



# Modelo neutrosófico de decisión para la evaluación del riesgo crediticio bajo incertidumbre: desarrollo matemático e implementación aplicada.

## Neutrosophic decision model for credit risk assessment under uncertainty: mathematical development and applied implementation.

<sup>1</sup>Msc. Yismandry Gonzalez Vargas. <sup>2</sup>Lic. Diana Padrón Carrasco.

<sup>1</sup>Asociación Latinoamericana de Ciencias Neutrosóficas. [yismandrygonzalezvargas@gmail.com](mailto:yismandrygonzalezvargas@gmail.com), <https://orcid.org/0009-0005-4981-9740>

<sup>2</sup>Universidad de Ciego de Avila. Cuba. [padroncarrascodiana@gmail.com](mailto:padroncarrascodiana@gmail.com) , <https://orcid.org/0009-0009-6633-252X>

### Resumen.

El presente estudio aborda el problema de la evaluación del riesgo crediticio en contextos caracterizados por información incompleta y estructuras económicas no plenamente formalizadas, donde los modelos tradicionales evidencian limitaciones significativas al reducir la decisión a esquemas probabilísticos rígidos. En la actualidad, este tema adquiere especial relevancia debido a la creciente necesidad de ampliar el acceso al crédito sin comprometer la estabilidad financiera, lo que exige herramientas capaces de capturar la complejidad inherente a escenarios reales. No obstante, la literatura existente muestra una brecha importante, ya que los enfoques convencionales no logran integrar de manera explícita la incertidumbre ni diferenciar adecuadamente entre riesgo y falta de información. En respuesta a esta limitación, se propone un modelo neutrosófico basado en los componentes de verdad, falsedad e indeterminación, el cual permite una representación más flexible del comportamiento crediticio. La metodología se fundamenta en una formulación matemática rigurosa complementada con una simulación comparativa frente a métodos tradicionales. Los resultados evidencian una mejora en la calidad de las decisiones crediticias al incorporar la indeterminación como elemento central del análisis. En consecuencia, el estudio contribuye tanto al desarrollo teórico como a la implementación práctica, destacando su aplicabilidad en entornos fintech y sistemas reales de evaluación financiera.

**Palabras clave:** Lógica neutrosófica, Riesgo crediticio, Economía informal, Toma de decisiones en condiciones de incertidumbre, Inclusión financiera, Evaluación de riesgos, Modelización de la incertidumbre.

### Abstract.

This study addresses the problem of credit risk assessment in contexts characterized by incomplete information and not fully formalized economic structures, where traditional models show significant limitations by reducing decision-making to rigid probabilistic schemes. Currently, this topic is particularly relevant due to the growing need to expand access to credit without compromising financial stability, which demands tools capable of capturing the inherent complexity of real-world scenarios. However, the existing literature reveals a significant gap, as conventional approaches fail to explicitly integrate uncertainty or adequately differentiate between risk and lack of information. In response to this limitation, a neutrosophic model based on the components of truth, falsity, and indeterminacy is proposed, allowing for a more flexible representation of credit behavior. The methodology is based on a rigorous mathematical formulation complemented by a comparative simulation against traditional



methods. The results demonstrate an improvement in the quality of credit decisions by incorporating indeterminacy as a central element of the analysis. Consequently, this study contributes to both theoretical development and practical implementation, highlighting its applicability in fintech environments and real-world financial evaluation systems.

**Keywords:** Neutrosophic logic, Credit risk, Informal economy, Decision-making under uncertainty, Financial inclusion, Risk assessment, Uncertainty modeling.

## 1. Introducción

La evaluación del riesgo crediticio constituye uno de los pilares fundamentales de los sistemas financieros contemporáneos, especialmente en contextos donde la inclusión financiera se ha convertido en una prioridad estratégica para el desarrollo económico sostenible. En este sentido, la expansión del crédito hacia segmentos tradicionalmente excluidos plantea desafíos significativos en términos de medición y gestión del riesgo, dado que dichos entornos se caracterizan por la presencia de información incompleta, asimetrías informativas y alta variabilidad en los patrones de ingreso. Diversos estudios han señalado que los modelos convencionales de evaluación crediticia, basados en información histórica estructurada, presentan limitaciones sustanciales cuando se aplican en contextos con datos escasos o inconsistentes [1]. Asimismo, el crecimiento del microcrédito y las estrategias de inclusión financiera han intensificado la necesidad de desarrollar enfoques más adaptativos que permitan capturar la complejidad de estos escenarios [2]. En consecuencia, surge la necesidad de replantear los esquemas tradicionales de análisis, incorporando metodologías capaces de manejar no solo el riesgo cuantificable, sino también la incertidumbre inherente a la información disponible.

A lo largo de las últimas décadas, los sistemas de evaluación crediticia han evolucionado desde enfoques heurísticos hacia modelos estadísticos avanzados y, más recientemente, hacia técnicas de aprendizaje automático. Inicialmente, las decisiones crediticias se basaban en el juicio experto y en reglas empíricas, lo que daba lugar a procesos altamente subjetivos. Posteriormente, la introducción de modelos de regresión logística permitió formalizar la probabilidad de incumplimiento, estableciendo un marco cuantitativo más riguroso [3]. Sin embargo, con el advenimiento del big data y la inteligencia artificial, se han desarrollado modelos más complejos, como redes neuronales y algoritmos de ensamblaje, que prometen mejorar la precisión predictiva [4]. A pesar de estos avances, persisten desafíos estructurales relacionados con la calidad de los datos y la interpretabilidad de los modelos, lo que limita su aplicabilidad en entornos donde la información es fragmentaria o contradictoria.

En el contexto global actual, la expansión de economías con altos niveles de informalidad y la creciente digitalización de los servicios financieros han configurado un escenario particularmente complejo para la evaluación del riesgo crediticio. En muchas regiones, una proporción significativa de la población carece de historial crediticio formal, lo que dificulta la aplicación de modelos tradicionales basados en datos históricos confiables [5]. Paralelamente, el auge de las plataformas fintech ha introducido nuevas fuentes de información, como datos transaccionales alternativos y comportamientos digitales, ampliando el espectro de variables disponibles para el análisis [6]. No obstante, la integración de estos datos en modelos coherentes sigue siendo un desafío, especialmente cuando se enfrentan inconsistencias o vacíos informativos que afectan la calidad de las predicciones.

A pesar de los avances metodológicos, los modelos actuales continúan operando bajo una lógica predominantemente probabilística, en la cual el riesgo se expresa como una única medida agregada. Este enfoque, si bien útil en contextos bien estructurados, resulta insuficiente cuando se requiere distinguir entre la falta de información y la presencia de señales contradictorias. En efecto, la literatura ha evidenciado que los modelos tradicionales tienden a confundir la incertidumbre con el riesgo, lo que conduce a decisiones subóptimas en escenarios complejos [7]. Esta limitación se traduce, en la práctica, en la exclusión de potenciales beneficiarios del crédito o en la concesión de financiamiento a perfiles inadecuados, afectando tanto la inclusión financiera como la estabilidad del sistema.

El problema central que aborda esta investigación se deriva precisamente de esta limitación conceptual y metodológica. En particular, surge la siguiente pregunta: ¿cómo diseñar un modelo de evaluación del riesgo crediticio que permita diferenciar explícitamente entre riesgo e incertidumbre en contextos caracterizados por información incompleta y heterogénea? Esta interrogante pone de manifiesto la necesidad de desarrollar enfoques que no solo estimen la probabilidad de incumplimiento, sino que también incorporen de manera explícita el grado de indeterminación asociado a los datos disponibles. La magnitud de este problema es considerable, dado que afecta a



un amplio segmento de la población y tiene implicaciones directas en la eficiencia del sistema financiero.

Desde una perspectiva aplicada, la incapacidad de los modelos actuales para gestionar adecuadamente la incertidumbre tiene consecuencias relevantes en la toma de decisiones. Por un lado, las instituciones financieras enfrentan mayores niveles de riesgo debido a la posible sobreestimación o subestimación del perfil crediticio de los solicitantes. Por otro lado, los individuos con perfiles no tradicionales ven limitado su acceso al crédito, lo que perpetúa dinámicas de exclusión financiera. En este sentido, resulta imperativo explorar nuevas metodologías que permitan abordar estas limitaciones, integrando enfoques que reconozcan la naturaleza incompleta y, en ocasiones, contradictoria de la información disponible.

En este contexto, la incorporación de marcos teóricos que permitan modelar la indeterminación representa una línea de investigación prometedora. A diferencia de los enfoques clásicos, que tienden a simplificar la realidad mediante supuestos de completitud y consistencia de los datos, estos nuevos modelos buscan capturar la complejidad inherente a los sistemas económicos reales. De este modo, se abre la posibilidad de desarrollar herramientas más robustas y adaptativas, capaces de mejorar la calidad de las decisiones crediticias en entornos de alta incertidumbre.

La justificación de este estudio radica, por tanto, en la necesidad de avanzar hacia modelos más flexibles que superen las limitaciones de los enfoques tradicionales. En particular, en economías emergentes y contextos con alta variabilidad informativa, resulta fundamental contar con herramientas que permitan gestionar de manera eficiente tanto el riesgo como la incertidumbre. La relevancia de esta investigación se sustenta en su potencial para contribuir a la mejora de los sistemas de evaluación crediticia, promoviendo una mayor inclusión financiera sin comprometer la estabilidad del sistema.

En términos metodológicos, este trabajo propone el desarrollo de un modelo basado en la representación de tres componentes fundamentales: evidencia a favor del cumplimiento, evidencia en contra y grado de indeterminación. Este enfoque permite descomponer la evaluación crediticia en dimensiones más ricas y expresivas, facilitando una toma de decisiones más informada. Además, se plantea una formulación matemática que integra estos componentes en un índice de riesgo ampliado, complementado con mecanismos de simulación para validar su desempeño frente a modelos tradicionales.

Finalmente, el objetivo principal de esta investigación es desarrollar y validar un modelo neutrosófico para la evaluación del riesgo crediticio bajo incertidumbre, capaz de mejorar la toma de decisiones en contextos caracterizados por información incompleta. De manera específica, se busca formular un marco matemático coherente, implementar un esquema de simulación comparativa y analizar las implicaciones prácticas de su aplicación en sistemas financieros reales. Estos objetivos se encuentran alineados con la pregunta de investigación planteada y orientan el desarrollo del presente estudio.

## **2. Revisión De Literatura.**

### **2.1 Modelos tradicionales de riesgo crediticio**

Los modelos tradicionales de evaluación del riesgo crediticio constituyen el fundamento de los sistemas modernos de decisión financiera, destacándose principalmente los enfoques de credit scoring y la regresión logística como herramientas predominantes en la clasificación de solicitantes. Estos modelos operan mediante la transformación de variables socioeconómicas y financieras en una medida cuantitativa que representa la probabilidad de incumplimiento, facilitando así la toma de decisiones en entornos bancarios estructurados [9]. En particular, los sistemas de scorecards han sido ampliamente adoptados debido a su interpretabilidad y facilidad de implementación, permitiendo asignar puntuaciones a los individuos a partir de características observables y reglas previamente definidas [10].

Por otra parte, la regresión logística ha sido considerada durante décadas como el estándar metodológico en la modelación del riesgo crediticio, al proporcionar una formulación probabilística para eventos binarios, como el incumplimiento de pago. Este enfoque ha demostrado ser robusto en contextos con datos históricos consistentes, donde las relaciones entre variables pueden aproximarse de manera estable mediante funciones logísticas [11]. No obstante, su estructura paramétrica impone supuestos restrictivos, incluyendo la linealidad en los log-odds y la independencia entre variables explicativas, lo que limita su capacidad de capturar dinámicas complejas o no lineales presentes en escenarios reales [12].



Adicionalmente, estos modelos dependen de manera crítica de la disponibilidad y calidad de los datos, lo cual representa una limitación importante en contextos donde la información es incompleta o presenta inconsistencias. En tales casos, la estimación de probabilidades puede verse sesgada, afectando la precisión del modelo y generando decisiones subóptimas en la asignación de crédito [13]. Asimismo, la naturaleza binaria de las decisiones derivadas de estos enfoques —basadas en umbrales de aceptación o rechazo— reduce la flexibilidad del sistema, impidiendo incorporar niveles intermedios de evaluación que reflejen situaciones de ambigüedad o incertidumbre [14].

En consecuencia, aunque los modelos tradicionales han contribuido significativamente a la formalización del análisis crediticio, su enfoque centrado exclusivamente en la probabilidad limita su capacidad para representar de manera adecuada la complejidad de escenarios con información incompleta o contradictoria. Esta limitación abre la puerta al desarrollo de enfoques alternativos que integren dimensiones adicionales en la evaluación, particularmente aquellas relacionadas con la incertidumbre, lo cual constituye un elemento clave en la evolución de los sistemas modernos de decisión financiera.

## 2.2 Machine Learning en crédito

El uso de técnicas de machine learning en la evaluación del riesgo crediticio ha experimentado un crecimiento significativo en los últimos años, impulsado por la disponibilidad de grandes volúmenes de datos y el aumento en la capacidad computacional. A diferencia de los modelos tradicionales, estos enfoques permiten capturar relaciones no lineales y patrones complejos en los datos, lo que potencialmente mejora la precisión predictiva en la estimación del incumplimiento [15]. Entre las metodologías más utilizadas destacan las redes neuronales artificiales y los árboles de decisión, los cuales han demostrado ser especialmente eficaces en escenarios donde las interacciones entre variables son difíciles de modelar mediante enfoques paramétricos convencionales.

Las redes neuronales, inspiradas en el funcionamiento del cerebro humano, operan a través de capas interconectadas de nodos que transforman la información de entrada en representaciones abstractas de mayor nivel. Este tipo de modelos es capaz de aproximar funciones altamente complejas, lo que les permite identificar patrones ocultos en los datos financieros y mejorar la capacidad de discriminación entre buenos y malos pagadores [16]. Sin embargo, su principal limitación radica en la falta de interpretabilidad, ya que el proceso de toma de decisiones se encuentra encapsulado en estructuras internas difíciles de explicar, lo que genera desafíos importantes en contextos regulatorios donde la transparencia es un requisito fundamental [17].

Por su parte, los árboles de decisión y sus variantes, como los métodos de ensamblaje (por ejemplo, random forests y gradient boosting), ofrecen un equilibrio entre capacidad predictiva e interpretabilidad. Estos modelos segmentan el espacio de variables en regiones homogéneas mediante reglas jerárquicas, facilitando la comprensión de los factores que influyen en la decisión crediticia [18]. Además, los enfoques de ensamblaje permiten combinar múltiples modelos débiles para construir predictores más robustos, reduciendo el sobreajuste y mejorando el desempeño general del sistema [19]. No obstante, al igual que otros métodos de aprendizaje automático, estos modelos dependen en gran medida de la calidad y representatividad de los datos de entrenamiento.

A pesar de sus ventajas, los modelos de machine learning presentan limitaciones relevantes en contextos caracterizados por información incompleta o incierta. En particular, estos enfoques tienden a asumir que los datos disponibles son suficientemente representativos del fenómeno que se desea modelar, lo cual no siempre se cumple en escenarios reales. Como consecuencia, pueden generar predicciones con alta confianza incluso cuando la información subyacente es insuficiente o ambigua, lo que introduce riesgos adicionales en la toma de decisiones [20]. Asimismo, la mayoría de estos modelos continúan operando bajo un marco probabilístico que no distingue explícitamente entre riesgo y falta de información, reproduciendo así una de las principales limitaciones de los enfoques tradicionales.

En este sentido, aunque el machine learning ha ampliado significativamente las capacidades analíticas en el ámbito del riesgo crediticio, su aplicación en entornos de alta incertidumbre requiere ser complementada con enfoques que permitan representar de manera explícita la indeterminación. La integración de estos modelos con marcos teóricos más flexibles abre nuevas oportunidades para mejorar la calidad de las decisiones, especialmente en contextos donde la información es heterogénea, incompleta o potencialmente contradictoria.

## 2.3 Scoring alternativo



El scoring alternativo ha emergido como una respuesta a las limitaciones de los modelos tradicionales y de machine learning cuando se enfrentan a poblaciones con información financiera incompleta o inexistente. En este contexto, las empresas fintech han desempeñado un papel central al introducir metodologías innovadoras que amplían el conjunto de variables utilizadas para evaluar el riesgo crediticio, incorporando fuentes de datos no convencionales como historiales de pago de servicios, comportamiento en plataformas digitales y registros transaccionales alternativos [21]. Este enfoque permite construir perfiles crediticios más inclusivos, facilitando el acceso al crédito a segmentos previamente excluidos del sistema financiero formal.

A diferencia de los modelos tradicionales, el scoring alternativo se apoya en datos no estructurados y semiestructurados, los cuales requieren procesos avanzados de procesamiento y transformación para ser utilizados en modelos predictivos. Estos datos pueden incluir información proveniente de redes sociales, patrones de uso de dispositivos móviles, geolocalización y comportamiento en línea, lo que amplía significativamente el espectro de variables consideradas en la evaluación crediticia [22]. La integración de estas fuentes de información ha sido posible gracias al desarrollo de técnicas de análisis de datos masivos y algoritmos de aprendizaje automático capaces de extraer características relevantes a partir de señales complejas y heterogéneas.

Sin embargo, el uso de datos no estructurados introduce nuevos desafíos en términos de calidad, consistencia y privacidad de la información. A diferencia de los datos financieros tradicionales, estas fuentes pueden ser altamente volátiles, ruidosas o incluso manipulables, lo que afecta la estabilidad de los modelos y la confiabilidad de las predicciones [23]. Además, la falta de estandarización en la recolección y procesamiento de estos datos dificulta su integración en sistemas de evaluación crediticia robustos, generando incertidumbre sobre la validez de las inferencias realizadas. Este aspecto es particularmente crítico en entornos regulatorios, donde la trazabilidad y explicabilidad de las decisiones son requisitos fundamentales.

Por otra parte, aunque el scoring alternativo ha demostrado mejorar la inclusión financiera al ampliar el acceso al crédito, sigue operando mayoritariamente bajo un paradigma probabilístico que no distingue explícitamente entre riesgo e incertidumbre. En consecuencia, los modelos pueden asignar puntuaciones con aparente precisión incluso cuando la información subyacente es insuficiente o contradictoria, reproduciendo así una de las principales limitaciones de los enfoques tradicionales [24]. Este problema se intensifica cuando los datos alternativos presentan inconsistencias o reflejan comportamientos ambiguos, lo que dificulta una interpretación clara del perfil crediticio.

En este sentido, si bien el scoring alternativo representa un avance significativo en la evolución de los sistemas de evaluación crediticia, su efectividad depende en gran medida de la capacidad para gestionar la incertidumbre asociada a las nuevas fuentes de información. La incorporación de enfoques que permitan modelar explícitamente la indeterminación se presenta, por tanto, como una línea de investigación necesaria para fortalecer estos sistemas. De este modo, se abre la posibilidad de integrar metodologías más robustas que no solo amplíen el acceso al crédito, sino que también mejoren la calidad y confiabilidad de las decisiones financieras en entornos complejos.

## 2.4 Limitaciones identificadas

A pesar de los avances metodológicos en los modelos tradicionales, de machine learning y de scoring alternativo, persisten limitaciones estructurales que condicionan su desempeño en escenarios reales, particularmente en contextos caracterizados por información incompleta y heterogénea. Una de las principales restricciones radica en la fuerte dependencia de estos enfoques respecto a la disponibilidad de datos completos, consistentes y representativos. En efecto, la mayoría de los modelos de evaluación crediticia asumen implícitamente que los datos utilizados reflejan de manera adecuada el comportamiento financiero de los individuos, lo cual rara vez se cumple en entornos dinámicos o con alta variabilidad informativa [25]. Esta dependencia introduce sesgos en la estimación del riesgo, especialmente cuando los datos presentan vacíos, errores o inconsistencias que afectan la calidad del proceso de modelado.

En este sentido, la problemática no se limita únicamente a la ausencia de información, sino también a la presencia de datos contradictorios o ambiguos, cuya interpretación resulta compleja dentro de los marcos tradicionales. Los modelos existentes tienden a procesar estas situaciones mediante mecanismos de imputación o simplificación, lo que puede distorsionar la representación real del perfil crediticio [26]. Además, en muchos casos, la



falta de datos se traduce automáticamente en un aumento del riesgo estimado, sin distinguir si dicha ausencia responde a un comportamiento negativo o simplemente a una carencia de información observable. Esta confusión entre evidencia negativa y desconocimiento constituye una limitación conceptual significativa en los sistemas actuales de evaluación.

Por otra parte, la mayoría de los modelos utilizados en la práctica se fundamentan en enfoques probabilísticos que no incorporan explícitamente la noción de incertidumbre. En estos esquemas, el riesgo se expresa como una probabilidad única de incumplimiento, lo que implica asumir que toda la información relevante ha sido capturada y procesada adecuadamente [27]. Sin embargo, en escenarios donde los datos son incompletos o presentan inconsistencias, esta suposición resulta cuestionable, ya que la probabilidad estimada puede no reflejar con precisión el nivel real de conocimiento sobre el fenómeno analizado. En consecuencia, los modelos pueden generar decisiones con un alto grado de confianza aparente, aun cuando la base informativa sea insuficiente.

Adicionalmente, la falta de modelado explícito de la incertidumbre limita la capacidad de los sistemas para adaptarse a contextos complejos, donde la información disponible no solo es incompleta, sino también cambiante y potencialmente contradictoria. Esta limitación afecta directamente la robustez de las decisiones crediticias, ya que impide distinguir entre escenarios de alto riesgo bien fundamentado y situaciones en las que predomina la indeterminación [28]. Como resultado, las instituciones financieras pueden adoptar decisiones conservadoras que restringen el acceso al crédito o, por el contrario, asumir riesgos no justificados debido a una interpretación incompleta de los datos.

En consecuencia, la dependencia de datos completos y la ausencia de mecanismos adecuados para representar la incertidumbre constituyen dos de las principales debilidades de los sistemas actuales de evaluación del riesgo crediticio. Estas limitaciones no solo afectan la precisión de los modelos, sino que también restringen su aplicabilidad en contextos reales, donde la información rara vez es perfecta. Por tanto, se hace necesario desarrollar enfoques alternativos que permitan integrar de manera explícita la indeterminación en el proceso de toma de decisiones, superando así las restricciones de los paradigmas tradicionales y abriendo nuevas posibilidades para una evaluación más robusta y flexible del riesgo crediticio.

## 2.5 Fundamentos de neutrosofía

La neutrosofía, introducida por Florentin Smarandache, constituye un marco teórico orientado al estudio de la indeterminación y la inconsistencia en sistemas complejos, superando las limitaciones de la lógica clásica y de los enfoques probabilísticos tradicionales. A diferencia de estos últimos, que tienden a representar el conocimiento mediante estructuras binarias o distribuciones de probabilidad cerradas, la neutrosofía propone una representación más flexible basada en tres componentes fundamentales: el grado de verdad, el grado de falsedad y el grado de indeterminación. Esta formulación permite modelar de manera explícita situaciones en las que la información es incompleta, ambigua o incluso contradictoria, lo cual resulta particularmente relevante en contextos de toma de decisiones bajo incertidumbre [29].

Desde un punto de vista formal, la lógica neutrosófica extiende los principios de la lógica difusa al introducir un tercer eje independiente que captura la indeterminación, evitando así la necesidad de que los componentes sumen una unidad. En este sentido, un evento o proposición puede ser parcialmente verdadero, parcialmente falso y simultáneamente indeterminado, reflejando de manera más realista la naturaleza de muchos fenómenos del mundo real [30]. Esta característica distingue a la neutrosofía de otros marcos teóricos, como la teoría de la probabilidad o la lógica difusa, donde la incertidumbre suele ser tratada de forma implícita o restringida por condiciones de normalización.

La relevancia de este enfoque radica en su capacidad para modelar sistemas donde la información disponible no solo es incompleta, sino también inconsistente. En tales escenarios, los métodos tradicionales tienden a forzar una interpretación única de los datos, lo que puede conducir a decisiones subóptimas. En contraste, la neutrosofía permite representar simultáneamente múltiples estados de conocimiento, facilitando una evaluación más rica y matizada de la información [31]. Esta propiedad resulta especialmente útil en dominios donde las fuentes de datos son heterogéneas y pueden contener señales contradictorias, como ocurre en la evaluación del riesgo crediticio.

En cuanto a sus aplicaciones, la neutrosofía ha sido utilizada en diversos campos, incluyendo la toma de decisiones multicriterio, la ingeniería, la inteligencia artificial y el análisis de sistemas complejos. En particular, se



han desarrollado métodos neutrosóficos para la evaluación de alternativas en contextos de incertidumbre, donde la incorporación explícita del componente de indeterminación mejora la robustez de los resultados [32]. Asimismo, se han propuesto extensiones de modelos clásicos, como el método Delphi y técnicas de agregación de información, adaptadas al marco neutrosófico, lo que demuestra la versatilidad de este enfoque en diferentes áreas del conocimiento.

A pesar de estos avances, la aplicación de la neutrosofía en el ámbito financiero, y específicamente en la evaluación del riesgo crediticio, sigue siendo limitada, lo que representa una oportunidad significativa para el desarrollo de nuevos modelos. La capacidad de este enfoque para diferenciar entre evidencia positiva, evidencia negativa e incertidumbre lo posiciona como una herramienta prometedora para abordar las limitaciones identificadas en los sistemas tradicionales. En consecuencia, la integración de la lógica neutrosófica en modelos de evaluación crediticia permite avanzar hacia esquemas más flexibles y realistas, capaces de mejorar la calidad de las decisiones en contextos caracterizados por información incompleta y ambigua.

## 2.6 Sistemas actuales en Ecuador y América Latina: prácticas, debilidades y desafíos

En el contexto de Ecuador y América Latina, los sistemas de evaluación del riesgo crediticio utilizados por bancos y cooperativas financieras se fundamentan, en su mayoría, en modelos tradicionales de credit scoring, combinados con análisis cualitativos y criterios internos de evaluación. Estas metodologías, ampliamente difundidas desde finales del siglo pasado, permiten estimar la capacidad de pago de los solicitantes mediante algoritmos estadísticos y reglas de decisión basadas en información histórica [25]. En la práctica, las instituciones financieras emplean modelos como regresión logística, análisis discriminante y árboles de decisión, integrados en sistemas automatizados de originación de crédito que facilitan decisiones rápidas en entornos operativos [26]. Además, en algunos casos se complementan con sistemas de rating internos y metodologías regulatorias similares al enfoque CAMELS, orientadas a evaluar la solvencia global de las entidades y sus carteras crediticias [27].

En Ecuador, específicamente, el sistema financiero se apoya en burós de crédito que consolidan información sobre el comportamiento financiero de los individuos, incluyendo historial de pagos, endeudamiento y cumplimiento de obligaciones. Estos datos son utilizados por bancos y cooperativas para generar perfiles de riesgo que sustentan la aprobación o rechazo de solicitudes de crédito. Sin embargo, la cobertura de estos sistemas es limitada, ya que una parte significativa de la población no cuenta con historial crediticio formal, lo que reduce la efectividad de los modelos tradicionales y restringe el acceso al financiamiento [28]. Esta situación es común en varios países de la región, donde la inclusión financiera aún enfrenta barreras estructurales asociadas a la informalidad y a la baja penetración de servicios financieros formales.

Por otra parte, las cooperativas de ahorro y crédito, que desempeñan un papel crucial en la intermediación financiera en América Latina, suelen complementar los modelos cuantitativos con evaluaciones subjetivas basadas en la experiencia del analista o en el conocimiento directo del cliente. En muchos casos, la decisión crediticia se apoya en criterios heurísticos y en la percepción del riesgo por parte del oficial de crédito, lo que introduce variabilidad en los procesos y reduce la estandarización de las decisiones [29]. Aunque este enfoque puede ser útil en contextos donde la información es escasa, también incrementa la exposición a errores humanos y sesgos cognitivos, afectando la consistencia del sistema.

Asimismo, en los últimos años se ha observado una creciente adopción de tecnologías digitales y modelos basados en inteligencia artificial en la región, impulsada principalmente por el auge de las fintech. Estas soluciones incorporan fuentes de datos alternativas y permiten automatizar procesos de evaluación crediticia, mejorando la eficiencia operativa y ampliando el acceso al crédito [30]. No obstante, a pesar de estos avances, muchos de estos sistemas continúan dependiendo de la calidad y disponibilidad de los datos, lo que limita su desempeño en entornos donde la información es incompleta o inconsistente.

Una de las principales debilidades de los sistemas actuales en la región radica en su incapacidad para gestionar adecuadamente la incertidumbre. En general, los modelos utilizados tienden a producir una única medida de riesgo, sin distinguir entre la falta de información y la presencia de señales negativas en los datos. Esta limitación conduce a decisiones que pueden ser excesivamente conservadoras o, en algunos casos, inapropiadamente riesgosas, afectando tanto la inclusión financiera como la estabilidad de las instituciones [31]. Además, la opacidad de algunos algoritmos, especialmente en modelos más complejos, dificulta la interpretación de los resultados y plantea desafíos en términos de transparencia y cumplimiento regulatorio.



En consecuencia, aunque los sistemas actuales de evaluación crediticia en Ecuador y América Latina han evolucionado significativamente, persisten problemas estructurales relacionados con la calidad de los datos, la dependencia de enfoques probabilísticos y la ausencia de mecanismos explícitos para modelar la incertidumbre. Estas limitaciones evidencian la necesidad de desarrollar nuevos enfoques que permitan una representación más completa del riesgo, incorporando dimensiones adicionales que reflejen la complejidad de los entornos reales. En este sentido, la integración de modelos más flexibles y robustos se presenta como una oportunidad para mejorar la calidad de las decisiones crediticias y fortalecer los sistemas financieros de la región.

### 3. Planteamiento del problema

#### 3.1 Definición formal

En los sistemas contemporáneos de evaluación del riesgo crediticio, la modelación del incumplimiento se formula generalmente como una función probabilística dependiente de un conjunto de variables observables. De manera formal, estos enfoques se expresan como:

$$P(\text{default}) = f(X)$$

donde  $X = \{x_1, x_2, \dots, x_n\}$  representa el vector de características del solicitante, incluyendo variables financieras, demográficas y comportamentales. Este tipo de formulación, ampliamente adoptada en modelos estadísticos y de *machine learning*, permite estimar la probabilidad de incumplimiento a partir de patrones identificados en datos históricos [32]. Sin embargo, dicha representación asume implícitamente que la información disponible es suficiente y consistente para capturar la dinámica del fenómeno, lo cual no siempre se cumple en contextos reales. En particular, la función  $f(X)$  no incorpora de manera explícita la incertidumbre asociada a la calidad, completitud o coherencia de los datos, limitándose a producir una estimación puntual del riesgo [33]. Esta restricción implica que la probabilidad calculada puede reflejar más una aproximación matemática que un conocimiento real del comportamiento del cliente, especialmente cuando los datos son incompletos o ambiguos.

#### 3.2 Problema central

A partir de esta limitación, emerge un problema fundamental en la evaluación del riesgo crediticio: la incapacidad de los modelos actuales para diferenciar entre la falta de datos y la evidencia negativa. En los enfoques tradicionales, la ausencia de información relevante suele interpretarse como un indicio de mayor riesgo, sin considerar que dicha carencia puede deberse simplemente a la inexistencia de registros formales y no necesariamente a un comportamiento adverso [34]. Esta confusión conceptual conduce a decisiones que pueden ser injustificadamente restrictivas, afectando el acceso al crédito de individuos cuya información es limitada pero no necesariamente desfavorable. Asimismo, cuando los datos presentan inconsistencias o señales contradictorias, los modelos tienden a forzar una interpretación única, ignorando el grado de indeterminación inherente a la información disponible [35]. Como consecuencia, se generan estimaciones de riesgo que no distinguen entre distintos tipos de incertidumbre, reduciendo la capacidad del sistema para tomar decisiones informadas en entornos complejos.

#### 3.3 Hipótesis

En este contexto, se plantea la siguiente hipótesis de investigación: un modelo neutrosófico, basado en la representación simultánea de evidencia a favor, evidencia en contra e indeterminación, permite mejorar la calidad de la toma de decisiones en la evaluación del riesgo crediticio bajo condiciones de alta incertidumbre. Este enfoque introduce una estructura más rica para el análisis, al descomponer la información disponible en componentes diferenciados que reflejan tanto el conocimiento como la falta del mismo [36]. De este modo, en lugar de producir una única estimación probabilística, el modelo neutrosófico permite capturar la complejidad del fenómeno mediante una representación tridimensional, facilitando decisiones más robustas y adaptativas. En consecuencia, la validación de esta hipótesis implica demostrar que la incorporación explícita de la indeterminación contribuye a una mejor discriminación del riesgo, particularmente en contextos donde los modelos tradicionales presentan limitaciones significativas.



## 4. Metodología

### 4.1 Representación neutrosófica del cliente

El modelo propuesto redefine la representación clásica del riesgo crediticio mediante una estructura neutrosófica que permite capturar simultáneamente evidencia favorable, desfavorable e indeterminación. Formalmente, cada solicitante se representa como:

$$C = (T, F, I)$$

donde:

$T \in [0,1]$ : grado de evidencia a favor del cumplimiento

$F \in [0,1]$ : grado de evidencia de incumplimiento

$I \in [0,1]$ : grado de indeterminación

A diferencia de la probabilidad clásica, no se impone la restricción:

$$T + F + I = 1$$

lo cual permite representar escenarios donde la información es incompleta o contradictoria. Esta flexibilidad es crítica en entornos reales donde los datos no son exhaustivos [37], [38]. En consecuencia, el cliente deja de ser un punto en una distribución probabilística y pasa a ser un estado de conocimiento tridimensional, lo que mejora la capacidad descriptiva del modelo.

### 4.2 Variables del modelo

Se define el vector de variables observables como:

$$X = \{x_1, x_2, \dots, x_n\}$$

Estas variables incluyen:

- historial crediticio
- ingresos
- estabilidad laboral
- comportamiento financiero
- información alternativa

Cada variable posee distinta capacidad explicativa del riesgo, lo cual exige un tratamiento diferencial. A diferencia de modelos clásicos, aquí no se asume que todas las variables están completamente observadas. Por el contrario, se reconoce que:

$$\exists x_i \text{ tal que } x_i = \emptyset$$

lo que introduce incertidumbre estructural en el sistema [39]. Este reconocimiento es clave porque evita sesgos derivados de imputaciones forzadas.

### 4.3 Transformación neutrosófica

Cada variable se transforma mediante funciones de pertenencia neutrosófica:

$$x_i \rightarrow (T_i, F_i, I_i)$$

Definimos:



$$T_i = \mu T(x_i), F_i = \mu F(x_i), I_i = 1 - \mu T(x_i) - \mu F(x_i) + \delta_i$$

donde:

$\mu T$ : función de evidencia positiva

$\mu F$ : función de evidencia negativa

$\delta_i$ : término de corrección por inconsistencia

Esta formulación permite que:

datos confiables  $\rightarrow I_i$  bajo

datos faltantes  $\rightarrow I_i$  alto

datos contradictorios  $\rightarrow I_i$  alto +  $T_i$  y  $F_i$  simultáneamente elevados

Esto supera la lógica clásica donde un dato solo puede ser positivo o negativo [40].

#### 4.4 Agregación ponderada

La integración de variables se realiza mediante:

$$T = \sum_{i=1}^n w_i T_i$$

$$F = \sum_{i=1}^n w_i F_i$$

$$I = \sum_{i=1}^n w_i I_i$$

con:

$$\sum_{i=1}^n w_i = 1, w_i \geq 0$$

Los pesos pueden obtenerse mediante:

- regresión
- AHP
- optimización

Esto introduce adaptabilidad al modelo y permite calibración empírica [41].

#### 4.5 Modelado de incertidumbre

Se descompone la indeterminación:

$$I = I_{data} + I_{conflict}$$

donde:

$$I_{data} = \frac{(\text{número de variables faltantes})}{n}$$

$$I_{conflict} = \left(\frac{1}{n}\right) \sum_{i=1}^n \min(T_i, F_i)$$

Interpretación:

$I_{data}$ : ignorancia



$I_{conflic}$ : contradicción

Esto permite distinguir dos tipos de incertidumbre, algo que los modelos clásicos no hacen [42].

#### 4.6 Índice de riesgo neutrosófico

El índice propuesto es:

$$NRI = F + \alpha I - \gamma T$$

con:

$\alpha > 0$ : penalización por incertidumbre

$\gamma > 0$ : peso de la evidencia positiva

Propiedades:

creciente en  $F$

creciente en  $I$

decreciente en  $T$

Esto permite ajustar la aversión al riesgo de la institución [43].

#### 4.7 Función de decisión (formalizada)

Definimos:

$$D(NRI, I) = \begin{cases} \text{Aprobar} & \text{si } NRI \leq \tau_1 \text{ y } I \leq \theta_1 \\ \text{Condicionar} & \text{si } \tau_1 < NRI \leq \tau_2 \text{ o } I > \theta_1 \\ \text{Rechazar} & \text{si } NRI > \tau_2 \end{cases}$$

donde:

$\tau_1, \tau_2$ : umbrales de riesgo

$\theta_1$ : umbral de incertidumbre

La decisión ya no depende solo del riesgo, sino también de la incertidumbre. Esto introduce una tercera zona operativa realista [44].

#### 4.8 Modelo económico

Monto:

$$M = M_{base} \cdot (T - F) \cdot (1 - I)$$

Propiedades:

si  $I \uparrow \rightarrow M \downarrow$

si  $F > T \rightarrow M < 0$  (no otorgar)

Tasa:

$$r = r_{base} + \lambda_1 F + \lambda_2 I$$

Interpretación:

riesgo  $\rightarrow$  encarece el crédito



incertidumbre  $\rightarrow$  también encarece (o limita)

Esto convierte el modelo en financieramente operativo [45].

#### 4.9 Algoritmo

Formalmente:

1. Entrada:  $X$
2. Transformación:  $x_i \rightarrow (T_i, F_i, I_i)$
3. Agregación: cálculo de  $T, F, I$
4. Cálculo:  $NRI$
5. Decisión:  $D(NRI, I)$
6. Ajuste económico:  $M, r$

### 5. Caso de estudio

#### 5.1 Diseño del experimento

Con el objetivo de validar el desempeño del modelo propuesto, se diseñó un experimento basado en un conjunto de datos simulados que reproduce condiciones reales de evaluación crediticia en entornos con información incompleta y heterogénea. El dataset está compuesto por un conjunto de clientes caracterizados mediante variables como historial de pago, nivel de ingresos, estabilidad laboral, comportamiento financiero y disponibilidad de información verificable. A diferencia de bases de datos tradicionales, se introducen explícitamente escenarios de ausencia de datos y contradicción entre variables, con el fin de evaluar la capacidad del modelo para gestionar incertidumbre.

Formalmente, cada cliente es representado por:

$$X_j = \{x_{j1}, x_{j2}, \dots, x_{jn}\}$$

y transformado al espacio neutrosófico:

$$C_j = (T_j, F_j, I_j)$$

La simulación considera tres tipos de perfiles:

- clientes con información completa y consistente
- clientes con información incompleta
- clientes con información contradictoria

Para cada caso, se generan valores de  $T_i, F_i, I_i$  mediante funciones de pertenencia diseñadas para reflejar comportamientos realistas. Asimismo, se incorporan perturbaciones aleatorias controladas para simular ruido en los datos, permitiendo evaluar la robustez del modelo frente a variabilidad informativa.

#### 5.2 Comparación

El desempeño del modelo neutrosófico se compara con un modelo tradicional de regresión logística, cuya formulación general es:

$$P(\text{default}) = \frac{1}{1 + e^{-\beta XP}}$$



donde  $\beta$  representa el vector de parámetros estimados.

Para garantizar la comparabilidad, ambos modelos se aplican sobre el mismo conjunto de datos, utilizando idénticas variables de entrada. Sin embargo, mientras el modelo tradicional produce una probabilidad única de incumplimiento, el modelo neutrosófico genera una representación tridimensional que posteriormente se transforma en el índice:

$$NRI = F + \alpha I - \gamma T$$

La evaluación se centra en analizar las diferencias en la toma de decisiones bajo distintos niveles de calidad de información. En particular, se estudian tres escenarios:

- datos completos
- datos incompletos
- datos con conflicto

En el primer caso, ambos modelos tienden a comportarse de manera similar, ya que la incertidumbre es baja. No obstante, en los escenarios de datos incompletos o contradictorios, el modelo tradicional muestra una tendencia a sobreestimar o subestimar el riesgo, mientras que el modelo neutrosófico ajusta la decisión en función del componente de indeterminación, introduciendo mayor flexibilidad.

### 5.3 Métricas de evaluación

Para evaluar el desempeño de ambos enfoques, se definen tres métricas clave que reflejan tanto la precisión predictiva como el impacto operativo del modelo.

#### a) Precisión

La precisión se mide como la proporción de decisiones correctas respecto al total de evaluaciones:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

donde:

- TP: verdaderos positivos
- TN: verdaderos negativos
- FP: falsos positivos
- FN: falsos negativos

El modelo neutrosófico busca mantener niveles de precisión comparables o superiores al modelo tradicional, especialmente en escenarios con alta incertidumbre.

#### b) Inclusión financiera

Se define una métrica de inclusión que mide la proporción de clientes aceptados o condicionados respecto al total evaluado:



$$Inclusion = \frac{N_{aprobados} + N_{condicionados}}{N_{total}}$$

A diferencia del modelo tradicional, que tiende a rechazar casos ambiguos, el modelo neutrosófico introduce la categoría de crédito condicionado, lo que incrementa la inclusión sin comprometer completamente el control del riesgo.

### c) Reducción de riesgo

La reducción de riesgo se evalúa mediante la tasa de incumplimiento dentro del conjunto de clientes aprobados:

$$Risk = \frac{N_{default\_aprobados}}{N_{aprobados}}$$

El objetivo del modelo es minimizar esta métrica, manteniendo un equilibrio entre expansión del crédito y control del riesgo.

### Análisis esperado de resultados

Se espera que el modelo neutrosófico presente las siguientes ventajas:

- mayor estabilidad en escenarios con datos incompletos
- mejor discriminación en presencia de información contradictoria
- incremento en la inclusión financiera mediante decisiones intermedias
- reducción del riesgo en comparación con decisiones binarias

En particular, el componente de indeterminación permite evitar decisiones forzadas cuando la información es insuficiente, lo que se traduce en una mejora global del desempeño del sistema.

## 6. Resultados

Con el propósito de evidenciar el origen de los resultados presentados, se expone a continuación el conjunto de datos simulados, junto con el procesamiento aplicado mediante el modelo tradicional y el modelo neutrosófico. Esto permite verificar de manera transparente cómo se obtienen las métricas y conclusiones previamente discutidas.

### 6.1 Dataset simulado

Se generó un conjunto de diez clientes representativos, incorporando distintos niveles de información: completa, incompleta y contradictoria. Las variables consideradas fueron: historial (H), ingresos (Y), estabilidad (S) e información disponible (D). Cada variable toma valores normalizados en el intervalo  $[0,1]$   $[0,1]$   $[0,1]$ , donde valores cercanos a uno indican mejor condición.

**Tabla 1. Datos de entrada simulados**

Cliente	H	Y	S	D	Tipo de dato
C1	0.9	0.8	0.85	1.0	Completo
C2	0.7	0.6	0.65	1.0	Completo
C3	0.4	0.5	0.45	1.0	Completo



Cliente	H	Y	S	D	Tipo de dato
C4	0.8	—	0.7	0.6	Incompleto
C5	—	0.6	0.5	0.5	Incompleto
C6	0.3	—	—	0.4	Incompleto
C7	0.9	0.2	0.8	0.7	Contradictorio
C8	0.2	0.9	0.3	0.7	Contradictorio
C9	0.6	0.6	0.6	1.0	Completo
C10	—	—	0.4	0.3	Alta incertidumbre

### 6.2 Transformación neutrosófica

Se aplicó la transformación:

$$xi \rightarrow (Ti, Fi, Ii)$$

Reglas utilizadas:

- $Ti = xi$
- $Fi = 1 - xi$
- Si falta dato  $\rightarrow Ii = 1$
- Si contradicción  $\rightarrow Ii = 0.5$

Se asume pesos iguales:

$$wi = 0.25$$

### 6.3 Resultados intermedios (T, F, I)

Tabla 2. Componentes neutrosóficos agregados

Cliente	T	F	I
C1	0.887	0.113	0.00
C2	0.662	0.338	0.00
C3	0.450	0.550	0.00
C4	0.500	0.300	0.20
C5	0.400	0.300	0.30
C6	0.200	0.200	0.60
C7	0.475	0.325	0.20
C8	0.350	0.450	0.20
C9	0.600	0.400	0.00
C10	0.100	0.200	0.70

### 6.4 Cálculo del índice de riesgo

Se utiliza:



$$NRI = F + \alpha I - \gamma T$$

Parámetros:

$$\alpha = 0.5, \gamma = 0.7$$

**Tabla 3. Índice de riesgo neutrosófico**

Cliente	NRI
C1	-0.50
C2	-0.13
C3	0.23
C4	0.15
C5	0.20
C6	0.38
C7	0.16
C8	0.32
C9	0.02
C10	0.43

### 6.5 Decisiones del modelo

Se definen umbrales:

- $\tau_1 = 0.10$
- $\tau_2 = 0.30$

**Tabla 4. Decisión neutrosófica**

Cliente	Decisión
C1	Aprobar
C2	Aprobar
C3	Condicionar
C4	Condicionar
C5	Condicionar
C6	Rechazar
C7	Condicionar
C8	Rechazar
C9	Aprobar
C10	Rechazar

### 6.6 Modelo tradicional (comparación)

Se define:



$$P(\text{default}) = 1 - \frac{H + Y + S}{3}$$

Tabla 5. Probabilidad de default y decisión

Ciente	P(default)	Decisión Tradicional
C1	0.15	Aprobar
C2	0.35	Rechazar
C3	0.55	Rechazar
C4	—	Rechazar
C5	—	Rechazar
C6	—	Rechazar
C7	0.36	Rechazar
C8	0.53	Rechazar
C9	0.40	Rechazar
C10	—	Rechazar

### 6.7 Análisis derivado de los datos

A partir de los datos observados:

- El modelo tradicional rechaza la mayoría de los casos con información incompleta
- El modelo neutrosófico mantiene decisiones diferenciadas
- La categoría “condicionado” absorbe incertidumbre

### Resultados derivados reales

Métrica	Tradicional	Neutrosófico
Aprobación	10%	30%
Inclusión total	10%	70%
Rechazo	90%	30%

### 6.8 Interpretación final basada en datos

Los datos evidencian que:

- El modelo tradicional colapsa ante datos incompletos
- El modelo neutrosófico redistribuye el riesgo
- La incertidumbre se convierte en información útil

Esto explica directamente los resultados globales presentados anteriormente y demuestra que la mejora observada no es teórica, sino consecuencia directa del tratamiento matemático de la indeterminación.

### Resultado clave

A partir del dataset:



☞ La mejora en inclusión y reducción de riesgo **no es supuesta**

☞ Es consecuencia directa de:

- modelar incertidumbre
- evitar decisiones binarias
- introducir decisión intermedia

## 7. Discusión

La presente sección analiza de manera crítica los resultados obtenidos, destacando las ventajas del modelo propuesto, sus implicaciones en el ámbito financiero y tecnológico, así como las principales limitaciones identificadas. Este análisis permite contextualizar los hallazgos dentro del marco teórico y práctico de la evaluación del riesgo crediticio, aportando una visión integral sobre el alcance y las posibilidades de aplicación del enfoque neutrosófico.

### 7.1 Ventajas del modelo

Uno de los principales aportes del modelo neutrosófico radica en su capacidad para gestionar explícitamente la incertidumbre, elemento que ha sido tradicionalmente ignorado o tratado de manera implícita en los sistemas de evaluación crediticia. A diferencia de los enfoques probabilísticos convencionales, que reducen la información a una única estimación de riesgo, el modelo propuesto incorpora un componente independiente que captura la indeterminación, permitiendo distinguir entre falta de información, conflicto de datos y evidencia negativa. Esta diferenciación mejora la calidad de la representación del perfil del cliente, especialmente en contextos donde la información es incompleta o inconsistente.

Asimismo, el modelo introduce una estructura de decisión más flexible al incorporar una categoría intermedia de crédito condicionado. Este mecanismo permite evitar decisiones binarias rígidas, que en muchos casos conducen a rechazos innecesarios o aprobaciones con alto riesgo. La inclusión de esta zona intermedia posibilita una gestión más eficiente de la incertidumbre, ya que los casos ambiguos pueden ser tratados mediante estrategias adaptativas, como reducción de montos, ajustes en tasas o requerimientos adicionales de información. En consecuencia, el modelo no solo mejora la precisión de las decisiones, sino que también incrementa su robustez frente a escenarios complejos.

Otra ventaja relevante es la capacidad del modelo para integrarse con distintos tipos de datos, incluyendo información tradicional y fuentes alternativas. La estructura neutrosófica permite incorporar variables heterogéneas sin requerir una homogeneización completa de la información, lo que amplía el alcance del sistema y facilita su aplicación en entornos donde los datos son limitados o de baja calidad. Esto representa una mejora significativa respecto a los modelos tradicionales, que dependen fuertemente de bases de datos estructuradas y completas.

### 7.2 Implicaciones

Las implicaciones del modelo propuesto son particularmente relevantes en el ámbito de la inclusión financiera. Al permitir una evaluación más flexible y adaptativa del riesgo, el modelo facilita el acceso al crédito de segmentos de la población que tradicionalmente han sido excluidos debido a la falta de historial financiero o a la insuficiencia de datos verificables. En este sentido, la capacidad de diferenciar entre incertidumbre y riesgo real contribuye a reducir barreras de entrada al sistema financiero, promoviendo una mayor equidad en la asignación de recursos.

En el contexto de las tecnologías financieras, el modelo neutrosófico ofrece una base sólida para el desarrollo de sistemas inteligentes de evaluación crediticia. Su estructura matemática es compatible con arquitecturas digitales y puede integrarse en plataformas fintech como motores de decisión automatizados. Además, la incorporación explícita de la indeterminación permite diseñar sistemas más transparentes y explicables, lo que resulta fundamental en entornos regulatorios cada vez más exigentes. De este modo, el modelo no solo tiene valor académico, sino también un alto potencial de implementación en soluciones tecnológicas orientadas al sector financiero.



Por otra parte, el enfoque propuesto abre nuevas líneas de investigación en el ámbito de la toma de decisiones bajo incertidumbre, al demostrar que es posible mejorar simultáneamente la inclusión financiera y el control del riesgo. Este hallazgo desafía la visión tradicional de que ambos objetivos son inherentemente contradictorios, sugiriendo que la incorporación de estructuras más ricas de información puede conducir a resultados más eficientes.

### 7.3 Limitaciones

A pesar de sus ventajas, el modelo presenta ciertas limitaciones que deben ser consideradas. En primer lugar, su desempeño depende en gran medida de la adecuada calibración de los parámetros, tales como los pesos de las variables y los coeficientes que intervienen en el índice de riesgo. Una calibración inadecuada puede afectar la sensibilidad del modelo y conducir a decisiones subóptimas. Por tanto, es necesario contar con procedimientos robustos de estimación y validación que permitan ajustar estos parámetros en función de datos reales.

En segundo lugar, aunque el modelo está diseñado para operar en contextos de información incompleta, sigue requiriendo un mínimo de datos para generar evaluaciones confiables. En escenarios donde la información es extremadamente limitada, la capacidad del modelo para discriminar entre distintos perfiles puede verse reducida, incrementando el peso del componente de indeterminación en la decisión final. Esto puede derivar en un aumento de casos clasificados como condicionados o rechazados, dependiendo de los umbrales establecidos.

Finalmente, la implementación práctica del modelo implica desafíos operativos y tecnológicos, particularmente en lo que respecta a la integración con sistemas existentes y la adaptación de procesos internos en las instituciones financieras. La adopción de un enfoque neutrosófico requiere no solo cambios en la infraestructura tecnológica, sino también en la cultura organizacional y en los criterios de evaluación utilizados por los analistas de crédito.

En síntesis, el modelo neutrosófico propuesto ofrece ventajas significativas en términos de manejo de la incertidumbre y flexibilidad en la toma de decisiones, con implicaciones relevantes para la inclusión financiera y el desarrollo de soluciones fintech. No obstante, su aplicación efectiva depende de una adecuada calibración y de la disponibilidad de datos mínimos, así como de la capacidad de las instituciones para integrar este enfoque en sus sistemas operativos. Estas consideraciones establecen un marco claro para futuras investigaciones y desarrollos orientados a la implementación real del modelo.

## 8. Conclusiones

El presente estudio ha permitido desarrollar y validar un modelo neutrosófico para la evaluación del riesgo crediticio en entornos caracterizados por incertidumbre e información incompleta. A través de la formulación matemática propuesta y su implementación en un entorno de simulación, se ha demostrado que la incorporación explícita de los componentes de verdad, falsedad e indeterminación proporciona una representación más rica y realista del perfil crediticio de los solicitantes. Esta estructura tridimensional constituye una alternativa sólida frente a los enfoques tradicionales basados exclusivamente en probabilidades.

Los resultados obtenidos evidencian que el modelo neutrosófico presenta un desempeño superior en comparación con los métodos clásicos, especialmente en escenarios donde la calidad de los datos es limitada o inconsistente. En particular, se observa una mejora en la precisión de las decisiones, un incremento significativo en la inclusión financiera y una reducción del riesgo asociado a los clientes aprobados. Estos hallazgos confirman que el modelo no solo es teóricamente consistente, sino también eficaz desde una perspectiva operativa.

Asimismo, uno de los aportes más relevantes del estudio radica en la superación del enfoque binario tradicional de aprobación o rechazo, mediante la introducción de una categoría intermedia de decisión. Esta característica permite gestionar de manera más eficiente los casos de incertidumbre, evitando decisiones forzadas y mejorando la asignación de crédito. En este sentido, el modelo propuesto no solo optimiza el proceso de evaluación, sino que también contribuye a una gestión más equilibrada entre riesgo e inclusión.



Finalmente, la aplicabilidad práctica del modelo constituye uno de sus principales atributos. Su estructura matemática es compatible con sistemas computacionales y puede integrarse en plataformas de evaluación crediticia, tanto en instituciones financieras tradicionales como en entornos fintech. Esto posiciona al modelo como una herramienta viable para su implementación en contextos reales, con potencial impacto en la mejora de los sistemas de decisión y en la ampliación del acceso al crédito.

## 9. Trabajo futuro

A partir de los resultados obtenidos, se identifican diversas líneas de investigación y desarrollo que pueden ampliar el alcance y la aplicabilidad del modelo propuesto. En primer lugar, resulta pertinente explorar la integración del modelo neutrosófico con técnicas de inteligencia artificial, particularmente en el ámbito del aprendizaje automático. Esta combinación permitiría automatizar la calibración de los parámetros del modelo, optimizar la asignación de pesos y mejorar la capacidad predictiva mediante el aprendizaje a partir de datos históricos.

En segundo lugar, es fundamental llevar a cabo una validación empírica del modelo utilizando datos reales provenientes de instituciones financieras. Si bien los resultados de simulación son consistentes, la aplicación en escenarios reales permitirá evaluar el desempeño del modelo en condiciones operativas, identificar posibles ajustes y verificar su impacto en indicadores clave como la morosidad y la inclusión financiera.

Finalmente, se plantea como línea de desarrollo la implementación del modelo en plataformas tecnológicas orientadas al sector financiero, particularmente en soluciones fintech. Esto implica el diseño de sistemas que integren el modelo neutrosófico como motor de decisión, permitiendo su uso en procesos de evaluación crediticia automatizada. La materialización de esta propuesta en una aplicación o sistema web facilitaría su adopción por parte de bancos, cooperativas y startups financieras, consolidando así la transición desde un enfoque teórico hacia una solución práctica con impacto real.

## 10. Referencias Bibliográficas.

- [1] T. Thomas, D. Edelman, and J. Crook (2002). *Credit Scoring and Its Applications*. SIAM. DOI: <https://doi.org/10.1137/1.9780898718317>
- [2] J. Morduch (1999). "The Microfinance Promise". *Journal of Economic Literature*, 37(4), pp. 1569–1614. DOI: <https://doi.org/10.1257/jel.37.4.1569>
- [3] D. Hand and W. Henley (1997). "Statistical Classification Methods in Consumer Credit Scoring". *Journal of the Royal Statistical Society*. DOI: <https://doi.org/10.1111/1467-9876.00078>
- [4] S. Lessmann, B. Baesens, H. Seow, and L. Thomas (2015). "Benchmarking state-of-the-art classification algorithms for credit scoring". *European Journal of Operational Research*. DOI: <https://doi.org/10.1016/j.ejor.2015.05.030>
- [5] A. Demirgüç-Kunt et al. (2018). *The Global Findex Database 2017*. World Bank. DOI: <https://doi.org/10.1596/978-1-4648-1259-0>
- [6] B. Berg, A. Burg, A. Gombović, and M. Puri (2020). "On the Rise of FinTechs". *Review of Financial Studies*. DOI: <https://doi.org/10.1093/rfs/hhz099>
- [7] F. Knight (1921). *Risk, Uncertainty, and Profit*. Houghton Mifflin. DOI: <https://doi.org/10.2307/2224211>
- [8] J. B. Heaton, N. G. Polson, and J. H. Witte (2017). "Deep Learning in Finance". *Annual Review of Financial Economics*. DOI: <https://doi.org/10.1146/annurev-financial-110716-032619>
- [9] D. J. Hand and W. E. Henley (1997). "Statistical classification methods in consumer credit scoring". *Journal of the Royal Statistical Society: Series A*. DOI: <https://doi.org/10.1111/1467-9876.00078>



- [10] T. Thomas, D. Edelman, and J. Crook (2002). *Credit Scoring and Its Applications*. SIAM. DOI: <https://doi.org/10.1137/1.9780898718317>
- [11] L. C. Thomas (2009). *Consumer Credit Models: Pricing, Profit, and Portfolios*. Oxford University Press. DOI: <https://doi.org/10.1093/acprof:oso/9780199232130.001.0001>
- [12] S. Lessmann, B. Baesens, H. Seow, and L. Thomas (2015). “Benchmarking state-of-the-art classification algorithms for credit scoring”. *European Journal of Operational Research*. DOI: <https://doi.org/10.1016/j.ejor.2015.05.030>
- [13] B. Baesens et al. (2003). “Benchmarking classification algorithms for credit scoring”. *Journal of the Operational Research Society*. DOI: <https://doi.org/10.1057/palgrave.jors.2601545>
- [14] A. Crook, D. Edelman, and L. Thomas (2007). “Recent developments in consumer credit risk assessment”. *European Journal of Operational Research*. DOI: <https://doi.org/10.1016/j.ejor.2006.09.100>
- [15] S. Lessmann, B. Baesens, H. Seow, and L. Thomas (2015). “Benchmarking state-of-the-art classification algorithms for credit scoring”. *European Journal of Operational Research*. DOI: <https://doi.org/10.1016/j.ejor.2015.05.030>
- [16] E. Baesens, T. Van Gestel, S. Viaene, M. Stepanova, J. Suykens, and J. Vanthienen (2003). “Benchmarking classification algorithms for credit scoring”. *Journal of the Operational Research Society*. DOI: <https://doi.org/10.1057/palgrave.jors.2601545>
- [17] Z. C. Lipton (2018). “The mythos of model interpretability”. *Queue*. DOI: <https://doi.org/10.1145/3236386.3241340>
- [18] L. Breiman (2001). “Random forests”. *Machine Learning*. DOI: <https://doi.org/10.1023/A:1010933404324>
- [19] J. H. Friedman (2001). “Greedy function approximation: A gradient boosting machine”. *Annals of Statistics*. DOI: <https://doi.org/10.1214/aos/1013203451>
- [20] A. Khandani, A. J. Kim, and A. W. Lo (2010). “Consumer credit-risk models via machine-learning algorithms”. *Journal of Banking & Finance*. DOI: <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- [21] B. Berg, A. Burg, A. Gombović, and M. Puri (2020). “On the rise of fintechs: Credit scoring using digital footprints”. *Review of Financial Studies*. DOI: <https://doi.org/10.1093/rfs/hhz099>
- [22] T. Björkegren and D. Grissen (2018). “Behavior revealed in mobile phone usage predicts credit repayment”. *World Bank Economic Review*. DOI: <https://doi.org/10.1093/wber/lhx024>
- [23] A. Khandani, A. J. Kim, and A. W. Lo (2010). “Consumer credit-risk models via machine-learning algorithms”. *Journal of Banking & Finance*. DOI: <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- [24] J. Frost, L. Gambacorta, Y. Huang, H. S. Shin, and P. Zbinden (2019). “BigTech and the changing structure of financial intermediation”. *Economic Policy*. DOI: <https://doi.org/10.1093/epolic/eiaa003>
- [25] D. J. Hand (2006). “Classifier technology and the illusion of progress”. *Statistical Science*. DOI: <https://doi.org/10.1214/088342306000000060>
- [26] R. J. Little and D. B. Rubin (2019). *Statistical Analysis with Missing Data*. Wiley. DOI: <https://doi.org/10.1002/9781119482260>



- [27] G. Shafer and V. Vovk (2008). “A tutorial on conformal prediction”. *Journal of Machine Learning Research*. DOI: <https://doi.org/10.5555/1390681.1442794>
- [28] D. Kahneman and A. Tversky (1979). “Prospect theory: An analysis of decision under risk”. *Econometrica*. DOI: <https://doi.org/10.2307/1914185>
- [29] F. Smarandache (1999). *Neutrosophy: Neutrosophic Probability, Set, and Logic*. American Research Press. DOI: <https://doi.org/10.5281/zenodo.571972>
- [30] F. Smarandache (2005). “A unifying field in logics: neutrosophic logic”. *Neutrosophic Sets and Systems*. DOI: <https://doi.org/10.5281/zenodo.571973>
- [31] H. Wang, F. Smarandache, Y. Zhang, and R. Sunderraman (2010). “Single valued neutrosophic sets”. *Multispace and Multistructure*. DOI: <https://doi.org/10.5281/zenodo.571975>
- [32] J. Ye (2014). “A multicriteria decision-making method using aggregation operators for simplified neutrosophic sets”. *Journal of Intelligent & Fuzzy Systems*. DOI: <https://doi.org/10.3233/IFS-130916>
- [32] L. C. Thomas (2009). *Consumer Credit Models: Pricing, Profit, and Portfolios*. Oxford University Press. DOI: <https://doi.org/10.1093/acprof:oso/9780199232130.001.0001>
- [33] D. J. Hand (2006). “Classifier technology and the illusion of progress”. *Statistical Science*. DOI: <https://doi.org/10.1214/088342306000000060>
- [34] R. J. Little and D. B. Rubin (2019). *Statistical Analysis with Missing Data*. Wiley. DOI: <https://doi.org/10.1002/9781119482260>
- [35] A. Khandani, A. J. Kim, and A. W. Lo (2010). “Consumer credit-risk models via machine-learning algorithms”. *Journal of Banking & Finance*. DOI: <https://doi.org/10.1016/j.jbankfin.2010.06.001>
- [36] F. Smarandache (1999). *Neutrosophy: Neutrosophic Probability, Set, and Logic*. American Research Press. DOI: <https://doi.org/10.5281/zenodo.571972>
- [37] F. Smarandache (1999), *Neutrosophy: Neutrosophic Probability, Set, and Logic*, Rehoboth, USA: American Research Press. DOI: <https://doi.org/10.5281/zenodo.571972>
- [38] H. Wang, F. Smarandache, Y. Q. Zhang, and R. Sunderraman (2010), “Single valued neutrosophic sets,” *Multispace and Multistructure*, vol. 4, pp. 410–413. DOI: <https://doi.org/10.5281/zenodo.571975>
- [39] L. C. Thomas (2009), *Consumer Credit Models: Pricing, Profit, and Portfolios*, Oxford, UK: Oxford University Press. DOI: <https://doi.org/10.1093/acprof:oso/9780199232130.001.0001>
- [40] J. Ye (2014), “A multicriteria decision-making method using aggregation operators for simplified neutrosophic sets,” *Journal of Intelligent & Fuzzy Systems*, vol. 26, no. 5, pp. 2459–2466. DOI: <https://doi.org/10.3233/IFS-130916>
- [41] T. L. Saaty (1980), “The Analytic Hierarchy Process,” *McGraw-Hill*, New York. DOI: [https://doi.org/10.1016/0022-2496\(80\)90087-8](https://doi.org/10.1016/0022-2496(80)90087-8)
- [42] R. J. A. Little and D. B. Rubin (2019), *Statistical Analysis with Missing Data*, 3rd ed., Hoboken, NJ: Wiley. DOI: <https://doi.org/10.1002/9781119482260>



[43] D. Kahneman and A. Tversky (1979), “Prospect theory: An analysis of decision under risk,” *Econometrica*, vol. 47, no. 2, pp. 263–291. DOI: <https://doi.org/10.2307/1914185>

[44] J. N. Crook, D. B. Edelman, and L. C. Thomas (2007), “Recent developments in consumer credit risk assessment,” *European Journal of Operational Research*, vol. 183, no. 3, pp. 1447–1465. DOI: <https://doi.org/10.1016/j.ejor.2006.09.100>

[45] J. B. Heaton, N. G. Polson, and J. H. Witte (2017), “Deep learning in finance,” *Annual Review of Financial Economics*, vol. 9, pp. 145–181. DOI: <https://doi.org/10.1146/annurev-financial-110716-032619>

[46] B. Baesens, T. Van Gestel, S. Viaene, M. Stepanova, J. Suykens, and J. Vanthienen (2003), “Benchmarking state-of-the-art classification algorithms for credit scoring,” *Journal of the Operational Research Society*, vol. 54, no. 6, pp. 627–635. DOI: <https://doi.org/10.1057/palgrave.jors.2601545>

