detallada aquellos conceptos claves para la elaboración de esta tesis, así mismo se presentan algunos trabajos que anteceden a ésta investigación. Al final del capítulo se resumen algunos trabajos que fueron pieza clave para este documento. A continuación, se presentan los conceptos básicos de la investigación para una mejor comprensión del tema.

2.1. Imágenes médicas

Gracias a los avances tecnológicos en el área de la medicina, los especialistas de la salud ahora son capaces de realizar diagnósticos para dar tratamiento a los pacientes evitando algún efecto secundario que pueda dañar su integridad física. Por ello, las imágenes médicas son una técnica que se ha desarrollado como una representación visual de las diferentes partes de la anatomía humana para poder diagnosticar algún padecimiento y poder ofrecer su pertinente tratamiento, por lo tanto, las imágenes médicas son un recurso eficiente y se pueden utilizar para fines de terapia y diagnosis.

2.1.1. Tipos de imágenes médicas

Existen diversos tipos de imágenes médicas, dependiendo el tipo de análisis y especialista se hace la selección de qué tipo es pertinente utilizar para emitir un diagnóstico. Algunos de los tipos son:

Imágenes por resonancia magnética

La resonancia magnética (RM) es una prueba médica que ayuda en el diagnóstico, pronóstico y tratamiento de algunas patologías. Incluye los campos magnéticos y ondas de radio para ver los órganos y otras estructuras del cuerpo humano. Para este proceso se requiere un escáner de IRM el cual contiene un imán en forma de círculo para crear un campo magnético y exponer los protones a ondas de radio. Con este proceso la máquina desarrolla una imagen.




Figura 2.1: Ejemplo de imagen por resonancia magnética

Ecografía

En este procedimiento se usan ondas sonoras de alta frecuencia (de ahí el nombre), que van a ser reflejadas en el tejido para desarrollar imágenes de tejidos blandos, músculos y otros órganos. No representa algún peligro para la salud, como otras técnicas de obtención de imágenes. También se le conocen como ultrasonido o sonogramas.




Figura 2.2: Ejemplo de ecografía

Radiografía

Para la obtención de este tipo de imágenes, es utilizada la radiación electromagnética. Para el proceso se requiere una máquina de rayos X que emite ondas de energía al cuerpo. Los órganos, tejidos blandos y piel no son capaces de absorber estas ondas, a diferencia del tejido óseo. La máquina va a transferir los resultados a un material donde se indicarán aquellas partes del cuerpo que absorbieron las ondas en blanco, dejando el material no absorbido en negro.




Figura 2.3: Ejemplo de radiografía

Tomografía

Similar a una radiografía, a diferencia que ésta se desarrolla en 3D. El escáner que se utiliza, también emite rayos X, gira alrededor del cuerpo del paciente para obtener la imagen. A diferencia del tipo de imágenes explicadas anteriormente, las tomografías ofrecen mayor claridad con imágenes más precisas de los huesos, vasos sanguíneos, órganos y tejidos blandos. Este tipo de procedimiento es utilizado para evitar una cirugía exploratoria.




Figura 2.4: Ejemplo de tomografía

Habiendo entrado en contexto con los diferentes tipos de imágenes médicas, a continuación en una sección aparte se describirán las imágenes dermatoscópicas, sobre las cuales se trabajó en esta investigación.

2.1.2. Imágenes dermatoscópicas

La dermatoscopia es una técnica no invasiva que permite hacer un diagnóstico en el área de la dermatología. Antes de su aparición, cuando un especialista quería descartar la presencia de un melanoma se tenía que realizar una biopsia, que es un procedimiento quirurgico donde es extraída una parte del tejido para ser analizado. Antes esta situación surge la dermatoscopia, la cual a través de un dermatoscopio se obtienen imágenes nítidas de la lesión. Esto representa una gran ventaja, ya que permite procesar la imagen de manera computacional logrando así un mejor análisis de la lesión y a su vez, acelerar el diagnóstico. Aunado a esto y con las nuevas tecnologías, las imágenes van siendo almacenadas, permitiendo al experto visualizar la evolución de la lesión, evitando biopsas. Como se puede observar en la Figura 2.5, en este tipo de imágenes es posible visualizar elementos externos a la lesión como tal, por ejemplo, vellos (a), pigmentación (b), bordes y texturas (c), lunares (d), etc [2].




Figura 2.5: Representación de imágenes dermatoscópicas [2]

Una vez que se han explicado los diferentes tipos de imágenes médicas, a continuación se explicarán los métodos computacionales que suelen utilizarse para su estudio y análisis.

2.2. Segmentación de imágenes

Es un proceso en el que se divide una imagen en regiones o segmentos con características visuales similares. Esto se utiliza en diversas aplicaciones, como reconocimiento de objetos, visión por computadora, medicina, análisis de imágenes satelitales y más. La segmentación de imágenes ha sido un problema fundamental en el campo de la visión por computadora desde hace años y puede definirse como un problema de clasificación de píxeles con etiquetado semántico, segmentación semántica, un particionamiento de objetos individuales, segmentación de instancia, o ambas, segmentación panóptica [3].

- *Segmentación semántica:* Realiza un etiquetado a nivel de píxel con un conjunto de categoría de objetos para cada píxel en la imagen; por lo tanto, suele ser una tarea más costosa que clasificar toda la imagen, lo cual realiza una predicción de una sola etiqueta para toda la imagen.
- *Segmentación de instancias:* Amplía el alcance de la segmentación semántica mediante la detección y delimitación de cada objeto de interés en la imagen.

Numerosos algoritmos para la segmentación de imágenes han sido desarrollados dentro de la literatura, tales como umbralización, histogramas, crecimiento de regiones, agrupamiento con k-means, etc. En años recientes los modelos de aprendizaje profundo han proporcionado una nueva generación de modelos de segmentación de imágenes con un mejor rendimiento, logrando una mayor precisión que los métodos clásicos.




Figura 2.6: Resultados de la segmentación de imágenes en ejemplos sencillos [3].

Una imagen digital es una representación bidimensional de una imagen a partir de una matriz numérica, frecuentemente binaria. Dependiendo del tipo de imagen (en escala de grises o a color) será el tipo de matriz que será resultante. Para poder realizar cualquier análisis y procesar una imagen si tiene que hacer una conversión de los canales a la matriz.

Dentro de las múltiples áreas de la inteligencia artificial, existe el procesamiento de imágenes, el cual es utilizado para el análisis y búsqueda de información en las imágenes. En este rubro y bajo este dominio surge la segmentación de imágenes, la cual puede definirse como el proceso a través del cual, una imagen es dividida en varias regiones que deben cumplir ciertas características para lograr un estudio completo.

Existen algunas técnicas de segmentación:

- **Basada en color.** Esta técnica divide la imagen en regiones en función de las diferencias de color. Sus aplicaciones son en la detección de objetos en imágenes médicas o seguimiento de objetos en video.
- **Basada en píxeles.** Realizan una clasificación de los píxeles tomando en cuenta sus características. En este tipo destacan la umbralización, los histogramas, el agrupamiento y las redes neuronales.
- **Basada en fronteras.** Este tipo dan contornos bien definidos y su desempeño es mejor cuando las características de las regiones son diferentes. En este tipo destacan los bordes locales, los bordes globales y los modelos deformables.
- **Basados en regiones.** Se basa en la división de la imagen en regiones homogéneas, muestra mayor tolerancia al ruido y es de utilidad cuando se definen criterios de similitud; sin embargo, es costoso en términos de tiempo y memoria.
- **Segmentación por crecimiento de superpíxeles.** En lugar de segmentar píxeles individuales, esta técnica agrupa píxeles en regiones superpíxel que representan áreas homogéneas
- **Segmentación por aprendizaje automático.** Utiliza algoritmos de aprendizaje automático, como redes neuronales convolucionales (CNN), para identificar y clasificar regiones en una imagen. Esto es común en aplicaciones de reconocimiento de objetos y detección de características.

Uno de los algoritmos que más se utilizan para la segmentación de imágenes es K-Means sobretodo dentro del área de la medicina, el cual añadiendo unas mejoras y algunos filtros se han obtenido resultados favorecedores para segmentar imágenes médicas, tal como lo presenta [4].

2.3. Agrupamiento de datos

El agrupamiento, o *clustering*, es una técnica en el campo del aprendizaje automático y la minería de datos que se utiliza para dividir un conjunto de datos en grupos de elementos similares. El objetivo del agrupamiento es encontrar patrones y estructuras dentro de los datos de manera no supervisada, es decir, sin etiquetas predefinidas ni categorías conocidas [5]. El objetivo principal del agrupamiento es dividir los datos en grupos de manera que los elementos dentro de un mismo grupo sean más similares entre sí que con los elementos en otros grupos. La similitud se define según alguna métrica específica, como la distancia euclidiana. A diferencia de la clasificación, donde se requieren etiquetas para entrenar un modelo, el agrupamiento es un enfoque no supervisado. Esto significa que no se necesita información previa sobre las categorías de los datos. Existen diversos métodos de agrupamiento, cada uno con sus propias características. El más conocido es K-means. De él surgen varias derivaciones, como el K-medoids y su contraparte difusa, *Fuzzy C-means*. En resumen, el agrupamiento es una técnica en el análisis de datos y tiene aplicaciones en una amplia variedad de campos. Permite descubrir patrones y estructuras en datos no etiquetados, lo que puede ser útil para la toma de decisiones, la segmentación y la comprensión de conjuntos de datos complejos [6].

El objetivo del agrupamiento es el particionamiento de datos en un cierto número de grupos o clusters con el fin de explorar la estructura de los datos y proporcionar información útil para su posterior análisis. Éste consiste en encontrar una estructura en la colección de datos no etiquetados. En la Figura 2.7 se observan ejemplos de agrupamiento de distintas formas y tamaño.




Figura 2.7: Grupos de diferentes formas y tamaños [7].

El agrupamiento, permite agrupar los objetos que son similares entre sí para que su análisis pueda ser más rápido y certero. Existe el agrupamiento difuso, el cual permite que todos los objetos de un conjunto de datos pertenezcan en cierta medida a los grupos que se formen; su objetivo es el particionamiento de datos en un cierto número de grupos o clusters con el fin de explorar la estructura de los datos y proporcionar información útil para su posterior análisis.

Uno de los algoritmos más conocido de agrupamiento es *K-Means*, el cual asigna el objeto a un solo grupo [8]. Dado que es un algoritmo discreto y no permite que un dato pertenezca en cierto grado a dos grupos esta teoría se ha extendido al algoritmo *Fuzzy C-Means*, el cual permite la pertenencia gradual en un intervalo cerrado $\mu \in [0, 1]$ de los datos con respecto a los grupos o regiones de interés. Esta flexibilidad permite expresar la pertenencia de un dato a todos los grupos o regiones en forma simultánea. En la Figura 2.8 se observa el agrupamiento realizado por ambos algoritmos, mostrando que hay un mejor agrupamiento con Fuzzy C-Means.




Figura 2.8: Agrupamiento en un conjunto de datos en $c = 5$ [7].

Uno de los algoritmos más conocido de agrupamiento es *K-Means*, el cual asigna el objeto a un solo grupo. Dado que es un algoritmo discreto y no permite que un dato pertenezca en cierto grado a dos grupos esta teoría se ha extendido al algoritmo *Fuzzy C-Means*, el cual permite la pertenencia gradual en un intervalo cerrado $\mu \in [0, 1]$ de los datos con respecto a los grupos o regiones de interés. Esta flexibilidad permite expresar la pertenencia de un dato a todos los grupos o regiones en forma simultánea.

Dentro de la clasificación de algoritmos de agrupamiento se encuentran los de agrupamiento difuso, que forman una clase de algoritmos de agrupamiento en la cual cada uno de los elementos tiene un grado de pertenencia a los grupos. Este tipo de algoritmos se desarrolló para resolver la deficiencia del agrupamiento exclusivo, el cual considera que cada elemento se puede agrupar inequívocamente con los elementos de su grupo y que, por lo tanto, no se asemeja al resto de los elementos. Tras la introducción de la lógica difusa surgió una solución para ese problema, la cual consiste en representar la similitud entre un elemento y un grupo por una función, llamada función de pertenencia, que toma valores entre cero y uno. Los valores cercanos a uno indican una mayor similitud, mientras que los cercanos a cero indican una menor similitud. Por lo tanto, el problema del agrupamiento difuso se reduce a encontrar una caracterización óptima para encontrar valores cercanos a uno. Conociendo las ventajas del uso de esta metodología y las mejoras que ha tenido a lo largo de diversas investigaciones, diferentes áreas de la ciencia hacen uso de ella para su beneficio. Uno de estos campos es la dermatología que, a través de la segmentación de imágenes dermatoscópicas con el uso de algún algoritmo de agrupamiento puede predecir de manera rápida y certera un diagnóstico sobre algún padecimiento.

2.4. Agrupamiento difuso

Dentro de la clasificación de algoritmos de agrupamiento se encuentran los de agrupamiento difuso, que forman una clase de algoritmos de agrupamiento en la cual cada uno de los elementos tiene un grado de pertenencia a los grupos. Este tipo de algoritmos resuelve una deficiencia del agrupamiento exclusivo, el cual considera que cada elemento se puede agrupar inequívocamente con los elementos de su grupo y que, por lo tanto, no se asemeja al resto de los elementos [7]. Tras la introducción de la lógica difusa surgió una solución para ese problema, la cual consiste en representar la similitud entre un elemento y un grupo por una función, llamada función de pertenencia, que toma valores entre cero y uno. Los valores cercanos a uno indican una mayor similitud, mientras que los cercanos a cero indican una menor similitud.

Por lo tanto, el problema del agrupamiento difuso se reduce a encontrar una caracterización óptima para encontrar valores cercanos a uno.

2.5. Conjuntos difusos

Un conjunto difuso es una clase de objetos con un grado continuo de pertenencia. Tal conjunto se caracteriza por una función de pertenencia (característica) que asigna a cada objeto un grado de pertenencia que varía entre cero y uno [9]. Un conjunto difuso es una correspondencia o función que a cada elemento del universo le asocia su grado de pertenencia. Enunciada así esta definición parece ser cíclica, mas no lo es: un conjunto difuso es una función cuyo dominio es el universo y cuyo contradominio es el intervalo $[0,1]$. En tanto el grado de pertenencia sea más cercano a 1 tanto más estará el elemento en el conjunto, y en tanto el grado de pertenencia sea más cercano a 0 tanto menos estará el elemento en el conjunto [10].

Definición Un conjunto difuso \bar{A} en $X = \{x\}$

$$\bar{A} = \{\langle x, \mu_{\bar{A}}(x) \rangle \mid x \in X\} \quad (2.1)$$

donde $\mu_{\bar{A}} : X \rightarrow [0, 1]$ es la función de pertenencia del conjunto difuso \bar{A} ; $\mu_{\bar{A}}(x) \in [0, 1]$ es la pertenencia de $x \in X$ in \bar{A} .

Definición Un conjunto difuso intuitivo A en X es dado por:

$$A = \{\langle x, \mu_A(x), v_A(x) \rangle \mid x \in X\} \quad (2.2)$$

donde $\mu_A : X \rightarrow [0, 1]$, $v_A : X \rightarrow [0, 1]$ con la condición: $0 \leq \mu_A(x) + v_A(x) \leq 1 \quad \forall x \in X$

Los números $\mu_A(x), v_A(x) \in [0, 1]$ denotan el grado de pertenencia y no pertenencia de x a A respectivamente. Cada conjunto difuso \bar{A} corresponde al siguiente conjunto difuso intuitivo:

$$A = \{\langle x, \mu_{\bar{A}}(x), 1 - \mu_{\bar{A}}(x) \rangle \mid x \in X\} \quad (2.3)$$

Dentro de la clasificación de algoritmos de agrupamiento se encuentran los de

agrupamiento difuso, los que forman una clase de algoritmos de agrupamiento en la cual cada uno de los elementos tiene un grado de pertenencia a los grupos. Este tipo de algoritmos resuelve una deficiencia del agrupamiento exclusivo, el cual considera que cada elemento se puede agrupar inequívocamente con los elementos de su grupo y que, por lo tanto, no se asemeja al resto de los elementos [7]. Tras la introducción de la lógica difusa surgió una solución para ese problema, la cual consiste en representar la similitud entre un elemento y un grupo por una función, llamada función de pertenencia, que toma valores entre cero y uno. Los valores cercanos a uno indican una mayor similitud, mientras que los cercanos a cero indican una menor similitud. Por lo tanto, el problema del agrupamiento difuso se reduce a encontrar una caracterización óptima para encontrar valores cercanos a uno.

2.6. *Fuzzy C-Means*

Los algoritmos de agrupamiento difuso permiten suprimir el requerimiento de que los objetos tengan que ser asignados a uno y solo uno de los grupos. El algoritmo *Fuzzy C-Means* es un algoritmo de agrupamiento derivado de *K-Means*. Ambos algoritmos están basados en funciones objetivo J , las cuales son criterios matemáticos que cuantifican la calidad de los modelos en el particionamiento de los datos [7]. La tarea de agrupamiento puede ser formulada como el problema de optimizar una función. Esto es, los algoritmos determinan la mejor descomposición de un conjunto de datos en un número predefinido de clases o grupos minimizando su función objetivo.

En sus formas más básicas ambos algoritmos buscan un número predefinido de c grupos en un conjunto de datos, donde cada grupo está representado por su centroide. Sin embargo, difieren en la forma en que se asignan los datos a cada grupo. En un análisis de agrupamiento, en *K-Means* cada dato es asignado a un solo grupo. En *Fuzzy C-Means*, los datos pueden pertenecer a más de un grupo y también tener diferentes grados de pertenencia en los diferentes grupos [7].

El algoritmo *Fuzzy C-Means* fue introducido por Dunn [11] y ampliado por Bezdek [12]. Bezdek y Dunn presentaron un método de agrupamiento que combinaba los conceptos de los métodos basados en función objetivo con los de la lógica difusa. De esta manera, un objeto podría tener distintos grados de pertenencia en los diferentes subgrupos resultantes, en lugar de poseer solamente una pertenencia discreta $\{0,1\}$. A continuación, se realizará una descripción matemática del algoritmo *Fuzzy C-Means*. Sea X un conjunto de N objetos,

una partición $P = \{c_1, c_2, \dots, c_c\}$ es una partición difusa de X si cumple con:

$$\sum_{i=1}^c \mu_{ij} = 1, j = 1, 2, \dots, N \quad (2.4)$$

$$1 \geq \mu_{ij} \geq 0, i = 1, 2, \dots, c, j = 1, 2, \dots, N \quad (2.5)$$

$$n > \sum_{j=1}^N \mu_{ij} > 0, i = 1, 2, \dots, c \quad (2.6)$$

donde, μ_{ij} es el grado de pertenencia del objeto i al centroide j

En (2.4) la suma de los grados de pertenencia de un objeto i a los distintos grupos j debe ser igual a 1. En (2.5) el grado de pertenencia de un objeto i al centroide j debe ser $[0,1]$. En (2.6) la suma de todos los grados de pertenencia en un grupo tiene que ser mayor que 0 y menor que N , es decir, no se pueden tener grupos vacíos ni un grupo con todos los elementos.

Por lo tanto, *Fuzzy C-Means* minimiza la siguiente función objetivo:

$$J_m = \sum_{i=1}^n \sum_{j=1}^c \mu_{ij}^m \|x_i - c_j\|^2 \quad (2.7)$$

donde: n es el número de objetos c el número de centroides m , parámetro fuzzificador, $m > 1$. $\mu_j(x_i)$ grado de pertenencia de x_i a c_j $\|x_i - c_j\|^2$ distancia euclidiana entre x_i y c_j .

Para realizar el cálculo de pertenencia μ_{ij} se utiliza la siguiente expresión:

$$\mu_{ij} = \frac{1}{\sum_{c=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_c\|} \right)^{\frac{2}{m-1}}} \quad (2.8)$$

donde m es el parámetro fuzzificador, $m > 1$. Este valor determina cuán difusa es la clasificación. Usualmente un valor $m = 2$ es seleccionado debido a que permite obtener mejores resultados [7]. Para actualizar los centroides y conocer su nueva posición, se utiliza la siguiente expresión:

$$c_j = \frac{\sum_{i=1}^n \mu_{ij}^m \cdot x_i}{\sum_{i=1}^n \mu_{ij}^m} \quad (2.9)$$

2.7. Conjuntos difusos intuitivos

En la lógica clásica a cada proposición se le otorga un valor verdadero o falso. En el caso de la lógica difusa, el valor de verdad es dado por un número real en el intervalo $[0,1]$, al cual se le denomina grado de pertenencia. En los conjuntos difusos intuitivos se agrega un valor de no pertenencia, el cual se ubica en el intervalo mencionado anteriormente [13]. Los conjuntos difusos intuitivos asignan a cada elemento un grado de pertenencia $\mu_F(x)$, un grado de no pertenencia $\nu_F(x)$ y un grado de indecisión $\pi_F(x)$.

Al seleccionar el grado de pertenencia, puede haber algún tipo de vacilación al definir esta misma función. Esta es la razón por la cual se obtienen diferentes resultados con diferentes funciones de pertenencia, debido a esto, surgen los conjuntos difusos intuitivos, donde el grado de no pertenencia no es igual al complemento del grado de pertenencia debido al hecho de que existe algún tipo de vacilación o falta de conocimiento al definir función de pertenencia. Entonces, en comparación con la teoría de conjuntos difusos, los conjuntos difusos intuitivos consideran más incertidumbres: grados de pertenencia y no pertenencia [14].

Intuitionistic Fuzzy Sets: Dado X como el conjunto de datos, dado $A \subset X$ como un conjunto fijo. Entonces un IFS A en X es expresado de la siguiente manera [15]:

$$A = \{\langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in X\} \quad (2.10)$$

donde las funciones $\mu_A : A \mapsto [0, 1]$ y $\nu_A : A \mapsto [0, 1]$ son los grados de pertenencia y no pertenencia del elemento $x \in X$ al conjunto A , respectivamente, y para cada $x \in X$

$$0 \leq \mu_A + \nu_A \leq 1 \quad (2.11)$$

Cada conjunto difuso intuitivo debe ser:

$$A^* = \{\langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in X\} \quad (2.12)$$

El siguiente parámetro es el grado de indecisión $\pi_A(x)$, al ser incluido en la expresión anterior, debe tomar la siguiente forma:

$$A^* = \{\langle x, \mu_A(x), \nu_A(x), \pi_A(x) \rangle \mid x \in X\} \quad (2.13)$$

donde el grado de indecisión puede ser expresado como $\pi_A = 1 - \mu_A(x) - \nu_A(x)$.

En la teoría de conjuntos difusos hay tres formas básicas de construir funciones de pertenencia [16]:

- Empleando conocimiento experto
- Realizar observaciones recopiladas por adelantado y procesadas adecuadamente (por ejemplo, por métodos estadísticos)
- Analizar funciones elegidas adecuadamente (por ejemplo, distribución probabilística)

Los dos últimos casos se tratan de la misma manera que para los conjuntos difusos comunes; sin embargo, estos métodos ahora se usan para la estimación de ambos grado de pertenencia y grado de no pertenencia de un elemento dado un universo fijo a un subconjunto del mismo universo, el método correcto debe respetar las desigualdades $0 \leq \mu_A(x) + \nu_A(x) \leq 1$.

Las definiciones que se muestran a continuación son válidas para todos los conjuntos difusos intuitivos A y B del conjunto X [13]:

1. $A \cup B = \{\max(\mu_A, \mu_B), \min(\nu_A, \nu_B)\}$
2. $A \cap B = \{\min(\mu_A, \mu_B), \max(\nu_A, \nu_B)\}$
3. $A \prec B = \{x, \mu_A(x) < \mu_B(x), \nu_A(x) < \nu_B(x)\}$
4. $\bar{A} = \{x, \nu_A(x), \mu_A(x)\}$
5. $A \leq B = \{x, \mu_A(x) \leq \mu_B(x), \nu_A(x) \geq \nu_B(x)\}$
6. $A \cdot B = \{x, \mu_A(x) \cdot \mu_B(x), \nu_A(x) + \nu_B(x) - \nu_A(x) \cdot \nu_B(x)\}$

2.8. Distancias en conjuntos difusos y conjuntos difusos intuitivos

El término distancia es ampliamente utilizado en una gran cantidad de campos, y dependiendo en el que se aplique es el contexto que puede tomar. En el área de la teoría difusa intuitiva se utiliza para medir la diferencia que hay entre dos conjuntos difusos intuitivos, dicho de otra forma, teniendo dos conjuntos difusos en el mismo universo, se desea calcular una diferencia entre ellos representada por una distancia [16]. A continuación se muestran las distancias más conocidas para conjuntos difusos y difusos intuitivos:

1. Distancia Hamming $d(A, B)$

$$d(A, B) = \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| \quad (2.14)$$

2. Distancia Hamming normalizada $l(A, B)$

$$l(A, B) = \frac{1}{n} \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| \quad (2.15)$$

3. Distancia euclidiana $e(A, B)$

$$e(A, B) = \sqrt{\sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2} \quad (2.16)$$

4. Distancia euclidiana normalizada $q(A, B)$

$$q(A, B) = \sqrt{\frac{1}{n} \sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2} \quad (2.17)$$

En las fórmulas anteriores, solo las funciones de pertenencia están presentes. Esto se debe al hecho de que para un conjunto difuso $\mu(x_i) + v(x_i) = 1$. Como se mencionó anteriormente, se puede representar un conjunto difuso A' en X en una equivalente de tipo intuitivo. Ecuación 2.10, por lo cual se empleará dicha representación y se reformularán las distancias. Teniendo esto en cuenta, las fórmulas de distancias para conjuntos difusos intuitivos quedan de la siguiente manera [16]:

1. Distancia Hamming

$$\begin{aligned}
 d'(A, B) &= \sum_{i=1}^n (|\mu_A(x_i) - \mu_B(x_i)| + |v_A(x_i) - v_B(x_i)|) \\
 &= \sum_{i=1}^n (|\mu_A(x_i) - \mu_B(x_i)| + |1 - \mu_A(x_i) - 1 + \mu_B(x_i)|) \\
 &= 2 \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| = 2d(A, B)
 \end{aligned} \tag{2.18}$$

2. Distancia Hamming normalizada

$$l'(A, B) = \frac{1}{n} d'(A, B) = \frac{2}{n} \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| \tag{2.19}$$

Es decir, el resultado de (2.15) se multiplica dos veces en comparación con (2.19).

3. Distancia euclidiana

$$\begin{aligned}
 e'(A, B) &= \sqrt{\sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2 + (v_A(x_i) - v_B(x_i))^2} \\
 &= \sqrt{\sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2 + (1 - \mu_A(x_i) - 1 + \mu_B(x_i))^2} \\
 &= \sqrt{2 \sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2}
 \end{aligned} \tag{2.20}$$

Se multiplica por $\sqrt{2}$ en comparación con la distancia euclidiana para la representación habitual de conjuntos difusos dada por (2.16)

4. Distancia euclidiana normalizada

$$q'(A, B) = \sqrt{\frac{1}{n}} e'(A, B) = \sqrt{\frac{2}{n} \sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2} \tag{2.21}$$

Igual que en la anterior, se multiplica por $\sqrt{2}$.

2.9. Algoritmo *Intuitionistic Fuzzy C-Means*

Gracias a la teoría de conjuntos difusos intuitivos surge *Intuitionistic Fuzzy C-Means* (IFCM) [13], que amplía el dominio de agrupamiento difuso transformando los datos X al dominio difuso $X \mapsto \bar{X}$ comprendido dentro de $\mu \in \mathbb{R}[0, 1]$, al dominio difuso intuitivo $\bar{X} \mapsto X^{IFS}$, el cual es definido por:

$$X \mapsto X^{IFS} = \{ \langle \mu(x_i), \nu(x_i), \pi(x_i) \rangle \mid i = 1, 2, 3, \dots, n \} \quad (2.22)$$

donde la tripleta X^{IFS} se compone por la pertenencia $\mu(\cdot)$, la no pertenencia $\nu(\cdot)$ e indecisión $\pi(\cdot)$ con respecto a cada grupo. Esta transformación es realizada por medio de los operadores Chaira de generación de valores intuitivos difusos:

$$\mu(x_i) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.23)$$

$$\nu(x_i) = \frac{1 - \mu(x_i)}{1 + (e^\lambda - 1)\mu(x_i)}, \lambda \in [0, 1] \quad (2.24)$$

$$\pi(x_i) = 1 - \mu(x_i) - \nu(x_i) \quad (2.25)$$

de forma que se satisfacen las condiciones: (a) $\mu(x_i) + \nu(x_i) + \pi(x_i) = 1$ las medidas son complementarias y (b) $0 \leq \pi(x_i) \leq 1$, para cada $x_i \in X$ debe existir indecisión. De forma resumida y para fines de comparación, en el Algoritmo 1 se detalla el algoritmo generalizado IFCM.

A pesar de que este algoritmo, debido a los parámetros de pertenencia, no pertenencia e indecisión lo vuelven más poderoso que el tradicional difuso, sigue mostrando la limitante de ser sensible a la presencia de información atípica. Para atenuar esta debilidad se trabajó en su variante en la función objetivo. Este tipo de variantes se basan en modificaciones más profundas de las funciones objetivo. Las modificaciones ayudan en la mejora de los resultados en casos específicos, por ejemplo, cuando se encuentran datos atípicos. Para esto, se propuso el uso de estimadores robustos.

2.10. Estimadores robustos

Definir algoritmos cuyo resultado no dependa de la presencia o ausencia de datos atípicos en la información que se desea agrupar es una tarea compleja. Un método que ha mostrado resultados favorables es hacer uso de los *estimadores robustos*, los cuales serán explicados a mayor detalle en la sección siguiente.

Los estimadores robustos intentan proporcionar métodos que emulan a los métodos clásicos, pero que no se vean afectados por valores atípicos o pequeñas discrepancias.

Como se ha mencionado, los datos atípicos dentro del conjunto de datos a agrupar afectan severamente la precisión del agrupamiento y dispersan su solución, esto ocurre principalmente cuando se aplican métodos lineales. En tales circunstancias es necesario aplicar estimadores robustos, pues estos ayudan a descartar aquellos datos que escapan a la tendencia general de

Algorithm 1 Generalización del algoritmo Intuitionistic Fuzzy C-Means

Require: x, c, m, ϵ **Ensure:** $u, v(\mu_l, \nu_l, \pi_l), 1 \leq l < c$

- 1: $\mu(x) = \frac{x - \min(x)}{\max(x) - \min(x)}$
 - 2: $\nu(x) = \frac{1 - \mu(x)}{1 + (e^\lambda - 1)\mu(x)}$
 - 3: $\pi(x) = 1 - \mu(x) - \nu(x)$
 - 4: $u_j^{IFS(0)} \leftarrow 0$
 - 5: $u_{ij}^{(0)} = \frac{1}{\sum_{i=1}^c \left(\frac{d^2(x_j^{IFS}, v_i^{IFS(0)})}{d^2(x_j^{IFS}, v_j^{IFS(0)})} \right)^{\frac{1}{m-1}}}$
 - 6: **do** for $l \leftarrow 1$ to \dots
 - 7: $\mu(v_i) = \frac{\sum_{j=1}^N u_{ij}^m \mu(x_j)}{\sum_{j=1}^N u_{ij}^m}$
 - 8: $\nu(v_i) = \frac{\sum_{j=1}^N u_{ij}^m \nu(x_j)}{\sum_{j=1}^N u_{ij}^m}$
 - 9: $\pi(v_i) = \frac{\sum_{j=1}^N u_{ij}^m \pi(x_j)}{\sum_{j=1}^N u_{ij}^m}$
 - 10: $u_{ij} = \frac{1}{\sum_{i=1}^c \left(\frac{d^2(x_j^{IFS}, v_i^{IFS})}{d^2(x_j^{IFS}, v_j^{IFS})} \right)^{\frac{1}{m-1}}}$
 - 11: $\mathcal{J}_m \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j^{IFS} - v_i^{IFS})$
 - 12: **while** $\|U_{if}^l - U_{if}^{l-1}\| < \epsilon$
return u, v
-

los datos de entrada. Se presenta un conjunto de siete datos de entrada y se desea estimar la recta que los represente; sin embargo, se observa un punto que se puede considerar atípico. Si se aplica un método lineal (mínimo cuadrados), el resultado se vería como lo marca la línea discontinua, pero aplicando un estimador robusto se obtendría algo como lo señala la línea continua.

En párrafos anteriores se hizo mención de que el algoritmo *Intuitionistic Fuzzy C-Means* está basado en una función objetivo de mínimos cuadrados, y esta parte es la que lo vuelve sensible ante la presencia de datos atípicos, lo que puede provocar un agrupamiento con resultados no satisfactorios. En este caso se introdujeron estimadores robustos en la función objetivo. Para cubrir la debilidad antes mencionada, se implementó el uso de estimadores robustos, esto para proveer información local de los datos a agrupar, posteriormente la función objetivo es reemplazada por otro tipo de funciones que ayudan a alimitar los datos atípicos, llamadas *funciones de influencia* (uso de estimador -M).

Estimador R

Propuestos por Hodges y Lehman [17], [18]. Son nombrados así porque trabajan por rangos $R_i = r_i(x)$. Un estimador -R de localización T_n es seleccionado a través de:

$$S_N = \frac{1}{n} \sum_{i=1}^n a_N(R_i) \quad (2.26)$$

el cual tiene que llegar cercanamente a cero tanto como sea posible. Donde R_i es el rango de la muestra x_i en el conjunto de datos $\{x_1, \dots, x_n\} \cup \{2T_n - x_1, \dots, 2T_n - x_n\}$, el cual es de tamaño $N = 2n$.

El estimador -R tiene una mejor eficiencia cuando se trata de una función de distribución Laplaciana ($f_0(x) = \frac{1}{2}e^{-|x|}$) (mediana). Esta se deriva mediante la estimación Hodghes-Lehmann de tal forma que:

$$\theta_R = \begin{cases} \frac{1}{2} (x_{(n/2)} + x_{(1+n/2)}) \\ x_{(1+n/2)}, \end{cases} \quad (2.27)$$

donde x_j es el elemento del rango j y θ_R es la estimación de la mediana calculada de un vector de n datos.

Estimador M

Propuestos por Huber [17]. Su definición está dada por una función $\rho(x) = \ln(f(x))$ que se conecta con una función de densidad de probabilidad $f(x)$ para una muestra de datos $x_i, i = 1, 2, \dots, n$.

$$\hat{\theta} = \operatorname{argmin}_{\theta \in \Theta} \left(\sum_{i=1}^n \rho(x_i - \theta) \right) \quad (2.28)$$

El parámetro de localización θ se calcula a partir de la derivada parcial de ρ con respecto a θ , para así introducir una función de influencia $\psi(x, \theta) = \frac{\partial}{\partial \theta} \rho(x, \theta)$.

$$\sum_{i=1}^n \psi(x_i - \theta) = 0 \quad (2.29)$$

Esta función es utilizada para encontrar una solución de minimización. Sin embargo, la solución de θ para el estimador -M presenta unos limitantes: la desviación de la función $\psi(x)$ (*winsorización*), y la desviación de $(x_i - \theta)$ (*ensorización* o *trimming*) [19] y [20]. Para realizar el cálculo de la estimación M, se usa el método iterativo de Newton [21], el cual se simplifica en un algoritmo de un solo paso, para así calcular la estimación de la media de θ

$$\theta_M = \frac{\sum_{i=1}^n x_i \tilde{\psi}(x_i - \operatorname{med}\{\vec{x}_n\})}{\sum_{i=1}^n 1_{[-r,r]}(x_i - \operatorname{med}\{\vec{x}_n\})} \quad (2.30)$$

donde $\operatorname{med}(\vec{x}_n)$ es la mediana de los elementos contenidos en el vector \vec{x}_n , $\tilde{\psi}$ es la función normalizada $\psi : \psi(x) = x\tilde{\psi}(x)$ y θ_M , es el estimador -M. El parámetro r se conecta con

las restricciones de $\tilde{\psi}(x)$. Por otra parte, la función de influencia tiende hacia la media aritmética cuando r tiende hacia infinito. Este estimador actúa como un filtro de mediana y a su vez, uno de media móvil. La función de influencia da información acerca del efecto de contaminación (información atípica) en un dato $x \in X$. Usando este estimador como filtro, el ruido impulsivo puede removerse de manera efectiva. Para implementar este tipo de estimadores, es necesario tener las siguientes consideraciones:

Sea $X = \{x_i \mid i = 1, 2, \dots, n\}$ un conjunto de n observaciones con densidad $f(x_i - \theta)$. El objetivo principal de este tipo de estimadores es obtener un estimado tal que:

$$\hat{\theta} = \arg \min_{\theta \in \Theta} \sum_{i=1}^n \rho(x_i - \theta) \quad (2.31)$$

o de manera análoga:

$$\sum_{i=1}^n \psi(x_i - \theta) = 0 \quad (2.32)$$

donde ρ es la función de pérdida, $argmin$ es el argumento mínimo, ψ es la función de influencia [22]. Cuando la función de pérdida es simétrica puede ser derivable y se relaciona con la función de influencia dada la media de $\psi(x, \theta) = \frac{\partial}{\partial \theta} \rho(x, \theta)$. Una manera eficaz de resolver esta parte es a través de un estimador W , su definición es $w(x) = \frac{\psi(x)}{x}$.

$$\hat{\theta} = \frac{\sum_{i=1}^n x_i w(x_i - \theta)}{\sum_{i=1}^n w(x_i - \theta)}. \quad (2.33)$$

La función W de peso es una manera de medir la importancia de una muestra y su contribución en el cálculo de $\hat{\theta}$, aparte de lo anterior, esta función asigna un peso alto (cerca de uno) a aquellos datos con residuos, los pesos pequeños (cerca de cero) a aquellos datos con grandes residuos. Las propiedades del estimador -M van a depender de la elección de la función de influencia $\psi(x)$, está refleja la influencia en la estimación, es decir, da información acerca del efecto de la presencia de datos atípicos.

Algunas funciones de influencia que pueden ser utilizadas para derivar este tipo de estimadores son:

- *Huber*
- *Simple cut*
- *Tukey Biweight*
- *Hampel's Three Part Redescending*
- *Andrew's Sine*
- *Bernoulli*
- *Lorentzian*

A partir de la experimentación realizada hasta el momento, la función *Hampel's three part redescending* dio como resultado mayor robustez para el tratamiento de información atípica al momento de realizar el agrupamiento de datos utilizando un algoritmo difuso intuitivo. La función de influencia se define:

$$\psi_{\alpha,\beta,r}(x) = \begin{cases} x, & 0 \leq |x_i - \text{med} \{\vec{x}_n\}| \leq 0 \\ \alpha \text{sgn}(x), & \alpha \leq |x_i - \text{med} \{\vec{x}_n\}| \leq \beta \\ \alpha \frac{r-|x|}{r-\beta}, & \beta \leq |x_i - \text{med} \{\vec{x}_n\}| \leq r \\ 0, & r \leq |x_i - \text{med} \{\vec{x}_n\}| \end{cases} \quad (2.34)$$

Estimador L

Estos estimadores están basados en un ordenamiento estadístico, por lo que están bien definidos y son fáciles de calcular. Este motivo es la razón por la que son muy utilizados en el área de segmentación de imágenes. Un estimador tiene la siguiente definición

$$\theta_L = \sum_{i=1}^n a_i x_{(i)} \quad (2.35)$$

donde x_i es una muestra de datos ordenada, $i = 1, \dots, n$. El buen funcionamiento de un estimador -L va a depender de los pesos a_i . La siguiente expresión ayuda a obtener una clase de estimadores -L de localización:

$$a_i = \frac{\int_{\frac{i-1}{n}}^{\frac{i}{n}} h(\lambda) d\lambda}{\int_0^1 h(\lambda) d\lambda} \quad (2.36)$$

donde $h(\lambda)$ es la función de densidad de probabilidad $[0, 1] \rightarrow \mathbb{R}$, la cual satisface $\int_0^1 h(\lambda) d\lambda \neq 0$. Con esta condición se deben satisfacer $\sum_{i=1}^n a_i = 1$.

Capítulo 3

Estado del arte

En esta sección se describen aquellos trabajos que son antecedentes y a la vez fungieron como base en la realización de esta investigación. Éstos son la base teórica respecto a conceptos como agrupamiento difuso, conjuntos difusos y su aplicación en tareas de reconocimiento de patrones y segmentación de imágenes.

A continuación, se hace una breve reseña sobre aquellos trabajos que fueron extraídos de la literatura y sirvieron como base para la elaboración de esta tesis de doctorado. Se dividió en subsecciones para acotar los principales temas que se abordan en la investigación y lograr una mejor comprensión de la metodología que se propone.

Agrupamiento difuso intuitivo

El agrupamiento difuso intuitivo surge en la literatura gracias a Chaira [14] con la introducción de los grados de pertenencia y no pertenencia. A partir de este punto, se han desarrollado muchas investigaciones que han dado solución a diversos problemas dentro de la inteligencia artificial a través de la implementación de algoritmos o métodos basados en este tipo de agrupamiento. En [23] Kumar et al. propone un algoritmo intuitionistic Fuzzy C-Means modificado (MIFCM) para resolver analíticamente su función objetivo usando el método de Lagrange o multiplicadores Lagrange. Para incorporar el grado de vacilación fueron investigados dos complementos difusos intuitivos paramétricos, llamados negaciones de Sugeno-Yager. Así mismo se ha aplicado este tipo de agrupamiento en tareas de reconocimiento de patrones, tal como lo muestra Souza [24] donde presentó un nuevo algoritmo de aprendizaje para redes neuronales de lógica difusa capaces de generar modelos precisos y transparentes. El algoritmo de aprendizaje se basa en ideas de *Extreme Learning Machine*, para lograr una baja complejidad de tiempo y teoría de la regularización, lo que resulta en modelos escasos y precisos. Los resultados sugieren el enfoque propuesto como una alternativa prometedora para el reconocimiento de patrones con una buena precisión y cierto nivel de interpretabilidad.

Por otro lado, Roh et al. [25] propuso un nuevo método de diseño para el clasificador de redes neuronales con función de base radial difusa. El enfoque propuesto se basa en el algoritmo de agrupamiento condicional Fuzzy C-Means realizado con la ayuda de información auxiliar, que se extrae mediante el algoritmo de reconstrucción localmente lineal. Condicional Fuzzy C-Means puede analizar la distribución de datos (patrones) sobre el espacio de entrada

cuando es supervisado por la información auxiliar. Fuzzy C-Means condicional puede sustituir al algoritmo Fuzzy C-Means convencional que se ha utilizado generalmente para definir las funciones de base radial sobre el espacio de entrada. Se recomienda que la información auxiliar extraída mediante la reconstrucción lineal local pueda determinar qué patrones entre el conjunto de datos completo son más importantes que los demás. Esta suposición se basa en la observación de que los datos, que no pueden ser completamente reconstruidos por la combinación lineal de sus vecinos, pueden transmitir mucha más información que los otros datos a reconstruir. Es bien sabido que en el caso del clasificador de redes neuronales de función de base radial, el rendimiento de clasificación de este clasificador se basa predominantemente en la distribución de la función de base radial sobre el espacio de entrada.

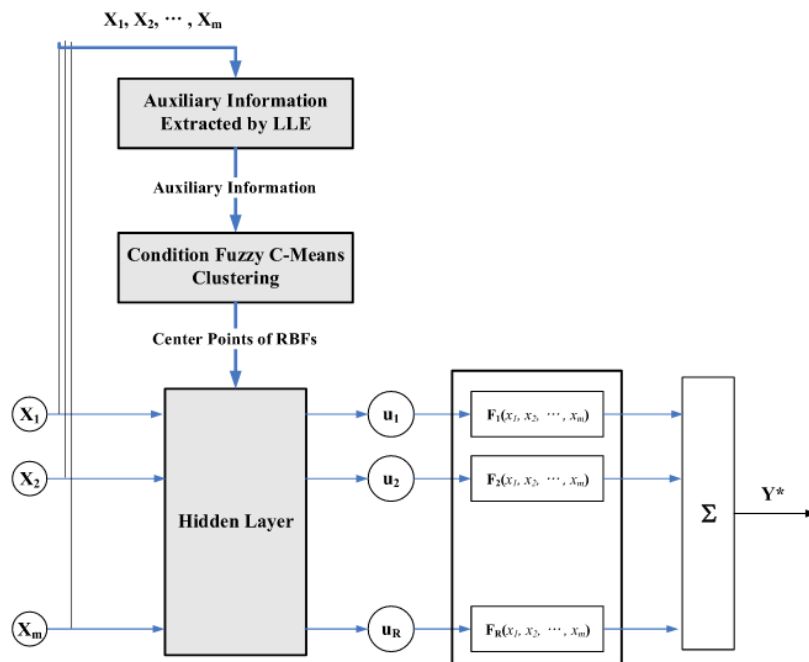


Figura 3.1: Topología general de las redes neuronales de función de base radial con información auxiliar [25].

En la Figura 3.1 se observa el diseño de una red de función de base radial con información auxiliar, en este caso, información del agrupamiento difuso.

Agrupamiento difuso aplicado a segmentación de imágenes

En este rubro Mújica et al. [22] mejoró el rendimiento de un algoritmo difuso intuitivo, modificando su función objetivo y derivando su expresión de actualización para la matriz de pertenencia y el vector de centroides. El rendimiento de la propuesta se evaluó en tareas de reconocimiento de patrones y segmentación de imágenes en color. En esta investigación se pudo señalar lo siguiente: el método fue capaz de agrupar datos corruptos con valores atípicos, los resultados sugirieron la precisión y un número de iteración reducido para converger. Fue capaz de segmentar imágenes de diferente naturaleza, con un equilibrio entre la calidad del

resultado y el tiempo de ejecución. De los resultados obtenidos, se debe resaltar para todas las imágenes, que el algoritmo las segmenta en menos de una docena de iteraciones, lo que se refleja en un tiempo de procesamiento más corto. Además mostró imágenes con baja densidad de ruido.




Figura 3.2: Iteraciones contra Función objetivo [22].

En el Figura 3.2 se muestra el equilibrio entre el número de iteraciones y la calidad, lo que demuestra su efectividad. y en la Figura 3.3 se observa la segmentación de una imagen por cada iteración con el método propuesto.

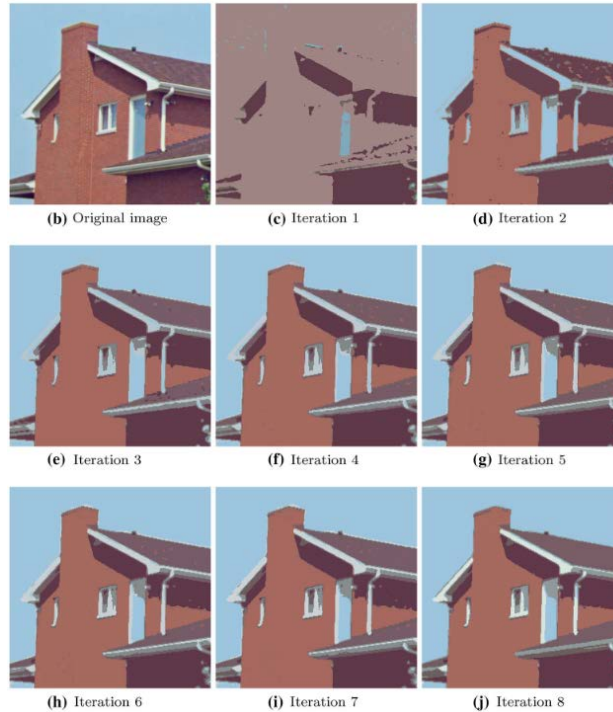


Figura 3.3: Segmentación de imágenes obtenidas usando RIFCM [22].

Por otro lado, el mismo autor en [26] mejoró el rendimiento de un algoritmo Fuzzy C-Means, para este propósito se modificó su función objetivo y se derivó su expresión de actualización para la matriz de pertenencia y el vector de centroides. Con esta modificación se puede garantizar que la propuesta fue capaz de segmentar imágenes de diferente naturaleza, con un equilibrio entre resultados cuantitativos y cualitativos; no requiere características especiales o sofisticadas, tiene un rendimiento superior incluso utilizando solo información de color (solo los componentes del espacio de color IJK). Además, se puede asegurar que la propuesta muestra imágenes con baja densidad de ruido.




Figura 3.4: Muestra de imágenes de un conjunto de datos [26].

En las Figuras 3.4 y 3.5 se observa en un conjunto de imágenes la segmentación con el método propuesto.

En otro trabajo [27], Lei propuso un algoritmo de segmentación de imágenes basado en un agrupamiento difuso mejorado. La teoría de agrupamiento difuso y el método de análisis




Figura 3.5: Segmentación de la muestra con RK-FCM [26].

se describieron en detalle, y la investigación del algoritmo de segmentación de imágenes se discutió en este documento. Y luego se utilizó el método de descomposición de subgrafos y fusión de regiones para mejorar el método de agrupamiento del algoritmo de segmentación de imagen de Fuzzy C-Means y se verificó mediante un ejemplo. Los resultados mostraron que el algoritmo era factible. En comparación con otros algoritmos existentes, tenía más ventajas en tiempo de ejecución y precisión de segmentación de imágenes.




Figura 3.6: Obra de arte, ruido de Gauss y ruido de sal y pimienta [27].




Figura 3.7: Resultados intermedios y resultados finales para la segmentación de mapas de sal y pimienta [27].

En las Figuras 3.6 y 3.7 se observan los resultados de la segmentación de imágenes. El diagrama de grano de arroz se utilizó como imagen experimental.

El algoritmo Fuzzy C-Means intuitivo es un método popular en el área de segmentación de imágenes. La segmentación de imagen basada en Fuzzy C-Means intuitivo es ampliamente utilizada. IFCM es sensible al ruido, ya que solo utiliza el criterio de distancia en el espacio de características para segmentar las imágenes. Para superar esto, se propuso un algoritmo Fuzzy C-Means intuitivo espacial mejorado que utiliza: una fuzzificación intuitiva de imagen para simplificar la representación de la imagen, un método mejorado para calcular el grado de vacilación en las imágenes, la propiedad espacial de una imagen para hacer que la

segmentación sea más robusta y efectiva. El rendimiento del método propuesto se evalúa para imágenes sintéticas y reales. El resultado indica la efectividad de la metodología propuesta sobre las metodologías existentes. En las Figuras 3.8 y 3.9 se muestra la segmentación de imágenes sintéticas y naturales con el método propuesto, S-IFCM. [28].




Figura 3.8: Segmentación de imágenes en escala de grises con ruido sal y pimienta, (f) Segmentación con S-IFCM [28].

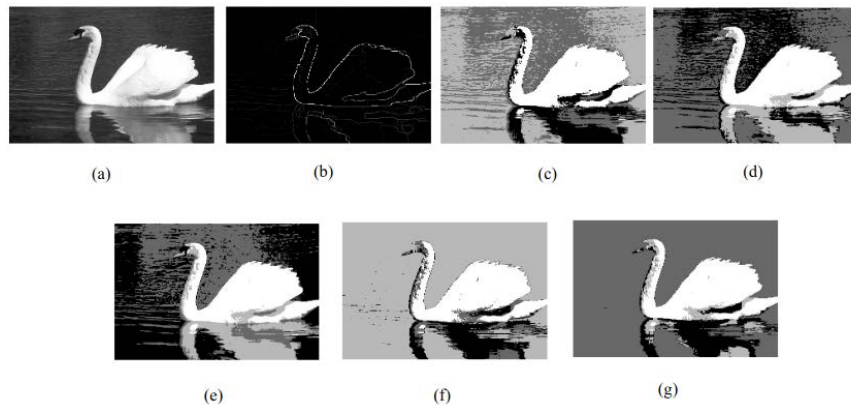


Figura 3.9: Segmentación de imágenes con diversos algoritmos, (g) con S-IFCM [28].

Agrupamiento difuso aplicado al reconocimiento de patrones

A continuación se describen de manera breve algunos trabajos que aplican este tipo de agrupamiento al área de reconocimiento de patrones. La agrupación de gráficos se aplica con éxito en varias aplicaciones para encontrar patrones similares. Recientemente, el autoencoder basado en aprendizaje profundo se ha utilizado de manera eficiente para detectar grupos disjuntos. Sin embargo, en los gráficos del mundo real, los vértices pueden pertenecer a múltiples grupos. Por lo tanto, es obligatorio analizar la pertenencia de los vértices hacia los grupos. Además, los enfoques existentes están centralizados y son ineficientes en el manejo de gráficos grandes. En este documento, se propuso un modelo basado en el aprendizaje profundo "DFuzzy" para encontrar grupos difusos de gráficos grandes en un entorno distribuido. Realiza la agrupación en tres fases. En la primera fase, el entrenamiento previo se realiza

inicializando los centros de clúster candidatos. Luego, se realiza un ajuste fino para aprender las representaciones latentes al extraer la información local y capturar la estructura usando PageRank. Además, la modularidad se utiliza para redefinir los clústeres. En la última fase, se minimiza el error de reconstrucción y se actualizan los centros de agrupación finales. Los experimentos se realizan sobre datos de gráficos de la vida real, y el rendimiento de DFuzzy se compara con cuatro algoritmos de agrupamiento de última generación. Los resultados muestran que DFuzzy se escala linealmente para manejar gráficos grandes y produce una mejor calidad de clústeres en comparación con los algoritmos de clúster de última generación. También se observa que las estructuras profundas pueden ayudar a obtener mejores representaciones gráficas y proporcionar un rendimiento de agrupamiento mejorado. [29].

En otra investigación, Dubey et al. [30] mostró dos objetivos principales: en primer lugar, comparar el rendimiento de los algoritmos de agrupación k-Means y Fuzzy C-Means (FCM); y en segundo lugar, hacer un intento de considerar y examinar cuidadosamente, desde múltiples puntos de vista, la combinación de diferentes medidas computacionales para algoritmos k-Means y FCM para lograr una mejor precisión de agrupamiento. Los resultados de este trabajo proporcionan una comprensión incisiva y extensa de los parámetros computacionales utilizados con los algoritmos k-Means y Fuzzy C-Means. Los resultados computacionales indican que se encontró que el algoritmo FCM es más prominente y consistente que el algoritmo k-Means cuando se ejecuta con diferentes iteraciones, valores de confusión y criterios de terminación. Es potencialmente capaz de clasificar el conjunto de datos BCW ya que la precisión de la clasificación es más importante que el tiempo. Por otro lado, Zhang [31] demostró que la red neuronal se aplica en los sistemas inteligentes y el ámbito de aplicación revisado en varios desarrollos nuevos de tecnología inteligente, en este documento se describió la dirección del desarrollo del sistema inteligente y presentó los conceptos básicos de minería de datos, incluida la tecnología de minería de datos, inteligencia artificial, aprendizaje automático, análisis estadístico, lógica difusa, reconocimiento de patrones y redes neuronales artificiales y otras tecnologías. Se separó la estructura del algoritmo general de minería de datos y se clasificó la tecnología de minería de datos en detalles, que incluyen más de 10 técnicas de tecnología de árbol de decisión, tecnología de red neuronal, conjunto de datos ásperos y difusos. Los algoritmos de mejora existentes no pueden satisfacer las necesidades de las personas y responder oportunamente al sistema de minería, por lo tanto, se necesita mejorar la eficiencia del proceso de minería e interactuar con el usuario para generar los resultados visuales. En ese momento, se presentaron diversas técnicas y modelos de reconocimiento de patrones. Varios ejemplos mostraron que el sistema informático inteligente basado en el reconocimiento de patrones y el algoritmo de minería de datos tiene una mayor eficiencia y tasa de reconocimiento.

Joshep y Thanakumar [32] presentaron la encuesta sobre los algoritmos de minería de datos y las técnicas que podrían emplearse con el sistema de computación inteligente, presentando una concepción básica de la minería de datos junto con los algoritmos destacados de la minería de datos y la clasificación de sus técnicas; además, la encuesta concluyó con los desafíos incluidos en la descripción general de la encuesta realizada junto con la mejora futura en la investigación que analiza las técnicas de minería de datos en las aplicaciones informáticas inteligentes.



Figura 3.10: Proceso de minería de datos [32].

En la Figura 3.10 se muestra el proceso de implementación involucrado en la minería de datos. La minería de datos podría utilizarse en multitud de aplicaciones en los diversos campos, sin limitarse a los sectores de salud, telecomunicaciones, bancos, seguros, manufactura, educación, prestación de servicios, comercialización minorista, bioinformática, etc., a medida que el futuro mejore el documento. es continuar con la implementación de la minería de datos en la aplicación de la informática inteligente.

Metodologías robustas aplicadas al tratamiento de información atípica

En esta sección se presentan algunos trabajos que utilizan algún tipo de metodología para tratar la presencia de información atípica en el proceso de agrupamiento orientado a la segmentación de imágenes o reconocimiento de patrones. En [33], Jia hace mención de cómo la información atípica o *outliers* interfiere con el resultado en el proceso de segmentar una imagen utilizando algún tipo de algoritmo difuso, por lo tanto presenta un nuevo algoritmo robusto de agrupamiento auto espaciado; el cual utilizando una métrica gaussiana que se integra en la función objetivo de algoritmo difuso. Logrando así reducir las características propias del ruido y por consiguiente, mejorando los resultados de agrupamiento.




Figura 3.11: Resultados del agrupamiento con la presencia de *outliers*[33]

En el trabajo de Yan et al. [34] se propone un nuevo método de agrupamiento basado en la identificación estadística automática del centroide a partir del grafo de decisión. Se hace mención que las funciones de densidad de probabilidad unidimensionales en valores de densidad específicos en el gráfico de decisión, se estiman utilizando funciones gaussianas bidimensionales; logrando así que los centroides se identifiquen automáticamente como valores atípicos en el grafo de decisión utilizando valores de expectativas y desviaciones estándar que son calculados en valores de densidad específicos.

En [4] Dhanachandra et al. presentan un nuevo método de segmentación basado en la




Figura 3.12: Visualización con mapa de calor usando diferentes algoritmos[33]



Figura 3.13: Resultados de la segmentación de imágenes con información atípica[34]

optimización dinámica por enjambre de partículas DPSO y Fuzzy C-Means para la reducción de ruido; utilizando las ventajas de la búsqueda de optimización global y el cálculo paralelo del DPSO para mejorar el resultado de Fuzzy C-Means.

Wang [35] desarrolló el método Fuzzy C-Means (FCM) residual para la segmentación de imágenes, que realiza una estimación precisa de los residuos (ruido/obstáculos) y permite que las imágenes sin ruido participen en el agrupamiento. A través de un *framework* FCM integra término de regularización relacionado con los residuos derivado de la distribución característica de los distintos tipos de ruido.




Figura 3.14: Imágenes de resonancias magnéticas comparando diversos métodos [4].




Figura 3.15: Resultados de la segmentación con el método propuesto [35].

3.1. Discusión del estado del arte

Desde la implementación del agrupamiento difuso y la relajación de la pertenencia exclusiva de objetos a los centroides, se han desarrollado diversas mejoras y algoritmos que se han aplicado a varios campos de la inteligencia artificial, como la segmentación de imágenes y el reconocimiento de patrones. El algoritmo Intuitionistic Fuzzy C-Means, el cual surge de la aplicación de los conjuntos difusos [9] y de los conjuntos difusos intuitivos [13], ha sido utilizado como base en muchas investigaciones, sobretodo en tareas de segmentación de imágenes para tratar de mejorar su rendimiento, siendo capaz de tratar con datos atípicos y reduciendo la cantidad de iteraciones para converger [22, 26]. Así mismo, se ha mejorado para tratar su sensibilidad al ruido al momento de segmentar las imágenes [27, 28]. Se seleccionaron algunos artículos para su discusión debido a que sus investigaciones ofrecen información de apoyo para este trabajo.

Tabla 3.1: Discusión del Estado del Arte

Título	Objetivo	Algoritmos, métricas o métodos	Resultados	Área de utilidad
segmentación de imagen basado en color por medio de un algoritmo robusto intuitivo Fuzzy C-Means [22].	Se mejoró el rendimiento de un algoritmo difuso intuitivo, modificando su función objetivo y derivando su expresión de actualización para la matriz de pertenencia y el vector de centroides	IFCM	Fue capaz de agrupar datos de valores atípicos con precisión y un número de iteraciones reducido para converger y segmentar imágenes de diferente naturaleza	IFCM en segmentación de imágenes y reconocimiento de patrones
Algoritmo robusto de agrupamiento difuso del núcleo radial de base gaussiana para la segmentación de imágenes [26].	Se mejoró el rendimiento de un algoritmo Fuzzy C-Means, modificando su función objetivo.	Fuzzy C-Means	Fue capaz de segmentar imágenes de diferente naturaleza, con un equilibrio entre resultados cuantitativos y cualitativos. Tiene un rendimiento superior incluso utilizando solo información de color	Segmentación de imágenes
Algoritmo de segmentación de imagen basado en agrupamiento difuso mejorado [27].	Se propuso un algoritmo un algoritmo de segmentación de imágenes basado en un agrupamiento difuso mejorado.	Los resultados mostraron que el algoritmo era factible	Segmentación de imágenes	
Un agrupamiento de Fuzzy C-Means espacial mejorado para la segmentación de imágenes [28].	Se propuso un algoritmo Fuzzy C-Means intuitivo espacial que no sea sensible al ruido	IFCM	El rendimiento del método propuesto indica la efectividad sobre las metodologías existentes	IFCM y segmentación de imágenes
Dfuzzy: un modelo de agrupación difusa basado en el aprendizaje basado en el aprendizaje profundo para gráficos grandes [29].	Proponer un modelo basado en el aprendizaje difuso Dfuzzy para encontrar grupos difusos de gráficos grande en un entorno distribuido.	PageRank.	Dfuzzy se escala linealmente para manejar gráficos grandes y produce una mejor calidad.	Segmentación de imágenes.

Título	Objetivo	Algoritmos, métricas o métodos	Resultados	Áreas de utilidad
Segmentación de imágenes mediante la clasificación de la función de base radial de la red neuronal en la detección del tumor cerebral [36].	Desarrollar un algoritmo que incorpore pasos para el pre-procesamiento, segmentación de imágenes y extracción de características a través de una RBFN	RBFN	No se muestran resultados	Segmentación de imágenes
Análisis empírico de algoritmos de agrupamiento de datos [37].	Estudiar diferentes enfoques de agrupamiento desde la perspectiva teórica par comprender su relevancia en el contexto de conjunto de datos	Algoritmos de agrupamiento clásicos.	Evaluaciones de algoritmos	Algoritmos de agrupamiento
Segmentación de imagen utilizando el algoritmo de luciérnaga híbrida y Fuzzy C-Means intuitivo [38].	Proponer un nuevo algoritmo híbrido que combina Fuzzy C-Means y el algoritmo de luciérnaga.	FCM, IFCM, IFCMFA. Índices D y DB	IFCM y segmentación de imágenes.	
Algoritmos de agrupamiento: un enfoque comparativo [39].	Realizar una comparación sistemática de 9 métodos de agrupamiento conocidos disponibles en lenguaje R	Algoritmos de agrupamiento clásico.	Al considerar las configuraciones predeterminadas de los métodos adoptados, el enfoque espectral tendía a presentar un rendimiento particularmente bueno	Algoritmos de agrupamiento
Estudio comparativo de los algoritmos K-Means y Fuzzy C-Means sobre los datos del cáncer de mama[30].	Comparar el rendimiento de ambos algoritmos, y hacer un intento de considerar y examinar cuidadosamente, la combinación de diferentes métricas y lograr una una mejor precisión de agrupamiento	FCM y K-Means.	Indican que el algoritmo FCM es más prominente y consistente que K-Means	Reconocimiento de patrones.
Agrupamiento difuso utilizando múltiples núcleos gaussianos con parámetros optimizados [40].	Un nuevo algoritmo de agrupamiento difuso basado en el núcleo que intenta encontrar los mejores resultados de agrupamiento utilizando parámetros óptimos.	Fuzzy C-Means	No se mostraron	Reconocimiento de patrones, IFCMs.

3.2. Antecedentes

- **Extracción de superpíxeles y su fusión mediante un algoritmo de agrupamiento difuso intuitivo aplicable a imágenes de resonancia magnética [41]:** El objetivo de este trabajo de investigación fue implementar y adaptar el algoritmo Intuitionistic Fuzzy C-Means para una eficiente extracción de superpíxeles en imágenes de resonancia magnética del cerebro.
- **Agrupamiento difuso titubeante para tareas de segmentación de imágenes y reconocimiento de patrones [42]:** Esta investigación se enfoca en el uso de los Conjunto Difusos Titubeantes para realizar los procesos de Reconocimiento de Patrones y Segmentación de Imágenes, el cual es una variante del algoritmo de agrupamiento tradicional, como es Fuzzy C-Means. Éste tipo de conjuntos permite expresar el agrupamiento de datos como varios posibles valores de pertenencia para un solo elemento de un conjunto de referencia.

En este capítulo se mostraron los conceptos claves y base para el desarrollo de esta investigación, como por ejemplo, agrupamiento difuso, conjuntos difusos, agrupamiento difuso intuitivo y estimadores robustos. Posteriormente se presentaron aquellos trabajos que fueron antecedentes y sirvieron como punto de partida para elaborar la metodología fundamental de la tesis, además de una síntesis del estado del arte en la que sobresale la aplicación del agrupamiento difuso intuitivo en tareas de segmentación de imágenes y reconocimiento de patrones; así cómo las extensiones que este tipo de agrupamiento ha tenido en otras áreas de la inteligencia artificial para la resolución de problemas, por ejemplo, las redes neuronales. Así como aquellos que han tratado de dar tratamiento a la presencia de información atípica. Toda esta información fue de suma importancia, ya que sentó las bases para el desarrollo de esta investigación y a la par, constar que el trabajo marca un precedente dentro de la literatura científica, al mostrar no se ha realizado ninguna investigación donde se desarrolle una metodología como la mostrada en esta estancia doctoral.

Capítulo 4

Metodología

En esta sección se describe de manera detallada la metodología que se implementó para el desarrollo del trabajo de investigación. Se presenta la justificación matemática de un nuevo algoritmo de agrupamiento intuitivo robusto, una explicación de los estimadores robustos y cómo fueron implementados dentro de la función objetivo del algoritmo *Intuitionistic Fuzzy C-Means* IFCM para poder ser aplicado en reconocimiento de patrones y segmentación de imágenes con información atípica.

4.1. Método tradicional

Conociendo el funcionamiento del algoritmo *Intuitionistic Fuzzy C-Means*, que trata de minimizar una función objetivo, la cual minimiza el error cuadrático y que la información atípica tiene efecto durante este proceso de minimización y afectan el cálculo de la posición de los centroides se desarrolló una metodología que permite atenuar esta debilidad. Comúnmente se realiza en primera instancia un análisis de la información atípica que presentan los datos a agrupar. Posteriormente se recurre al uso de alguna técnica de tratamiento de información atípica, y poder así implementar el algoritmo que hará el agrupamiento. Esta tarea en conjunto, representa más tiempo y costo computacional. En pocas palabras, es necesario un tipo de pre-procesamiento de los datos para identificar y reducir información atípica, esto se puede visualizar en la Figura 4.1.

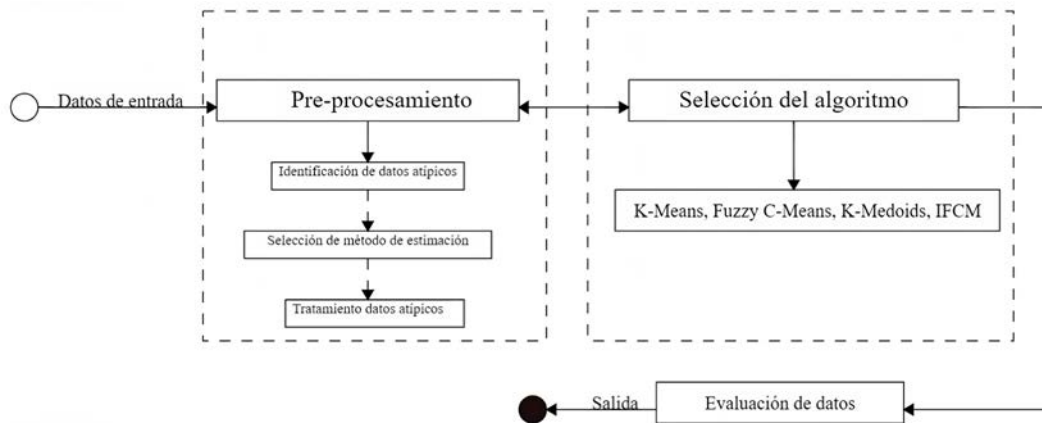


Figura 4.1: Forma tradicional del proceso de agrupamiento de datos

Como datos de entrada se entiende a aquella información que ha de ser procesada, en este caso bases de datos sintéticas para las tareas de reconocimiento de patrones, e imágenes dermatoscópicas para la segmentación. Para el bloque de pre-procesamiento, los datos deben pasar por una etapa de tratamiento de datos, es decir, identificar la información atípica posteriormente realizar la selección de algún método específico para la eliminación o tratamiento de esos datos y que no interfieran con el agrupamiento o segmentación. Una vez cubierto este bloque, se debe seleccionar el algoritmo que se adecue a las especificaciones de las tareas a realizar, para ser implementado; por último, con el uso de las métricas propias para ello, se evalúa la calidad de los resultados tanto en agrupamiento como en segmentación para así realizar un análisis comparativo y verificar el desempeño del método utilizado.

4.2. Método propuesto

Partiendo de este punto, se formuló una versión robusta de un algoritmo difuso intuitivo frente a información atípica y poder ser comparado con las versiones base y otros métodos de la literatura y así agilizar el proceso de agrupamiento mediante la implementación de algún estimador robusto. Con esto se pretende disminuir la tarea del pre-procesamiento, es decir, dentro del mismo algoritmo se implementará un estimador robusto y a través de formulación matemática, el algoritmo será capaz de identificar la información atípica, suavizarla y realizar el agrupamiento sin necesidad de realizar un pre-procesamiento, como en la forma tradicional.

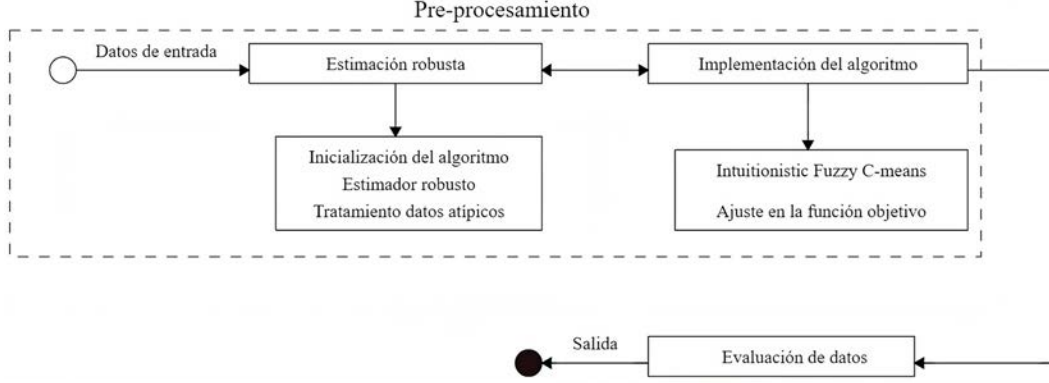


Figura 4.2: Propuesta de solución

La propuesta de solución mostrada en la Figura 4.2 realiza menos iteraciones que los métodos presentados en la literatura.

A diferencia de la metodología tradicional, para el pre-procesamiento de las tareas de reconocimiento de patrones o segmentación de imágenes, solo es necesario un bloque de actividades. Los datos de entrada no requieren ningún tratamiento adicional, es decir, no se aplicará algún método de limpieza o eliminación de información atípica ya que dentro del mismo algoritmo se le da la ponderación a dicha información de tal manera que no interfiera en el resultado. Para esta metodología se trabajó con el algoritmo *Intuitionistic Fuzzy C-Means* realizando un ajuste directo en la función objetivo. Y como último punto, los resultados son evaluados a través de métricas de calidad de agrupamiento o segmentación.

Tomando en cuenta la información antes presentada, se formuló un algoritmo difuso intuitivo utilizando un estimador robusto, el desarrollo del mismo se muestra en la sección siguiente:

4.3. Algoritmo *Redescending Intuitionistic Fuzzy C-Means* RIFCM

Tomando como base la función del algoritmo *Intuitionistic Fuzzy C-Means* IFCM, se reformula la función objetivo:

$$\mathcal{J}_m(\mathbf{X}^{IFS}; \mathbf{U}, \mathbf{V}^{IFS}) = \sum_{i=1}^n \sum_{k=1}^c u_{ik}^m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2), \quad (4.1)$$

donde se expresa la distancia cuadrática $\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2$ como una abreviación de la función:

$$d^2(x_j^{IFS} - v_I^{IFS}) = ((\mu(x_j) - \mu(v_i))^2 + (\nu(x_j) - \nu(v_I))^2 + (\pi(x_j) - \pi(v_I))^2). \quad (4.2)$$

Como se observa en (4.1), se incluye una función de pérdida ρ en función de la distancia, dando paso a la reformulación del algoritmo IFCM a su forma robusta como una generalización de la actualización de la matriz de partición u y de centroides v .

Esta generalización permite utilizar en ρ cualquier función que ayude a robustecer el agrupamiento, siempre y cuando se apegue a la restricción de pertenecer al dominio continuo y sea derivable. Para formular el algoritmo es necesario considerar las dos restricciones de la función objetivo:

$$\sum_{i=1}^n U_{ij} > 0, \quad \sum_{j=1}^c U_{ij} = 1, \quad (4.3)$$

a partir de estas restricciones, para calcular los elementos u_{ik} se opera mediante el operador Lagrangiano:

$$L(\mathcal{J}_m, \lambda) = \sum_{i=1}^n \sum_{k=1}^c u_{ik}^m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) - \sum_{k=1}^x \lambda_i \left(\sum_{i=1}^n u_{ik} - 1 \right), \quad (4.4)$$

e igualando a 0 las derivadas parciales del Lagrangiano, se obtiene el siguiente sistema de ecuaciones que satisfacen las condiciones iniciales:

$$\frac{\partial L}{\partial u_{ik}} = 0 \Leftrightarrow m u_{ik}^{m-1} \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) = \lambda_i, \quad (4.5)$$

$$\frac{\partial L}{\partial \lambda_i} = 0 \Leftrightarrow \sum_{k=1}^c u_{ik} = 1. \quad (4.6)$$

En primer lugar se derivan las expresiones de restricción por separado con el fin de formular la función de partición para u_{ik} . Primero, derivado de (4.5) se obtiene la ecuación:

$$\left(u_{ik}^{m-1} = \left[\frac{\lambda_i}{m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \right]^{\frac{1}{m-1}} \right) \quad (4.7)$$

que despejando el exponente u^{m-1} con respecto a $\frac{1}{m-1}$, se obtiene:

$$u_{ik} = \left[\frac{\lambda_i}{m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \right]^{\frac{1}{m-1}} \quad (4.8)$$

Esta expresión satisface la primera restricción y sirve como base para el despeje de la segunda. Ahora para (4.6), sustituyendo λ_i y despejando el exponente de $\lambda_i^{\frac{1}{m-1}}$, se obtiene la solución a la segunda restricción:

$$\lambda_i = \left[\frac{1}{\left(\frac{1}{m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \right)^{\frac{1}{m-1}}} \right]^{m-1} \quad (4.9)$$

Ahora por simple sustitución de λ_i en (4.8), se obtiene la función de partición u_{ik} , para simplificar la actualización u_{ik} . Finalmente considerando la diferencia de los centroides v_{ik} sobre el resto de los datos v_{ij} , y simplificando la distancia cuadrática, la expresión (4.10) es

reformulada para ser robusta ante datos atípicos.

$$u_{ik} = \frac{1}{\sum_{k=1}^c \left[\frac{m\rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2)}{m\rho(\|x_{ij}^{IFS} - v_{ij}^{IFS}\|_2)} \right]^{\frac{2}{m-1}}} \quad (4.10)$$

Por otra parte para el calculo de centroides v_{kj}^{IFS} se considera la distancia como:

$$\left[\sum_{i=1}^n \sum_{k=1}^c u_{ij}^m \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \right] = 0, \quad (4.11)$$

$$\left[\sum_{i=1}^n \sum_{k=1}^c u_{ij}^m \nabla \rho \left((\mu(x_{ij}) - \mu(x_{kj}))^2 + (\nu(x_{ij}) - \nu(x_{kj}))^2 + (\pi(x_{ij}) - \pi(x_{kj}))^2) \right) \right] = 0, \quad (4.12)$$

y derivando con respecto al vector de prototipos v_{kj}^{IFS} de igual forma:

$$\begin{aligned} \frac{d}{dv_{kj}^{IFS}} \sum_{i=1}^n \sum_{k=1}^c u_{ij}^m \nabla \rho \left((\mu(x_{ij}) - \mu(x_{kj}))^2 + (\nu(x_{ij}) - \nu(x_{kj}))^2 + (\pi(x_{ij}) - \pi(x_{kj}))^2) \right) \\ - \sum_{i=1}^n \sum_{k=1}^c \lambda_i u_{ij} + \sum_{i=1}^n \lambda_i = 0 \end{aligned} \quad (4.13)$$

$$\begin{aligned} \frac{d}{dv_{kj}^{IFS}} \sum_{i=1}^n u_{ij}^m [\psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \cdot (\mu(x_{ij}) - \mu(x_{kj}))^2 + (\nu(x_{ij}) - \nu(x_{kj}))^2 \\ + (\pi(x_{ij}) - \pi(x_{kj})) \cdot -1] \end{aligned} \quad (4.14)$$

donde $\psi(\cdot)$ representa la primera derivada de la función de pérdida $\rho(\cdot)$, la cual es llamada función de influencia. A partir de aquí se realiza la derivación para cada valor del vector de prototipos $v_{kj}^{IFS} = \langle \mu(v_{kj}), \nu(v_{kj}), \pi(v_{kj}) \rangle$ por separado. Para el caso del valor de pertenencia se deriva (4.14) con respecto a $\mu(v_{kj})$, obteniendo:

$$\sum_{i=1}^n u_{ij}^m \left[\psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \cdot -2\mu(x_{ij}) - \mu(v_{kj}) \right] \quad (4.15)$$

y factorizando con respecto a $\mu(v_{kj})$, se obtiene la función de actualización para la pertenencia en la expresión (4.16).

$$\mu(v_{kj}) = \frac{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \mu(x_{ij})}{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \quad (4.16)$$

Para el caso de la no pertenencia $\nu(v_{kj})$ e indecisión $\pi(v_{kj})$ es el mismo proceso, el desglose del despeje de ambas funciones se muestra a continuación y se resumen en las funciones finales (4.17) para $\nu(v_{kj})$ y (4.18) para $\pi(v_{kj})$.

$$\nu(v_{kj}) = \frac{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \nu(x_{ij})}{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \quad (4.17)$$

$$\pi(v_{kj}) = \frac{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2) \pi(x_{ij})}{\sum_{i=1}^n u_{ij}^m \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2^2)} \quad (4.18)$$

A partir de la derivación del algoritmo se obtiene la versión robusta del algoritmo IFCM, aunque la única restricción de la función de pérdida $\rho(\cdot)$ es que sea derivable en $\psi(\cdot)$, para robustecer al algoritmo se optó por hacer uso de los estimadores redescendentes M, ya que se encuentran en el dominio continuo y son funciones derivables. Por lo tanto, en el Algoritmo 2 se resume la propuesta RIFCM.

Algorithm 2 Algoritmo Redescending Intuitionistic Fuzzy C-Means

Require: x, c, m, ϵ

Ensure: $u, v(\mu_l, \nu_l, \pi_l), 1 \leq l < c$

- 1: $X \mapsto X^{IFS}$
 - 2: $v_{kj}^{IFS(0)} \leftarrow 0$
 - 3: $u_{ik}^{(0)} = \frac{1}{\sum_{k=1}^c \left[\frac{m\rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2)}{m\rho(\|x_{ij}^{IFS} - v_{ij}^{IFS}\|_2)} \right]^{\frac{2}{m-1}}}$
 - 4: **do for** $l \leftarrow 1$ **to** \dots
 - 5: $\mu(v_{kj}^{(l)}) = \frac{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2) \mu(x_{ij})}{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2)}$
 - 6: $\nu(v_{kj}^{(l)}) = \frac{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2) \nu(x_{ij})}{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2)}$
 - 7: $\pi(v_{kj}^{(l)}) = \frac{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2) \pi(x_{ij})}{\sum_{i=1}^n (u_{ij}^m)^{l-1} \psi(\|x_{ij}^{IFS} - v_{kj}^{IFS(l-1)}\|_2^2)}$
 - 8: $v_{kj}^{IFS(l)} \leftarrow (\mu(v_{kj}^{(l)}), \nu(v_{kj}^{(l)}), \pi(v_{kj}^{(l)}))$
 - 9: $u_{ik}^{(l)} = \frac{1}{\sum_{k=1}^c \left[\frac{m\rho(\|x_{ij}^{IFS} - v_{kj}^{IFS}\|_2)}{m\rho(\|x_{ij}^{IFS} - v_{ij}^{IFS}\|_2)} \right]^{\frac{2}{m-1}}}$
 - 10: $\|x_{ij}^{IFS} - v_{kj}^{IFS(l)}\|_2^2 \leftarrow (\mu(x_{ij}) - \mu(v_{kj}^{(l)}))^2 + (\nu(x_{ij}) - \nu(v_{kj}^{(l)}))^2 + (\pi(x_{ij}) - \pi(v_{kj}^{(l)}))^2$
 - 11: $\mathcal{J}_m \leftarrow \sum_{i=1}^c \sum_{j=1}^N u_{ik}^{m(l)} \rho(\|x_{ij}^{IFS} - v_{kj}^{IFS(l)}\|_2^2)$
 - 12: **while** $\|U_{if}^l - U_{if}^{l-1}\| < \epsilon$
return $u_{if}^{(l)}, v_j^{IFS(l)} \mapsto Y$
-

Como se mencionó anteriormente, se optó por un estimador redescendente M ya se adapta mejor a las restricciones del algoritmo, a la vez que ayuda a disminuir la afectación por datos atípicos. Sin embargo en la literatura existen diversas propuestas diseñadas a partir de diferentes formas de influencia. El algoritmo reformulado se entiende como universal, por lo que para seleccionar un estimador en concreto se realizó la experimentación con los más usados en la literatura, esta se hizo con los estimadores implementados dentro del algoritmo RIFCM, la cual es detallada a continuación.

4.4. Estimador M-Redescendente

El primer estimador replicado es el *Hampel's three-part redescending M-estimator* [43]. El estimador Hampel es una función escalonada de tres partes, como se observa en la Figura 4.3.a la función de pérdida $\rho(\cdot)$ es generada a partir de una distribución normal invertida, mientras que la función de influencia $\psi(\cdot)$ muestra esta forma escalonada a partir de los umbrales a , b y c que recibe como parámetro:

$$\rho(x) = \begin{cases} \frac{x^2}{2} & |x| \leq a, \\ a|x| - \frac{1}{2}a^2 & a < |x| \leq b, \\ ab - \frac{a^2}{2} + \frac{a(c-b)}{2} \left[1 - \left(\frac{c-|x|}{c-b} \right)^2 \right] & b < |x| \leq c, \\ ab - \frac{a^2}{2} + \frac{a(c-b)}{2} & |x| > c \end{cases} \quad (4.19)$$

$$\psi(x) = \begin{cases} x & |x| \leq a, \\ a \operatorname{sign}(x) & a < |x| \leq b, \\ a \frac{c-|x|}{c-b} \operatorname{sign}(x) & b < |x| \leq c, \\ 0 & |x| > c. \end{cases} \quad (4.20)$$

El estimador *Andrew's Sine* [44, 45] es representado por una función senoidal, la cual está en función de un parámetro de varianza c y de la constante π .

$$\rho(x) = \begin{cases} c^2 \left[1 - \cos\left(\frac{x}{c}\right) \right] & |x| \leq c\pi, \\ 2c^2 & |x| > c\pi \end{cases} \quad (4.21)$$

$$\psi(x) = \begin{cases} c \sin\left(\frac{x}{c}\right) & |x| \leq c\pi, \\ 0 & |x| > c\pi. \end{cases} \quad (4.22)$$

Similar, el estimador *Tukey's Biweight* [46, 47] introduce una función bponderada. Se diferencia de *Andrew's Sine* porque no está en función de π , sino que solo a la varianza c , como se puede observar en la Figura 4.3.c. Su función de pérdida (4.23) y de influencia (4.24) son dadas por funciones polinomiales de dos partes.

$$\rho(x) = \begin{cases} \frac{c^2}{6} \left[1 - \left(1 - \left(\frac{x}{c} \right)^2 \right)^3 \right] & |x| \leq c, \\ \frac{c^2}{6} & |x| > c \end{cases} \quad (4.23)$$

$$\psi(x) = \begin{cases} x \left[1 - \left(\frac{x}{c} \right)^2 \right]^2 & |x| \leq c, \\ 0 & |x| > c \end{cases} \quad (4.24)$$

En contraparte a los estimadores clásicos mencionados anteriormente, se replicó el estimador Ali [48] el cual es una propuesta reciente basada en funciones hiperbólicas que no habían sido consideradas. Como lo muestran su función de pérdida (4.25) y de pérdida (4.26), este estimador es de una sola parte a diferencia de los anteriores que consideran dos

o tres partes. Sus formas son mostradas en la Figura 4.3.d. Aunque el estimador Ali está conformado por una sola parte a diferencia de los antes mostrados, este también depende del parámetro c .

$$\rho(x) = c \tan^{-1}\left(\tanh\left(\frac{x^2}{2c}\right)\right), \quad |x| \geq 0 \quad (4.25)$$

$$\psi(x) = \frac{x}{\cosh\left(\frac{x^2}{c}\right)}, \quad |x| \geq 0. \quad (4.26)$$

Por otra parte el estimador Lorenziano [49, 50] no requiere de ningún parámetro como se muestra en sus funciones de pérdida (4.27) y de influencia (4.28). En la Figura 4.3.e se muestran las formas logarítmicas de este estimador.

$$\rho(x) = \log\left(1 + \frac{1}{2}x^2\right) \quad (4.27)$$

$$\psi(x) = \frac{x}{1 + \frac{1}{2}x^2}. \quad (4.28)$$

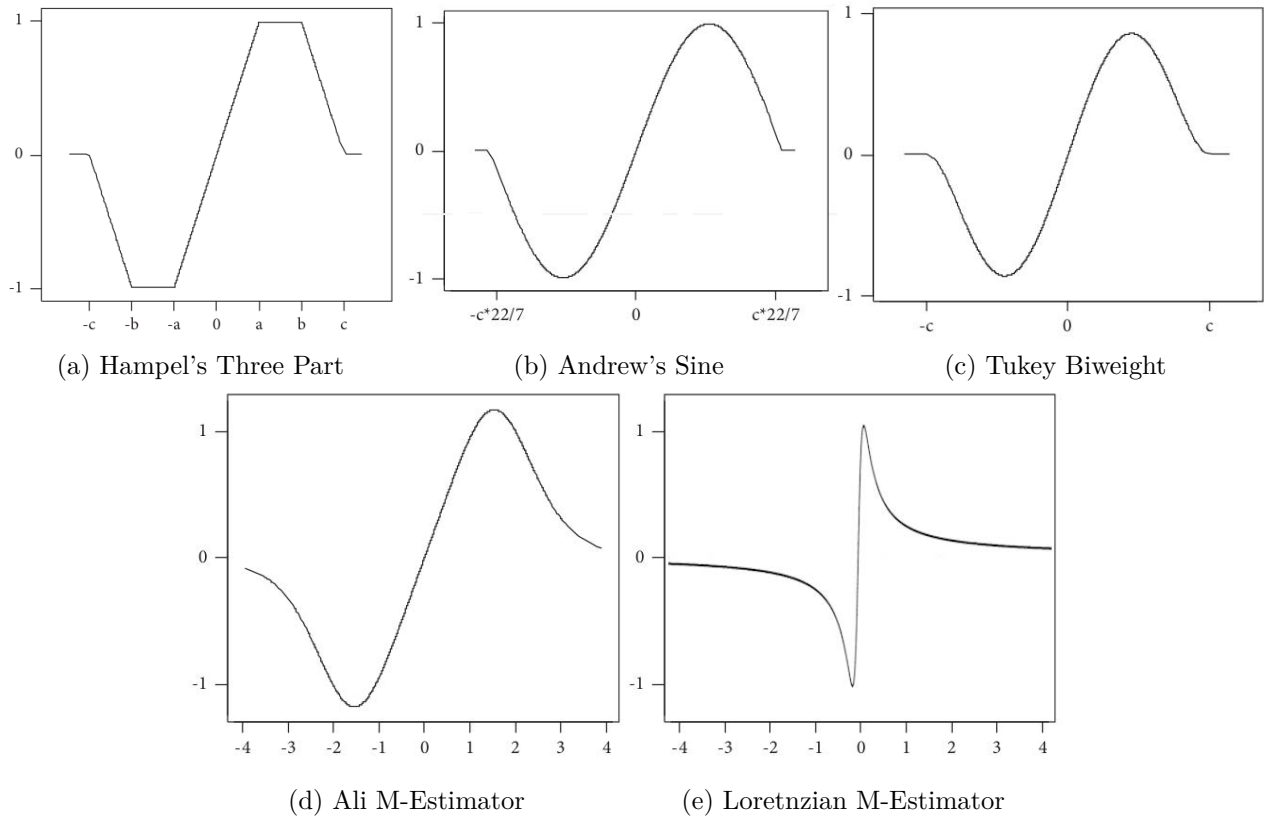


Figura 4.3: Formas de las funciones ρ y ψ del estimador Andrew's Sine

Las funciones de influencia pueden interpretarse como la importancia que se le da a cada

dato procesado por el estimador, de tal forma que aquellos datos ubicados en las tendencias centrales, es decir dentro de las zonas más altas y bajas de la función, son más representativas que aquellas que se encuentran en los bordes, donde frecuentemente se encuentran los datos atípicos. Para validar el funcionamiento del algoritmo RIFCM y cada uno de los estimadores replicados se realizó experimentación en la tarea de agrupamiento.

Capítulo 5

Experimentación y Resultados

En este capítulo se explican los conjuntos de datos utilizados para la experimentación con el algoritmo propuesto, tanto para reconocimiento de patrones como de segmentación de imágenes. De igual manera, se presentan las métricas de evaluación y la comparación con otras metodologías utilizadas en la literatura. El proceso de experimentación llevado a la práctica se describe en la Figura 5.1, donde se observa que, una imagen dermatoscópica es adquirida dentro de un programa especializado, el cual la convertirá en un vector; este vector será implementado dentro del algoritmo *Redescending Intuitionistic Fuzzy C-Means* RIFCM y se llevarán a cabo los cálculos necesarios para llegar al resultado de acuerdo con los parámetros establecidos (cálculo de centroides, matriz de pertenencia, función de influencia, etc), dando como resultado final un arreglo de 2 dimensiones, es decir, una imagen segmentada en escala de grises que ayudará a realizar la comparación con el *ground truth*; y un archivo de texto donde se almacenan los valores de las métricas establecidas para medir la calidad de agrupamiento y segmentación. Se debe recordar que en Matlab una imagen en formato de color RGB se representa por 3 matrices bidimensionales, correspondientes a los planos R, G y B. La programación se llevó a cabo en una laptop con capacidad de 1tb de almacenamiento y 8gb de memoria RAM; en Matlab 2022b.

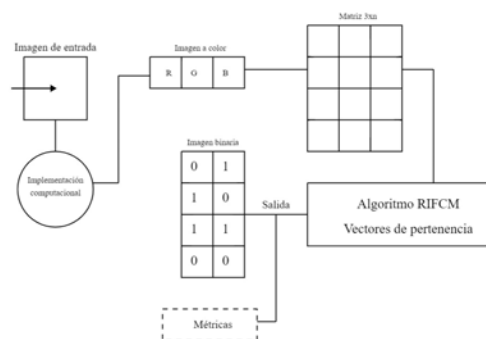


Figura 5.1: Proceso de implementación computacional.

5.1. Experimentación de RIFCM con bases de datos sintéticas

Para la experimentación con el algoritmo robusto intuitivo difuso, se utilizaron 2 conjuntos de datos diferentes, uno orientado a tareas de reconocimiento de patrones y el segundo, a segmentación de imágenes; en este caso se trabajó con imágenes dermatoscópicas.

Se experimentó con bases de datos simuladas de dos dimensiones que permiten visualizar de forma simple la caracterización de estos e identificar los grupos. Adicionalmente partiendo de las dispersiones de datos simuladas, se le agregaron mayores varianzas a fin de crear datos atípicos sintéticos. Esto es visible en la Figura 5.2.

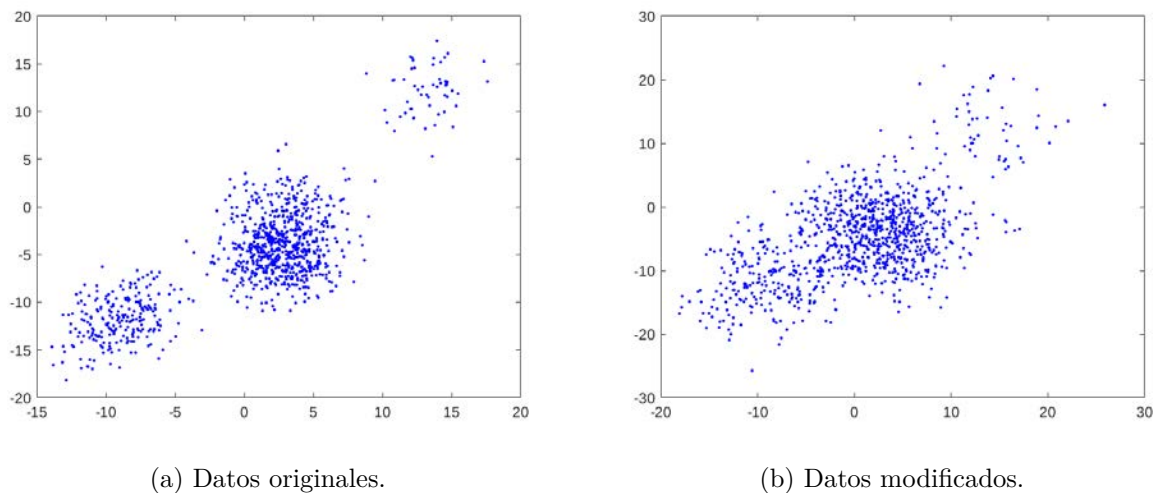


Figura 5.2: Ejemplo de una base de datos simulada y su modificación para crear datos atípicos de forma simulada

Para extender la experimentación se crearon 4 bases de datos con distinto número de grupos preasignados, a las cuales se les modificaron con varias varianzas entre $\sigma \in [0.1, 0.25]$. En la Figura 5.3 se muestra un caso que en comparación con la Figura 5.2, muestra mayor porcentaje de dispersión.

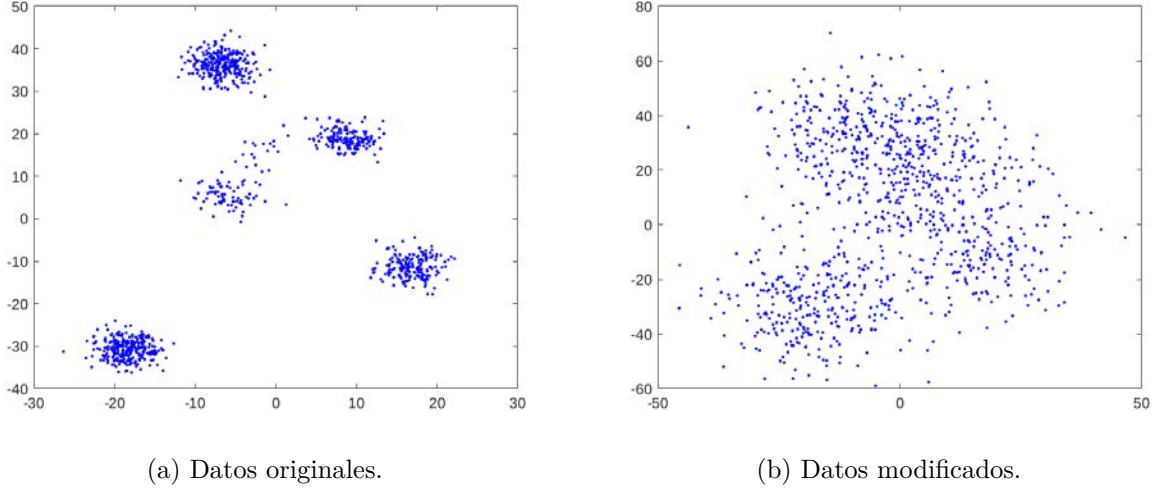


Figura 5.3: Base datos con $\sigma = 0.2$

Como se mencionó antes, se crearon 4 bases de datos con 4 modificaciones cada una, teniendo un total de 16 fuentes de datos. Se experimentó con el algoritmo RIFCM con los 5 estimadores presentados, además del algoritmo IFCM que no hace uso de un estimador, por lo que representa un total de 96 experimentos. Para validar la precisión de cada propuesta se utilizaron métricas enfocadas en la calidad de agrupamiento.

5.1.1. Métricas para evaluación de agrupamiento

El Coeficiente de Partición (PC) [51, 52] mide el grado difuso de los grupos finales divididos por medio de la matriz de partición difusa u , y cuanto mayor sea su valor, mejor será el resultado de la partición:

$$PC = \frac{1}{N} \sum_{i=1}^c u_i^m \quad (5.1)$$

De forma similar al Coeficiente de Partición, la Entropía de Clasificación (CE) [12, 52] mide el grado difuso de los grupos finales divididos por medio de la matriz de partición difusa, y cuanto menor sea su valor, mejor será el resultado de la partición:

$$CE = -\frac{1}{N} \sum_{i=1}^c u_i \log(u_i) \quad (5.2)$$

Teniendo en cuenta el grado de pertenencia y la estructura de los conjuntos de datos, el índice Xie y Beni (XB) [53, 54] se propuso para medir la compacidad y separación promedio general, y cuanto menor sea su valor, mejor será el resultado de la partición:

$$XB = \frac{\sum_{i=1}^c \sum_{j=1}^n \mu_{ij}^2 \|v_i - x_j\|^2}{n \min_{ij} \|v_i - x_j\|^2} \quad (5.3)$$

El índice de Dunn (DI) [11] tiene como objetivo identificar grupos densos y bien separados.

Está definido como la proporción entre la mínima distancia entre grupo y la máxima distancia dentro de un mismo grupo. Para cada partición de grupo, el índice de Dunn puede ser calculado por:

$$DI(u) = \min_{1 \leq i < c} \left[\min_{1 \leq j < c, j \neq i} \left(\frac{\sigma(x_i, x_j)}{\max_{1 \leq k < c} \{\Delta(x_k)\}} \right) \right] \quad (5.4)$$

De la misma forma se hace uso del Índice Alternativo de Dunn (ADI) [55]:

$$ADI(u) = \min_{1 \leq i < c} \left[\min_{1 \leq j < c, j \neq i} \left(\frac{\min_{x_i \in C_i, x_j \in C_j} \sigma(y_i, v_j) - \sigma(x_i, v_j)}{\max_{1 \leq k < c} \{\Delta(x_k)\}} \right) \right] \quad (5.5)$$

Adicionalmente se consideraron el índice de separación (S) y el índice de partición (SC) los cuales indican mejor desempeño cuando la tendencia es a 0 [52].

5.1.2. Resultados de agrupamiento con RIFCM en base de datos sintéticas

Como primera validación experimental se llevó a cabo la medición del agrupamiento con las bases de datos originales. En la Figura 5.5 se muestra un ejemplo del agrupamiento generado por el algoritmo RIFCM y el IFCM sin estimador para la base de datos original de 3 grupos.

En este experimento de prueba es notable la separación de grupos, sin embargo en el caso del IFCM sin estimador se puede notar un desempeño muy bajo en la ubicación de los centroides, indicados por los círculos rojos, lo cual delimita las regiones de cada grupo muy cercanas. Esto puede ser causado por una mala inicialización del algoritmo, que como es sabido es aleatoria. Por otro lado, a excepción del estimador *Andrew's Sine*, el resto de estimadores presentan delimitaciones y centroides muy similares, siendo que este último se ve afectado por las leves dispersiones de los otros grupos.

De manera cuantitativa, el resumen de los experimentos realizados con todas las bases sin datos atípicos se muestra en la Tabla 5.1, reportando la media de las métricas obtenidas en los 48 experimentos.

Tabla 5.1: Métricas obtenidas de la experimentación sin presencia de datos atípicos

Estimador	PC	CE	SC	S	XB	DI	ADI	Iteraciones
Sin estimador	0.785	0.369	118.860	0.185	9.799	0.074	0.009	5
Hampel	0.971	0.060	0.468	0.0007	6.795	0.028	0.007	4.3
Andrew's sine	0.973	0.061	0.470	0.0007	7.946	0.034	0.008	5.6
Tukey	0.961	0.082	0.668	0.001	6.799	0.025	0.007	5.3
Ali	0.973	0.065	0.488	0.0007	8.799	0.068	0.009	5.3
Lorentzian	0.971	0.065	0.498	0.0007	9.043	0.074	0.006	5

PC = Coficiente de Partición, CE = Entropía de Clasificación, XB = Índice Xie Beni, DI = Índice de Dunn, ADI = Índice Alternativo de Dunn.


Acorde a lo mostrado de forma cualitativa en la Figura 5.5 y cuantitativamente en la Tabla 5.1, la versión base de IFCM se muestra con la menor calidad. Esto se ve sesgado dado el experimento con mala inicialización por parte del algoritmo, exceptuando ese caso la métrica SC pasa de 110.860 a 0.986, que sigue siendo la de menor calidad. Por otra parte el resto de estimadores presentan métricas similares donde Hampel resulta ser ≈ 0.02 mejor en general, al mismo tiempo que reduce en 18 % las iteraciones para converger.

Ahora en cuanto a desempeño con presencia de datos atípicos es común que la calidad decaiga, sin embargo se busca la configuración que se vea menos afectada por estos datos. Para el experimento con la base de datos de 3 grupos no hubo mala inicialización del algoritmo IFCM. A simple vista en la Figura 5.6 las delimitaciones de los grupos se ven muy similares, por ello en la Tabla 5.2 se muestran las métricas obtenidas para los experimentos con datos atípicos.


Tabla 5.2: Métricas obtenidas de la experimentación con datos atípicos

Estimador	PC	CE	SC	S	XB	DI	ADI	Iteraciones
Sin estimador	0.850	0.336	1.468	0.0016	4.907	0.019	0.013	5
Hampel	0.817	0.324	1.390	0.001	4.998	0.010	0.014	4.6
Andrew's sine	0.821	0.277	1.250	0.001	5.122	0.008	0.014	5
Tukey	0.829	0.323	1.362	0.001	4.985	0.010	0.009	5
Ali	0.828	0.324	1.375	0.002	5.111	0.009	0.013	5
Lorentzian	0.821	0.336	1.468	0.002	4.907	0.009	0.013	4.6

De acuerdo con lo visto en la Tabla 5.2, el estimador Hampel se muestra nuevamente con la mejor calidad ≈ 0.01 y converge 7% mas rápido junto con el estimador Lorentziano. Con respecto a los experimentos sin datos atípicos se muestra una disminución de ≈ 0.04 para el mejor de los casos y de 0.1 como máximo. Nuevamente la versión sin estimación robusta presenta la menor calidad. Para demostrar cualitativamente, en la Figura 5.4 se muestra el mejor resultado obtenido en comparación al caso mas complicado con mejor resultado.




(a) Hampel en el caso más sencillo.




(b) Hampel en el caso mas complicado.

Figura 5.4: Desempeño de Hampel en el caso más sencillo y en la dispersión con $\sigma = 0.25$.


En la Figura 5.7 se observan los resultados obtenidos al ejecutar cada base de datos y las métricas resultantes, cada línea, 4 colores diferentes, representa un conjunto de datos, es decir, las cuatro bases de datos sintéticas mencionadas en la sección anterior; y los números del 1 al 6 son los estimadores con los cuales se comparó: 1, sin estimador; 2, *Hampel*; 3, *Andrew's Sine*; 4, *Tukey*; 5, *Ali* y 6, *Lorentzian* y en cada subfigura se observa una métrica y sus valores promedio.




(a) Sin estimador.




(b) Hampel.




(c) Sine.



(d) Tukey.




(e) Ali.




(f) Lorentzian.


Figura 5.5: Caso de prueba con la base de datos original de 3 grupos.




(a) Sin estimador.




(b) Hampel.




(c) Sine.



(d) Tukey.



(e) Ali.



(f) Lorentzian.

Figura 5.6: Caso de prueba base de datos de 3 grupos y variación $\sigma = 0.1$.



Figura 5.7: Resultados de las métricas para reconocimiento de patrones.

Con la experimentación realizada, se pudo obtener la información del total de tiempo de ejecución y las iteraciones realizadas en cada base de datos con cada estimador, ver Tabla 5.3.

Tabla 5.3: Tiempo de ejecución e iteraciones en cada base de datos

Base de datos (sintética)	Estimador	Tiempo de ejecución	Iteraciones
1	<i>Sin estimador</i>	0.013	5
	<i>Hampel</i>	0.011	4.3
	<i>Andrew's Sine</i>	0.020	5.6
	<i>Tukey</i>	0.019	5.3
	<i>Ali</i>	0.011	5.3
	<i>Lorentzian</i>	0.013	5
2	<i>Sin estimador</i>	0.010	5
	<i>Hampel</i>	0.011	4.6
	<i>Andrew's Sine</i>	0.010	5
	<i>Tukey</i>	0.019	5
	<i>Ali</i>	0.011	5
	<i>Lorentzian</i>	0.014	4.6
3	<i>Sin estimador</i>	0.012	5
	<i>Hampel</i>	0.017	5
	<i>Andrew's Sine</i>	0.016	4.3
	<i>Tukey</i>	0.019	4.6
	<i>Ali</i>	0.010	5
	<i>Lorentzian</i>	0.017	5
4	<i>Sin estimador</i>	0.014	4.6
	<i>Hampel</i>	0.014	4.3
	<i>Andrew's Sine</i>	0.011	4.3
	<i>Tukey</i>	0.012	5
	<i>Ali</i>	0.012	5
	<i>Lorentzian</i>	0.010	5

Otra forma de evaluar es con respecto a la distancia de los centroides obtenidos con los originales, es mostrada en la Tabla 5.4.

Tabla 5.4: Vectores de prototipos obtenidos por cada algoritmo y distancia con respecto al *ground truth*

Algoritmo	Prototipos ($\hat{\mu}$)	Distancias	Error
<i>Ground truth</i>	[0.904, 0.780; 0.244, 0.367; 0.707, 0.696] ^T	-	-
Andrew's sine	[0.876, 0.687; 0.283, 0.343; 0.712, 0.630] ^T	[0.046; 0.066; 0.096] ^T	0.069
Hampel	[0.682, 0.256; 0.210, 0.455; 0.769, 0.760] ^T	[0.115; 0.242; 0.136] ^T	0.164
Tukey	[0.848, 0.616; 0.295, 0.305; 0.505, 0.709] ^T	[0.081; 0.217; 0.090] ^T	0.129
Ali	[0.690, 0.222; 0.235, 0.396; 0.762, 0.781] ^T	[0.145; 0.299; 0.141] ^T	0.195
Lorentzian	[0.689, 0.233; 0.233, 0.397; 0.774, 0.778] ^T	[0.134; 0.299; 0.130] ^T	0.188

Como se pudo observar en la información dada en las tablas y gráficas, es notable la diferencia entre las distancias obtenidas de cada estimador, así como la calidad de agrupamiento, pues en muchos casos los valores obtenidos distan mucho de los parámetros idóneos para considerarse un buen agrupamiento sin perder calidad. En las gráficas de la Figura 5.7 se aprecian aquellos picos donde, dependiendo el estimador, los valores distan mucho del rango dado por el estimador en cuestión. Por ello para esta aplicación se define a ρ como el estimador Andrew's Sine. Una vez validada y seleccionado el estimador, se realizó la experimentación para validar la propuesta en términos de delimitación de lesiones en imágenes dermatoscópicas.

5.2. Experimentación de RIFCM con imágenes dermatoscópicas

La dermatoscopia es una técnica no invasiva desarrollada para el estudio de lesiones cutáneas, la cual consiste en visualizar la lesión a través de un dermatoscopio. Ésta técnica es de gran ayuda para el diagnóstico oportuno de enfermedades cutáneas y su posible tratamiento [56]. Las imágenes dermatoscópicas no contienen ruido y son a color, debido a que se utiliza un dispositivo especializado para obtenerlas; sin embargo, al existir diferentes tipos de dermatoscopios, el resultado de cada imagen puede interferir en la interpretación de la lesión. Un dermatoscopio es un lente de aumento que se le ha integrado un sistema de iluminación.

Como se puede observar en el ejemplo anterior, la intensidad de luz provoca que cada imagen se visualice de manera diferente, ocasionando que al momento de querer realizar un análisis pueda verse afectado. Así como se muestra este ejemplo, existen otros tipos de artefactos que pueden provocar una mala interpretación al momento de estudiar una imagen de este tipo, por ejemplo:

- Presencia de vello.
- Diferentes bordes, texturas y coloración.
- Marcas de tinta.
- Artículos externos (electrodos, marcas del dermatoscopio, lunares, etc).

Todos estos artefactos influyen de manera directa al momento de querer realizar un análisis en este tipo de imágenes, sobretodo cuando se quiere realizar un proceso de segmentación ya que, al utilizar un método tradicional para efectuar esta tarea toda esta información atípica ocasionará que la segmentación resultante sea muy diferente a lo esperado (*ground truth*). Algunos ejemplos de estos artefactos se muestran en la Figura 5.8.

Todo lo mostrado anteriormente de ahora en adelante será llamado como información atípica, ya que es parte de la imagen desde su adquisición y es importante saber el tratamiento adecuado que se le ha de dar al momento de realizar una segmentación. Hay que tener presente que este tipo de información no es lo mismo que ruido en la imagen, pues por la naturaleza de este tipo de imágenes médicas y la forma en que son obtenidas no suelen venir

con ruido. A partir de la revisión de la literatura se identificaron 5 tipos de condiciones presentes en la base de datos ISIC 2020 [57], la cual fue utilizada en esta experimentación. Estas condiciones se clasificaron de la siguiente forma: 1) condiciones generales, 2) presencia de vellos, 3) variación de coloración, 4) objetos extraños y 5) presencia de tinta. Esta investigación se enfoca solo en los tipos 1 y 5. Debido a que la aplicación es distinta, la medición se realizó en términos de segmentación binaria de imágenes, por lo que las métricas utilizadas son enfocadas a esta tarea.

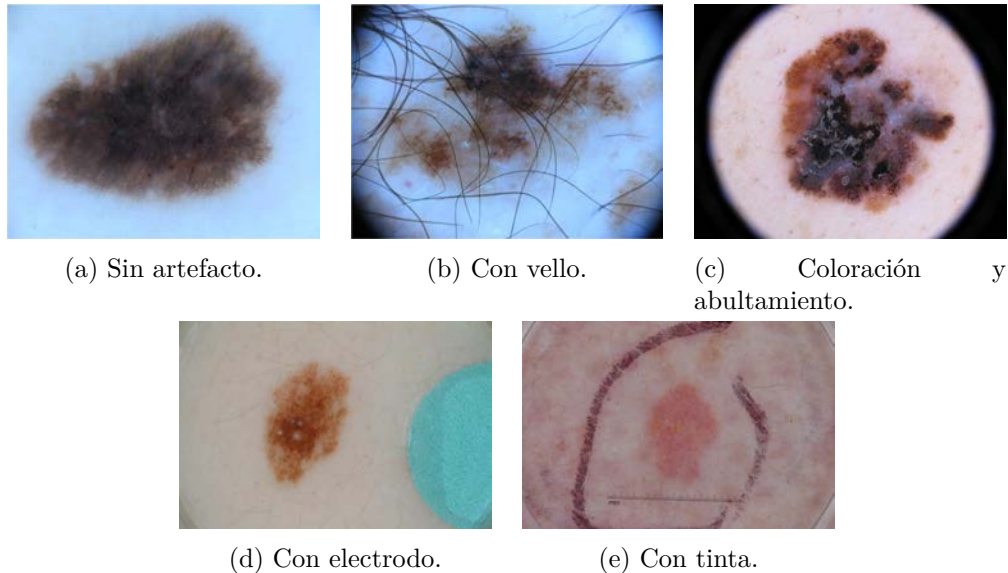


Figura 5.8: Imágenes dermatoscópicas con diferentes artefactos.

Tabla 5.5: Clasificación de imágenes para experimentación.

Clase.	Características.
1. General.	La lesión se visualiza perfectamente, sin la presencia de algún artefacto.
2. Vello	Junto con la lesión, se observa la presencia de vello.
3. Color y abultamiento.	La lesión presenta diferentes tonos de coloración y es observable algún tipo de abultamiento.
4. Artículos externos.	Junto a la lesión se observan electrodos, lunares, manchas, etc.
5. Tinta	La lesión se encuentra señalada o encerrada en tinta.

En la Figura 5.9 se observa un ejemplo de cada tipo de imágenes de las cuales se realizó la clasificación para llevar a cabo la experimentación y comparar resultados.

Debido a que la aplicación es distinta, la medición se realizó en términos de segmentación binaria de imágenes, por lo que las métricas utilizadas son enfocadas a esta tarea. Estas

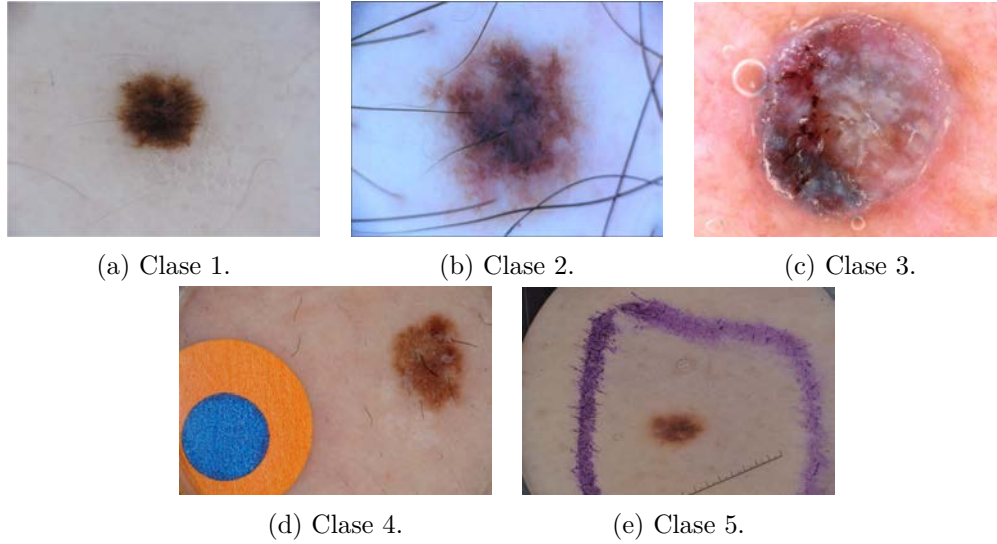


Figura 5.9: Clasificación de imágenes.

métricas son descritas a continuación.

5.2.1. Métricas para evaluación de segmentación

Para evaluar la calidad de la segmentación se toma en cuenta la imagen de referencia mencionada anteriormente y se calcula inicialmente las métricas derivadas de la matriz de confusión: *Precision*, *Accuracy*, *Sensitivity*, *Specificity* y *F1*, a razón de medir la intersección entre los resultados obtenido y los esperados. De igual forma se utiliza el Coeficiente de Correlación de Matthews MCC [58] es un valor de coeficiente de correlación entre $[-1, 1]$. Un coeficiente de 1 representa una predicción perfecta, 0 una predicción aleatoria promedio y -1 una predicción inversa:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (5.6)$$

Además, para medir más precisamente las intersecciones de la delimitación, se utiliza el Índice Jaccard, el cual mide el grado de similitud entre dos conjuntos, en este caso pixeles. Para complementar esta medición, se hace uso del coeficiente Dice [59]:

$$DICE = \frac{2C}{A + B} = \frac{2|A \cap B|}{|A| + |B|} \quad (5.7)$$

donde A y B representan las instancias de cada clase y C es las instancias compartidas por las dos, el coeficiente se encuentra en el rango $[0, 1]$ siendo 1 un mejor resultado. Como segunda medición se usa la Proporción Máxima de Señal a Ruido PSNR [60], esta define la relación entre la máxima intensidad posible de una imagen y el ruido que afecta a su representación fidedigna. Para obtener esta medición es indispensable el cálculo previo del MSE y la máxima intensidad de color en cada canal. Los valores típicos que adopta este

parámetro están entre 30 y 50 dB, siendo mayor cuanto mejor es la codificación.

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_x^2}{MSE} \right) \quad (5.8)$$

La tercera métrica es el Índice de Similitud Estructural SSIM [61], ésta es una métrica de calidad conocida que se utiliza para medir la similitud entre dos imágenes.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C1)(2\sigma_{xy} + C2)}{(\mu_x^2 + \mu_y^2 + C1)(\sigma_x^2 + \sigma_y^2 + C2)} \quad (5.9)$$

Donde μ_x y μ_y son las medias de x y y respectivamente, σ_x^2 y σ_y^2 las varianzas, σ_{xy} la covarianza entre x y y , y $C1 = (k_1, L)^2$, $C2 = (k_2, L)^2$ son variables para estabilizar la división, L es el rango de intensidad de pixeles y las constantes $k_1 = 0.01$ y $k_2 = 0.03$.

5.2.2. Resultados de segmentación con RIFCM en imágenes dermatoscópicas

En esta sección se muestran los resultados con dos, de los cinco tipos de imágenes que se clasificaron dependiendo de la presencia de artefactos.

Imágenes médicas

El primer tipo de imagen es el escenario más simple, donde la lesión es bien definida y no hay afectaciones. Como métodos de comparación se tomaron los algoritmos K-Means, K-Medoids, el algoritmo *Fuzzy C-Means* y la base de la propuesta, el algoritmo *Intituiunistic Fuzzy C-Means*. De forma cualitativa se muestra los resultados obtenidos en la Figura 5.10.




Figura 5.10: Formas de las funciones ρ y ψ del estimador Andrew's Sine.

En la Figura 5.10.b se muestra el *ground truth*, que es la delimitación de la lesión realizada manualmente. En este ejemplo se visualiza que la mayoría de los métodos pudieron no solo delimitar adecuadamente la lesión, sino que cualitativamente se aprecia mejor delimitada que el *ground truth*. Sin embargo, la comparación cualitativa difiere cuando se cuantifica con las métricas especializadas, para ello en la Tabla 5.6 se resumen las métricas obtenidas de las pruebas con imágenes de tipo 1.


Tabla 5.6: Métricas obtenidas de la experimentación con datos atípicos para la segmentación de imágenes.

Estimador	PREC	ACC	SENS	SPEC	F1	MSE	SSIM	PSNR	MCC	DICE	JACCARD	Iteraciones
Kmeans	0.12	0.05	0.09	0	0.11	0.94	0.28	0.26	0.88	0.11	0.05	10
Kmedoids	0.12	0.05	0.09	0	0.11	0.94	0.28	0.26	0.88	0.11	0.05	5
FCM	0.87	0.94	1	0.90	0.93	0.05	0.90	12.28	0.88	0.93	0.87	8
IFCM	0.87	0.94	1	0.90	0.93	0.05	0.90	12.28	0.88	0.93	0.87	8
RIFCM	0.86	0.93	1	0.89	0.92	0.063	0.90	51.95	0.87	0.92	0.86	1


MCC= Coeficiente de Correlación de Matthews, DICE= Coeficiente DICE, PSNR= Proporción Máxima de Señal a Ruido, SSIM= Índice de Similitud Estructural.

Como se reporta en la Tabla 5.6, el algoritmo RIFCM propuesto muestra una confianza del 92 % a partir de las métricas de intersección reportadas. Se muestra como un 90 % similar la delimitación realizada con respecto al GT, aunque es un resultado excelente, podría ser mejorado ya que la delimitación manual no considera zonas como el área cóncava de la parte izquierda de la lesión mostrada en la Figura 5.10.a. Aún así en estos casos sencillos el algoritmo solo requiere de 1 iteración para obtener la delimitación, por lo que se muestra como el más rápido en términos de convergencia.


En las Figuras 5.11 y 5.12 se visualizan los resultados de las métricas para la evaluación de la calidad de la segmentación de imágenes. Cada subfigura representa una métrica y cada barra el algoritmo con el que se ejecutó.




(a) ACC.




(b) DICE.



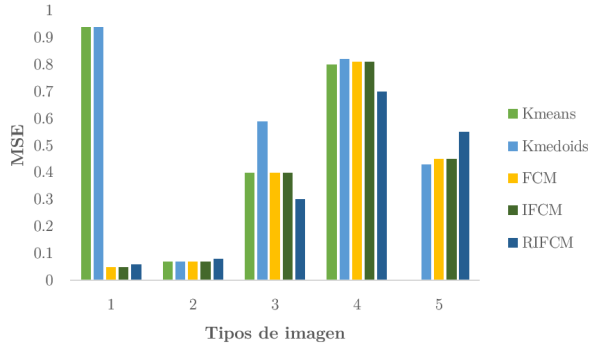
(c) F1.



(d) JACCARD.



(e) MCC.



(f) MSE.

Figura 5.11: Resultados de las métricas para segmentación de imágenes Clase 1.

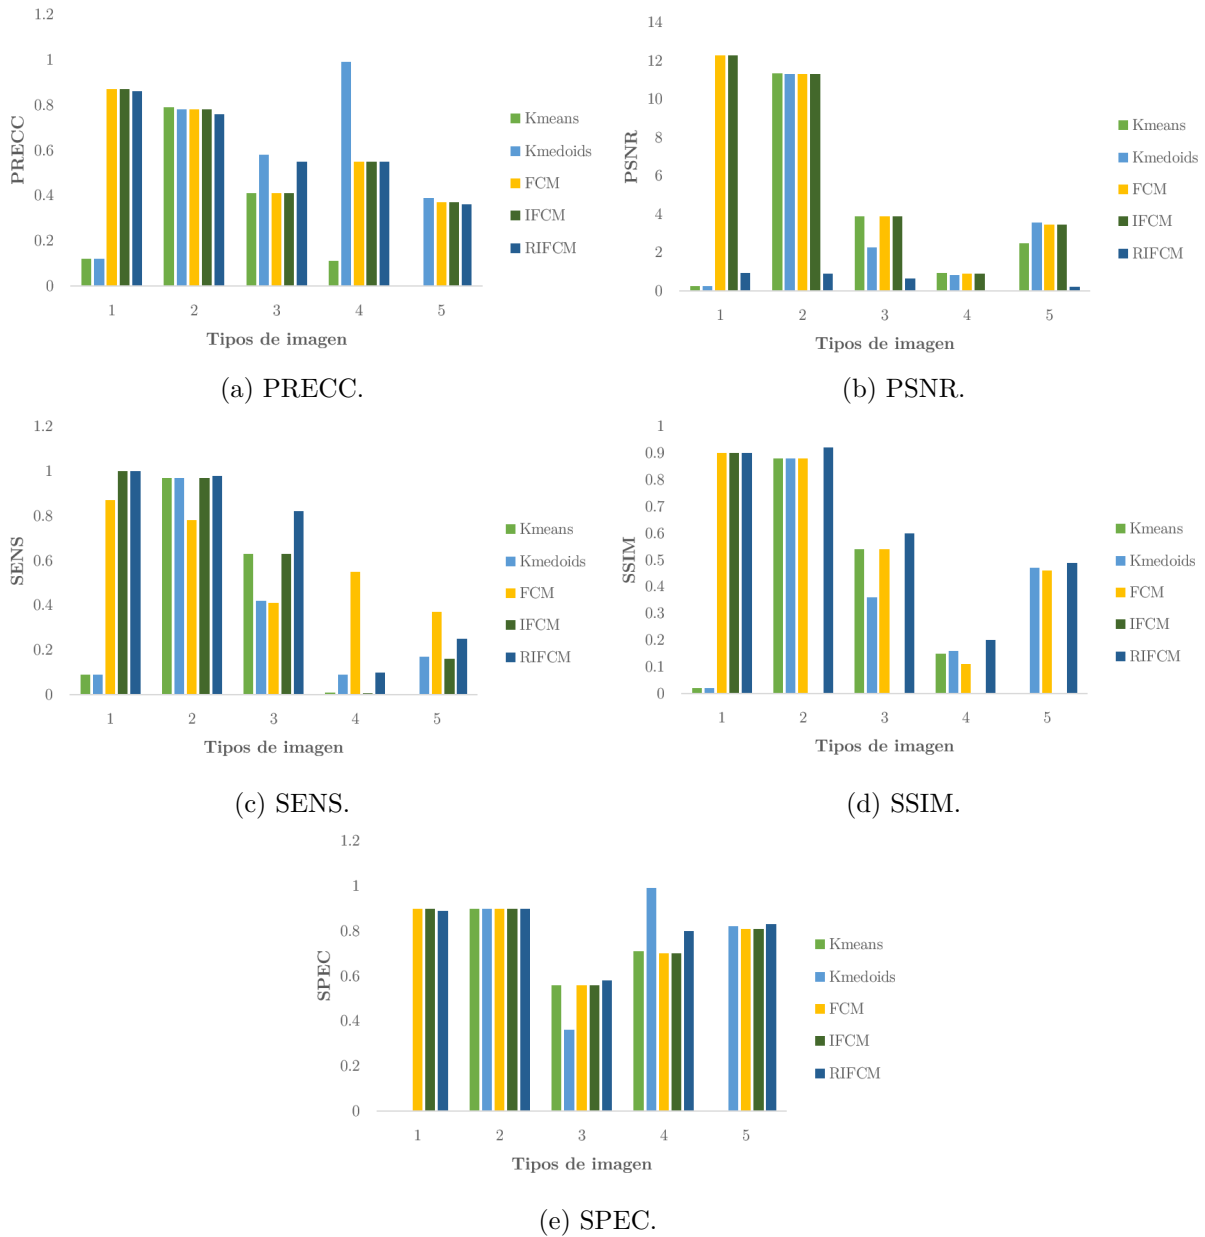


Figura 5.12: Resultados de las métricas para segmentación de imágenes Clase 1.

Presencia de tinta

En este experimento se busca demostrar la robustez del algoritmo ante las manchas de tinta, que agrega el médico para resaltar el área afectada. Aunque estos artefactos no son considerados ruido, si pueden ser identificados como una región por un algoritmo e incluso confundirse con el área de interés. De forma cualitativa, en la Figura 5.13.a se muestra un ejemplo de esta afectación y las delimitaciones realizadas por los algoritmos de comparación.

En la Figura 5.13.a se observan manchas de tinta alrededor de la lesión, estas manchas no son consideradas en la delimitación manual mostrada en la Figura 5.13.b, por lo que son consideradas como información atípica. El objetivo es obtener una delimitación sin que sea afectada por la información atípica, lo cual no fue logrado por la mayoría de los métodos de comparación. Sin embargo la propuesta RIFCM, al ser robusto ante este tipo de datos, presenta una delimitación más parecida al *ground truth*, lo cual es notable cualitativamente. Para respaldar este resultado, en la Tabla 5.7 se muestran las métricas obtenidas en la experimentación con las imágenes con estos artefactos.

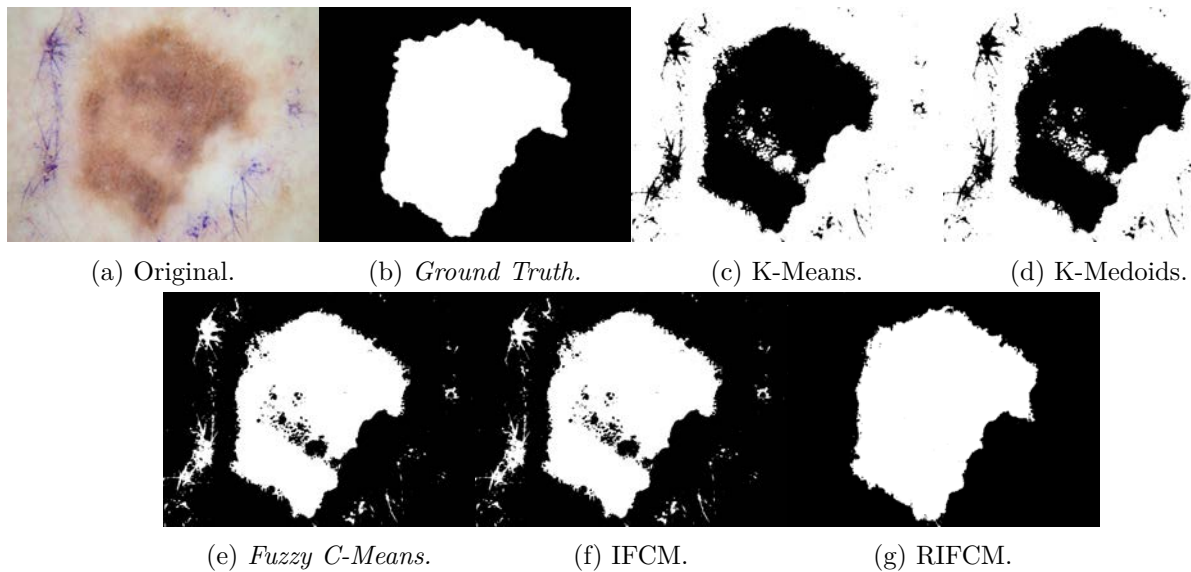


Figura 5.13: Formas de las funciones ρ y ψ del estimador Andrew's Sine.

Tabla 5.7: Métricas obtenidas de la experimentación con datos atípicos para imágenes con tinta.

Estimador	PREC	ACC	SENS	SPEC	F1	MSE	SSIM	PSNR	MCC	DICE	JACCARD
Kmeans	0.56	0.43	0.17	0.81	0.26	0.56	0.35	2.47	0.17	0.26	0.15
Kmedoids	0.39	0.56	0.17	0.82	0.24	0.43	3.56	0.35	0.50	0.24	0.13
FCM	0.37	0.54	0.16	0.81	0.23	0.45	0.46	3.46	0.27	0.23	0.13
IFCM	0.37	0.54	0.16	0.81	0.23	0.45	0.46	3.46	0.27	0.23	0.13
RIFCM	0.96	0.95	0.98	0.90	0.97	0.068	0.99	50.25	0.87	0.97	0.99

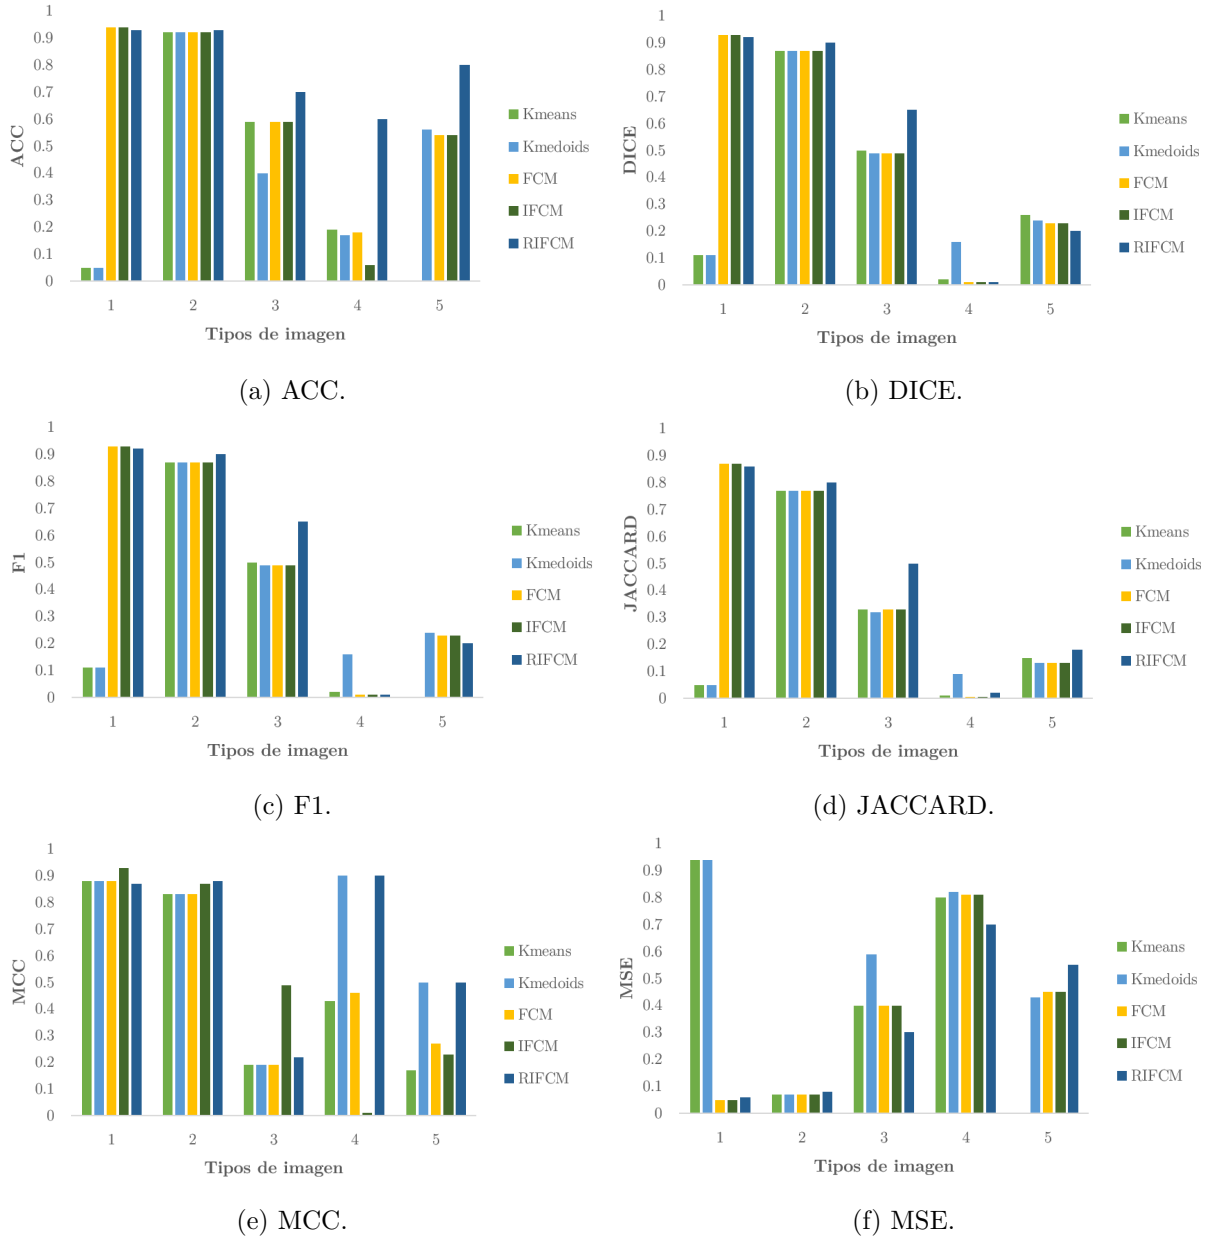


Figura 5.14: Resultados de las métricas para segmentación de imágenes Clase 5.

Como se reporta en la Tabla 5.7, la propuesta es preciso en un 0.96 y similar al *ground truth* en un 99%. La métrica PSNR sirve de apoyo para detectar ruido en la delimitación, que es representado como la delimitación de las regiones atípicas. Para RIFCM se reporta una proporción de 50, lo cual indica una proporción baja, es decir que no fue afectado en comparación a los otros métodos. Como resumen de todas las métricas, la propuesta RIFCM es confiable en un 95%, y en el peor de los casos un 90%. En las Figuras 5.14 y 5.15 muestran los resultados gráficos de cada métrica al ejecutar los algoritmos utilizados para la

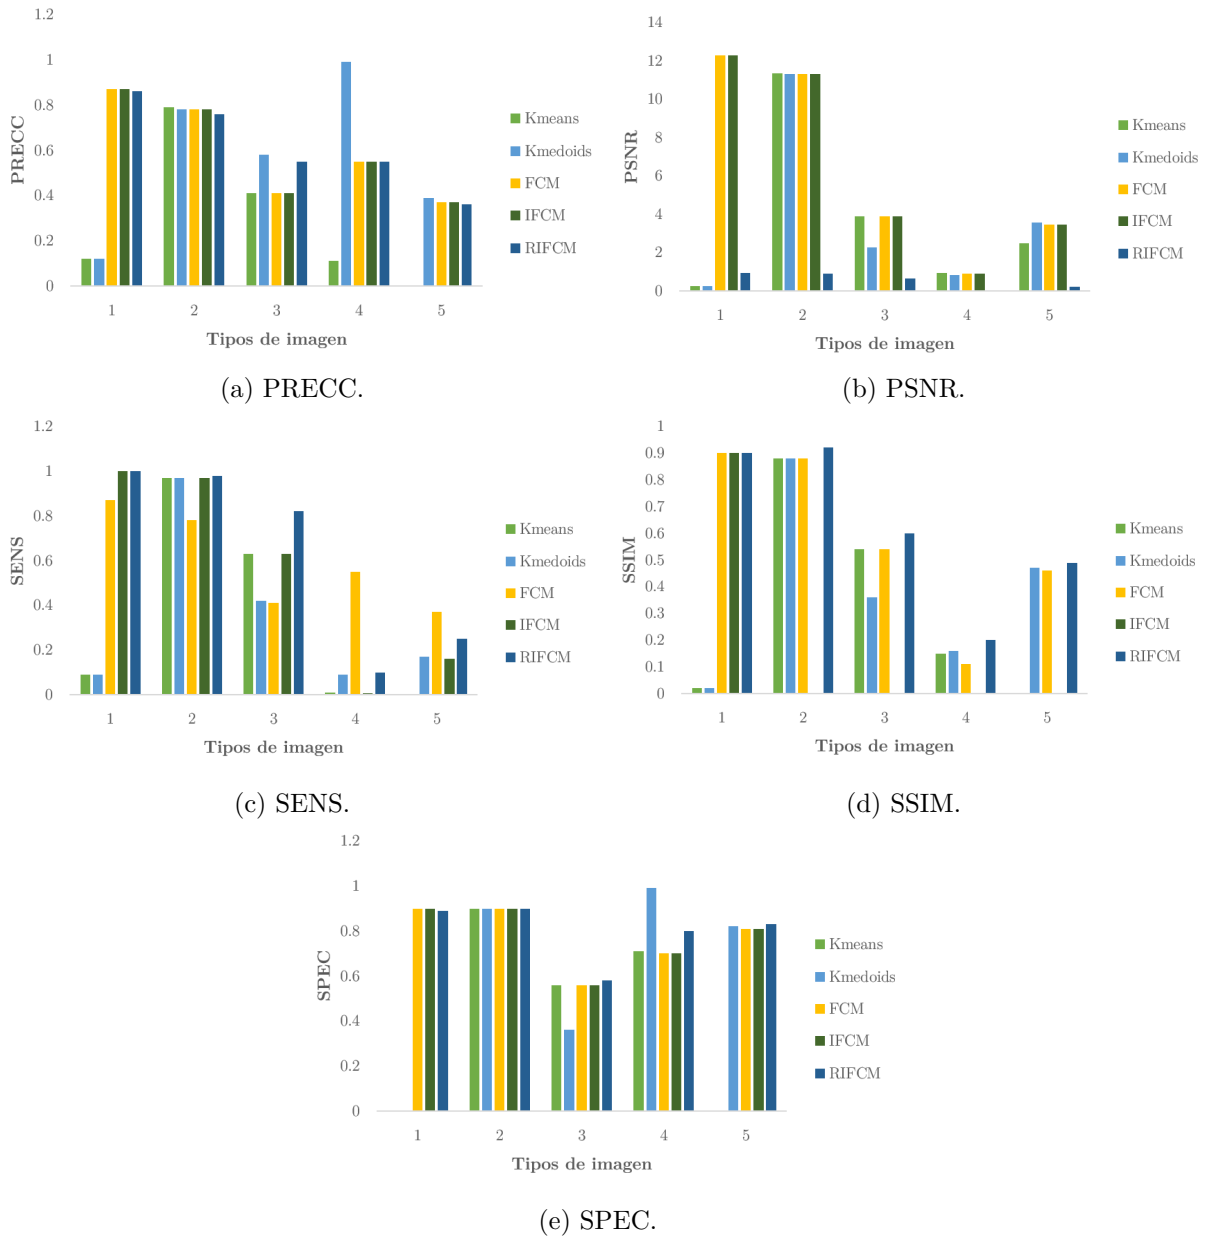


Figura 5.15: Resultados de las métricas para segmentación de imágenes Clase 5.

experimentación, para las imágenes dermatoscópicas Tipos 5, es decir, con la presencia de tinta.

En la Tabla 5.8 se observa el promedio del tiempo de ejecución y del total de iteraciones realizados durante la ejecución de los diferentes algoritmos para la base de datos de imágenes médicas dermatoscópicas. La investigación realizada tiene su base en la teoría de los conjuntos difusos intuitivos.

Tabla 5.8: Promedio de iteraciones y tiempo de ejecución segmentación de imágenes.

Algoritmo	Tiempo	Iteraciones
Kmeans	0.858	10
Kmedoid	0.763	5
FCM	0.923	8
IFCM	1.002	8
RIFCM	1.002	1

Los algoritmos de agrupamiento han tenido una evolución importante a lo largo del tiempo, el tradicional Kmeans ha buscado suavizar las limitantes que tiene, como el agrupamiento binario, a través de la implementación de la lógica difusa, agregando un grado de pertenencia y dando como resultado un algoritmo de agrupamiento difuso. Retomando los conceptos de los conjuntos difusos intuitivos, el agrupamiento difuso agrega dos parámetros que lo vuelven más eficiente que su contraparte difusa (algoritmo difuso intuitivo). En este trabajo se buscó robustecer un algoritmo de agrupamiento difuso intuitivo mediante el uso de estimadores robustos. Derivado de la investigación y experimentación realizada, se llegó a la formulación de un algoritmo robusto intuitivo difuso intuitivo RIFCM, que ha sido implementado en tareas de reconocimiento de patrones y segmentación de imágenes dermatoscópicas. Los resultados mostraron que, la propuesta minimizó el error de agrupamiento a 0.06 en bases de datos sintéticas, con una precisión del 95%. En la segmentación de imágenes es preciso en un 92% y en casos más complejos se mantiene la precisión al no ser afectado por los artefactos presentes en la imagen. Además de estos resultados, este algoritmo se diferencia de otras investigaciones en que, al usar estimación robusta, se reformula directamente la función objetivo y puede derivarse; a diferencia del uso de una heurística ya que ésta no puede replicarse.

5.3. Experimentos adicionales

Una vez presentado el desempeño del algoritmo propuesto bajo ciertos escenarios y características específicas, se realizó una experimentación alterna para conocer su comportamiento al momento de segmentar imágenes dermatoscópicas con otro tipo de artefactos, para sí conocer sus debilidades y poder mejorarlas para trabajos futuros. Las imágenes analizadas cuentan con las siguientes características:

- La lesión se encuentra rodeada de mucho vello.
- La lesión presenta diferentes bordes y texturas.
- En una sola lesión se aprecia la presencia de dos o más artefactos, por ejemplo: vello y electródo, tinta y regla milimétrica, etc.

Para verificar el desempeño del algoritmo, se realizó una experimentación con la misma base de datos de imágenes con melanomas, sin embargo, con artefactos diferentes a los antes presentados y, con todos los estimadores mencionados, esto con la finalidad de encontrar áreas de mejora en la aplicación del mismo. Por ejemplo, presencia de vello abundante, lesiones con diferentes bordes y texturas, y la presencia de dos tipos de información atípica en una sola imagen (vellos y electrodo, tinta y regla milimétrica).

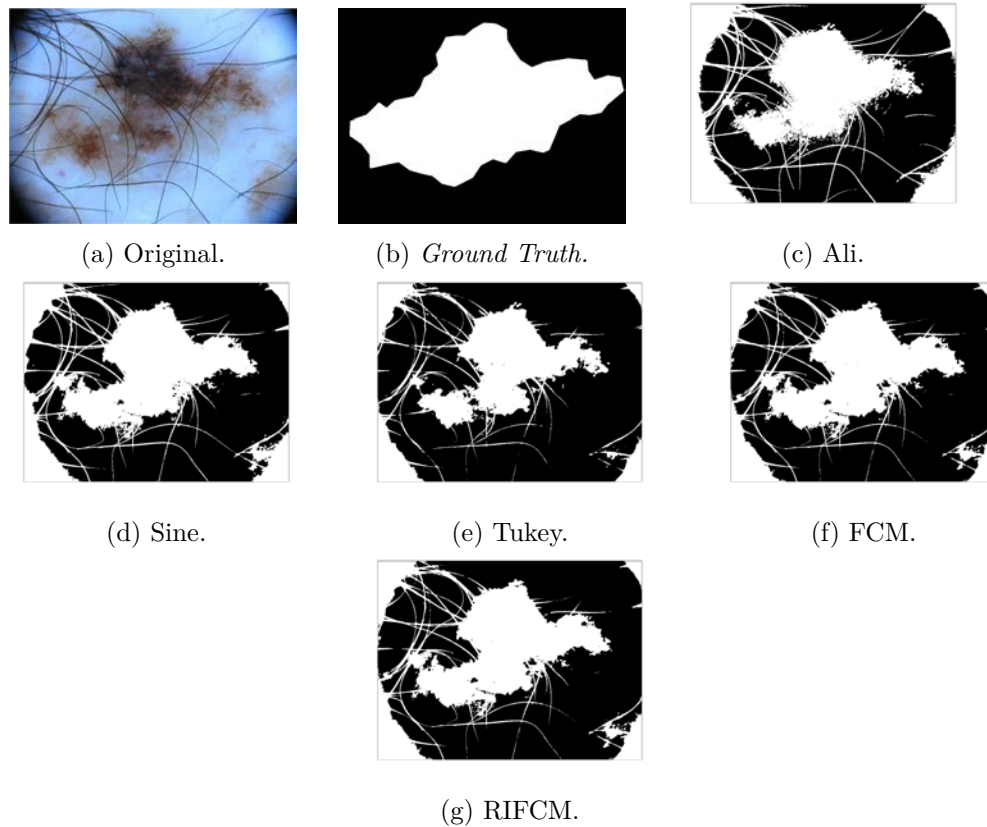


Figura 5.16: Segmentación con diferentes estimadores con presencia de vello abundante.




Figura 5.17: Segmentación con diferentes estimadores con presencia de dos artefactos diferentes, vello y electródo.

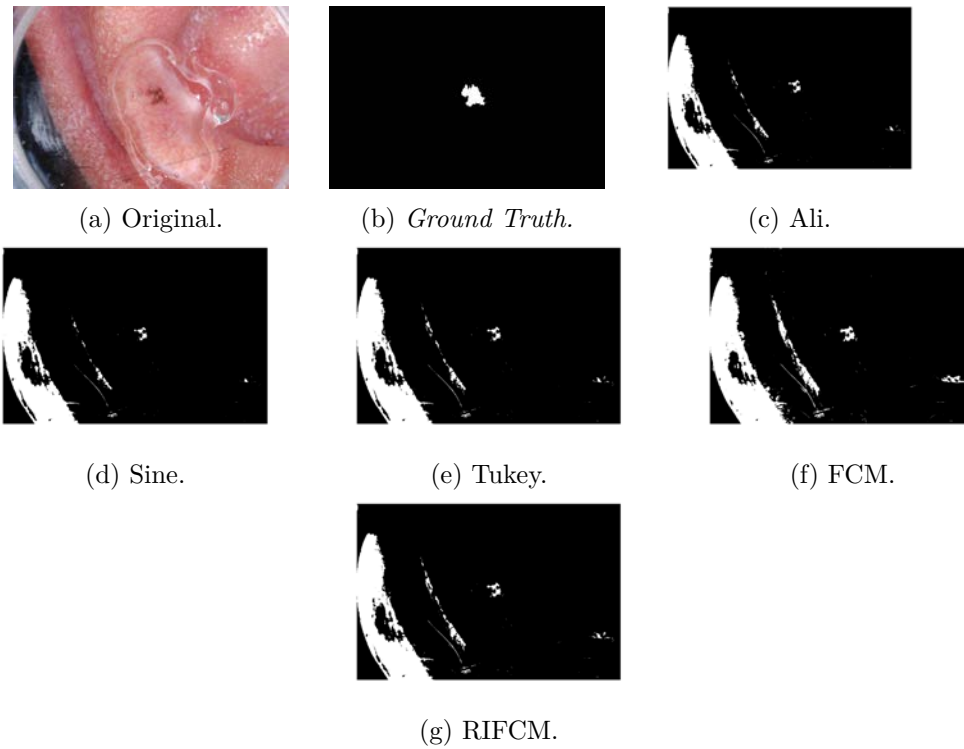


Figura 5.18: Segmentación con diferentes estimadores en lesión con diferentes bordes y texturas.

Tabla 5.9: Promedio de iteraciones y tiempo de ejecución experimentos adicionales.

Algoritmo	Tiempo	Iteraciones
Ali	0.825	5
Sine	0.778	7
Tukey	0.957	5
FCM	1.022	10
RIFCM	1.013	2

Tabla 5.10: Métricas obtenidas de la experimentación con datos atípicos.

Estimador	PREC	ACC	SENS	SPEC	F1	MSE	SSIM	PSNR	MCC	DICE	JACCARD
Ali	0.23	0.135	0.82	0.81	0.27	0.34	0.35	2.47	0.17	0.26	0.15
Sine	0.48	0.56	0.17	0.82	0.24	0.37	3.56	0.35	0.50	0.24	0.13
Tukey	1.00	0.54	0.16	0.83	0.23	0.45	0.46	3.28	0.27	0.23	0.13
FCM	0.37	0.54	0.16	0.79	0.23	0.45	0.46	3.46	0.27	0.23	0.13
RIFCM	0.96	0.95	0.98	0.90	0.97	0.068	0.99	50.25	0.87	0.97	0.99

Como se observa en las imágenes, el resultado de la segmentación con los estimadores mencionados, aun toma la información atípica como parte de la lesión, distando de lo esperado (*ground truth*), por ello se realizará un análisis de cómo se pueden ajustar los parámetros para que sólo sea visible la lesión segmentada. En cuanto a términos de calidad de agrupamiento, el algoritmo propuesto sigue mostrando mejor desempeño respecto a los estimadores presentados en este reporte. Tablas 5.9 y 5.10.

Para mejorar la segmentación en este tipo imágenes se tiene que realizar un ajuste de los parámetros de los estimadores implementados dentro del programa, lo mismo sucede si se desea incrementar el número de regiones a segmentar. Esta experimentación fue para reforzar el desempeño del algoritmo propuesto, explorar sus debilidades y cómo puede ser usado para trabajos futuros. Derivado de lo observado, se concluye que la presencia de información atípica interfiere con el desempeño del algoritmo, es por ello que, como trabajo futuro se propone realizar la sintonización necesaria para que, sin importar el tipo de información atípica ni de imagen, la segmentación sea igual o mejor que la segmentación propuesta (*ground truth*). Logrando así un método de segmentación y agrupamiento global.

5.4. Discusión de los resultados

Anteriormente se hizo mención de cómo robustecer un algoritmo de agrupamiento difuso intuitivo mediante el uso de estimadores robustos. Derivado de la investigación y experimentación realizada, se llegó a la formulación de un algoritmo robusto intuitivo difuso intuitivo RIFCM, que ha sido implementado en tareas de reconocimiento de patrones y segmentación de imágenes dermatoscópicas. Los resultados mostraron que, la propuesta minimizó el error de agrupamiento a 0.06 en bases de datos sintéticas, con una precisión del 95%. En la segmentación de imágenes es preciso en un 92% y en casos más complejos se mantiene la precisión al no ser afectado por los artefactos presentes en la imagen. Además de estos resultados, este algoritmo se diferencia de otras investigaciones en que, al usar estimación robusta, se reformula directamente la función objetivo y puede derivarse; a diferencia del uso de una heurística ya que ésta no puede replicarse. Con la nueva experimentación se demuestra que es necesario realizar una sintonización de los parámetros para mejorar los resultados, ya que como se puede observar, el algoritmo ha mostrado mejor rendimiento con algunos casos en específico. Por lo tanto el algoritmo propuesto funciona mejor con imágenes de melanomas con presencia de tinta usando el estimador *Hampel*, pues la segmentación no se ve afectada por la presencia de información atípica, el número de iteraciones es menor y la calidad no se ve afectada en comparativa con otros algoritmos.

Capítulo 6

Conclusiones

Después de la investigación realizada y comprobada a lo largo del documento, en este capítulo se presentan las conclusiones derivadas de los resultados obtenidos a través de la experimentación con el método propuesto, así como la producción y aportes que se realizaron durante la elaboración de esta investigación doctoral.

6.1. Productos de la investigación

Durante la realización de este tema de investigación doctoral se desarrollaron las siguientes aportaciones:

1. Reporte del estado del arte: Durante los primeros semestres, se realizó una investigación sobre los temas fundamentales que servirían de base para dar solución al problema planteado. Se presentó un resumen de diferentes artículos publicados en revistas indizadas, los cuales se dividieron en: Algoritmos de agrupamiento, en específico de agrupamiento difuso, como *Fuzzy C-Means*; y uso de conjuntos difusos intuitivos y sus aplicaciones, *Intuitionistic Fuzzy C-Means*
2. Formulación e implementación de un algoritmo robusto intuitivo para tareas de reconocimiento de patrones.
3. Formulación e implementación de un algoritmo robusto intuitivo para tareas de segmentación de imágenes dermatoscópicas.
4. Artículo de congreso para el Congreso Mexicano de Inteligencia Artificial COMIA 2020, titulado *Análisis Comparativo de la Calidad de Agrupamiento del Algoritmo Intuitionistic Fuzzy C-Means*.
5. Artículo aceptado en la revista DYNA incluida en *Science Citation Index Expanded* y con factor de impacto 1.0 en JCR, titulado *Agrupamiento Intuitivo Robusto para Segmentación de Lesiones en Imágenes Dermatoscópicas*.

6.2. Aportaciones de la investigación

Derivado de la investigación doctoral, se realizaron las siguientes aportaciones:

1. Formulación matemática de un algoritmo robusto intuitivo, que une el agrupamiento con un estimador robusto.
2. Algoritmo de agrupamiento robusto intuitivo para tareas de reconocimiento de patrones.
3. Algoritmo de agrupamiento robusto intuitivo para segmentación de imágenes dermatoscópicas.

6.3. Conclusiones

En este trabajo se propuso la formulación del algoritmo RIFCM partiendo del agrupamiento intuitivo difuso. A diferencia de otras propuestas heurísticas, este algoritmo se formula a partir de la derivación de la función objetivo del IFCM, dando una solución adaptable a cualquier dominio. Se robustece al integrar una función de pérdida e influencia a las actualizaciones de pertenencia, permitiendo ponderar los datos mediante un estimador M-Redescendente y así minimizar la influencia de los datos atípicos. Por la naturaleza de los datos que fueron utilizados para esta investigación, es decir, información atípica no se requirió del uso de aprendizaje máquina, ya que el algoritmo se desarrolló para que sea capaz de segmentar sin utilizar etapas de pre-procesamiento. La propuesta fue evaluada en la tarea de agrupamiento de datos y delimitación de lesiones en imágenes dermatoscópicas, presentando las siguientes ventajas:

- Permite ser robusto ante datos atípicos, minimizando el error de agrupamiento a 0.06.
- Genera un agrupamiento con precisión hasta del 95 %.
- En casos sencillos de imágenes dermatoscópicas, es preciso en un 92 % y en casos más complejos se mantiene la precisión al no ser afectado por los artefactos presentes en la imagen.
- Reduce el número de iteraciones hasta 1.

6.4. Objetivos y alcances logrados

De acuerdo a los objetivos y alcances planteados al inicio de esta investigación, en la Tabla 6.1 se describen las actividades realizadas para poder llevarlos a cabo.

6.4.1. Objetivos alcanzados

- Proponer un estimador robusto que sea implementado dentro de un algoritmo difuso intuitivo.
- Formular una versión robusta de un algoritmo difuso intuitivo.
- Evaluar el desempeño del algoritmo propuesto en bases de datos e imágenes dermatoscópicas con información atípica.
- Validar los resultados utilizando métricas de la literatura en el dominio del reconocimiento de patrones y la segmentación de imágenes.
- Comparar los resultados con antecedentes de la literatura.

Tabla 6.1: Objetivos alcanzados.

Objetivo	Actividad
Proponer un estimador robusto que sea implementado dentro de un algoritmo difuso intuitivo.	Se estudiaron tres estimadores robustos, se realizaron pruebas para evaluar su comportamiento al ser implementados dentro del algoritmo IFCM.
Formular una versión robusta de un algoritmo difuso intuitivo.	A través de formulación matemática, se desarrolló una implementación de estimación robusta en la función objetivo del algoritmo IFCM, logrando así un nuevo algoritmo de agrupamiento difuso intuitivo robusto.
Evaluar el desempeño del algoritmo propuesto en bases de datos e imágenes dermatoscópicas con información atípica.	El nuevo algoritmo robusto se diseñó para ser tolerante a la información atípica, por lo tanto, se llevó a cabo la experimentación en tareas de reconocimiento de patrones y segmentación de imágenes con datos atípicos.
Validar los resultados utilizando métricas de la literatura en el dominio del reconocimiento de patrones y la segmentación de imágenes.	Los resultados obtenidos de la experimentación fueron validados con métricas propias para evaluar la calidad de agrupamiento y de segmentación.
Comparar los resultados obtenidos con antecedentes de la literatura.	Una vez que los resultados fueron satisfactorios en términos de calidad de agrupamiento y segmentación, así como la disminución de iteraciones. El nuevo algoritmo fue comparado con otros métodos clásicos, como K-means, Fuzzy C-means, K-medoids, etc. Para comprobar su eficiencia y demostrar un nuevo enfoque en la literatura.

6.4.2. Alcances realizados

En esta sección se muestran los alcances obtenidos durante la investigación y en la Tabla 6.2 son explicados detalladamente.

- Robustecer un algoritmo de agrupamiento difuso intuitivo.
- Establecer las bases para que la propuesta se pueda extender a otras metodologías basadas en agrupamiento difuso.
- Proponer un algoritmo robusto intuitivo aplicable a tareas de reconocimiento de patrones.
- Proponer un esquema basado en agrupamiento difuso con aprendizaje aplicable a tareas de segmentación de imágenes dermatoscópicas.
- Posicionarse en el estado del arte, como un referente importante en el proceso de robustecer a los algoritmos de agrupamiento difuso.

Tabla 6.2: Alcances realizados.

Alcance	Actividad
Robustecer a un algoritmo de agrupamiento difuso intuitivo.	Con el uso de estimadores dentro de la función objetivo del algoritmo IFCM se desarrolló una versión robusta de este último.
Establecer la bases para que la propuesta se pueda extender a otras metodologías basadas en agrupamiento difuso.	Con un ajuste de parámetros y continuando con la experimentación usando más estimadores, esta metodología puede aplicarse a otro algoritmos de agrupamiento.
Proponer un algoritmo intuitivo robusto aplicable a tareas de reconocimiento de patrones.	El algoritmo se desarrolló para ser evaluado en reconocimiento de patrones, realizando experimentaciones con bases de datos sintéticas que contienen información atípica y a su vez ser evaluado con métricas para medir la calidad de agrupamiento.
Proponer un esquema basado en agrupamiento difuso con aprendizaje aplicable a tareas de segmentación de imágenes dermatoscópicas.	La nueva metodología fue desarrollada de tal manera que no es necesario ingresar más que la imagen de entrada que se desea segmentar, la cual contiene datos atípicos. El algoritmo realiza las tareas necesarias de tal manera que no se requiera información extra.
Posicionarse en el estado del arte como un referente importante en el proceso de robustecer a los algoritmos de agrupamiento difuso.	Con los estudios realizados desde el inicio de esta investigación se logró la publicación de un artículo donde se hace una comparación entre los algoritmos de agrupamiento clásicos y el IFCM. Posteriormente una vez listo el nuevo algoritmo, se sometió un artículo a una revista indexada donde se demuestra el aporte, siendo aceptado para su publicación.

6.5. Trabajos Futuros

- Sintonización de los parámetros con otro tipo de algoritmos presentes en la literatura para extender el método propuesto.
- Utilizar el algoritmo robustecido en otro tipo de imágenes, con algún tipo de ruido. Por ejemplo, radiografías o tomografías.
- Implementar un estimador robusto en otro tipo de algoritmos.
- Mejorar los resultados usando el mismo tipo de imágenes pero con otro tipo de información atípica.
- Replicar el algoritmo con otros estimadores para evaluar su desempeño.

Referencias

- [1] Peláez, J. I., Prometeo, P., Ecuador, G., Martínez, E. A., Vaccaro, G., y Yanez, A., “Un modelo de detección automática de bordes en imágenes dermatoscópicas,” en CISCI 2016-Decima Quinta Conferencia Iberoamericana en Sistemas, Cibernética e Informática, Decimo Tercer Simposium Iberoamericano en Educacion, Cibernética e Informática, SIECI 2016-Memorias, 2016.
- [2] Silveira, M., Nascimento, J. C., Marques, J. S., Marçal, A. R., Mendonça, T., Yamauchi, S., Maeda, J., y Rozeira, J., “Comparison of segmentation methods for melanoma diagnosis in dermoscopy images,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 3, no. 1, pp. 35–45, 2009.
- [3] Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., y Terzopoulos, D., “Image segmentation using deep learning: A survey,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 44, no. 7, pp. 3523–3542, 2021.
- [4] Dhanachandra, N. y Chanu, Y. J., “An image segmentation approach based on fuzzy c-means and dynamic particle swarm optimization algorithm,” *Multimedia tools and applications*, vol. 79, no. 25-26, pp. 18839–18858, 2020.
- [5] Golalipour, K., Akbari, E., Hamidi, S. S., Lee, M., y Enayatifar, R., “From clustering to clustering ensemble selection: A review,” *Engineering Applications of Artificial Intelligence*, vol. 104, p. 104388, 2021.
- [6] Ghosal, A., Nandy, A., Das, A. K., Goswami, S., y Panday, M., “A short review on different clustering techniques and their applications,” *Emerging Technology in Modelling and Graphics: Proceedings of IEM Graph 2018*, pp. 69–83, 2020.
- [7] Mújica-Vargas, D., *Segmentación de Imágenes Utilizando Algoritmos Robustos de Agrupamiento Difuso*. PhD thesis, Escuela Superior de Ingeniería Mecánica y Eléctrica, Instituto Politécnico Nacional, 2013.
- [8] Bezdek, J. C., Keller, J., Krisnapuram, R., y Pal, N., *Fuzzy models and algorithms for pattern recognition and image processing*, vol. 4. Springer Science & Business Media, 1999.
- [9] Zadeh, L. A., “Fuzzy sets,” *Information and control*, vol. 8, no. 3, pp. 338–353, 1965.
- [10] Morales Luna, G., “Introducción a la lógica difusa,” *Centro de Investigación y Estudios Avanzados*. México, 2002.
- [11] Dunn, J. C., “A fuzzy relative of the isodata process and its use in detecting compact

- well-separated clusters,” *Journal of Cybernetics*, 1973.
- [12] Bezdek, J. C., “Cluster validity with fuzzy sets,” *Journal and cybernetics*, vol. 3, pp. 58–73, 1973.
- [13] Xu, Z., *Intuitionistic fuzzy aggregation and clustering*, vol. 279. Springer, 2013.
- [14] Chaira, T., *Fuzzy set and its extension: The intuitionistic fuzzy set*. John Wiley & Sons, 2019.
- [15] Atanassov, K. T., “Intuitionistic fuzzy sets,” en *Intuitionistic fuzzy sets*, pp. 1–137, Springer, 1999.
- [16] Szmidt, E. y Kacprzyk, J., “Distances between intuitionistic fuzzy sets,” *Fuzzy sets and systems*, vol. 114, no. 3, pp. 505–518, 2000.
- [17] Pitas, I. y Venetsanopoulos, A. N., *Nonlinear digital filters: principles and applications*, vol. 84. Springer Science & Business Media, 2013.
- [18] Huber, P. J. y Ronchetti, E. M., “Robust statistics john wiley & sons,” New York, vol. 1, no. 1, 1981.
- [19] Gallegos, F., Ponomaryov, V., Pogrebnyak, O., y Niño de Rivera, L., “Filtros robustos rm-knn con diferentes funciones de influencia para supresión de ruido impulsivo en imágenes digitales,” *Computación y Sistemas*, vol. 6, no. 3, pp. 183–195, 2003.
- [20] Gallegos-Funes, F. J. y Rosales-Silva, A. J., “Rank m-type filters for image denoising,” *Image Processing*, 2009.
- [21] Astola, J. y Kuosmanen, P., *Fundamentals of nonlinear digital filtering*. CRC press, 2020.
- [22] Mújica-Vargas, D., Kinani, J. M. V., y Rubio, J. d. J., “Color-based image segmentation by means of a robust intuitionistic fuzzy c-means algorithm,” *International Journal of Fuzzy Systems*, vol. 22, no. 3, pp. 901–916, 2020.
- [23] Kumar, D., Verma, H., Mehra, A., y Agrawal, R., “A modified intuitionistic fuzzy c-means clustering approach to segment human brain mri image,” *Multimedia Tools and Applications*, vol. 78, no. 10, pp. 12663–12687, 2019.
- [24] Souza, P. V. C., “Regularized fuzzy neural networks for pattern classification problems,” *International Journal of Applied Engineering Research*, vol. 13, no. 5, pp. 2985–2991, 2018.
- [25] Roh, S.-B., Oh, S.-K., Pedrycz, W., Seo, K., y Fu, Z., “Design methodology for radial basis function neural networks classifier based on locally linear reconstruction and conditional fuzzy c-means clustering,” *International Journal of Approximate Reasoning*, vol. 106, pp. 228–243, 2019.
- [26] Mújica-Vargas, D., Carvajal-Gómez, B., Ochoa, G., y Rubio, J., “Robust gaussian-base radial kernel fuzzy clustering algorithm for image segmentation,” *Electronics Letters*, vol. 55, no. 15, pp. 835–837, 2019.
- [27] Lei, X. y Ouyang, H., “Image segmentation algorithm based on improved fuzzy

- clustering,” *Cluster Computing*, vol. 22, no. 6, pp. 13911–13921, 2019.
- [28] Arora, J. y Tushir, M., “An enhanced spatial intuitionistic fuzzy c-means clustering for image segmentation,” *Procedia Computer Science*, vol. 167, pp. 646–655, 2020.
- [29] Bhatia, V. y Rani, R., “Dfuzzy: a deep learning-based fuzzy clustering model for large graphs,” *Knowledge and Information Systems*, vol. 57, no. 1, pp. 159–181, 2018.
- [30] Dubey, A. K., Gupta, U., y Jain, S., “Comparative study of k-means and fuzzy c-means algorithms on the breast cancer data,” *International Journal on Advanced Science, Engineering and Information Technology*, vol. 8, no. 1, pp. 18–29, 2018.
- [31] Zhang, J., Williams, S. O., y Wang, H., “Intelligent computing system based on pattern recognition and data mining algorithms,” *Sustainable Computing: Informatics and Systems*, vol. 20, pp. 192–202, 2018.
- [32] Joseph, S. I. T. y Thanakumar, I., “Survey of data mining algorithm’s for intelligent computing system,” *Journal of trends in Computer Science and Smart technology (TCSST)*, vol. 1, no. 01, pp. 14–24, 2019.
- [33] Jia, X., Lei, T., Du, X., Liu, S., Meng, H., y Nandi, A. K., “Robust self-sparse fuzzy clustering for image segmentation,” *IEEE Access*, vol. 8, pp. 146182–146195, 2020.
- [34] Yan, H., Wang, L., y Lu, Y., “Identifying cluster centroids from decision graph automatically using a statistical outlier detection method,” *Neurocomputing*, vol. 329, pp. 348–358, 2019.
- [35] Wang, C., Pedrycz, W., Li, Z., y Zhou, M., “Residual-driven fuzzy c-means clustering for image segmentation,” *IEEE/CAA Journal of Automatica Sinica*, vol. 8, no. 4, pp. 876–889, 2020.
- [36] PRIYADHARSHINI, P., THILLAIKKARASI, R., y SARAVANAN, S., “Image segmentation using classification of radial basis function of neural network in brain tumor detection,” *IMAGE*, vol. 6, no. 05, 2019.
- [37] Nerurkar, P., Shirke, A., Chandane, M., y Bhirud, S., “Empirical analysis of data clustering algorithms,” *Procedia Computer Science*, vol. 125, pp. 770–779, 2018.
- [38] Chinta, S. S., Jain, A., y Tripathy, B., “Image segmentation using hybridized firefly algorithm and intuitionistic fuzzy c-means,” en *Proceedings of First International Conference on Smart System, Innovations and Computing*, pp. 651–659, Springer, 2018.
- [39] Rodriguez, M. Z., Comin, C. H., Casanova, D., Bruno, O. M., Amancio, D. R., Costa, L. d. F., y Rodrigues, F. A., “Clustering algorithms: A comparative approach,” *PloS one*, vol. 14, no. 1, 2019.
- [40] Dagher, I., “Fuzzy clustering using multiple gaussian kernels with optimized-parameters,” *Fuzzy Optimization and Decision Making*, vol. 17, no. 2, pp. 159–176, 2018.
- [41] Domínguez-López, D., “Extracción de superpíxeles y su fusión mediante un algoritmo de agrupamiento difuso intuitivo aplicable a imágenes de resonancia magnética,” Master’s thesis, Tecnológico Nacional de México. CENIDET, 2019.

- [42] Vela-Rincón, V. V., Agrupamiento difuso titubeante para tareas de segmentación de imágenes y reconocimiento de patrones . PhD thesis, Tecnológico Nacional de México. CENIDET, 2022.
- [43] Andrews, D. F. y Hampel, F. R., “Robust estimates of location,” en *Robust Estimates of Location*, Princeton University Press, 2015.
- [44] Andrews, D. F., “A robust method for multiple linear regression,” *Technometrics*, vol. 16, no. 4, pp. 523–531, 1974.
- [45] Hadi, A., Huang, X., Ali, B., y Li, Y., “Sparse andrew’s sine norm promoting adaptive algorithm under non-gaussian noises,” en *2022 IEEE 5th International Conference on Electronic Information and Communication Technology (ICEICT)*, pp. 131–133, IEEE, 2022.
- [46] Beaton, A. E. y Tukey, J. W., “The fitting of power series, meaning polynomials, illustrated on band-spectroscopic data,” *Technometrics*, vol. 16, no. 2, pp. 147–185, 1974.
- [47] Chen, D., “Tukey’s biweight estimation for uncertain regression model with imprecise observations,” *Soft Computing*, vol. 24, no. 22, pp. 16803–16809, 2020.
- [48] Khan, D. M., Ali, M., Ahmad, Z., Manzoor, S., y Hussain, S., “A new efficient redescending m-estimator for robust fitting of linear regression models in the presence of outliers,” *Mathematical Problems in Engineering*, vol. 2021, 2021.
- [49] Huber, P. J. y Ronchetti, E. M., “The basic types of estimates,” *Robust Statistics*, pp. 43–72, 1981.
- [50] Tataridou, A., Ghibaudo, G., y Theodorou, C., “Verilor: A verilog-a model of lorentzian spectra for simulating trap-related noise in cmos circuits,” en *ESSDERC 2021-IEEE 51st European Solid-State Device Research Conference (ESSDERC)*, pp. 247–250, IEEE, 2021.
- [51] Bezdek, J. C., “Numerical taxonomy with fuzzy sets,” *Journal of mathematical biology*, vol. 1, no. 1, pp. 57–71, 1974.
- [52] Liu, Y., Zhang, X., Chen, J., y Chao, H., “A validity index for fuzzy clustering based on bipartite modularity,” *Journal of Electrical and Computer Engineering*, vol. 2019, 2019.
- [53] Xie, X. L. y Beni, G., “A validity measure for fuzzy clustering,” *IEEE Transactions on pattern analysis and machine intelligence*, vol. 13, no. 8, pp. 841–847, 1991.
- [54] Sitepu, K. A. B., Sitompul, O. S., y Situmorang, Z., “Analysis of fuzzy c-means and analytical hierarchy process (ahp) models using xie-beni index,” en *2019 International Conference of Computer Science and Information Technology (ICoSNIKOM)*, pp. 1–6, IEEE, 2019.
- [55] Gopika, S. y Vanitha, M., “machine learning approach of chronic kidney disease prediction using clustering,” *Machine learning*, vol. 6, no. 7, 2017.
- [56] Palacios-Martínez, D. y Díaz-Alonso, R., “Dermatoscopia para principiantes (i):

- características generales,” SEMERGEN-Medicina de Familia, vol. 43, no. 3, pp. 216–221, 2017.
- [57] Rotemberg, V., Kurtansky, N., Betz-Stablein, B., Caffery, L., Chousakos, E., Codella, N., Combalia, M., Dusza, S., Guitera, P., Gutman, D., *et al.*, “A patient-centric dataset of images and metadata for identifying melanomas using clinical context,” Scientific data, vol. 8, no. 1, pp. 1–8, 2021.
- [58] Boughorbel, S., Jarray, F., y El-Anbari, M., “Optimal classifier for imbalanced data using matthews correlation coefficient metric,” PloS one, vol. 12, no. 6, p. e0177678, 2017.
- [59] Carass, A., Roy, S., Gherman, A., Reinhold, J. C., Jesson, A., Arbel, T., Maier, O., Handels, H., Ghafoorian, M., Platel, B., *et al.*, “Evaluating white matter lesion segmentations with refined sørensen-dice analysis,” Scientific reports, vol. 10, no. 1, pp. 1–19, 2020.
- [60] Hore, A. y Ziou, D., “Image quality metrics: Psnr vs. ssim,” en 2010 20th International Conference on Pattern Recognition, pp. 2366–2369, IEEE, 2010.
- [61] Casti, P., Mencattini, A., Salmeri, M., y Rangayyan, R. M., “Analysis of structural similarity in mammograms for detection of bilateral asymmetry,” IEEE transactions on medical imaging, vol. 34, no. 2, pp. 662–671, 2014.

Análisis comparativo de la calidad de agrupamiento del algoritmo Intuitionistic Fuzzy C-Means

Celia Ramos-Palencia, Dante Mújica-Vargas, Manuel Mejía-Lavalle

Tecnológico Nacional de México,
CENIDET,
México

{celia.ramos17ce, dante.mv}@cenidet.tecnm.mx

Resumen. En este artículo se presenta un estudio comparativo de la calidad del agrupamiento obtenido por el algoritmo Intuitionistic Fuzzy C-Means respecto a los algoritmos Fuzzy C-Means, Gath-Geva, Gustafson Kesel, K-Means y K-Medoid. La evaluación se hace en tareas de reconocimiento de patrones, utilizando las métricas: Xie-Beni, de Dunn, de Partición, Coeficiente de Partición, Entropía de Clasificación, de Separación y alternativo de Dunn. Los resultados indican que el algoritmo Intuitionistic Fuzzy C-Means es más eficiente en la calidad de agrupamiento y convergencia en comparación con los otros algoritmos utilizados para este trabajo.

Palabras clave: Agrupamiento, Intuitionistic Fuzzy C-means, algoritmos clásicos de agrupamiento, calidad de agrupamiento.

Comparative Analysis of the Clustering Quality of the Intuitionistic Fuzzy C-Means Algorithm

Abstract. In this paper we proposed a comparative study of the clustering quality obtained by the Intuitionistic Fuzzy C-Means algorithm about the Fuzzy C-Means, Gath-Geva, Gustafson Kesel, K-Means and K-Medoid algorithms. The evaluation is done in pattern recognition tasks, using the metrics: Xie-Beni, Dunn's, Index, Partition Coefficient, Classification Entropy, Index Separation, and Dunn's Alternative Index. The experimental results show that the Intuitionistic Fuzzy C-Means algorithm is more efficient in the quality of clustering and convergence compared to the other algorithms used in this work.

Keywords: Clustering, Intuitionistic Fuzzy C-means, classic clustering algorithms, clustering quality.



UNIVERSIDAD AUTÓNOMA
DE CIUDAD JUÁREZ

LA SOCIEDAD MEXICANA DE INTELIGENCIA ARTIFICIAL
Y LA UNIVERSIDAD AUTÓNOMA DE CIUDAD JUÁREZ



OTORGAN ESTE CERTIFICADO A:

Celia Ramos-Palencia y Dante Mújica-Vargas

POR LA PRESENTACIÓN DEL ARTÍCULO TITULADO:

Análisis Comparativo de la Calidad de Agrupamiento del Algoritmo Intuitionistic Fuzzy C-Means

en el XII Congreso Mexicano de Inteligencia Artificial - COMIA 2020

Cd. Juárez, Chihuahua, México, del 5 al 7 de agosto de 2020


Dr. Félix Castro Espinoza
Presidente SMIA

Dr. Oscar Herrera Aleántara
Presidente Comité de Programa

Dr. Noé A. Castro Sánchez
Presidente Comité de Programa

Dr. Manuel de J. Nandayapa Alfaro
Comité Local COMIA

Agrupamiento intuitivo robusto para segmentación de lesiones en imágenes dermatoscópicas



Intuitionistic robust clustering for segmentation of lesions in dermoscopic images



Celia Ramos-Palencia¹, Dante Mújica-Vargas¹, Jean Marie Vianney-Kinani², Antonio Luna-Álvarez¹, Noé-Alejandro Castro-Sánchez¹

¹ CENIDET. TecNM. Dpto. de Ciencias Computacionales. Interior Internado Palmira S/N, Col. Palmira - 62490 Cuernavaca, Morelos (México).

² IPN. Unidad Profesional Interdisciplinaria de Ingeniería Campus Hidalgo. Carretera Pachuca - Actopan Kilómetro 1+500 - 42162 Pachuca, Hidalgo (México).

DOI: <https://doi.org/10.6036/10787> | Recibido: 13/dic/2022 • Inicio Evaluación: 15/dic/2022 • Aceptado: 29/mar/2023

To cite this article: RAMOS-PALENCIA, Celia; MÚJICA-VARGAS, Dante; VIANNEY-KINANI, Jean-Marie; LUNA-ÁLVAREZ, Antonio; CASTRO-SÁNCHEZ, Noé-Alejandro. INTUITIONISTIC ROBUST CLUSTERING FOR SEGMENTATION OF LESIONS IN DERMATOSCOPIC IMAGES. DYNA. January-December 2024. vol. 99, n.1, pp. xx | DOI: <https://doi.org/10.6036/10787>

FINANCIACIÓN

Los autores agradecen al CONACYT, así como al Tecnológico Nacional de México/CENIDET por su apoyo brindado para la elaboración de esta investigación.

ABSTRACT

- This paper presents the formulation of the intuitive fuzzy clustering algorithm to be robust to atypical data present in dermoscopic images and to delimit the affected area. This algorithm is formulated from the objective function derivation for memberships update, to integrate an m-redescending estimator influence function. Experimentation shows an accuracy of 95% with the proposal algorithm with respect to other clustering algorithms to perform delimitations, in addition the iterations number is considerably reduced.
- Keywords:** Robust Intuitionistic Fuzzy Clustering, Dermoscopic Images, Delimitations of Lesions, M-redescending Estimator.

RESUMEN

En este artículo se presenta la formulación del algoritmo de agrupamiento difuso intuitivo para ser robusto ante datos atípicos presentes en imágenes dermatoscópicas y realizar la delimitación de la zona afectada. Este algoritmo es formulado a partir de la derivación de la función objetivo para la actualización de pertenencias, para integrar una función de influencia de un estimador m-redescendente. La experimentación demuestra una precisión del 95% con el uso del algoritmo propuesto con respecto a otros algoritmos de agrupamiento para realizar delimitaciones, además se reduce considerablemente el número de iteraciones.

Palabras Clave: Agrupamiento Difuso Intuitivo Robusto, Imágenes Dermatoscópicas, Delimitación de Lesiones, Estimador M-Redescendente.

1. INTRODUCCIÓN

La dermatoscopia es una técnica de diagnóstico no invasiva para estudiar las lesiones cutáneas, generalmente se realiza a partir de la captura de imágenes digitales [1]. Utilizando el equipo especializado denominado dermatoscopio, las imágenes capturadas a color permiten al médico ver estructuras por debajo de la super-

ficie de la piel, las lesiones se evalúan en función de su pigmentación, colores y estructuras [2]. Estas características pueden ayudar en el diagnóstico de posibles melanomas, lunares benignos, Carcinoma de células basales pigmentado, hemangioma, entre otras, sin embargo, una mala delimitación de la lesión puede llevar al médico a dar un mal diagnóstico, por ejemplo, confundiendo ciertas pigmentaciones con lesiones por quemaduras o por su forma, por melanomas. Por lo general este tipo de errores ocurren cuando hay una mala adquisición de la imagen, sin embargo, por el tipo de adquisición, a diferencia de otro tipo de imágenes médicas esta presenta mínimas afectaciones de ruido [3], por lo que es posible utilizar diversos métodos para la delimitación de la lesión.

Para esta aplicación se han utilizado métodos basados en umbralización [4, 5], métodos probabilísticos [6, 7], métodos basados en filtrados locales [8], algoritmos de agrupamiento [9], clasificadores [10, 11] y modelos de aprendizaje profundo [12, 13]. Aunque los métodos antes mencionados han demostrado buenos resultados, existen factores que pueden afectar el rendimiento de los algoritmos, por ejemplo: la variedad de formas de lesiones, tamaño, coloración, tipo de piel y textura, lesiones con bordes irregulares y la suave transición entre la piel y la lesión [14]. Por lo tanto, los métodos de umbralización son débiles ante las transiciones y coloración, los métodos de filtrado se ven afectados por bordes irregulares. Por otro lado, es sabido que los modelos de aprendizaje profundo requieren de una gran cantidad de datos para garantizar la generalización, por lo que la amplia variación de las formas de las lesiones demanda una mayor cantidad y calidad de datos. Basado en lo anterior, los métodos probabilísticos y de agrupamiento se muestran como los más aptos para esta aplicación. Aunque este tipo de imagen no es afectada por ruido, las afecciones antes mencionadas pueden considerarse como información atípica, por lo que un algoritmo de agrupamiento local o global puede ser afectado en su rendimiento [15]. A partir de esta debilidad de los algoritmos de agrupamiento, en esta investigación se propone la reformulación del algoritmo de Agrupamiento Difuso Intuitivo IFCM [16], incorporando la influencia de un estimador M-Redescendente sobre las funciones objetivo y de actualización del algoritmo. El algoritmo propuesto *Redescending Intuitionistic Fuzzy C-Means* RIFCM permite realizar la delimitación de las lesiones sin necesidad de preprocesar las imágenes para atenuar las afectaciones y posibles obstrucciones identificados como información atípica.