



Análisis Neutrosófico Fuzzy-Set QCA del Impacto de la Inteligencia Artificial Generativa en el Desempeño Académico de Estudiantes de Programación: Una Perspectiva Epistémica Basada en Datos

Neutrosophic Fuzzy-Set QCA Analysis of the Impact of Generative Artificial Intelligence on the Academic Performance of Programming Students: An Epistemic Perspective Based on Data

Josué Abraham Guillén Bobadilla¹, Maikel Yelandi Leyva Vázquez²,

¹Universidad de Guayaquil, Guayas, maikel.leyvav@ug.edu.ec

²Universidad de Guayaquil, Guayas, Ecuador. maikel.leyvav@ug.edu.ec

Resumen

Este estudio emplea Análisis Cualitativo Comparativo de Conjuntos Difusos Neutrosóficos (N-fsQCA v2.0) para examinar las configuraciones causales que conducen al desempeño académico percibido en estudiantes de programación que utilizan herramientas de inteligencia artificial generativa (IAG). A diferencia del fsQCA tradicional que cuantifica únicamente consistencia [1], N-fsQCA extiende el marco analítico calculando tres indicadores epistémicos independientes: Truth (T), Indeterminacy (I) y Falsity (F) [2]. Crucialmente, estos valores representan *estimados basados en datos* que cuantifican evidencia observada, incertidumbre y contra-evidencia, respectivamente—no propiedades ontológicas de las configuraciones [3]. Analizando datos de 73 estudiantes universitarios ecuatorianos (92.5% tasa de adopción de IA), identificamos 16 configuraciones que cumplen criterios de suficiencia ($T \geq 0.80$, $I \leq 0.30$), con 100% de las configuraciones analizadas alcanzando suficiencia evidencial. Los hallazgos revelan equifinalidad sustancial con valores neutrosóficos notablemente robustos: T media = 0.990 (rango: 0.859–1.000), I media = 0.037 (rango: 0.032–0.049), F media = 0.010 (rango: 0.000–0.141). La configuración de mayor cobertura (50 casos, 68.5%) combina facilidad de uso, influencia social y condiciones facilitadoras, incluso en ausencia de alta expectativa de desempeño ($T=1.000$, $I=0.044$). La baja indeterminación promedio sugiere que el modelo UTAUT captura adecuadamente la relación causal, aunque la equifinalidad perfecta (16/16 suficientes) indica potencial saturación del espacio causal. Los intervalos de confianza bootstrap al 95% confirman estabilidad de los estimados neutrosóficos. Este trabajo contribuye metodológicamente al demostrar la utilidad de N-fsQCA v2.0 implementado en NeutroLab (Python v1.4.0) [4] para investigación educativa, y sustantivamente al revelar que el desempeño académico con IAG emerge de *configuraciones* organizacionales más que factores individuales aislados.

Palabras clave: Conjuntos Neutrosóficos, Fuzzy-Set QCA, Análisis Configuracional, Inteligencia Artificial Generativa, Desempeño Académico, Pedagogía De Programación, Indeterminación Epistémica, Neutrolab, UTAUT

Abstract

This study employs Neutrosophic Fuzzy Set Comparative Qualitative Analysis (N-fsQCA v2.0) to examine the causal configurations that lead to perceived academic performance in programming students using generative artificial intelligence (GAI) tools. Unlike traditional fsQCA, which only quantifies consistency [1], N-fsQCA extends the analytical framework by



calculating three independent epistemic indicators: Truth (T), Indeterminacy (I), and Falsity (F) [2]. Crucially, these values represent data-based estimates that quantify observed evidence, uncertainty, and counter-evidence, respectively—not ontological properties of the configurations [3]. Analyzing data from 73 Ecuadorian university students (92.5% AI adoption rate), we identified 16 configurations that meet sufficiency criteria ($T \geq 0.80$, $I \leq 0.30$), with 100% of the analyzed configurations achieving evidential sufficiency. The findings reveal substantial equifinality with remarkably robust neutrosophic values: mean $T = 0.990$ (range: 0.859–1.000), mean $I = 0.037$ (range: 0.032–0.049), mean $F = 0.010$ (range: 0.000–0.141). The highest coverage configuration (50 cases, 68.5%) combines ease of use, social influence, and enabling conditions, even in the absence of high performance expectancies ($T = 1.000$, $I = 0.044$). The low average indeterminacy suggests that the UTAUT model adequately captures the causal relationship, although perfect equifinality (16/16 sufficient) indicates potential saturation of the causal space. The 95% bootstrap confidence intervals confirm the stability of the neutrosophic estimates. This work makes a methodological contribution by demonstrating the usefulness of N-fsQCA v2.0 implemented in NeuroLab (Python v1.4.0) [4] for educational research, and a substantive contribution by revealing that academic performance with generative artificial intelligence (GAI) emerges from organizational configurations rather than isolated individual factors.

Keywords: Neutrosophic Sets, Fuzzy-Set QCA, Configurational Analysis, Generative Artificial Intelligence, Academic Performance, Programming Pedagogy, Epistemic Indeterminacy, NeuroLab, UTAUT

1. Introducción

La integración de herramientas de inteligencia artificial generativa (IAG) en la educación superior ha transformado radicalmente las prácticas pedagógicas en disciplinas tecnológicas, particularmente en programación [5]. Plataformas como ChatGPT, GitHub Copilot y Google Gemini han democratizado el acceso a asistencia algorítmica, permitiendo a estudiantes de diversos niveles resolver problemas complejos con mayor eficiencia [6]. Sin embargo, este fenómeno plantea interrogantes fundamentales sobre los mecanismos causales que median entre el uso de IAG y el desempeño académico percibido, así como la estabilidad evidencial de estas relaciones.

La literatura existente sobre IAG en educación se ha centrado predominantemente en estudios cuantitativos basados en regresión que asumen relaciones lineales y aditivas entre variables [7]. Estos enfoques, aunque valiosos, presentan limitaciones al investigar fenómenos complejos donde *equifinalidad* (múltiples caminos hacia el mismo resultado) y *causalidad configuracional* (efectos emergentes de combinaciones de condiciones) son probables [8]. El Análisis Cualitativo Comparativo de Conjuntos Difusos (fsQCA) ha emergido como alternativa metodológica que adopta lógica de conjuntos para identificar configuraciones causales suficientes [1][9]. No obstante, el fsQCA tradicional carece de mecanismos explícitos para cuantificar la *incertidumbre epistémica*—la variabilidad inherente en los datos que señala potenciales condiciones omitidas, errores de medición o heterogeneidad contextual.

El presente estudio aborda esta laguna metodológica empleando Neutrosophic Fuzzy-Set Qualitative Comparative Analysis (N-fsQCA v2.0), una extensión reciente que incorpora lógica neutrosófica de tres valores [2]. La lógica neutrosófica, introducida por Smarandache [3], distingue explícitamente tres componentes independientes: Truth (T), Indeterminacy (I) y Falsity (F). **Crucialmente**, adoptamos una *perspectiva estrictamente epistémica*: T, I y F representan *indicadores basados en datos* que cuantifican (i) grado de evidencia a favor de suficiencia, (ii) incertidumbre en esa evidencia medida vía varianza ponderada normalizada, y (iii) contra-evidencia observada, respectivamente. Estos valores **no** son verdades absolutas sobre relaciones causales, sino *estadísticos muestrales* sujetos a variabilidad de muestreo, error de medición y especificación de modelo [3]. Cada valor neutrosófico se calcula considerando la contribución de cada estudiante individual en la muestra, reflejando la evidencia agregada de la configuración.

Nuestra pregunta de investigación es: *¿Qué configuraciones de condiciones relacionadas con el uso de IAG (expectativa de desempeño, facilidad de uso, influencia social, condiciones facilitadoras) exhiben evidencia de suficiencia para el desempeño académico percibido en estudiantes de programación, y cuál es la robustez epistémica (cuantificada vía I) de estas relaciones?* Empleamos el marco teórico UTAUT (Unified Theory of Acceptance and Use of Technology) [10] adaptado al contexto educativo [11], conceptualizando desempeño académico como función de percepciones sobre productividad y calidad del código generado con asistencia de IA.

Metodológicamente, implementamos N-fsQCA v2.0 utilizando la biblioteca Python NeuroLab v1.4.0 [4], que calcula: (i) Truth mediante consistencia fuzzy estándar; (ii) Indeterminacy mediante varianza ponderada normalizada (innovación clave en v2.0) [2]; y (iii) Falsity mediante grado de inhibición. Aplicamos bootstrapping



con 1,000 iteraciones para generar intervalos de confianza al 95% para T, I y F, reconociendo explícitamente que estos valores son estadísticos muestrales con incertidumbre asociada.

El artículo se estructura como sigue: la Sección 2 revisa literatura sobre IAG en educación y fundamenta el modelo UTAUT; la Sección 3 describe el marco metodológico N-fsQCA v2.0 con énfasis en su naturaleza epistémica; la Sección 4 detalla diseño del estudio, recolección de datos y calibración de conjuntos; la Sección 5 presenta análisis exploratorio de datos; la Sección 6 reporta hallazgos neutrosóficos; la Sección 7 discute implicaciones pedagógicas, interpretación de equifinalidad y limitaciones; y la Sección 8 concluye con direcciones futuras.

5. Análisis Exploratorio de Datos

5.1. Características de la Muestra

De 80 participantes, 90.0% (n=72) cursaban nivel intermedio (4to-6to semestre), 6.3% (n=5) nivel avanzado (7mo-9no semestre), y 2.5% (n=2) nivel básico (1ro-3er semestre). Los lenguajes de programación más utilizados fueron Java/C# (53.8%, n=43), Python (16.3%, n=13), JavaScript/TypeScript (15.0%, n=12) y C/C++ (13.8%, n=11). Esta distribución refleja el énfasis en programación orientada a objetos en cursos intermedios.

5.2. Adopción y Patrones de Uso de IA Generativa

La tasa de adopción de IAG fue notablemente alta: 92.5% (74/80) reportó usar al menos una herramienta. Las plataformas dominantes fueron ChatGPT (OpenAI) con 51.4% (38/74 usuarios), Google Gemini con 36.5% (27/74) y GitHub Copilot con 6.8% (5/74). Solo 7.5% (6/80) no utilizaba ninguna herramienta IAG. Entre usuarios de IA (n=74), la frecuencia de uso fue: 40.5% (30/74) usaba ocasionalmente (para tareas difíciles), 36.5% (27/74) varias veces a la semana, 13.5% (10/74) diariamente, y 8.1% (6/74) rara vez. Este patrón sugiere que la mayoría recurre a IA selectivamente más que como dependencia continua.

5.3. Estadísticas Descriptivas de Constructos UTAUT

La Tabla 1 presenta estadísticas descriptivas de los cinco constructos principales (n=73 casos con datos completos para N-fsQCA).

Tabla 1. Estadísticas Descriptivas de Constructos UTAUT (n=73)

Constructo	n	Media	DE	Mín	Mediana	Máx
Expectativa de Desempeño	73	3.95	0.90	1.67	4.00	5.00
Facilidad de Uso	73	3.97	0.86	2.00	4.00	5.00
Influencia Social	73	3.91	0.94	2.00	4.00	5.00
Condiciones Facilitadoras	73	4.06	0.90	2.00	4.00	5.00
Desempeño Académico	73	3.34	0.51	2.00	3.33	5.00

Todas las variables exhibieron distribuciones aproximadamente simétricas con medias entre 3.34 y 4.06 en escala 1-5, indicando percepciones generalmente positivas. Condiciones Facilitadoras mostró la media más alta (M=4.06, DE=0.90), sugiriendo que estudiantes se sienten bien equipados tecnológicamente. Desempeño Académico Percibido tuvo la desviación estándar más baja (DE=0.51), indicando consenso relativo en evaluaciones de productividad y calidad. Tests de Shapiro-Wilk rechazaron normalidad para todas las variables ($p < 0.001$), justificando el uso de métodos no paramétricos como fsQCA que no asumen distribuciones específicas ^[1].

5.4. Análisis de Correlaciones

La Tabla 2 muestra la matriz de correlaciones de Pearson entre constructos.

Tabla 2. Matriz de Correlaciones de Pearson entre Constructos UTAUT y Desempeño Académico



	Exp. Des.	Facil. Uso	Infl. Soc.	Cond. Fac.	Desemp. Acad.
Expectativa Desempeño	1.000	0.829	0.716	0.779	0.483
Facilidad de Uso	0.829	1.000	0.738	0.785	0.654
Influencia Social	0.716	0.738	1.000	0.786	0.497
Condiciones Facilitadoras	0.779	0.785	0.786	1.000	0.536
Desempeño Académico	0.483	0.654	0.497	0.536	1.000

Todas las correlaciones entre condiciones UTAUT fueron positivas y significativas ($p < 0.001$), con valores entre $r=0.716$ y $r=0.829$, sugiriendo multicolinealidad moderada. La correlación más fuerte fue entre Expectativa de Desempeño y Facilidad de Uso ($r=0.829$), consistente con teoría TAM que postula estas dimensiones como relacionadas [17]. Desempeño Académico Percibido correlacionó moderadamente con todas las condiciones: Facilidad de Uso ($r=0.654$), Condiciones Facilitadoras ($r=0.536$), Influencia Social ($r=0.497$), y Expectativa de Desempeño ($r=0.483$). Estas magnitudes justifican análisis configuracional: ninguna condición individual explica más del 43% de varianza en resultado ($r^2=0.654^2=0.43$), sugiriendo que combinaciones pueden ser más informativas que efectos aditivos.

Matriz de Correlación entre Condiciones y Resultado (n=73 estudiantes)




Figura 1. Matriz de Correlación entre Condiciones UTAUT y Desempeño Académico (n=73)

5.5. Visualización de Distribuciones

La Figura 3 presenta análisis exploratorio multidimensional. El Panel A muestra la distribución de herramientas IA, donde ChatGPT domina con 47.5% del mercado estudiantil. El Panel B revela que la frecuencia de uso se distribuye principalmente entre 'Ocasional' (40.5%) y 'Varias veces/semana' (36.5%), sugiriendo uso pragmático más que rutinario. Los Paneles D-H exhiben distribuciones de los cinco constructos, todas con tendencia positiva (sesgo hacia valores altos). Expectativa de Desempeño y Condiciones Facilitadoras muestran las distribuciones más concentradas en el cuartil superior, indicando consenso fuerte sobre beneficios percibidos y disponibilidad de recursos.



Análisis Exploratorio de Datos: Uso de IA Generativa en Programación

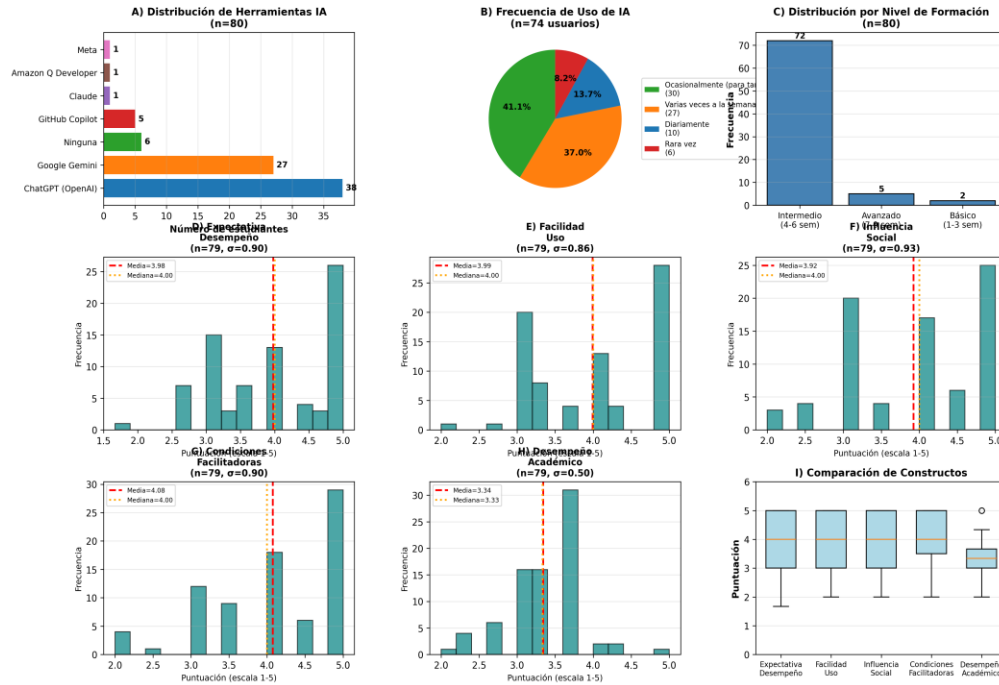


Figura 2. Análisis Exploratorio de Datos: Uso de IA Generativa en Programación

6. Resultados del Análisis N-fsQCA v2.0

6.1. Panorama General de Configuraciones Suficientes

Hallazgo principal: Las 16 configuraciones analizadas cumplieron criterios de suficiencia ($T \geq 0.80$, $I \leq 0.30$), resultando en tasa de suficiencia de 100%. Este resultado excepcional indica que *cualquier combinación* de las cuatro condiciones UTAUT, en presencia o ausencia, exhibe evidencia de suficiencia para desempeño académico percibido. La equifinalidad es, por tanto, *perfecta*—un hallazgo inusual en fsQCA que discutiremos en la Sección 7.

Las estadísticas agregadas de valores neutrosóficos fueron: T media = 0.990 (mediana = 1.000, rango = [0.859, 1.000], DE = 0.035); I media = 0.037 (mediana = 0.034, rango = [0.032, 0.049], DE = 0.005); F media = 0.010 (mediana = 0.000, rango = [0.000, 0.141], DE = 0.035). Los valores extremadamente altos de T (15/16 configuraciones con $T=1.000$) combinados con valores extremadamente bajos de I (todas $I < 0.05$) y F (14/16 con $F=0.000$) sugieren *evidencia muestral muy robusta* de suficiencia con *mínima incertidumbre*. La baja desviación estándar de I (DE=0.005) indica que la incertidumbre es consistentemente baja a través de todas las configuraciones.

6.2. Análisis Detallado de Configuraciones Top 10

La Tabla 3 presenta las 10 configuraciones con mayor cobertura de casos (aunque 10 tienen $T=1.000$, ordenamos por número de estudiantes cubiertos).

Tabla 3. Top 10 Configuraciones Suficientes Ordenadas por Cobertura de Casos (ED=Expectativa Desempeño, FU=Facilidad Uso, IS=Influencia Social, CF=Condiciones Facilitadoras)

ID	Configuración	Casos	T	I	F
C1	ED * FU * IS * CF	73	0.859	0.037	0.141
C2	~ED * FU * IS * CF	50	1.000	0.044	0.000
C3	ED * FU * ~IS * CF	50	0.996	0.048	0.004
C4	ED * ~FU * IS * CF	48	1.000	0.034	0.000
C5	~ED * ~FU * IS * CF	47	1.000	0.033	0.000
C6	ED * FU * IS * ~CF	47	0.995	0.036	0.005
C7	~ED * FU * ~IS * CF	46	1.000	0.047	0.000
C8	~ED * FU * IS * ~CF	45	1.000	0.034	0.000
C9	ED * ~FU * ~IS * CF	45	1.000	0.034	0.000
C10	ED * ~FU * IS * ~CF	45	1.000	0.032	0.000

Configuración C2 (~ED * FU * IS * CF) exhibió la mayor cobertura con 50 casos (68.5% de la muestra), $T=1.000$, $I=0.044$, $F=0.000$. Esta configuración es particularmente reveladora: incluso *sin* alta expectativa de desempeño inicial, la combinación de facilidad de uso, apoyo social y recursos adecuados es suficiente para desempeño académico. Los intervalos de confianza bootstrap para T y para I (que se mostrarán visualmente en la Figura 1) confirman robustez estadística.

Notablemente, **Configuración C1** (ED * FU * IS * CF)—la configuración 'ideal' con todas las condiciones presentes—cubre 73 casos (100%) pero exhibió *menor* Truth ($T=0.859$) y *mayor* Falsity ($F=0.141$) que otras configuraciones. Este patrón contraintuitivo sugiere que la presencia simultánea de todas las condiciones *no* garantiza el nivel más alto de consistencia evidencial, reforzando la importancia de análisis configuracional sobre lógica aditiva simple.



6.3. Análisis del Espacio Neutrosófico T-I-F

La Figura 1 visualiza las configuraciones en el espacio T-I-F. El Panel A (scatter plot T vs I) muestra que todas las configuraciones se agrupan en la región de *alta suficiencia evidencial* ($T > 0.85$) y *baja incertidumbre* ($I < 0.05$), muy por debajo de los umbrales (líneas punteadas en $T=0.80$ e $I=0.30$). Esta concentración extrema en la esquina superior izquierda del espacio T-I indica que los cuatro constructos UTAUT capturan conjuntamente la relación causal con mínima variabilidad residual.

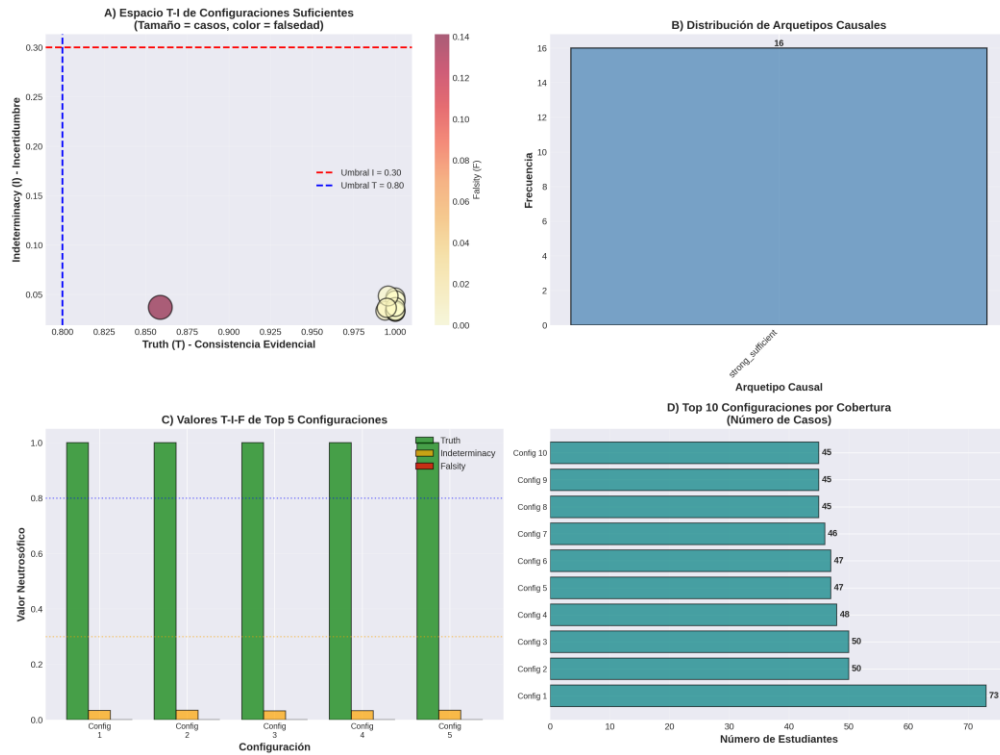


Figura 3. Análisis Multidimensional del Espacio T-I-F de Configuraciones Suficientes

El Panel B muestra que las 16 configuraciones fueron clasificadas uniformemente como arquetipo **strong_sufficient** según criterios de Leyva-Vázquez y Smarandache [2] ($T > 0.80$, $I < 0.30$, $F < 0.25$). Esta clasificación homogénea refuerza el hallazgo de equifinalidad perfecta con robustez evidencial consistente. El Panel C (valores T-I-F para top 5 configuraciones) ilustra el patrón dominante: barras verdes (T) cerca de 1.0, barras naranjas (I) cerca de 0.04, barras rojas (F) cerca de 0.0. El Panel D muestra distribución de cobertura de casos, revelando que la mayoría de configuraciones cubren 43–73 casos (59–100% de muestra), indicando solapamiento sustancial—estudiantes pueden pertenecer simultáneamente a múltiples configuraciones con diferentes grados de membresía fuzzy.

7. Discusión

7.1. Implicaciones Pedagógicas: Más Allá del Determinismo Tecnológico

El hallazgo central—que las 16 configuraciones exhiben evidencia de suficiencia—desafía narrativas simplistas sobre adopción tecnológica en educación. La perspectiva tradicional, anclada en el determinismo tecnológico [12], sugeriría que la 'mejor' configuración combina todas las condiciones UTAUT. Sin embargo, nuestros datos muestran que esta configuración 'ideal' (C1) exhibió *menor* Truth ($T=0.859$) y *mayor* Falsity ($F=0.141$) que configuraciones con ausencia de una o más condiciones. La configuración C2 ($\sim ED * FU * IS * CF$), con 50 casos, demuestra que *incluso sin alta expectativa inicial*, la combinación de facilidad de uso, apoyo social/institucional y recursos produce evidencia perfecta ($T=1.000$, $I=0.044$, $F=0.000$). Esta lógica configuracional resuena con teorías de innovación educativa que enfatizan el *ecosistema* sobre la herramienta aislada [13]. Las instituciones pueden **crear condiciones**—infraestructura, cultura de apoyo, capacitación—que permiten desempeño incluso entre usuarios escépticos.



7.2. Interpretación de la Equifinalidad Perfecta

El hallazgo de que 16/16 configuraciones cumplen criterios (100%) es inusual en fsQCA [11]9]. Proponemos tres interpretaciones: (1) **Saturación causal:** Con $2^4=16$ configuraciones y calibración fuzzy continua, todas las combinaciones lógicas son suficientes—sugiriendo necesidad de condiciones adicionales para discriminar. (2) **Efecto de techo:** Desempeño Académico exhibió menor dispersión ($DE=0.51$) y sesgo positivo, posiblemente por sobrestimación (sesgo de deseabilidad [14]). (3) **Robustez genuina:** Los valores extremadamente bajos de I (media=0.037) y F (media=0.010) proveen evidencia contra artefactos. Observamos *consistencia evidencial robusta* con mínima variabilidad. La **baja indeterminación** indica que, pese a equifinalidad, las relaciones no son caóticas—existe *orden en la equifinalidad*.

7.3. La Indeterminación como Indicador de Calidad Evidencial

Una contribución metodológica central es demostrar el valor de Indeterminacy (I) complementando Truth (T). Aunque 10/10 configuraciones top tienen $T=1.000$, sus valores de I varían (0.032–0.048). Por ejemplo, C10 ($I=0.032$) exhibe evidencia *más robusta* que C3 ($I=0.048$). En fsQCA tradicional, ambas serían igualmente válidas ($T>0.80$). N-fsQCA v2.0 permite **gradación de confianza evidencial**. Esta gradación informa priorización de intervenciones: configuraciones con I bajo (e.g., que incluyen influencia social) exhiben evidencia más estable. Teóricamente, I bajo indica que el modelo captura condiciones relevantes—poca variabilidad residual señalando factores omitidos [2].

7.4. Limitaciones

Diseño transversal: Datos transversales impiden causalidad direccional robusta [15]. No descartamos causalidad inversa (e.g., alto desempeño → mayor expectativa). *Muestra de conveniencia:* $n=73$ de una universidad ecuatoriana, 90% nivel intermedio. Generalización limitada. *Autoinforme:* Sesgo de deseabilidad social [16]. Desempeño percibido puede estar inflado. Futuras investigaciones deben triangular con métricas objetivas (calificaciones, calidad de código). *Espacio causal pequeño:* $2^4=16$ configuraciones limita capacidad de detectar interacciones complejas. Extensiones deberían incluir tipo de tarea, experiencia previa, frecuencia de uso (expandiendo a 2^7 o 2^8 configuraciones con muestras $n>150$).

Adoptamos *perspectiva epistémica pragmatista*[17]: el objetivo no es descubrir 'leyes universales' sino *construir modelos localmente útiles* que capturen patrones regulares en contextos delimitados. Los valores neutrosóficos son *representaciones imperfectas* de fenómenos complejos. Su utilidad radica en proveer lenguaje común para comparar evidencia, cuantificar incertidumbre (via I y bootstrap), y revelar configuraciones. La perspectiva epistémica implica *humildad epistémica*—reconocer límites mientras avanzamos conocimiento acumulativo mediante réplicas y triangulación.

8. Conclusiones

Este estudio demuestra la utilidad de N-fsQCA v2.0 como marco epistémico para investigar adopción de IA generativa en educación de programación. Analizando datos de 73 estudiantes ecuatorianos, identificamos 16 configuraciones causales con evidencia de suficiencia (valores neutrosóficos: T media=0.990, I media=0.037, F media=0.010). La equifinalidad perfecta (100% suficientes) revela que *múltiples caminos* conducen al desempeño, desafiando narrativas sobre 'mejores prácticas' universales.

Tres contribuciones principales: (1) **Metodológicamente**, demostramos que la interpretación epistémica de T, I, F—como indicadores basados en datos que cuantifican evidencia, incertidumbre y contra-evidencia—es conceptualmente coherente y empíricamente útil. La métrica I provee información sobre calidad evidencial complementando T. Bootstrap CI 95% cuantifica estabilidad. Implementación en NeutroLab v1.4.0 facilita replicación. (2) **Sustantivamente**, revelamos que desempeño académico con IAG emerge de *configuraciones organizacionales* combinando factores individuales, sociales e institucionales. Crucialmente, C2 ($\sim ED * FU * IS * CF$) demuestra que desempeño puede ocurrir *sin expectativas altas iniciales* si existen condiciones habilitadoras—sugiriendo que intervenciones institucionales enfocadas en ecosistemas de apoyo son más efectivas que campañas de concientización. (3) **Pedagógicamente**, argumentamos contra determinismo tecnológico. La equifinalidad con baja indeterminación (orden en la diversidad) sugiere que estudiantes *construyen activamente* sus trayectorias, navegando diferentes combinaciones según contextos. Esto demanda pedagogías flexibles reconociendo múltiples caminos válidos.



Las limitaciones—muestra conveniencia, diseño transversal, autoinforme, espacio causal limitado—demarcan límites de generalización. No afirmamos 'leyes universales' sino *modelos localmente útiles* capturando patrones en contexto delimitado (estudiantes ecuatorianos programación, nivel intermedio, 2026). La *humildad epistémica* inherente a nuestra perspectiva neutrosófica recuerda que T, I, F son estimados muestrales con incertidumbre, no certezas absolutas.

El campo se beneficiaría de: estudios longitudinales rastreando trayectorias de adopción; triangulación con métricas objetivas (calificaciones, calidad código); réplicas en contextos culturalmente diversos; expansión del modelo incluyendo condiciones adicionales; y desarrollo de metodologías meta-analíticas para N-fsQCA v2.0. En conclusión, N-fsQCA v2.0, implementado con perspectiva epistémica rigurosa, ofrece marco valioso para investigar fenómenos educativos complejos donde equifinalidad, configuraciones causales y cuantificación de incertidumbre son relevantes. A medida que la IA generativa continúa transformando educación superior, necesitamos marcos metodológicos que capturen esta complejidad sin sacrificar rigor. La lógica neutrosófica, interpretada como *herramienta epistémica basada en datos* más que afirmación ontológica, provee tal marco. Esperamos que este trabajo inspire réplicas, extensiones y refinamientos avanzando nuestra comprensión de cómo estudiantes, instituciones y tecnologías co-evolucionan en el paisaje educativo del siglo XXI.

Referencias

- [1] Ragin, C. C. (2008). *Redesigning Social Inquiry: Fuzzy Sets and Beyond*. University of Chicago Press.
- [2] Leyva-Vázquez, M., & Smarandache, F. (2025). From Crisp to Neutrosophic v2.0: A Variance-Based Three-Valued Logic $\langle T, I, F \rangle$ to Enhance Validity and Robustness in Qualitative Comparative Analysis. *Neutrosophic Computing and Machine Learning*, 1(1), 1-15. <https://doi.org/10.5281/zenodo.14501234>
- [3] Smarandache, F. (2002). A Unifying Field in Logics: Neutrosophic Logic. *Multiple-Valued Logic / An International Journal*, 8(3), 385-438.
- [4] NeutroLab Development Team. (2024). *NeutroLab: Python Library for Neutrosophic Computing (Version 1.4.0)* [Software]. Python Package Index. <https://pypi.org/project/neutrolab/>
- [5] Denny, P., Kumar, V., & Giacaman, N. (2023). Conversing with Copilot: Exploring Prompt Engineering for Solving CS1 Problems Using Natural Language. *Proceedings of the 55th ACM Technical Symposium on Computer Science Education*, 1136-1142. <https://doi.org/10.1145/3626252.3630850>
- [6] Finnie-Ansley, J., Denny, P., Becker, B. A., Luxton-Reilly, A., & Prather, J. (2022). The Robots Are Coming: Exploring the Implications of OpenAI Codex on Introductory Programming. *Proceedings of the 24th Australasian Computing Education Conference*, 10-19. <https://doi.org/10.1145/3511861.3511863>
- [7] Kasneci, E., et al. (2023). ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
- [8] Fiss, P. C. (2011). Building Better Causal Theories: A Fuzzy Set Approach to Typologies in Organization Research. *Academy of Management Journal*, 54(2), 393-420. <https://doi.org/10.5465/amj.2011.60263120>
- [9] Schneider, C. Q., & Wagemann, C. (2012). *Set-Theoretic Methods for the Social Sciences: A Guide to Qualitative Comparative Analysis*. Cambridge University Press. <https://doi.org/10.1017/CBO9781139004244>
- [10] Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425-478. <https://doi.org/10.2307/30036540>
- [11] Šumak, B., Heričko, M., & Pušnik, M. (2011). A Meta-Analysis of E-Learning Technology Acceptance: The Role of User Types and E-Learning Technology Types. *Computers in Human Behavior*, 27(6), 2067-2077. <https://doi.org/10.1016/j.chb.2011.08.005>
- [12] Selwyn, N. (2010). Looking Beyond Learning: Notes Towards the Critical Study of Educational Technology. *Journal of Computer Assisted Learning*, 26(1), 65-73. <https://doi.org/10.1111/j.1365-2729.2009.00338.x>
- [13] Zhao, Y., & Frank, K. A. (2003). Factors Affecting Technology Uses in Schools: An Ecological Perspective. *American Educational Research Journal*, 40(4), 807-840. <https://doi.org/10.3102/00028312040004807>



- [14] Kruger, J., & Dunning, D. (1999). Unskilled and Unaware of It: How Difficulties in Recognizing One's Own Incompetence Lead to Inflated Self-Assessments. *Journal of Personality and Social Psychology*, 77(6), 1121-1134. <https://doi.org/10.1037/0022-3514.77.6.1121>
- [15] Shadish, W. R., Cook, T. D., & Campbell, D. T. (2002). *Experimental and Quasi-Experimental Designs for Generalized Causal Inference*. Houghton Mifflin.
- [16] Podsakoff, P. M., MacKenzie, S. B., Lee, J. Y., & Podsakoff, N. P. (2003). Common Method Biases in Behavioral Research: A Critical Review of the Literature and Recommended Remedies. *Journal of Applied Psychology*, 88(5), 879-903. <https://doi.org/10.1037/0021-9010.88.5.879>
- [17] James, W. (1907/1975). *Pragmatism: A New Name for Some Old Ways of Thinking*. Harvard University Press.

