Neutrosophic Computing and Machine Learning , Vol. 39, 2025
University of New Mexico

Integración de Decisiones Académicas y Clustering con el Método NAHP+NSC Neutrosófico en Sistemas Recomendadores para Estudiantes

Integration of Academic Decisions and Clustering with the Neutrosophic NAHP+NSC Method in Recommender Systems for Students

Alfonso A. Guijarro-Rodríguez [1], Juan Carlos Cedeño-Rodríguez [2*], Silvia Adriana Ruata Avilés [3], Mirella C. Ortiz-Zambrano [4],

[1] Facultad de Ciencias Matemáticas y Físicas. Universidad de Guayaquil. Ecuador. alfonso.guijarror@ug.edu.ec, https://orcid.org/0000-0001-6046-426X

[2] Facultad de Ciencias Matemáticas y Físicas. Universidad de Guayaquil. Ecuador. juan.cedenor@ug.edu.ec, https://orcid.org/0000-0002-3985-3858

[3] Facultad de Ciencias Matemáticas y Físicas. Universidad de Guayaquil. Ecuador. silvia.ruataav@ug.edu.ec, https://orcid.org/0000-0002-4145-3917

[4] Facultad de Ciencias Matemáticas y Físicas. Universidad de Guayaquil. Ecuador. mirella.ortizz@ug.edu.ec, https://orcid.org/0000-0001-9290-4194

Resumen.

La investigación aborda la dificultad de los estudiantes de la carrera de Software para seleccionar asignaturas que optimicen su perfil académico, un desafío crítico en entornos educativos donde la personalización es clave. Este tema cobra relevancia en el contexto actual, dado el creciente uso de tecnologías de recomendación para mejorar trayectorias académicas, impactando positivamente la formación profesional. Sin embargo, la literatura existente carece de enfoques que integren la incertidumbre inherente a las preferencias estudiantiles con métodos de clustering robustos. Para superar esta brecha, el estudio propone un sistema recomendador basado en el método NAHP+NSC neutrosófico, combinando el Proceso Analítico Jerárquico Neutrosófico (NAHP) con Clustering de Conjuntos Neutrosóficos (NSC). Mediante encuestas y análisis de calificaciones, se evalúan preferencias y desempeño académico, manejando indeterminaciones con herramientas neutrosóficas implementadas en Python. Los resultados revelan que el modelo identifica con precisión asignaturas óptimas, logrando una factibilidad del 80% en la predicción de perfiles académicos. Esta investigación aporta una metodología innovadora que enriquece la toma de decisiones educativas, ofreciendo a estudiantes y docentes una guía práctica para personalizar trayectorias

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

académicas. Además, sienta las bases para futuros desarrollos interdisciplinarios, como la integración con chatbots o estudios psicológicos, fortaleciendo la aplicabilidad de sistemas recomendadores en contextos universitarios.

Palabras clave: Sistema Recomendador, Perfil Académico, NAHP Neutrosófico, Clustering Neutrosófico, Toma De Decisiones, Personalización Educativa, Incertidumbre.

Abstract.

The research addresses the difficulty faced by Software Engineering students in selecting courses that optimize their academic profile—a critical challenge in educational environments where personalization is key. This issue gains relevance in the current context, given the growing use of recommendation technologies to enhance academic pathways, positively impacting professional training. However, the existing literature lacks approaches that integrate the inherent uncertainty of student preferences with robust clustering methods. To bridge this gap, the study proposes a recommender system based on the neutrosophic NAHP+NSC method, combining the Neutrosophic Analytic Hierarchy Process (NAHP) with Neutrosophic Set Clustering (NSC). Through surveys and grade analysis, student preferences and academic performance are evaluated, while uncertainties are managed using neutrosophic tools implemented in Python. The results reveal that the model accurately identifies optimal courses, achieving an 80% feasibility in predicting academic profiles. This research contributes an innovative methodology that enhances educational decision-making, offering students and instructors a practical guide for personalizing academic trajectories. Furthermore, it lays the groundwork for future interdisciplinary developments, such as integration with chatbots or psychological studies, thereby strengthening the applicability of recommender systems in university contexts.

Keywords: Recommender System, Academic Profile, Neutrosophic NAHP, Neutrosophic Clustering, Decision-Making, Educational Personalization, Uncertainty.

1. Introducción

La personalización de trayectorias académicas en estudiantes de la carrera de Software representa un desafío crucial en la educación superior moderna, donde la tecnología desempeña un papel transformador. La integración de sistemas recomendadores inteligentes permite orientar a los estudiantes hacia asignaturas que potencien sus fortalezas y mitiguen sus debilidades, optimizando así su formación profesional. Este tema adquiere relevancia en un contexto donde la demanda de profesionales altamente capacitados en tecnología crece exponencialmente, y las universidades buscan herramientas innovadoras para mejorar el rendimiento académico [1]. La capacidad de los sistemas de recomendación para analizar datos complejos y ofrecer soluciones personalizadas ha revolucionado diversos sectores, desde el comercio electrónico hasta la educación, destacando su potencial para transformar la experiencia estudiantil [2]. Este estudio propone un enfoque novedoso que combina decisiones académicas con técnicas de clustering, abordando las limitaciones de los métodos tradicionales al incorporar herramientas que manejan la incertidumbre inherente a las preferencias humanas.

Históricamente, los sistemas de recomendación han evolucionado desde enfoques basados en filtrado colaborativo hasta modelos híbridos que integran aprendizaje automático y análisis contextual. En el ámbito educativo, su aplicación ha crecido en las últimas dos décadas, especialmente en plataformas de aprendizaje en línea, donde han demostrado mejorar la retención y el compromiso estudiantil [3]. En Ecuador, instituciones como la Universidad Politécnica Salesiana han implementado sistemas recomendadores para niños, evidenciando su adaptabilidad a contextos educativos diversos [4]. Sin embargo, en la educación superior, particularmente en carreras técnicas como Software, la falta de sistemas que consideren tanto el desempeño académico como las preferencias individuales sigue siendo una barrera significativa. Este vacío motiva la exploración de metodologías avanzadas que aborden la complejidad de las decisiones académicas en entornos dinámicos. El problema central de esta investigación radica en la dificultad de los estudiantes de Software para seleccionar asignaturas que se alineen con sus habilidades y objetivos profesionales, en un contexto donde la incertidumbre y la variabilidad de sus preferencias complican la toma de decisiones. Las metodologías tradicionales, como los sistemas basados en promedios o filtrado colaborativo, no logran capturar la ambigüedad inherente a las percepciones estudiantiles, lo que limita la personalización de las recomendaciones [5]. ¿Cómo puede un sistema recomendador integrar decisiones académicas y clustering para generar perfiles académicos precisos, considerando la incertidumbre en las preferencias y el desempeño de los estudiantes? Esta pregunta orienta el estudio, buscando una solución que combine

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

rigor analítico con aplicabilidad práctica.

Para abordar este problema, el estudio propone el uso del método NAHP+NSC neutrosófico, una combinación del Proceso Analítico Jerárquico Neutrosófico (NAHP) y el Clustering de Conjuntos Neutrosóficos (NSC). Este enfoque permite modelar la incertidumbre en las preferencias y calificaciones de los estudiantes, utilizando encuestas y análisis de datos implementados en entornos de programación como Python [6]. A diferencia de los métodos convencionales, el enfoque neutrosófico captura la indeterminación inherente a las decisiones humanas, ofreciendo una perspectiva más completa. La metodología se apoya en un prototipo de software que procesa datos cualitativos y cuantitativos, generando recomendaciones personalizadas que respetan las normativas de matriculación universitaria.

El interés en sistemas recomendadores para educación ha crecido debido a su capacidad para mejorar la eficiencia y la satisfacción estudiantil. Estudios previos han destacado cómo los sistemas basados en contenido pueden adaptarse a las necesidades individuales, pero pocos han explorado la integración de técnicas avanzadas de clustering con enfoques que manejen incertidumbre [7]. En este sentido, el método NAHP+NSC neutrosófico se presenta como una innovación, al combinar la jerarquización de decisiones con la segmentación de datos en un marco que considera la ambigüedad. Este enfoque es particularmente relevante en carreras técnicas, donde las asignaturas varían en complejidad y requieren un análisis detallado de las capacidades del estudiante. La implementación de sistemas recomendadores en entornos educativos enfrenta desafíos, como la resistencia institucional y la falta de formación docente en tecnologías emergentes. Sin embargo, la adopción de herramientas basadas en inteligencia artificial, como las propuestas en este estudio, puede superar estas barreras al ofrecer soluciones escalables y precisas [3]. En el contexto de la Universidad de Guayaquil, donde la Facultad de Ciencias Matemáticas y Físicas carece de sistemas de este tipo, la investigación adquiere una relevancia práctica inmediata. La propuesta no solo busca beneficiar a los estudiantes, sino también a docentes y autoridades, al proporcionar datos que apoyen la toma de decisiones estratégicas.

La pregunta de investigación se centra en cómo integrar decisiones académicas y clustering bajo un marco neutrosófico para generar recomendaciones personalizadas que optimicen el perfil académico. Este enfoque no solo aborda la incertidumbre en las preferencias estudiantiles, sino que también ofrece una metodología reproducible en otras disciplinas. La combinación de NAHP y NSC permite un análisis multidimensional, considerando factores como calificaciones, encuestas de preferencias y normativas institucionales, lo que garantiza recomendaciones robustas y contextualizadas.

Los objetivos del estudio son claros: primero, diseñar un sistema recomendador que utilice el método NAHP+NSC neutrosófico para generar perfiles académicos personalizados en estudiantes de Software; segundo, evaluar la precisión de las recomendaciones mediante pruebas con datos reales; y tercero, proponer un prototipo escalable que pueda integrarse en la plataforma universitaria. Estos objetivos están alineados con la pregunta de investigación, buscando no solo responder al problema planteado, sino también contribuir al avance de los sistemas recomendadores en la educación superior.

2. Preliminares.

2.1. Sistemas Recomendadores.

La integración de sistemas recomendadores en la educación superior, especialmente en la formación de perfiles académicos para estudiantes de Software, constituye una innovación significativa en la personalización del aprendizaje. Estos sistemas, que analizan datos como calificaciones y preferencias, facilitan la selección de asignaturas alineadas con las capacidades y objetivos de los estudiantes. En un contexto donde la tecnología transforma la educación, los sistemas recomendadores emergen como herramientas esenciales para optimizar trayectorias académicas, mejorando tanto el rendimiento estudiantil como la eficiencia institucional. Este trabajo argumenta la relevancia de incorporar el método NAHP+NSC neutrosófico en dichos sistemas, destacando su capacidad para manejar la incertidumbre inherente a las decisiones humanas.

Históricamente, los sistemas recomendadores han evolucionado desde enfoques básicos de filtrado colabora-

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

tivo hasta modelos avanzados que integran inteligencia artificial y aprendizaje automático. En el ámbito educativo, su aplicación ha crecido, particularmente en plataformas de e-learning, donde han demostrado mejorar la retención y el compromiso [8]. Sin embargo, en carreras técnicas como Software, donde las asignaturas varían en complejidad, los enfoques tradicionales a menudo no logran capturar la ambigüedad de las preferencias estudiantiles. Esta limitación resalta la necesidad de metodologías que aborden la incertidumbre, como el enfoque neutrosófico propuesto.

El método NAHP+NSC neutrosófico combina el Proceso Analítico Jerárquico Neutrosófico (NAHP) con el Clustering de Conjuntos Neutrosóficos (NSC), ofreciendo una solución robusta para modelar decisiones académicas complejas. Al integrar datos cuantitativos, como calificaciones, con datos cualitativos, como encuestas de preferencias, este enfoque permite generar recomendaciones personalizadas que respetan las normativas universitarias. A diferencia de los sistemas convencionales, que suelen basarse en promedios o patrones rígidos, el método neutrosófico captura la indeterminación, proporcionando un análisis más preciso de las necesidades individuales [9]. La implementación de este sistema en la Universidad de Guayaquil, donde la Facultad de Ciencias Matemáticas y Físicas carece de herramientas similares, evidencia su relevancia práctica. Los estudiantes de Software enfrentan dificultades para seleccionar asignaturas que optimicen su perfil académico, lo que puede retrasar su formación o limitar su especialización. El sistema propuesto, al analizar datos mediante algoritmos como regresión lineal y KNN, logra una factibilidad del 80% en la predicción de perfiles, según pruebas realizadas. Esta precisión subraya el potencial del enfoque neutrosófico para superar las limitaciones de los métodos tradicionales.

Además, el uso de herramientas como Python y frameworks como Laravel en el desarrollo del prototipo demuestra la viabilidad técnica del sistema. La metodología Kanban, empleada para organizar el desarrollo, evitó cuellos de botella, asegurando un proceso ágil y eficiente. Este enfoque no solo beneficia a los estudiantes, sino que también proporciona a docentes y autoridades datos valiosos para la toma de decisiones estratégicas, como la planificación curricular o la evaluación de competencias [10].

No obstante, la adopción de sistemas recomendadores enfrenta desafíos, como la resistencia institucional y la falta de formación docente en tecnologías emergentes. Estos obstáculos, comunes en entornos educativos tradicionales, pueden limitar la implementación efectiva de innovaciones tecnológicas [11]. Sin embargo, el enfoque neutrosófico mitiga estas barreras al ofrecer un marco flexible que se adapta a contextos diversos, desde universidades con recursos limitados hasta instituciones con infraestructura avanzada. Otro aspecto destacable es la capacidad del sistema para integrar variables cualitativas, como las preferencias de los estudiantes, con un peso del 30%, complementando el análisis cuantitativo de calificaciones (70%). Esta combinación asegura que las recomendaciones no solo sean precisas, sino también relevantes para el estilo de aprendizaje de cada estudiante. En comparación con sistemas basados únicamente en datos numéricos, el enfoque neutrosófico ofrece una perspectiva holística, alineada con las necesidades de la educación moderna [12].

La escalabilidad del sistema propuesto representa otra ventaja significativa. Al diseñarse como un prototipo integrable en plataformas universitarias, permite su adaptación a otras carreras y contextos educativos. Proyectos futuros podrían incorporar chatbots o colaboraciones interdisciplinarias con áreas como la psicología, enriqueciendo aún más el análisis de los perfiles académicos. Esta versatilidad posiciona al sistema como una herramienta estratégica para la educación superior en un mundo cada vez más digitalizado.

En términos de impacto, el sistema recomendador basado en NAHP+NSC neutrosófico no solo mejora la experiencia estudiantil, sino que también contribuye al avance teórico en el campo de los sistemas recomendadores. Al introducir un enfoque que maneja la incertidumbre de manera explícita, este trabajo llena una brecha en la literatura, donde los modelos tradicionales a menudo ignoran la complejidad de las decisiones humanas [9]. Este aporte es particularmente valioso en contextos educativos, donde las preferencias y el desempeño varían ampliamente entre individuos. En conclusión, la integración de decisiones académicas y clustering mediante el método NAHP+NSC neutrosófico redefine la forma en que los sistemas recomendadores pueden apoyar la formación de perfiles académicos. Su capacidad para manejar incertidumbre, combinada con su aplicabilidad práctica y escalabilidad, lo convierte en una herramienta transformadora para la educación superior. A pesar de los desafíos institucionales, los beneficios de este enfoque superan las limitaciones, abriendo nuevas oportunidades para

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

personalizar el aprendizaje y fortalecer la preparación profesional de los estudiantes de Software.

2.2. NAHP+NSC Conceptos neutrosóficos.

Definición 1 : ([13-26]) El conjunto neutrosófico N se caracteriza por tres funciones de membresía, que son la función de membresía de verdad T_A, la función de membresía de indeterminación IA_y la función de membresía de falsedad F_A, donde U es el Universo del Discurso y $\forall x \in U$, $T_A(x)$, $I_A(x)$, y $F_A(x) \subseteq]^-0,1^+[$, y $^-0 \leq \inf T_A(x) + \inf I_A(x) + \inf F_A(x) \leq \sup T_A(x) + \sup I_A(x) + \sup F_A(x) \leq 3^+$. Observe que, según la definición, $T_A(x)$, $I_A(x)$ y $F_A(x)$ son subconjuntos reales estándar o no estándar de $]^-0, 1^+[$ y, por tanto, $T_A(x)$, $I_A(x)$ y $F_A(x)$ pueden ser subintervalos de [0, 1].

Definición 2 : El conjunto neutrosófico de valor único (SVNS) N sobre U es A = {<x; TA(x), IA(x), FA(x)>: x ∈U}, donde TA: U →[0, 1], IA: U →[0, 1], y FA: U →[0, 1], 0 ≤TA(x) + IA(x) +FA(x) ≤3. El Número Neutrosófico de Valor Único (SVNN) está representado por N = (t, I, f), tal que 0 ≤t, I, f ≤1 y 0 ≤t + yo + f ≤3.

Definición 3 : el número neutrosófico trapezoidal de un solo valor, $\tilde{a} = \langle(a_1, a_2. a_3, a_4); \alpha_{\tilde{a}}, \beta_{\tilde{a}}, \gamma_{\tilde{a}}\rangle$es un conjunto neutrosófico en ℝ, cuyas funciones de pertenencia de verdad, indeterminación y falsedad se definen en [13, 15].

Definición 4 : dados $\tilde{a} = \langle(a_1, a_2, a_3, a_4); \alpha_{\tilde{a}}, \beta_{\tilde{a}}, \gamma_{\tilde{a}}\rangle$ y $\tilde{b} = \langle(b_1, b_2, b_3, b_4); \alpha_{\tilde{b}}, \beta_{\tilde{b}}, \gamma_{\tilde{b}}\rangle$ dos números neutrosóficos trapezoidales de un solo valor y λcualquier número no nulo en la línea real. Luego, las operaciones se definen en [13, 15].

Las definiciones 3 y 4 se refieren al *número neutrosófico triangular de valor único* cuando la condición $a_2 = a_3$. Para simplificar, utilizamos la escala lingüística de números neutrosóficos triangulares, consulte la Tabla 1 y también la comparamos con la escala definida en.

Tabla 1: Escala de Saaty traducida a una escala triangular neutrosófica. Fuente [15]

Definición	Escala Triangular Neutrosófica
Igualmente influyente	$\tilde{1} = \langle(1,1,1); 0.50, 0.50, 0.50\rangle$
Ligeramente influyente	$\tilde{3} = \langle(2, 3, 4); 0.30, 0.75, 0.70\rangle$
Fuertemente influyente	$\tilde{5} = \langle(4, 5, 6); 0.80, 0.15, 0.20\rangle$
Muy influyente	$\tilde{7} = \langle(6, 7, 8); 0.90, 0.10, 0.10\rangle$
Absolutamente influyente	$\tilde{9} = \langle(9, 9, 9); 1.00, 1.00, 1.00\rangle$
Valores esporádicos entre dos escalas cercanas	$\tilde{2} = \langle(1, 2, 3); 0.40, 0.65, 0.60\rangle$ $\tilde{4} = \langle(3, 4, 5); 0.60, 0.35, 0.40\rangle$ $\tilde{6} = \langle(5, 6, 7); 0.70, 0.25, 0.30\rangle$ $\tilde{8} = \langle(7, 8, 9); 0.85, 0.10, 0.15\rangle$

Para la verificación del modelo de proceso de jerarquía analítica en una metodología de entorno neutrosófico (N-AHP), consulte [13, 15-17] .

Teoría de la elección social neutrosófica

Esta subsección resume los conceptos principales de la teoría de la Elección Social Neutrosófica desarrollada en [27].

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Definición 5: ([27]) Sea a = (Ta, Ia, Fa) un número neutrosófico de valor único con valor de verdad Ta, valor de indeterminación Ia y valor de falsedad Fa. *La forma de indeterminación distribuida* (DIF) de *a* se define como $_{DIF}$ = (Ta − TaIa, 0, Fa − FaIa).
El DIF tiene como objetivo distribuir el resultado de la indeterminación sobre la verdad y la falsedad, así, mide el grado de afectación de la veracidad y la falsedad, cuando varía la indeterminación.
Definición 6: ([27]) Sea *a* un número neutrosófico de un solo valor. Una *función de precisión* H de *a* es:
$H(a) = \frac{(1+T_a-I_a\,(1-T_a)-F_a(1-I_a)}{2}$(1)
Donde para todo *a* , H $_{(a)}$ Є [0, 1]. H es una relación de orden que representa una puntuación de precisión de la información de *a* . Si H(a_1) = H(a_2), entonces a_1= a_2, es decir, tienen la misma información, mientras que, si H(a_1)< H(a_2), entonces $a_2$es mayor que a_1.
Sea S = {s1, s2, . . . , sn} será un conjunto de alternativas y m será un conjunto de individuos. Cada individuo declara sus preferencias sobre S, que están representadas por una relación de preferencia neutrosófica individual Rk, donde N R_k:
S × S → [0,1] × [0,1] × [0,1] y matriz Rk =[r_{ij}^k], j= 1,2,3,…, n; k = 1,2,3, . . . , m, donde r_{ij}^k= N R_k(r_i^k, r_j^k).

$$R_k = \begin{matrix} (0.5, 0.5, 0.5) & \\ r_{21}^k & \\ r_{n1}^k & \end{matrix}$$

La función H (llamada *índice neutrosófico* o *función de vacilación neutrosófica*) asigna cada a_{ij} valor neutrosófico a un número en [0, 1]. Así, el *índice neutrosófico* o *función de vacilación neutrosófica* se define de la siguiente manera:
$H(a) = \frac{(1+T(a_{ij})-I\,(a_{ij})\,(1-T(a_{ij}))-F(a_{ij})(1-I(a_{ij}))}{2}$(2)
La matriz R_k^H= [H(r_{ij}^k)], i, j = 1,2,3, . . , norte; k = 1, 2, 3, ..., metro. R_k^H es *casi recíproco* si y sólo si $H(r_{ij}^k) \leq 1-H(r_{ij}^k)$. Si R_k^Hno es cuasi recíproco, llamamos a k un
individuo irracional . Otras definiciones se declaran en [27].
Definición 7: ([27]) *:* $S_i \in W$ se llama *ganador por consenso* si y sólo si $\forall S_j \neq S_i: r_{ij} > 0.5$,donde$r_{ij} \in$ de$r_{ij} \in H_{\pi}$.
Definición 8: ([27]) La *función promedio de agregación social C* se define para calcular el orden de $S_i$en el grupo en la medida en que los individuos no estén en contra de la opción si, utilizando la siguiente ecuación:
$C(S_i) = \frac{1}{m-1}\sum_{i\neq j} r_{ij}$(3)
Donde i, j = 1, 2, ⋯ , m.

Método NAHP+NSC

En esta sección se presenta el método NAHP+NSC propuesto para el análisis del objeto de estudio en el artículo. El primer elemento se define para cualquier número triangular neutrosófico ã como la función de precisión triangular de ã = ‹(a1, a2, a3); αa, βa, γa›, que es la función TA definida de la siguiente manera:

$$TA(\tilde{a}) = A(‹(a1, a2, a3);\ DIF((\alpha a, \beta a, \gamma a))›) \quad (4)$$

Este es el grado de precisión de la Ecuación 6 calculado para el DIF del número neutrosófico contenido en ã. La inclusión de DIF sigue la idea de [27], en la que la función de precisión H calcula el efecto de la Indeterminación sobre la verdad y la falsedad.

Se puede observar que las propiedades recíprocas o cuasi recíprocas en la teoría NSC son similares a la propiedad recíproca en NAHP, desde la perspectiva de la racionalidad que posee quien toma las decisiones.

El método analizado consta de los siguientes pasos:

1. Se establece el objetivo del problema y en consecuencia se selecciona el grupo de expertos. Luego se especifican atributos, subatributos y alternativas.
2. El grupo de expertos se divide en M subgrupos de interés, denotados por IG = {IG $_1$, IG $_2$, ⋯ , IG $_M$}. En el análisis se supone que los miembros de cada subgrupo forman un grupo de decisión homogéneo.
3. Cada experto evalúa su propio NAHP. Sin embargo, respecto de cada IG $_i$, las matrices equivalentes de los miembros del subgrupo se agregan mediante la fórmula 5.

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Dado {Ãi1, Vi2,…, Ã in_i} como un conjunto de n $_i$ SVTNN que representa la evaluación de cada miembro del i-ésimo subgrupo, donde Ã $_{ij}$ = ‹(a $_{ij}$, a $_{ij}$, a $_{ij}$); α $\tilde{a}_{ij}$, β $\tilde{a}_{ij}$, γ $\tilde{a}_{ij}$› (i = 1, 2, …, M)(j = 1, 2, …, n $_i$), el promedio ponderado del SVTNN se calcula usando la siguiente ecuación:

$$\tilde{A}_i = \sum_{j=1}^{n_i} \lambda_{ij} \tilde{A}_{ij} \qquad (5)$$

donde λ $_{ij}$ es el peso de Ã $_{ij}$, $\lambda_{ij} \in [0,1]$y$\sum_{j=1}^{n_i} \lambda_{ij} = 1$.

Tenga en cuenta que λ $_{ij}$ mide la importancia relativa del j-ésimo experto en el i-ésimo subgrupo.

Cada Ã $_i$ representa la matriz de comparación por pares del método NAHP en IGi, para agregar las matrices de comparación por pares de criterios, subcriterios y alternativas.

Ã $_i$ se convierte a Ã $_i$ usando la Ecuación 13. Este proceso se puede repetir hasta que los resultados sean consistentes según el Índice de Consistencia del método NAHP. Según este método se obtiene un vector de preferencia de las alternativas.

Aquí se utiliza la Agregación de Juicios Individuales (IJA) porque existe interés en medir los juicios del subgrupo como una unidad sinérgica.

Denotemos $O_i = \{O_{i1,} O_{i2}, \dots, O_{iN}\}$la posición de cada alternativa cuando la evalúan los miembros del i-ésimo subgrupo. Por ejemplo, O $_1$ = {1, 1, 3, 5, 4} significa que según el primer subgrupo, las alternativas 1 y 2 son igualmente preferidas, mientras que las siguientes son la tercera, quinta y cuarta alternativas, en ese orden. .

4. Para cada S_{il}(l = 1, 2, ..., N), V_{il}se forma el siguiente triplete $P_{il} = card\ (k \neq l: S_{il}$= (, donde P_{il}, I_{il}, N_{il}) es estrictamente preferible a S_{ik}}), I_{il}= c ard ({$k \neq l: S_{il}$es igualmente preferido a S_{ik}}), y N_{il}= card ({k ≠ l: s_{ik}es estrictamente preferido encima s_{il}}).

Se observa que, V_{il} ∈[0, N − 1] × [0, N − 1] × [0, N − 1] y P_{il}+ I_{il}+ N_{il} = N − 1.

Finalmente, $_{Vl}$ ∈ [0, 1] × [0, 1] × [0, 1], V $_l$ = (P , I $_l$, N $_l$), suma la l-ésima preferencia alternativa para todos los subgrupos, donde P_l= $\frac{\sum_{i=1}^{M} P_{il}}{M(N-1)}$, $I_l = \frac{\sum_{i=1}^{M} I_{il}}{M(N-1)}$,y$N_l = \frac{\sum_{i=1}^{M} N_{il}}{M(N-1)}$.

Tenga en cuenta que este es un método de votación neutrosófico.

5. H(V $_l$) (l = 1,2, ⋯ , N) y las alternativas se ordenan por preferencia, de modo que V $l_1$es preferible a V $l_2$si y sólo si H(V l_1) > H(V l_2). Cuando H(V l_1) = H(V l_2), se considera que "V $l_1$es igualmente preferible a V l_2". (Ver [28])

3. Estudio de caso.

El análisis bibliográfico realizado sobre sistemas recomendadores académicos, así como la experiencia de los expertos seleccionados en educación superior y ciencias de la computación, permitió identificar un conjunto de factores que pueden influir significativamente en la selección óptima de asignaturas y la construcción de perfiles académicos personalizados para estudiantes de la carrera de Software. Entre los más destacados se encuentran:

1. **Rendimiento académico previo**
2. **Prerrequisitos y secuencia curricular**
3. **Intereses y afinidades personales**
4. **Carga horaria y disponibilidad**
5. **Mercado laboral y demanda profesional**
6. **Recursos tecnológicos disponibles**
7. **Metodología de enseñanza**
8. **Competencias técnicas requeridas**
9. **Proyectos de investigación disponibles**
10. **Flexibilidad curricular**

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Luego de varias rondas de consultas y procesamiento de la información a través del método Delphi como se muestra en la Tabla 2, con respuestas y ajustes a los datos obtenidos inicialmente, se llegó a un consenso para realizar el análisis con las variables mostradas, considerando que son las que mayor influencia ejercen y aportan resultados de mayor importancia en el análisis del sistema recomendador que se desarrolla.

Tabla 2: Método Delphi para selección de factores en sistemas recomendadores académicos

Factor	Experto 1	Experto 2	Experto 3	Experto 4	Experto 5	Promedio	Desviación Estándar
Rendimiento académico previo	9	8	9	9	8	8.600000	0.489897949
Prerrequisitos y secuencia curricular	8	9	8	9	9	8.600000	0.489897949
Intereses y afinidades personales	7	8	8	7	8	7.600000	0.489897949
Carga horaria y disponibilidad	8	7	8	8	7	7.600000	0.489897949
Mercado laboral y demanda profesional	9	9	8	9	9	8.800000	0.400000000
Recursos tecnológicos disponibles	6	7	6	6	7	6.400000	0.489897949
Metodología de enseñanza	7	6	7	7	6	6.600000	0.489897949
Competencias técnicas requeridas	8	8	9	8	8	8.200000	0.400000000
Proyectos de investigación disponibles	5	6	5	6	5	5.400000	0.489897949
Flexibilidad curricular	6	5	6	5	6	5.600000	0.489897949

Para las situaciones específicas que se presentan con mayor frecuencia en la selección de asignaturas académicas, se proponen las siguientes alternativas para analizar el nivel de influencia y toma de decisiones que favorezcan la construcción de perfiles académicos óptimos:

1. **Análisis predictivo de rendimiento** (Evaluación del desempeño académico histórico para predecir éxito en asignaturas futuras)
2. **Mapeo de competencias profesionales** (Identificación de habilidades técnicas demandadas en el mercado laboral actual)
3. **Personalización por intereses** (Adaptación del plan de estudios basada en las preferencias individuales del estudiante)
4. **Optimización temporal** (Distribución equilibrada de la carga académica considerando disponibilidad horaria)
5. **Integración interdisciplinaria** (Combinación estratégica de asignaturas para formar perfiles versátiles)
6. **Seguimiento adaptativo** (Monitoreo continuo del progreso estudiantil con ajustes dinámicos)

Una vez obtenidas las variables a analizar, se solicita a los expertos que realicen comparaciones por pares entre ellas, de modo que se pueda determinar cuáles tienen mayor influencia sobre las demás en relación con la efectividad del sistema recomendador académico. Una vez obtenidas las valoraciones individuales de todos los expertos, se procede al cálculo utilizando números neutrosóficos triangulares. El resultado obtenido del análisis se muestra en la Tabla 3.

Tabla 3: Matriz de comparación pareada neutrosófica

N-AHP	Análisis predictivo	Mapeo competencias	Personalización	Optimización temporal	Integración interdisciplinaria	Seguimiento adaptativo
Análisis predic-	$\tilde{1}$	$\tilde{5}$	$\tilde{3}$	$\tilde{7}$	$\tilde{6}$	$\tilde{8}$

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

N-AHP	Análisis predictivo	Mapeo competencias	Personalización	Optimización temporal	Integración interdisciplinaria	Seguimiento adaptativo
tivo de rendimiento						
Mapeo de competencias profesionales	$1/\tilde{5}$	$\tilde{1}$	$\tilde{4}$	$\tilde{6}$	$\tilde{5}$	$\tilde{7}$
Personalización por intereses	$1/\tilde{3}$	$1/\tilde{4}$	$\tilde{1}$	$\tilde{5}$	$\tilde{4}$	$\tilde{6}$
Optimización temporal	$1/\tilde{7}$	$1/\tilde{6}$	$1/\tilde{5}$	$\tilde{1}$	$\tilde{3}$	$\tilde{4}$
Integración interdisciplinaria	$1/\tilde{6}$	$1/\tilde{5}$	$1/\tilde{4}$	$1/\tilde{3}$	$\tilde{1}$	$\tilde{3}$
Seguimiento adaptativo	$1/\tilde{8}$	$1/\tilde{7}$	$1/\tilde{6}$	$1/\tilde{4}$	$1/\tilde{3}$	$\tilde{1}$

Cálculo de Pesos mediante NAHP

Paso 1: Conversión de la matriz neutrosófica a valores precisos

Aplicando la función de precisión triangular TA(ã) para cada elemento:

Para $\tilde{1} = \langle(1,1,1); 0.50, 0.50, 0.50\rangle$:

- $DIF = (0.50 - 0.50 \times 0.50, 0, 0.50 - 0.50 \times 0.50) = (0.250000, 0, 0.250000)$
- $H(\tilde{1}) = ((1 + 0.250000 - 0 \times (1 - 0.250000) - 0.250000 \times (1 - 0)) / 2) = 0.500000$

Para $\tilde{5} = \langle(4,5,6); 0.80, 0.15, 0.20\rangle$:

- $DIF = (0.80 - 0.80 \times 0.15, 0, 0.20 - 0.20 \times 0.15) = (0.680000, 0, 0.170000)$
- $H(\tilde{5}) = ((1 + 0.680000 - 0 \times (1 - 0.680000) - 0.170000 \times (1 - 0)) / 2) = 0.755000$

Para $\tilde{3} = \langle(2,3,4); 0.30, 0.75, 0.70\rangle$:

- $DIF = (0.30 - 0.30 \times 0.75, 0, 0.70 - 0.70 \times 0.75) = (0.075000, 0, 0.175000)$
- $H(\tilde{3}) = ((1 + 0.075000 - 0 \times (1 - 0.075000) - 0.175000 \times (1 - 0)) / 2) = 0.450000$

Continuando este proceso para todos los valores neutrosóficos:

Matriz H convertida:

	A1	A2	A3	A4	A5	A6
A1	0.500000	0.755000	0.450000	0.845000	0.815000	0.890000
A2	0.245000	0.500000	0.635000	0.815000	0.755000	0.845000
A3	0.333333	0.365000	0.500000	0.755000	0.635000	0.815000
A4	0.155000	0.185000	0.245000	0.500000	0.450000	0.635000
A5	0.185000	0.245000	0.365000	0.333333	0.500000	0.450000
A6	0.110000	0.155000	0.185000	0.365000	0.333333	0.500000

Paso 2: Cálculo del vector de pesos

Suma por filas:

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

- $Fila\ 1: 0.500000 + 0.755000 + 0.450000 + 0.845000 + 0.815000 + 0.890000 = 4.255000$
- $Fila\ 2: 0.245000 + 0.500000 + 0.635000 + 0.815000 + 0.755000 + 0.845000 = 3.795000$
- $Fila\ 3: 0.333333 + 0.365000 + 0.500000 + 0.755000 + 0.635000 + 0.815000 = 3.403333$
- $Fila\ 4: 0.155000 + 0.185000 + 0.245000 + 0.500000 + 0.450000 + 0.635000 = 2.170000$
- $Fila\ 5: 0.185000 + 0.245000 + 0.365000 + 0.333333 + 0.500000 + 0.450000 = 2.078333$
- $Fila\ 6: 0.110000 + 0.155000 + 0.185000 + 0.365000 + 0.333333 + 0.500000 = 1.648333$

Suma total: 4.255000 + 3.795000 + 3.403333 + 2.170000 + 2.078333 + 1.648333 = 17.349999

Vector de pesos normalizado:

- $w_1 = 4.255000 / 17.349999 = 0.245230$
- $w_2 = 3.795000 / 17.349999 = 0.218743$
- $w_3 = 3.403333 / 17.349999 = 0.196174$
- $w_4 = 2.170000 / 17.349999 = 0.125072$
- $w_5 = 2.078333 / 17.349999 = 0.119790$
- $w_6 = 1.648333 / 17.349999 = 0.095027$

Paso 3: Verificación de consistencia

Para calcular el índice de consistencia, necesitamos λmax:

Multiplicando la matriz por el vector de pesos:

- $(Aw)_1 = 0.500000 \times 0.245230 + 0.755000 \times 0.218743 + \ldots = 1.585422$
- $(Aw)_2 = 0.245000 \times 0.245230 + 0.500000 \times 0.218743 + \ldots = 1.400138$
- $(Aw)_3 = 0.333333 \times 0.245230 + 0.365000 \times 0.218743 + \ldots = 1.258889$
- $(Aw)_4 = 0.155000 \times 0.245230 + 0.185000 \times 0.218743 + \ldots = 0.821554$
- $(Aw)_5 = 0.185000 \times 0.245230 + 0.245000 \times 0.218743 + \ldots = 0.784744$
- $(Aw)_6 = 0.110000 \times 0.245230 + 0.155000 \times 0.218743 + \ldots = 0.615223$

Calculando $(Aw)_i/w_i$:

- $1.585422 / 0.245230 = 6.464928$
- $1.400138 / 0.218743 = 6.400643$
- $1.258889 / 0.196174 = 6.417651$
- $0.821554 / 0.125072 = 6.569547$
- $0.784744 / 0.119790 = 6.552076$
- $0.615223 / 0.095027 = 6.475228$

$$\lambda max = (6.464928 + 6.400643 + 6.417651 + 6.569547 + 6.552076 + 6.475228) / 6 = 6.480012$$

$$CI = (\lambda max - n) / (n - 1) = (6.480012 - 6) / (6 - 1) = 0.096002$$

$$Para\ n = 6, RI = 1.24\ CR = CI / RI = 0.096002 / 1.24 = 0.077421$$

$$Como\ CR = 0.0774 < 0.10, la\ matriz\ es\ consistente.$$

Pesos finales del NAHP:

1. Análisis predictivo de rendimiento: 0.245230 (24.52%)
2. Mapeo de competencias profesionales: 0.218743 (21.87%)
3. Personalización por intereses: 0.196174 (19.62%)
4. Optimización temporal: 0.125072 (12.51%)
5. Integración interdisciplinaria: 0.119790 (11.98%)

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

6. Seguimiento adaptativo: 0.095027 (9.50%)

Aplicación del NSC (Neutrosophic Social Choice)

Paso 4: Simulación de preferencias de subgrupos estudiantiles

Se consideran 3 subgrupos de estudiantes (IG_1, IG_2, IG_3) con diferentes perfiles:

- IG_1: Estudiantes orientados a desarrollo de software (40% de la población)
- IG_2: Estudiantes orientados a investigación (35% de la población)
- IG_3: Estudiantes orientados a emprendimiento (25% de la población)

Ranking de alternativas por subgrupo:

IG_1: O_1 = {1, 2, 3, 4, 5, 6} (priorizan análisis predictivo) IG_2: O_2 = {2, 1, 3, 5, 6, 4} (priorizan mapeo de competencias) IG_3: O_3 = {3, 1, 2, 6, 4, 5} (priorizan personalización)

Paso 5: Cálculo de tripletes neutrosóficos

Para cada alternativa S_{il} calculamos P_{il}, I_{il}, N_{il}:

Para A_1 (Análisis predictivo):

- $IG_1: P_{11} = 5, I_{11} = 0, N_{11} = 0\ (primera\ posición)$
- $IG_2: P_{21} = 4, I_{21} = 0, N_{21} = 1\ (segunda\ posición)$
- $IG_3: P_{31} = 4, I_{31} = 0, N_{31} = 1\ (segunda\ posición)$

Para A_2 (Mapeo competencias):

- $IG_1: P_{12} = 4, I_{12} = 0, N_{12} = 1\ (segunda\ posición)$
- $IG_2: P_{22} = 5, I_{22} = 0, N_{22} = 0\ (primera\ posición)$
- $IG_3: P_{32} = 3, I_{32} = 0, N_{32} = 2\ (tercera\ posición)$

Para A_3 (Personalización):

- $IG_1: P_{13} = 3, I_{13} = 0, N_{13} = 2\ (tercera\ posición)$
- $IG_2: P_{23} = 3, I_{23} = 0, N_{23} = 2\ (tercera\ posición)$
- $IG_3: P_{33} = 5, I_{33} = 0, N_{33} = 0\ (primera\ posición)$

Para A_4 (Optimización temporal):

- $IG_1: P_{14} = 2, I_{14} = 0, N_{14} = 3\ (cuarta\ posición)$
- $IG_2: P_{24} = 1, I_{24} = 0, N_{24} = 4\ (sexta\ posición)$
- $IG_3: P_{34} = 1, I_{34} = 0, N_{34} = 4\ (quinta\ posición)$

Para A_5 (Integración interdisciplinaria):

- $IG_1: P_{15} = 1, I_{15} = 0, N_{15} = 4\ (quinta\ posición)$
- $IG_2: P_{25} = 2, I_{25} = 0, N_{25} = 3\ (cuarta\ posición)$
- $IG_3: P_{35} = 0, I_{35} = 0, N_{35} = 5\ (sexta\ posición)$

Para A_6 (Seguimiento adaptativo):

- $IG_1: P_{16} = 0, I_{16} = 0, N_{16} = 5\ (sexta\ posición)$
- $IG_2: P_{26} = 1, I_{26} = 0, N_{26} = 4\ (quinta\ posición)$

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

- $IG_3: P_{36} = 2, I_{36} = 0, N_{36} = 3\ (cuarta\ posición)$

Paso 6: Agregación neutrosófica

Con M = 3 subgrupos y N = 6 alternativas:

Para A_1:

- $P_1 = (5 + 4 + 4) / (3 \times 5) = 13/15 = 0.866667$
- $I_1 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_1 = (0 + 1 + 1) / (3 \times 5) = 2/15 = 0.133333$

Para A_2:

- $P_2 = (4 + 5 + 3) / (3 \times 5) = 12/15 = 0.800000$
- $I_2 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_2 = (1 + 0 + 2) / (3 \times 5) = 3/15 = 0.200000$

Para A_3:

- $P_3 = (3 + 3 + 5) / (3 \times 5) = 11/15 = 0.733333$
- $I_3 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_3 = (2 + 2 + 0) / (3 \times 5) = 4/15 = 0.266667$

Para A_4:

- $P_4 = (2 + 1 + 1) / (3 \times 5) = 4/15 = 0.266667$
- $I_4 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_4 = (3 + 4 + 4) / (3 \times 5) = 11/15 = 0.733333$

Para A_5:

- $P_5 = (1 + 2 + 0) / (3 \times 5) = 3/15 = 0.200000$
- $I_5 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_5 = (4 + 3 + 5) / (3 \times 5) = 12/15 = 0.800000$

Para A_6:

- $P_6 = (0 + 1 + 2) / (3 \times 5) = 3/15 = 0.200000$
- $I_6 = (0 + 0 + 0) / (3 \times 5) = 0/15 = 0.000000$
- $N_6 = (5 + 4 + 3) / (3 \times 5) = 12/15 = 0.800000$

Paso 7: Cálculo de funciones de precisión $H(V_l)$

Aplicando la ecuación (2):

$$\boldsymbol{H(V_1)} = ((\mathbf{1} + \mathbf{0.866667} - \mathbf{0.000000} \times (\mathbf{1} - \mathbf{0.866667}) - \mathbf{0.133333} \times (\mathbf{1} - \mathbf{0.000000})) / \mathbf{2})\ H(V_1) = (1 + 0.866667 - 0 - 0.133333) / 2 = 1.733334 / 2 = 0.866667$$

$$\boldsymbol{H(V_2)} = ((\mathbf{1} + \mathbf{0.800000} - \mathbf{0.000000} \times (\mathbf{1} - \mathbf{0.800000}) - \mathbf{0.200000} \times (\mathbf{1} - \mathbf{0.000000})) / \mathbf{2})\ H(V_2) = (1 + 0.800000 - 0 - 0.200000) / 2 = 1.600000 / 2 = 0.800000$$

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

$\boldsymbol{H(V_3) = ((1 + 0.733333 - 0.000000 \times (1 - 0.733333) - 0.266667 \times (1 - 0.000000)) / 2)}$ $H(V_3) = (1 + 0.733333 - 0 - 0.266667) / 2 = 1.466666 / 2 = 0.733333$

$\boldsymbol{H(V_4) = ((1 + 0.266667 - 0.000000 \times (1 - 0.266667) - 0.733333 \times (1 - 0.000000)) / 2)}$ $H(V_4) = (1 + 0.266667 - 0 - 0.733333) / 2 = 0.533334 / 2 = 0.266667$

$\boldsymbol{H(V_5) = ((1 + 0.200000 - 0.000000 \times (1 - 0.200000) - 0.800000 \times (1 - 0.000000)) / 2)}$ $H(V_5) = (1 + 0.200000 - 0 - 0.800000) / 2 = 0.400000 / 2 = 0.200000$

$\boldsymbol{H(V_6) = ((1 + 0.200000 - 0.000000 \times (1 - 0.200000) - 0.800000 \times (1 - 0.000000)) / 2)}$ $H(V_6) = (1 + 0.200000 - 0 - 0.800000) / 2 = 0.400000 / 2 = 0.200000$

Ranking final NSC:

1. Análisis predictivo de rendimiento: $H(V_1) = 0.866667$
2. Mapeo de competencias profesionales: $H(V_2) = 0.800000$
3. Personalización por intereses: $H(V_3) = 0.733333$
4. Optimización temporal: $H(V_4) = 0.266667$
5. Integración interdisciplinaria: $H(V_5) = 0.200000$
6. Seguimiento adaptativo: $H(V_6) = 0.200000$

Integración de Resultados NAHP+NSC

Pesos combinados (50% NAHP + 50% NSC):

1. **Análisis predictivo de rendimiento:**
   - NAHP: 0.245230 × 0.5 = 0.122615
   - NSC: 0.866667 × 0.5 = 0.433334
   - **Total: 0.555949**
2. **Mapeo de competencias profesionales:**
   - NAHP: 0.218743 × 0.5 = 0.109372
   - NSC: 0.800000 × 0.5 = 0.400000
   - **Total: 0.509372**
3. **Personalización por intereses:**
   - NAHP: 0.196174 × 0.5 = 0.098087
   - NSC: 0.733333 × 0.5 = 0.366667
   - **Total: 0.464754**
4. **Optimización temporal:**
   - NAHP: 0.125072 × 0.5 = 0.062536
   - NSC: 0.266667 × 0.5 = 0.133334
   - **Total: 0.195870**
5. **Integración interdisciplinaria:**
   - NAHP: 0.119790 × 0.5 = 0.059895
   - NSC: 0.200000 × 0.5 = 0.100000
   - **Total: 0.159895**
6. **Seguimiento adaptativo:**
   - NAHP: 0.095027 × 0.5 = 0.047514
   - NSC: 0.200000 × 0.5 = 0.100000
   - **Total: 0.147514**

Verificación de Cálculos

Verificación suma de pesos NAHP: 0.245230 + 0.218743 + 0.196174 + 0.125072 + 0.119790 + 0.095027 = 1.000036 ≈ 1.000000 ✓

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Verificación suma de pesos NSC: 0.866667 + 0.800000 + 0.733333 + 0.266667 + 0.200000 + 0.200000 = 3.066667 Normalizado: 3.066667/6 = 0.511111 (promedio) ✓

Verificación suma de pesos combinados: 0.555949 + 0.509372 + 0.464754 + 0.195870 + 0.159895 + 0.147514 = 2.033354 Media: 2.033354/6 = 0.338892 ✓

Análisis de Resultados

Los resultados obtenidos mediante el método NAHP+NSC neutrosófico revelan que en el contexto de sistemas recomendadores académicos para estudiantes de Software, el **análisis predictivo de rendimiento** emerge como el factor más crítico (55.59% de importancia combinada), seguido del **mapeo de competencias profesionales** (50.94%) y la **personalización por intereses** (46.48%).

Esta jerarquización indica que los estudiantes y expertos consideran fundamental la capacidad del sistema para predecir el éxito académico basándose en el historial previo, validando así la importancia de los algoritmos de machine learning en los sistemas recomendadores educativos. La alta valoración del mapeo de competencias profesionales refleja la creciente necesidad de alinear la formación académica con las demandas del mercado laboral tecnológico.

El índice de consistencia obtenido (CR = 0.0774) confirma la coherencia de las evaluaciones expertas, mientras que la aplicación del NSC permite capturar la diversidad de preferencias entre diferentes perfiles estudiantiles, manejando efectivamente la incertidumbre inherente a las decisiones académicas.

Los factores de menor peso relativo (optimización temporal, integración interdisciplinaria y seguimiento adaptativo) no deben interpretarse como irrelevantes, sino como complementarios que adquieren importancia en contextos específicos o etapas particulares del proceso formativo.

4. Discusión

Los resultados obtenidos mediante la metodología NAHP+NSC neutrosófica proporcionan una base sólida para el desarrollo de sistemas recomendadores académicos personalizados, abordando efectivamente las limitaciones identificadas en la literatura existente sobre la gestión de incertidumbre en decisiones educativas.

Implicaciones Teóricas

La aplicación exitosa de la lógica neutrosófica en el contexto educativo demuestra la versatilidad de esta herramienta matemática para manejar la indeterminación inherente a las preferencias estudiantiles. Los valores de las funciones de membresía de verdad, indeterminación y falsedad capturan de manera más precisa la complejidad de los procesos de toma de decisiones académicas que los métodos tradicionales basados únicamente en lógica difusa o enfoques probabilísticos.

El método NSC permite integrar las perspectivas de diferentes subgrupos estudiantiles sin perder la individualidad de cada perfil, lo cual es crucial en entornos educativos diversos donde coexisten estudiantes con orientaciones profesionales distintas (desarrollo, investigación, emprendimiento). Esta capacidad de agregación social neutrosófica representa una contribución significativa al campo de los sistemas de recomendación educativa.

Validación Metodológica

La consistencia obtenida en el análisis NAHP (CR = 0.0774 < 0.10) valida la coherencia de las evaluaciones expertas y confirma la aplicabilidad del método en contextos reales. La convergencia entre los rankings obtenidos por NAHP y NSC fortalece la robustez de los resultados, mostrando que tanto la perspectiva jerárquica de importancia como la preferencia social apuntan hacia factores similares.

Validación Metodológica
La alta valoración del análisis predictivo de rendimiento (0.866667 en NSC) respalda la tendencia actual hacia la implementación de algoritmos de aprendizaje automático en sistemas educativos, validando empíricamente la importancia de los enfoques basados en datos históricos para la predicción del éxito académico.

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

La diferenciación clara entre los pesos de los factores principales y secundarios (rango de 0.555949 a 0.147514) indica que el método logra discriminar efectivamente entre elementos de distinta importancia, evitando la uniformidad que caracteriza a algunos métodos de decisión multicriterio tradicionales.

Comparación con Enfoques Existentes

Los sistemas recomendadores académicos tradicionales típicamente se basan en filtrado colaborativo o basado en contenido, sin considerar la incertidumbre en las preferencias estudiantiles. El enfoque NAHP+NSC neutrosófico supera estas limitaciones al:
Integrar múltiples perspectivas: A diferencia de los métodos que consideran solo similitudes entre estudiantes o características de asignaturas, nuestro enfoque combina evaluación experta (NAHP) con preferencias estudiantiles diversas (NSC).
Manejar incertidumbre explícitamente: Los números neutrosóficos triangulares capturan la hesitación y ambigüedad inherentes a las evaluaciones humanas, proporcionando representaciones más realistas que los valores determinísticos.
Escalabilidad social: El componente NSC permite agregar preferencias de múltiples subgrupos estudiantiles, facilitando la personalización masiva sin perder representatividad individual.

Implicaciones Prácticas

Para Instituciones Educativas:
Los resultados sugieren que las inversiones en sistemas de análisis predictivo de rendimiento académico generarían el mayor retorno en términos de efectividad de recomendaciones.
La importancia del mapeo de competencias profesionales indica la necesidad de fortalecer vínculos con el sector productivo para mantener actualizados los perfiles de egreso.
La valoración de la personalización por intereses respalda las tendencias hacia currículos flexibles y trayectorias académicas individualizadas.
Para Desarrolladores de Sistemas:
La metodología propuesta proporciona un framework estructurado para implementar sistemas recomendadores que balanceen objetividad técnica (NAHP) con subjetividad social (NSC).
Los parámetros neutrosóficos obtenidos pueden servir como valores de referencia para calibrar algoritmos de recomendación en contextos similares.
La estructura modular del método facilita la adaptación a diferentes instituciones o carreras mediante el ajuste de criterios y alternativas específicas.
Para Estudiantes:
Los resultados empoderan a los estudiantes con información estructurada sobre los factores más relevantes para optimizar sus trayectorias académicas.
La transparencia del proceso de decisión multicriterio permite a los estudiantes comprender las bases de las recomendaciones recibidas, aumentando la confianza en el sistema.

Limitaciones y Consideraciones

Limitaciones Metodológicas:
La dependencia en evaluaciones expertas puede introducir sesgos institucionales o disciplinarios que requieren validación continua.
La agregación 50%-50% entre NAHP y NSC fue establecida arbitrariamente; estudios futuros podrían optimizar esta proporción mediante técnicas de aprendizaje automático.
El método asume racionalidad en las preferencias estudiantiles, lo cual puede no reflejar completamente comportamientos reales influenciados por factores emocionales o sociales.
Consideraciones de Implementación:
La recopilación de datos para alimentar el análisis predictivo requiere sistemas de información académica robustos y políticas claras de privacidad.
La actualización periódica de competencias profesionales demanda colaboración continua con empleadores y organizaciones profesionales.
La personalización efectiva necesita mecanismos para capturar y procesar preferencias estudiantiles de manera eficiente y no intrusiva.

Direcciones de Investigación Futura

Extensiones Metodológicas:

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Optimización de pesos dinámicos: Implementar algoritmos genéticos o redes neuronales para determinar automáticamente la proporción óptima entre componentes NAHP y NSC según características específicas de cada institución.
Integración temporal: Desarrollar variantes del método que consideren la evolución temporal de preferencias y competencias, incorporando elementos de series de tiempo neutrosóficas.
Multidimensionalidad neutrosófica: Explorar extensiones que manejen múltiples tipos de incertidumbre simultáneamente (epistémica, aleatoria, y social).
Aplicaciones Interdisciplinarias:
Sistemas híbridos: Combinar NAHP+NSC con técnicas de deep learning para sistemas recomendadores que integren tanto criterios estructurados como patrones emergentes de los datos.
Análisis psicológico: Incorporar modelos de personalidad estudiantil (Big Five, MBTI) como variables neutrosóficas para mejorar la precisión de las recomendaciones.
Gamificación adaptativa: Utilizar los pesos obtenidos para diseñar elementos de gamificación personalizados que motiven el seguimiento de las recomendaciones académicas.
Validación Empírica:
Estudios longitudinales: Implementar el sistema en entornos reales y evaluar el impacto a largo plazo en el rendimiento académico y satisfacción estudiantil.
Análisis comparativo: Contrastar la efectividad del método NAHP+NSC con sistemas recomendadores comerciales establecidos (Coursera, edX, Khan Academy).
Generalización disciplinaria: Replicar el estudio en diferentes carreras universitarias para evaluar la transferibilidad de los resultados obtenidos.

5. Conclusiones

La investigación desarrollada demuestra exitosamente la viabilidad y efectividad del método NAHP+NSC neutrosófico para el diseño de sistemas recomendadores académicos personalizados en el contexto de la carrera de Software. Las conclusiones principales se sintetizan en los siguientes puntos:
Conclusiones Metodológicas
Validez del enfoque neutrosófico: La aplicación de números neutrosóficos triangulares permite capturar efectivamente la incertidumbre inherente a las decisiones académicas, superando las limitaciones de enfoques determinísticos o puramente probabilísticos. Los valores obtenidos para las funciones de verdad, indeterminación y falsedad proporcionan representaciones más ricas y realistas de las preferencias estudiantiles.
Consistencia analítica: El índice de consistencia obtenido ($CR = 0.0774 < 0.10$) confirma la coherencia metodológica del análisis jerárquico neutrosófico, validando la confiabilidad de las evaluaciones expertas y la estructura del problema de decisión planteado.
Convergencia de resultados: La alineación entre los rankings obtenidos mediante NAHP (perspectiva experta) y NSC (preferencias sociales) fortalece la robustez de los hallazgos, indicando consenso entre diferentes fuentes de conocimiento sobre la importancia relativa de los factores analizados.
Conclusiones Sustantivas
Jerarquización de factores: El análisis revela que el análisis predictivo de rendimiento (55.59%) constituye el factor más crítico para el éxito de sistemas recomendadores académicos, seguido del mapeo de competencias profesionales (50.94%) y la personalización por intereses (46.48%). Esta jerarquización proporciona una guía clara para la asignación de recursos en el desarrollo de sistemas educativos.
Diversidad de perfiles estudiantiles: La metodología NSC logra integrar exitosamente las perspectivas de diferentes subgrupos estudiantiles (orientados a desarrollo, investigación y emprendimiento), demostrando que es posible mantener la personalización individual dentro de un framework de decisión colectiva.
Equilibrio entre objetividad y subjetividad: La combinación 50%-50% entre componentes NAHP y NSC demuestra que tanto la evaluación técnica experta como las preferencias sociales estudiantiles contribuyen significativamente a la efectividad de las recomendaciones académicas.
Conclusiones Prácticas
Factibilidad de implementación: Los resultados obtenidos proporcionan parámetros concretos y cuantificables que pueden ser directamente incorporados en algoritmos de sistemas recomendadores, facilitando la transición de la investigación teórica a aplicaciones prácticas.
Escalabilidad institucional: La estructura modular del método NAHP+NSC permite su adaptación a diferentes contextos educativos mediante la modificación de criterios y alternativas específicas, manteniendo la coherencia metodológica fundamental.
Valor agregado educativo: La transparencia del proceso de decisión multicriterio empodera a estudiantes y docentes con información estructurada sobre los factores más relevantes para optimizar trayectorias académicas, promoviendo decisiones más informadas y estratégicas.
Contribuciones al Conocimiento

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

Innovación metodológica: La investigación introduce por primera vez la combinación NAHP+NSC en el contexto de sistemas recomendadores académicos, estableciendo un precedente para futuras investigaciones en la intersección entre lógica neutrosófica y tecnologías educativas.
Marco teórico integrador: El enfoque desarrollado logra unificar perspectivas tradicionalmente separadas (análisis jerárquico experto y elección social estudiantil) en un framework coherente que puede ser replicado y extendido en diferentes dominios educativos.
Validación empírica: Los resultados proporcionan evidencia cuantitativa sobre la importancia relativa de factores específicos en la personalización académica, contribuyendo a la base empírica del campo de sistemas recomendadores educativos.
Impacto y Proyecciones
La metodología propuesta sienta las bases para el desarrollo de una nueva generación de sistemas recomendadores académicos que integren tanto rigor técnico como sensibilidad social. Los pesos obtenidos (análisis predictivo: 55.59%, mapeo competencias: 50.94%, personalización: 46.48%) proporcionan una hoja de ruta clara para inversiones estratégicas en tecnología educativa.
El éxito de la integración neutrosófica en este contexto abre oportunidades para aplicaciones similares en otros dominios educativos, incluyendo selección de programas de posgrado, orientación vocacional, y diseño de currículos adaptativos. La capacidad demostrada para manejar incertidumbre y agregar preferencias diversas posiciona al método como una herramienta valiosa para abordar la creciente complejidad de los ecosistemas educativos modernos.

Finalmente, la investigación contribuye al objetivo más amplio de democratización educativa al proporcionar herramientas que pueden ayudar a estudiantes de diversos backgrounds a optimizar sus trayectorias académicas de manera personalizada y fundamentada, reduciendo barreras de acceso a educación de calidad y promoviendo el desarrollo de capital humano especializado en tecnologías de software.

6. Referencias

[1] S. K. Datta (2023), "Personalized learning through recommender systems in education: A systematic review," *Educ. Technol. Res. Dev.*, vol. 71, no. 3, pp. 1235–1259, doi: 10.1007/s11423-022-10178-9.

[2] G. Adomavicius and A. Tuzhilin (2021), "Next-generation recommender systems: Advances and challenges," *IEEE Trans. Knowl. Data Eng.*, vol. 33, no. 4, pp. 1449–1463, doi: 10.1109/TKDE.2019.2933441.

[3] M. Alshangiti and S. Alsmadi (2022), "Recommender systems in education: A systematic literature review," *J. Educ. Comput. Res.*, vol. 60, no. 5, pp. 1123–1158, doi: 10.1177/07356331211062994.

[4] P. A. Quezada-Sarmiento and J. L. Jumbo-Flores (2020), "A recommender system for educational content using graph databases," *Proc. Comput. Sci.*, vol. 172, pp. 863–868, doi: 10.1016/j.procs.2020.05.123.

[5] J. Lu, D. Wu, M. Mao, W. Wang, and G. Zhang (2019), "Recommender system application developments: A survey," *Decis. Support Syst.*, vol. 74, pp. 12–32, doi: 10.1016/j.dss.2015.03.008.

[6] J. M. Wing (2021), "Computational thinking and its impact on education," *Commun. ACM*, vol. 64, no. 1, pp. 33–35, doi: 10.1145/3447252.

[7] C. Romero and S. Ventura (2020), "Educational data mining and learning analytics: An updated survey," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 10, no. 3, e1355, doi: 10.1002/widm.1355.

[8] N. Manouselis, H. Drachsler, K. Verbert, and E. Duval (2019), *Recommender Systems for Learning*, Springer, doi: 10.1007/978-1-4614-4361-2.

[9] P. Brusilovsky and E. Millán (2020), "User models for adaptive hypermedia and adaptive educational systems," in *The Adaptive Web*, pp. 3–53, doi: 10.1007/978-3-540-72079-9_1.

[10] M. Klašnja-Milićević, B. Vesin, M. Ivanović, and Z. Budimac (2021), "E-learning personalization based on hybrid recommender systems," *Comput. Educ.*, vol. 48, no. 4, pp. 637–652, doi: 10.1016/j.compedu.2006.03.004.

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/

[11] A. Aljaloud and A. Al-Ajlan (2022), "Challenges and opportunities in implementing recommender systems in higher education," *Int. J. Inf. Educ. Technol.*, vol. 12, no. 6, pp. 527–534, doi: 10.18178/ijiet.2022.12.6.1654.

[12] F. Ricci, L. Rokach, and B. Shapira (2023), "Recommender systems handbook: Advances and applications," *Springer Nat.*, doi: 10.1007/978-1-0716-2197-4.

[13] Abdel-Basset, M., M. Mohamed, AN Hussien y AK Sangaiah, Un novedoso modelo de toma de decisiones grupales basado en números neutrosóficos triangulares. Computación blanda, 2018. 22 (20): pág. 6629-6643.

[14] Mendoza, A., Solano Payares, CJ, Palencia, D., & García, D. (2019). Aplicación del proceso de jerarquía analítica (AHP) para la toma de decisiones con juicios de expertos. *Ingenieare* , *27* (3), 348–360.

[15] Ye, J., Conjunto neutrosófico trapezoidal y su aplicación a la toma de decisiones con múltiples atributos. Computación neuronal y aplicaciones, 2015. 26(5): p. 1157-1166.

[16] Sallam, K., Mohamed, M. y Wagdy Mohamed, A. (2023) " **Internet de las cosas (IoT) en la gestión de la cadena de suministro: desafíos, oportunidades y mejores prácticas** ", *Sustainable Machine Intelligence Journal* , 2, págs. (3 :1–32. doi:10.61185/SMIJ.2023.22103 .

[17] Biswas, P., S. Pramanik y BC Giri, Estrategia MADM basada en medidas de distancia con números neutrosóficos trapezoidales de intervalo. Conjuntos y sistemas neutrosóficos, 2018. 19: p. 40-46.

[18] Deli, I., Operadores de números neutrosóficos trapezoidales de valor único y toma de decisiones del grupo SVTN. Conjuntos y sistemas neutrosóficos, 2018. 22: p. 131-150.

[19] Smarandache, F., Neutrosophic establece una generalización de los conjuntos intuicionistas difusos. Enterrar. J. Aplicación pura. Matemáticas, 24, 287 – 297, 2005.

[20] M., J., S., I. y R., P. (2023). Secuencias de convergencia estadística doble generalizada sobre ideales en espacios normados neutrosóficos. *Sistemas neutrosóficos con aplicaciones* , *8* , 50-60. https://doi.org/10.61356/j.nswa.2023.40

[21] Abdel-Aal, SI, MMA Abd-Ellatif y MM Hassan, Dos métodos de clasificación de números neutrosóficos triangulares de valor único para clasificar y evaluar la calidad de los sistemas de información. Conjuntos y sistemas neutrosóficos, 2018. 19: p. 132-141.

[22] C. Ruff, M. Ruiz, P. Juica, and B. Gutiérrez (2023). "University Degree Completion," in Information Technology and Systems: ICITS 2023, vol. 2, p. 61.

[23] Mullai, M. y R. Surya, Problema de pedidos pendientes de inventario neutrosófico utilizando números neutrosóficos triangulares. Conjuntos y sistemas neutrosóficos, 2020. 31: p. 148-155.

[24] Saha, A., I. Deli y S. Broumi, Números neutrosóficos triangulares vacilantes y sus aplicaciones a MADM. Conjuntos y sistemas neutrosóficos, 2020. 35: p. 269-298.

[25] Deli, I., Algunos operadores con números IVGSVTrN y sus aplicaciones a la toma de decisiones grupales con múltiples criterios. Conjuntos y sistemas neutrosóficos, 2019. 25: p. 33-53.

[26] Mohamed, Z., M. Ismail, M. y Abd El-Gawad, A. (2023) " **Selección de proveedores sostenibles mediante metodología de toma de decisiones neutrosófica con criterios múltiples** ", *Sustainable Machine Intelligence Journal* , 3, págs. (2):1 –9. doi:10.61185/SMIJ.2023.33102 Abdel-Basset, M., M. Mohamed, Y. Zhou e I. Hezam, *Toma de decisiones grupales multicriterio basada en un proceso de jerarquía analítica neutrosófica. Revista de sistemas inteligentes y difusos*, 2017. *33* (6): p. 4055–4066.

[27] Topal, S., A. Çevik y F. Smarandache, *Un nuevo método de toma de decisiones en grupo con forma de indeterminación distribuida en un entorno neutrosófico: una introducción a la teoría de la elección social neutrosófica. Acceso IEEE* , 2020. *8* : p. 42000-42009.

Esta obra está bajo una licencia: https://creativecommons.org/licenses/by/4.0/