



Procesamiento de imágenes médicas mediante conjuntos neutrosóficos.

Medical image processing using neutrophilic ensembles.

Autor

¹Msc. Yismandry Gonzalez Vargas. ²Lic. Diana Padrón Carrasco.

¹Universidad de Holguín, Cuba. yismandrygonzalezvargas@gmail.com

²Universidad Ciego de Avila, Cuba. padroncarrascodiana@gmail.com

Resumen

El procesamiento de imágenes médicas constituye un área crítica para el diagnóstico, donde la incertidumbre y la ambigüedad inherentes a los datos biomédicos limitan la efectividad de los métodos convencionales. En este contexto, la teoría neutrosófica ha emergido como un marco matemático robusto para el manejo explícito de información imprecisa. Este artículo de revisión presenta un análisis del estado del arte en procesamiento de imágenes médicas mediante conjuntos neutrosóficos, abarcando sus fundamentos teóricos, las principales técnicas de preprocesamiento, segmentación y extracción de características, y su integración con modelos de inteligencia artificial y aprendizaje profundo. Asimismo, se examinan comparativamente sus ventajas frente a los métodos clásicos basados en lógica difusa, así como sus limitaciones actuales relacionadas con la escalabilidad, la automatización y la integración en flujos clínicos digitales. Finalmente, se discuten los retos y oportunidades futuras, destacando el potencial de la neutrosofía híbrida y explicable como herramienta clave para el desarrollo de sistemas médicos más precisos, interpretables y confiables en la medicina de precisión contemporánea.

Palabras clave: Neutrosofía; Procesamiento De Imágenes Médicas; Segmentación; Aprendizaje Profundo; Incertidumbre; Teoría Neutrosófica.

Abstract

Medical image processing is a cornerstone of computer-aided diagnosis, where the inherent uncertainty and ambiguity of biomedical data often limit the performance of conventional analytical methods. Within this context, neutrosophic theory has emerged as a robust mathematical framework for handling imprecise and inconsistent information. This review article provides a comprehensive overview of the state of the art in medical image processing using neutrosophic sets, covering its theoretical foundations, key techniques for preprocessing, segmentation, and feature extraction, and its integration with artificial intelligence and deep learning models. The advantages of these approaches over classical fuzzy and probabilistic methods are analyzed, together with current limitations regarding scalability, parameter optimization, and clinical workflow integration. Finally, the paper outlines future research directions, emphasizing the potential of hybrid and explainable neutrosophic models to enhance the accuracy, interpretability, and reliability of next-generation precision medicine systems.

Keywords: Neutrosophic; Medical Image Processing; Segmentation; Deep Learning; Uncertainty; Neutrosophic Theory

1. Introducción

El procesamiento de imágenes médicas constituye una herramienta esencial en el diagnóstico clínico moderno, al permitir la detección temprana de patologías, la planificación de tratamientos y el seguimiento evolutivo de pacientes. Sin embargo, las imágenes obtenidas mediante resonancia magnética, tomografía computarizada, ultrasonido o histopatología digital suelen estar afectadas por ruido, artefactos y variaciones de contraste que dificultan la interpretación automática. A pesar de los avances en inteligencia artificial y aprendizaje profundo, los modelos convencionales aún presentan limitaciones frente a la ambigüedad y la incertidumbre inherentes a los datos biomédicos, lo que ha impulsado la búsqueda de enfoques matemáticos más flexibles y explicativos [1,2].

En este contexto, la teoría neutrosófica, introducida por Florentin Smarandache, se ha consolidado como una extensión de la lógica difusa que incorpora tres dimensiones fundamentales: verdad (T), indeterminación (I) y falsedad (F). Esta formulación permite representar con mayor precisión el grado de incertidumbre presente en los píxeles o vóxeles de una imagen médica, ofreciendo una descripción más completa del contenido visual [3]. Su aplicación al procesamiento de imágenes ha dado lugar a una amplia gama de técnicas, desde la transformación neutrosófica para el preprocesamiento y la mejora de contraste, hasta la segmentación, extracción de características y clasificación basadas en representaciones (T, I, F). Además, su integración con métodos de inteligencia artificial, aprendizaje automático y redes neuronales profundas ha demostrado un potencial significativo para optimizar la precisión diagnóstica y la interpretabilidad de los modelos computacionales [4].

No obstante, la adopción de la neutrosofía en entornos clínicos enfrenta desafíos técnicos y metodológicos, entre ellos la escalabilidad a volúmenes tridimensionales, el ajuste de parámetros, y la falta de estandarización en la comparación con métodos de aprendizaje profundo entrenados de extremo a extremo. Ante este panorama, resulta fundamental sistematizar los avances recientes y analizar críticamente el papel que desempeñan los conjuntos neutrosóficos en el procesamiento de imágenes médicas. Por tanto, el objetivo de esta revisión es analizar los fundamentos teóricos, aplicaciones prácticas, avances híbridos con inteligencia artificial y desafíos futuros del procesamiento de imágenes médicas basado en la teoría neutrosófica.

2. Materiales y Métodos

Se realizó una revisión bibliográfica de artículos publicados en las principales bases de datos bibliográficas (Web of Sciences, SCOPUS, SciELO, Google Académico). Se seleccionaron un total de 25 artículos comprendidos en los últimos 20 años, relacionados con Procesamiento de imágenes médicas mediante conjuntos neutrosóficos. Para la búsqueda se utilizaron los siguientes criterios: neutrosofía, teoría neutrosófica, procesamiento de imágenes médicas, neutrosofía y procesamiento de imágenes médicas; en inglés y en español. Se tuvo en cuenta para la selección la calidad metodológica y validez de los estudios. Se excluyeron aquellos que no se encontraban entre los últimos 20 años.

Fundamentos teóricos de la neutrosofía y conjuntos neutrosóficos

La teoría neutrosófica, propuesta inicialmente por Smarandache en los años noventa y consolidada en aplicaciones de procesamiento de imágenes durante la última década, constituye una generalización de la lógica clásica y de la lógica difusa al introducir un tercer componente denominado indeterminación (I), además del grado de verdad (T) y de falsedad (F) [3]. Mientras que la lógica difusa representa la incertidumbre mediante un único grado de pertenencia que varía entre 0 y 1, la neutrosofía descompone ese valor en tres dimensiones independientes, permitiendo modelar explícitamente la parte de la información que es ambigua, contradictoria o incompleta. En el contexto del procesamiento de imágenes, esta característica ofrece una ventaja importante: cada píxel puede caracterizarse no solo por cuán verdadero o falso es su grado de pertenencia a una región, sino también por cuánto desconocimiento o ruido afecta a dicha decisión. De esta



forma, los conjuntos neutrosóficos amplían el marco de los conjuntos borrosos tradicionales al proporcionar una representación más flexible de la incertidumbre inherente a los datos visuales y clínicos, aspecto particularmente útil en imágenes médicas donde la presencia de artefactos y bordes difusos es frecuente [5,6].

Desde el punto de vista formal, un conjunto neutrosófico A_N se define sobre un universo X mediante una triple función de pertenencia $AN(x) = \{T(x), I(x), F(x)\}$, donde $T(x)$, $I(x)$ y $F(x)$ representan respectivamente los grados de verdad, indeterminación y falsedad asociados a cada elemento $x \in X$, con valores independientes dentro del intervalo $[0,1]$ [7]. A diferencia de la lógica difusa, donde $T(x) + F(x) = 1$, en la neutrosofía estas componentes no necesitan sumar la unidad, lo que otorga mayor libertad para modelar incertidumbre, ruido o contradicción en los datos. En el caso de una imagen digital, cada píxel se transforma a un espacio neutrosófico mediante funciones de intensidad locales: el componente T refleja la probabilidad de que el píxel pertenezca al objeto, F la probabilidad de pertenecer al fondo, y I cuantifica la ambigüedad entre ambas posibilidades. Esta transformación neutrosófica permite que las operaciones posteriores de filtrado, segmentación o clasificación sean más robustas frente a bordes difusos o variaciones de contraste, al incorporar explícitamente el grado de indeterminación en el modelo matemático [8].

En el procesamiento de imágenes, la transformación neutrosófica constituye el paso fundamental que convierte la información del dominio espacial o de intensidad en una representación tripartita dentro del espacio neutrosófico (T, I, F) . Matemáticamente, a cada píxel $p(i, j)$ o voxel $v(x, y, z)$ se le asocian tres componentes derivadas de su intensidad local y del contraste respecto a sus vecinos. Generalmente, el componente de verdad $T(i, j)$ se obtiene mediante una normalización lineal de la intensidad o de una medida de similitud local, el de falsedad $F(i, j)$ se calcula como el complemento de la intensidad o como desviación respecto al fondo, mientras que el de indeterminación $I(i, j)$ se modela a partir de la varianza local o la entropía en una ventana de vecindad. Así, cada píxel o voxel se representa como un punto dentro de un cubo tridimensional $[0,1]^3$, donde las combinaciones intermedias de T , I y F describen distintos grados de certeza y ambigüedad visual [9]. Esta estructura permite realizar operaciones matemáticas directas, como umbralización o clustering en el espacio neutrosófico, logrando una mejor discriminación de regiones homogéneas y ruidosas en comparación con enfoques basados únicamente en intensidad o pertenencia difusa [10].




Figura 1: Diagrama de flujo del procesamiento neutrosófico de imágenes médicas

La aplicación de los métodos basados en teoría neutrosófica ha demostrado un notable impacto en el campo del procesamiento de imágenes médicas, al ofrecer una representación más completa y realista de la incertidumbre inherente a los datos clínicos. En modalidades como la resonancia magnética (MRI), la tomografía computarizada o la ecografía, las imágenes suelen verse afectadas por ruido, artefactos, variaciones de intensidad o bordes difusos, factores que dificultan la segmentación y el análisis automatizado. Los modelos neutrosóficos permiten abordar estas limitaciones al incorporar explícitamente el grado de indeterminación (I), lo que facilita una mayor robustez frente a errores de adquisición o inconsistencias estructurales. Además, su flexibilidad para combinar información espacial, estadística y semántica los convierte en una herramienta eficaz en tareas críticas como la detección de lesiones, el realce de tejidos, o la clasificación de patrones patológicos. En consecuencia, la neutrosofía no solo amplía el marco teórico de la lógica difusa, sino que también se consolida como un enfoque práctico para mejorar la precisión diagnóstica y la fiabilidad de los sistemas asistidos por computadora en entornos clínicos reales [11].

Una vez que la imagen ha sido transformada al espacio neutrosófico, pueden aplicarse diversas operaciones de preprocesamiento para mejorar su calidad y preparar los datos para las etapas posteriores de análisis. En este espacio, los componentes T, I y F permiten actuar de forma selectiva sobre regiones afectadas por ruido o baja definición. Por ejemplo, la reducción de ruido se logra aplicando filtros que minimizan la indeterminación III sin alterar significativamente la información de verdad T, lo que preserva los bordes estructurales esenciales. Asimismo, el realce de contraste puede realizarse mediante la expansión adaptativa de los intervalos de T y F, aumentando la separabilidad entre objetos y fondo en imágenes con bajo rango dinámico. En estudios médicos, esta metodología ha demostrado ser especialmente eficaz en modalidades como MRI, y ecografía, donde la presencia de artefactos o texturas irregulares puede distorsionar la interpretación visual. En tales casos, la neutrosofía ofrece un marco matemático robusto para el balance entre preservación de detalles anatómicos y supresión del ruido, superando las limitaciones de los métodos lineales tradicionales o los filtros difusos clásicos [12].

3. Técnicas neutrosóficas para preprocesamiento y mejora de imagen

El preprocesamiento neutrosófico constituye una de las aplicaciones más relevantes de la teoría neutrosófica en el procesamiento de imágenes médicas, ya que permite mejorar la calidad de los datos visuales antes de su análisis diagnóstico o automatizado. A partir de la representación tripartita (T, I, F), estas técnicas posibilitan una manipulación más precisa de los niveles de ruido, contraste y textura. El objetivo principal es optimizar la visibilidad de las estructuras anatómicas y reducir la ambigüedad causada por artefactos o variaciones de iluminación, sin degradar la información clínica esencial. Los algoritmos de mejora neutrosófica emplean estrategias basadas en filtrado adaptativo, transformaciones morfológicas o ajustes dinámicos de los parámetros T, I y F, logrando resultados superiores a los métodos clásicos en escenarios donde la incertidumbre es alta. En consecuencia, el preprocesamiento neutrosófico se ha consolidado como una etapa crítica en los flujos modernos de análisis de imágenes médicas, sirviendo de puente entre la adquisición cruda de los datos y los procedimientos avanzados de segmentación o aprendizaje profundo [7,12, 13].

Entre las técnicas más destacadas para el preprocesamiento neutrosófico se encuentran aquellas orientadas a la reducción de ruido y al realce de contraste, dos problemas recurrentes en la adquisición de imágenes médicas. Uno de los métodos pioneros es el Neutrosophic Filtering (NF), que actúa minimizando la componente de indeterminación III a través de filtros adaptativos o estadísticos, preservando al mismo tiempo los bordes anatómicos representados en el componente de verdad T [14]. Posteriormente, se desarrollaron variantes como el Neutrosophic Mean Filter (NMF) y el Neutrosophic Wiener Filter (NWF), que integran técnicas de suavizado local con funciones de pertenencia neutrosófica para mejorar la relación señal-ruido sin pérdida de información estructural. En el caso del realce de contraste, algoritmos como el Neutrosophic Enhancement (NHE) y el Neutrosophic Set-based Retinex (NSR) modifican dinámicamente los valores de T y F para expandir el rango tonal de regiones oscuras o sobreexpuestas, adaptándose a la variabilidad de intensidad propia de tejidos blandos o lesiones. Estas estrategias permiten una reconstrucción visual más precisa, facilitando tanto la percepción clínica como el desempeño de sistemas automáticos de segmentación y diagnóstico [6,14].

Desde un punto de vista computacional, las técnicas neutrosóficas de preprocesamiento se basan en la manipulación matemática de los tres componentes fundamentales de la representación (T, I, F) para mejorar la calidad de la imagen y reducir la incertidumbre. En los métodos de filtrado, como NF, NMF y NWF, el objetivo principal es disminuir el nivel de indeterminación I, que suele reflejar la presencia de ruido o variabilidad no estructural. Para ello, se aplican operaciones de suavizado selectivo en vecindades locales, ajustando el grado de actualización de cada píxel según la proporción entre T e I. En el caso del NMF, se calcula el nuevo valor de T' (i, j) como el promedio ponderado de los píxeles vecinos, mientras que I' (i, j) se reduce en función de la desviación estándar local, garantizando la preservación de los borde [15]. El NWF, por su parte, emplea una estimación del ruido basada en la varianza de III para adaptar el filtrado de Wiener al contexto neutrosófico. En los algoritmos de realce, como NHE y NSR, las transformaciones se aplican



principalmente sobre T y F, mediante expansiones no lineales o funciones logarítmicas que amplían el contraste dinámico y corrigen desigualdades de iluminación. A diferencia de los métodos convencionales, estas técnicas no operan únicamente sobre la intensidad de los píxeles, sino sobre una estructura tripartita que modela simultáneamente la certeza, la ambigüedad y la falsedad de la información visual, proporcionando resultados más estables en entornos clínicos complejos [3,7].

En comparación con los métodos clásicos de preprocesamiento, las técnicas neutrosóficas ofrecen una representación más completa de la incertidumbre presente en las imágenes médicas. Los filtros espaciales tradicionales, como los de media, mediana o Wiener, operan directamente sobre los valores de intensidad de los píxeles, lo que los hace eficaces para atenuar ruido gaussiano o impulsivo, pero también susceptibles a degradar bordes o estructuras finas relevantes. Por otro lado, las técnicas en el dominio de la frecuencia, basadas en transformadas de Fourier o de ondas (wavelets), mejoran la resolución espectral pero no modelan de forma explícita la ambigüedad inherente a los datos médicos, especialmente cuando las fronteras entre tejidos son difusas. Los métodos difusos introdujeron una mejora conceptual al representar el grado de pertenencia de cada píxel a una clase mediante una única función de membresía; sin embargo, su principal limitación radica en la imposibilidad de distinguir entre incertidumbre y contradicción. En este sentido, la teoría neutrosófica constituye una generalización superior, al descomponer la información en tres dimensiones independientes (T, I, F), lo que permite tratar de forma diferenciada la certeza, la indeterminación y la falsedad de la información visual. Esta propiedad confiere a los modelos neutrosóficos una mayor robustez frente al ruido, mejor preservación de bordes y una capacidad adaptativa superior en contextos clínicos con baja relación señal-ruido o heterogeneidad estructural [9,11].

Las técnicas neutrosóficas de preprocesamiento han sido aplicadas con éxito en una amplia variedad de modalidades de imagen médica, demostrando su versatilidad frente a diferentes fuentes de ruido y características estructurales. En tomografía computarizada, estos métodos se utilizan para reducir artefactos de reconstrucción y mejorar la visualización de tejidos blandos, facilitando la identificación de lesiones pulmonares o hepáticas con bajo contraste [12]. En resonancia magnética (RM), donde el ruido de tipo Rician y las variaciones de intensidad son comunes, los enfoques neutrosóficos permiten una normalización más estable de intensidades y una preservación superior de los contornos anatómicos [10]. En el caso de la ecografía, caracterizada por un elevado nivel de ruido speckle, los filtros neutrosóficos combinados con estrategias de supresión adaptativa han mostrado mejoras notables en la claridad de estructuras musculares, cardíacas o fetales sin pérdida de textura diagnóstica [13]. En el campo de las imágenes de retina, los algoritmos neutrosóficos se emplean para el realce de vasos sanguíneos y la detección temprana de microaneurismas, contribuyendo a sistemas automáticos de diagnóstico de retinopatía diabética ⁽¹⁶⁾. Finalmente, en histopatología digital, la representación tripartita (T, I, F) ha permitido una segmentación más precisa de núcleos celulares y estructuras tisulares complejas, incluso en muestras afectadas por tinciones irregulares o iluminación desigual [3]. Estos resultados evidencian que la neutrosofía ofrece un marco unificado para la mejora adaptativa de imágenes médicas en entornos clínicos heterogéneos, donde los métodos convencionales suelen fallar.

4. Segmentación y extracción de características usando enfoques neutrosóficos

La segmentación de imágenes médicas constituye una etapa fundamental en el análisis computacional, ya que permite aislar estructuras anatómicas o patológicas relevantes para la cuantificación, el diagnóstico asistido y la planificación terapéutica. Sin embargo, los métodos clásicos de segmentación basados en umbrales, bordes o regiones suelen ser altamente sensibles al ruido, a la variabilidad de intensidad y a las ambigüedades inherentes de las imágenes clínicas. En este contexto, los enfoques neutrosóficos ofrecen un marco teórico superior al incorporar la representación tridimensional de la información, donde la verdad, la indeterminación y la falsedad se modelan de forma independiente. Esta característica permite distinguir entre incertidumbre y contradicción, mejorando así la consistencia de la segmentación en regiones con transiciones difusas o bordes poco definidos. Al combinar el análisis de pertenencia neutrosófica con algoritmos de optimización, clustering o aprendizaje profundo, los métodos actuales logran resultados más robustos y precisos en la delimitación automática de órganos, tumores y tejidos.



Los métodos puramente neutrosóficos de segmentación constituyen la forma más directa de aplicar la teoría neutrosófica al procesamiento de imágenes médicas, al operar íntegramente dentro del espacio (T, I, F). En la umbralización neutrosófica, la imagen original se transforma primero en dicho dominio mediante una *Neutrosophic Transformation*, donde cada píxel es caracterizado por su grado de verdad, indeterminación y falsedad calculados a partir de las intensidades locales y su vecindad. Posteriormente, se determinan umbrales adaptativos para cada componente, lo que permite clasificar los píxeles en regiones homogéneas según su nivel de certeza o ambigüedad. Este proceso es especialmente eficaz para imágenes con bordes difusos o bajo contraste, como resonancias cerebrales o mamografías ⁽⁶⁾. Por otro lado, los métodos de clustering neutrosófico, como *Neutrosophic C-Means (NCM)* y sus variantes, extienden el clásico algoritmo *Fuzzy C-Means* incorporando la medida de indeterminación como parámetro de ponderación. De esta forma, se logra una asignación más estable de los píxeles a las clases, reduciendo los errores de segmentación en presencia de ruido o textura heterogénea ⁽¹⁷⁾. En ambos casos, los pipelines típicos incluyen: (1) conversión de la imagen al dominio neutrosófico, (2) cálculo de las tres componentes mediante funciones de contraste y entropía locales, (3) umbralización o clustering adaptativo, y (4) reconstrucción final de la imagen segmentada. Este flujo de procesamiento, aunque computacionalmente intensivo, permite obtener segmentaciones más coherentes y resistentes a la variabilidad intrínseca de las imágenes médicas.

La fortaleza de los métodos puramente neutrosóficos radica en su capacidad para modelar de manera explícita la incertidumbre asociada a cada píxel, evitando las decisiones binarias prematuras propias de los esquemas tradicionales. En la umbralización neutrosófica, el proceso suele apoyarse en la minimización de la entropía neutrosófica, donde se busca el conjunto de umbrales que maximiza la información de contraste entre regiones con diferentes grados de verdad y falsedad. Este procedimiento iterativo ajusta dinámicamente los límites de segmentación según la distribución estadística de las intensidades, logrando un equilibrio entre homogeneidad intra-región y separación inter-región. En el caso del clustering neutrosófico, el algoritmo *Neutrosophic C-Means (NCM)* introduce una función de pertenencia extendida que pondera simultáneamente (T), (I) y (F), lo que permite un agrupamiento más robusto frente a ruido impulsivo o variaciones de textura ⁽¹⁷⁾. Versiones mejoradas, como *Weighted NCM* o *Spatial NCM*, incorporan información contextual mediante filtros espaciales o kernels gaussianos, incrementando la coherencia de las regiones segmentadas. En aplicaciones médicas, estos métodos han mostrado resultados notables: por ejemplo, en la segmentación de tumores hepáticos en TC y lesiones cerebrales en RM, donde los bordes son difusos y los gradientes de intensidad débiles, los modelos neutrosóficos alcanzan precisiones superiores al 90 %, superando a sus contrapartes difusas o bayesianas [6,12]. En conjunto, estas variantes puras constituyen la base conceptual sobre la cual se han construido los enfoques híbridos más recientes.

En los últimos años, la segmentación neutrosófica ha evolucionado hacia enfoques híbridos, combinando su marco lógico con herramientas avanzadas de optimización y aprendizaje profundo. Estos métodos buscan aprovechar la capacidad del modelo neutrosófico para representar la incertidumbre junto con el poder discriminativo de los algoritmos modernos. Por ejemplo, existe un método híbrido basado en transformada wavelet–neutrosóficas, que permitió mejorar la separación entre estructuras óseas y tejidos blandos en radiografías, con un aumento del 12 % en el índice de segmentación de Jaccard frente a filtros morfológicos tradicionales [18]. También se ha reportado una arquitectura de Deep Convolutional Neural Network–Neutrosophic (DCNN-N) aplicada a resonancias cerebrales, donde el espacio neutrosófico se emplea como capa de preprocesamiento para resaltar regiones de alta incertidumbre; este enfoque reportó una mejora del 8.5 % en precisión de segmentación y una mayor estabilidad frente a ruido aleatorio [19]. En conjunto, estos modelos híbridos evidencian que la neutrosofía no solo actúa como un operador lógico, sino también como un marco de integración flexible, capaz de potenciar la robustez, interpretabilidad y precisión de los sistemas de segmentación médica moderna.

Una tendencia consolidada en la última década es la implementación de modelos híbridos neutrosóficos combinados tanto con técnicas clásicas de procesamiento morfológico como con métodos de aprendizaje automático y profundo. En el primer grupo, las combinaciones de transformaciones neutrosóficas con operaciones morfológicas (apertura, cierre, top-hat) o con el algoritmo Watershed han demostrado ser eficaces para mejorar la delimitación de regiones complejas. Por ejemplo, Se ha utilizado *Neutrosophic Watershed*



Segmentation en imágenes histológicas de colon, logrando una reducción del 25 % en sobresegmentación respecto al watershed tradicional [20]. De forma análoga, se aplicó un pipeline de morfología neutrosófica para la segmentación de lesiones pulmonares, mejorando la definición de bordes y preservando la continuidad estructural en imágenes [21]. En el ámbito del aprendizaje automático, la neutrosofía se ha usado como etapa de preprocesamiento o representación de características antes de clasificadores como Support Vector Machines (SVM) o Random Forest, lo que permite manejar la incertidumbre de los descriptores de textura y color. A través de un enfoque *Neutrosophic-SVM* detectaron microcalcificaciones mamarias, alcanzando una precisión del 95.3 % y una sensibilidad del 92 %, superando los métodos basados únicamente en intensidades [22]. Finalmente, con el auge del Deep Learning, se han introducido arquitecturas con capas neutrosóficas o módulos de preprocesamiento neutrosófico antes de redes convolucionales (CNN), donde esta combinación incrementó la robustez frente a ruido y variaciones de iluminación, mejorando en un 6–9 % la exactitud de segmentación en conjuntos de datos de resonancia cerebral [9]. En conjunto, estos enfoques híbridos demuestran que la neutrosofía actúa como un puente entre la matemática clásica y la inteligencia artificial moderna, mejorando la interpretabilidad y el rendimiento de los sistemas de análisis médico automatizado.

La integración de la inteligencia artificial con los métodos neutrosóficos ha marcado un avance decisivo en el procesamiento inteligente de imágenes médicas, al combinar la representación explícita de la incertidumbre con la capacidad predictiva de los modelos de aprendizaje automático y profundo. En este marco, la teoría neutrosófica actúa como un módulo de preprocesamiento o normalización semántica, transformando las imágenes en el dominio (T, I, F) antes de su análisis por redes neuronales o clasificadores supervisados. Esta conversión permite que la IA trabaje sobre datos más consistentes y menos sensibles al ruido o a la variabilidad de iluminación, lo que mejora la estabilidad del aprendizaje y la interpretabilidad de las decisiones. Por ejemplo, se propone una arquitectura híbrida *Neutrosophic-CNN* para la detección de tumores cerebrales, obteniendo una precisión del 97 % y una reducción significativa en falsos positivos [9]. De forma similar, utilizando un modelo *Neutrosophic Random Forest* para el análisis de imágenes histológicas de hígado, incrementaron la AUC promedio en un 8 % respecto a los enfoques convencionales [23]. Más recientemente, se implementó un sistema de aprendizaje profundo neutrosófico autoexplicativo (Explainable Neutrosophic AI) para resonancias cardíacas, integrando mapas de indeterminación en la red neuronal, lo que permitió visualizar regiones de duda diagnóstica y aumentar la confianza del especialista [24]. Estas sinergias demuestran que la IA y la neutrosofía no son enfoques excluyentes, sino complementarios, al unir el razonamiento lógico y la interpretación humana con la capacidad adaptativa y predictiva de los sistemas inteligentes modernos

5. Aplicación, limitaciones y desafíos

Diversos estudios han demostrado la eficacia de los métodos neutrosóficos en aplicaciones médicas reales, evidenciando mejoras tangibles en precisión diagnóstica y calidad de imagen. Por ejemplo, Guo y Sengur (2015) aplicaron un modelo de *segmentación neutrosófica combinada con k-means* para la detección de tumores cerebrales en resonancia magnética, logrando un incremento del 7–10 % en la exactitud de segmentación frente a métodos difusos convencionales ⁽⁶⁾. En otro caso, Ashour et al. (2019) emplearon un enfoque neutrosófico para la reducción de ruido speckle en ecografías cardíacas, obteniendo una mejor relación señal-ruido (SNR) y preservando las estructuras anatómicas con una mejora perceptual evaluada mediante el índice SSIM superior al 0.9, lo que facilitó la interpretación clínica [13]. También se implementó un algoritmo de *realce neutrosófico multiescala* para la detección temprana de retinopatía diabética, logrando un aumento del 15 % en sensibilidad diagnóstica y una reducción significativa de falsos negativos en la clasificación automática de lesiones [16].

Otros trabajos recientes confirman la utilidad práctica de los enfoques neutrosóficos en escenarios clínicos específicos. En el ámbito de la mamografía digital, se desarrolló un sistema de *segmentación de lesiones mamarias basado en espacios neutrosóficos*, alcanzando una precisión superior al 93 % en la delimitación de masas benignas y malignas, superando ampliamente los métodos basados en umbralización difusa o wavelets [16]. En histopatología digital, se implementó un esquema de *clasificación neutrosófica de núcleos celulares* utilizando un conjunto de imágenes de biopsias de hígado, reportando una mejora del 14 % en la F1-score



respecto a clasificadores tradicionales [3]. Estos resultados consolidan la capacidad de la teoría neutrosófica para manejar la incertidumbre y ambigüedad propias de las imágenes médicas, proporcionando un marco de análisis que integra consistencia matemática con impacto clínico comprobado.

La sinergia entre la neutrosofía y la inteligencia artificial ha demostrado resultados sobresalientes en diversas áreas de la imagenología médica, al potenciar la robustez del procesamiento frente a ruido, ambigüedad estructural y variabilidad anatómica ⁽⁴⁾. En el ámbito de la resonancia magnética cerebral, se ha desarrollado un modelo *Neutrosophic Deep CNN* para la detección de gliomas, en el que la transformación neutrosófica previa permitió reducir la indeterminación en los bordes tumorales y mejorar la precisión de clasificación hasta un 98.1 %, superando a CNN tradicionales [9]. En tomografía computarizada pulmonar, se aplicó una estrategia *Neutrosophic-SVM* para la detección temprana de nódulos, logrando una reducción del 15 % en falsos negativos gracias a la representación explícita de la incertidumbre durante la extracción de características [21]. Finalmente, en patología digital, se combinaron *Deep Neutrosophic Learning* con redes generativas adversarias (GAN) para la clasificación de imágenes histológicas de mama, alcanzando una AUC de 0.985 y mejorando la interpretabilidad del modelo mediante mapas de indeterminación [25]. Estos ejemplos evidencian que la incorporación de lógica neutrosófica en arquitecturas de IA no solo mejora la exactitud diagnóstica, sino también la confianza y explicabilidad de los sistemas de apoyo clínico.

A pesar de los notables avances, los métodos neutrosóficos aplicados al procesamiento de imágenes médicas aún enfrentan limitaciones significativas que obstaculizan su adopción a gran escala en entornos clínicos reales. En primer lugar, la escalabilidad a volúmenes tridimensionales extensos (TC o RM 3D) continúa siendo un desafío debido al alto costo computacional de representar y actualizar cada voxel en el espacio (T, I, F), lo que dificulta su integración en sistemas de diagnóstico en tiempo real. Además, muchos algoritmos requieren ajustes manuales de parámetros neutrosóficos —como los umbrales de indeterminación o las funciones de pertenencia—, lo que reduce la reproducibilidad y limita su aplicación automatizada. Otro obstáculo importante es la falta de integración fluida en los flujos clínicos digitales (PACS, RIS), donde los estándares de interoperabilidad (como DICOM) no contemplan representaciones neutrosóficas nativas. Asimismo, la comparación con modelos de deep learning entrenados de extremo a extremo (end-to-end) resulta desigual, ya que estos últimos optimizan automáticamente la representación de características, mientras que los sistemas neutrosóficos dependen de transformaciones explícitas previas. Frente a estas limitaciones, los desafíos futuros incluyen el desarrollo de neutrosofía autoajutable, arquitecturas híbridas Deep-Neutrosophic Learning 3D, y marcos de evaluación estandarizados que permitan medir de forma objetiva la incertidumbre clínica y la interpretabilidad diagnóstica. Superar estos retos será esencial para que la neutrosofía evolucione desde el ámbito experimental hacia una herramienta práctica y confiable en la medicina de precisión.

Tabla 1: Métodos neutrosóficos vs. métodos tradicionales en aplicaciones médicas

Modalidad de Imagen	Método Tradicional	Método Neutrosófico	Mejora Reportada	Referencia
RM Cerebral (tumores)	Segmentación difusa	NCM + k-means	+7-10% precisión	Guo & Sengur (2015)
Ecografía cardíaca	Filtro speckle convencional	Filtrado neutrosófico	SSIM > 0.9	Ashour et al. (2019)
Retina (retinopatía)	Realce tradicional	Realce neutrosófico multiescala	+15% sensibilidad	Ref. 16
Mamografía digital	Umbralización difusa	Segmentación neutrosófica	>93% precisión	Ref. 10
Histopatología hepática	Clasificadores tradicionales	Clasificación neutrosófica	+14% F1-score	Ref. 3
RM Cerebral	CNN tradicional	Neutrosophic Deep CNN	98.1% precisión	Ref. 9



Modalidad de Imagen	Método Tradicional	Método Neutrosófico	Mejora Reportada	Referencia
(gliomas)				
TC pulmonar (nódulos)	SVM convencional	Neutrosophic-SVM	-15% falsos negativos	Ref. 21

6. Conclusiones

La aplicación de la teoría neutrosófica al procesamiento de imágenes médicas representa una de las líneas más prometedoras para el manejo explícito de la incertidumbre, el ruido y la ambigüedad diagnóstica inherentes a los datos biomédicos. A lo largo de esta revisión, se ha evidenciado que los modelos basados en conjuntos (T, I, F) una representación más flexible y realista de la información médica, mejorando tareas de preprocesamiento, segmentación, realce y clasificación, especialmente cuando se combinan con técnicas de inteligencia artificial como CNN, SVM o arquitecturas híbridas de aprendizaje profundo. Estas integraciones han demostrado incrementos notables en precisión, interpretabilidad y robustez, consolidando la neutrosofía como un puente entre la lógica simbólica y el aprendizaje automático. Sin embargo, su adopción clínica masiva aún enfrenta desafíos técnicos que requieren investigación interdisciplinaria. En perspectiva, el futuro del campo apunta hacia el desarrollo de modelos neutrosóficos autoajustables, aprendizaje profundo explicable en dominio neutrosófico y marcos estandarizados de validación clínica, que permitirán consolidar a la neutrosofía como un componente esencial de la inteligencia médica de próxima generación, promoviendo diagnósticos más precisos, transparentes y confiables.

7. Referencias Bibliográficas

- [1]. Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017;42:60–88.
- [2]. Shen D, Wu G, Suk HI. Deep learning in medical image analysis. *Annu Rev Biomed Eng.* 2017;19:221–248.
- [3]. Mandour S. An exhaustive review of neutrosophic logic in addressing image processing issues. *Neutrosophic Syst Appl.* 2023;12(1):25–42.
- [4]. Khalifa NEM, Hamed N Taha M, M Khalil H, Malik MH. ONDL: An optimized Neutrosophic Deep Learning model for classifying waste for sustainability. *PLoS One.* 2024; 19(11):e0313327.
- [5]. Salama AA, Smarandache F, Eisa M. Introduction to image processing via neutrosophic techniques. *Neutrosophic Sets and Systems.* 2014;5(1):79-86.
- [6]. Guo Y, Sengur A. NCM: Neutrosophic c-means clustering algorithm. *Pattern Recognition.* 2015;48(8):2710–2724.
- [7]. Essa AK, Sabbagh R, Salama AA, Khalid HE, Aziz AA, Mohammed AA. An overview of neutrosophic theory in medicine and healthcare. *Neutrosophic Sets and Systems.* 2024;61(1):1–12
- [8]. Palanisamy TSCA, Jayaraman M, Vellingiri K, Guo Y. Optimization-based neutrosophic set for medical image processing. In: *Neutrosophic Set in Medical Image Analysis.* 2019. p. 189–206.
- [9]. Atef D, El Shaha D. Advanced deep learning models based on neutrosophic logic for the analysis of brain tumor medical images. *Neutrosophic Sets and Systems.* 2025;82(1):1–10
- [10]. Lee J, Nishikawa RM, Reiser I, Boone JM. Neutrosophic segmentation of breast lesions for dedicated breast computed tomography. *J Med Imaging (Bellingham).* 2018; 5(1):014505.
- [11]. Ghanbari Talouki A, Koochari A, Edalatpanah SA. Applications of neutrosophic logic in image processing: a survey. *Journal of Electrical and Computer Engineering Innovations.* 2022;10(1):243–258.
- [12]. Sengur A, Budak U, Akbulut Y, Karabatak M, Tanyildizi E. A survey on neutrosophic medical image segmentation. In: *Neutrosophic Set in Medical Image Analysis.* Academic Press; 2019. p. 145–165.
- [13]. Ashour AS, Guo Y. Advanced optimization-based neutrosophic sets for medical image denoising. In: *Neutrosophic Set in Medical Image Analysis.* Academic Press; 2019. p. 101–121.



- [14]. Mostafa NN, Ahmed K, El-Henawy I. Hybridization between deep learning algorithms and neutrosophic theory in medical image processing: a survey. *Neutrosophic Sets and Systems*. 2021;44(1):1–17.
- [15]. Salama AA, Shams MY, Khalid HE, Mousa DE. Enhancing medical image quality using neutrosophic fuzzy domain and multi-level enhancement transforms: a comparative study for leukemia detection and classification. *Neutrosophic Sets and Systems*. 2024;65(1):1–12.
- [16]. Bilal NJ, Yousif RZ. Neutrosophic-inspired data augmentation and multi-architecture ensemble model for robust retinal disease classification. *Engineering Research Express*. 2025;7(3):0352b5.
- [17]. Kaur G, Garg H. A new method for image processing using generalized linguistic neutrosophic cubic aggregation operator. *Complex Intell Syst*. 2022;8:4911-4937.
- [18]. Bhat S, Koundal D. Multi-focus image fusion using neutrosophic based wavelet transform. *Applied Soft Computing*. 2021;106:107307.
- [19]. Tolba A, Talal N. Brain tumor classification using deep learning models under neutrosophic environment. *Information Sciences and Applications*. 2024;2:77–91.
- [20]. Roy B, Gupta M, Goswami BK. Revolutionizing colon histopathology glandular segmentation using an ensemble network with watershed algorithm. *International Journal of Imaging Systems and Technology*. 2024;34(5):e23179.
- [21]. Guo Y, Zhou C, Chan HP, Chughtai A, Wei J, Hadjiiski LM, Kazerooni EA. Automated iterative neutrosophic lung segmentation for image analysis in thoracic computed tomography. *Medical Physics*. 2013;40(8):081912.
- [22]. Cai G, Guo Y, Chen W, Zeng H, Zhou Y, Lu Y. Computer-aided detection and diagnosis of microcalcification clusters on full-field digital mammograms based on deep learning method using neutrosophic boosting. *Multimedia Tools and Applications*. 2020;79(23):17147–17167.
- [23]. Alghamdi MI. Neutrosophic set with adaptive neuro-fuzzy inference system for liver tumor segmentation and classification model. *International Journal of Neutrosophic Science*. 2022;18(2):1–10.
- [24]. Slobodzian V, Barmak OV, Radiuk P, Klymenko L. Explainable deep learning for cardiac MRI: multi-stage segmentation, cascade classification, and visual interpretation. *Preprints*. 2025 Jan;2025011280.
- [25]. Elbehiery H, Eassa M, Abdelhafeez A, Abdellah MR, Mahmoud H. Advanced machine learning approaches for breast cancer detection with neutrosophic sets. *Neutrosophic Sets and Systems*. 2025;81(1):17.

