



Automatización de auditoría de costos con IA: mejorando la precisión y reducción de errores

Automation of cost auditing with artificial intelligence: improving accuracy and reducing errors



Darwin Fabricio Sánchez Caguana ^I

dfsanchez@institutos.gob.ec

<https://orcid.org/0000-0002-9716-2887>

Instituto Superior Tecnológico Pelileo,
Pelileo – Ecuador



Juan Carlos Pico Lescano ^{II}

jcpico7@gmail.com

<https://orcid.org/0000-0003-2627-9989>

Instituto Superior Tecnológico Pelileo,
Pelileo – Ecuador



Fecha de envío: 2026-06-17 Fecha de revisión: 2026-07-18 Fecha de aceptación: 2026-08-28

Resumen

El objetivo del artículo fue analizar de qué manera una propuesta de automatización de auditoría de costos con inteligencia artificial (IA) puede mejorar la precisión y reducir errores en procesos de validación, conciliación y documentación contable. La metodología se diseñó como un estudio cuasi experimental de enfoque correlacional descriptivo, con grupo de control y grupo experimental, integrado por 80 empresas participantes. Se elaboró un test de base estructurada para medir destrezas de auditoría de costos, validado por expertos y con confiabilidad alta mediante alfa de Cronbach de 0.89. Se aplicaron correlación de Pearson, prueba t de Student para muestras independientes, análisis de varianza descriptivo y d de Cohen para estimar el tamaño del efecto. Los resultados simulados muestran que el grupo experimental alcanzó mayores niveles de precisión global, reducción de inconsistencias y trazabilidad documental frente al grupo de control. La ganancia más relevante se observó en detección de anomalías e identificación de variaciones, con diferencias estadísticamente significativas y tamaños de efecto muy altos. La conclusión sostiene que la IA, aplicada con supervisión humana, reglas contables claras y documentación verificable, fortalece la auditoría de costos al transformar grandes volúmenes de datos en alertas útiles para el juicio profesional. Se advierte que los resultados deben reemplazarse por datos reales antes de su publicación, pues el presente documento funciona como modelo académico de estructura, análisis estadístico y redacción científica.

Palabras clave: auditoría de costos; inteligencia artificial; automatización; reducción de errores; precisión contable.

Abstract

The objective of this article was to analyze how an artificial intelligence (AI)-based cost auditing automation proposal can improve accuracy and reduce errors in accounting validation, reconciliation, and documentation processes. The methodology was designed as a quasi-experimental study with a descriptive correlational approach, including a control group and an experimental group with 80 participants. A structured test was developed to measure cost auditing skills, validated by experts and showing high reliability through a Cronbach's alpha of 0.89. Pearson correlation, independent-samples Student's t-test, descriptive analysis of variance, and Cohen's d were applied to estimate statistical significance and effect size. The simulated results show that the experimental

group achieved higher levels of overall accuracy, lower inconsistency rates, and stronger documentary traceability compared with the control group. The most relevant gain was observed in anomaly detection and variance identification, with statistically significant differences and very large effect sizes. The conclusion argues that AI, when applied with human supervision, clear accounting rules, and verifiable documentation, strengthens cost auditing by transforming large volumes of data into useful alerts for professional judgment. It is noted that the results must be replaced with real data before publication, since this document functions as an academic model for structure, statistical analysis, and scientific writing.

Keywords: cost auditing; artificial intelligence; automation; error reduction; accounting accuracy.

Introducción

La auditoría de costos atraviesa una transición profunda: dejó de ser un proceso centrado únicamente en muestreo documental, conciliaciones manuales y revisión posterior de desviaciones, para convertirse en un sistema de aseguramiento apoyado en datos masivos, automatización y análisis predictivo. En este artículo, la inteligencia artificial (IA) se entiende como el conjunto de técnicas computacionales capaces de identificar patrones, clasificar transacciones, detectar anomalías, aprender de históricos contables y asistir la toma de decisiones del auditor. En costos, esa asistencia resulta especialmente sensible porque las variaciones de materiales, mano de obra, gastos indirectos, centros de costo, órdenes de producción, inventarios, depreciación y prorrateos pueden generar errores acumulativos que afectan márgenes, presupuestos y decisiones gerenciales. La literatura contable advierte que los datos masivos están modificando la naturaleza de la evidencia, la oportunidad del análisis y el papel profesional del auditor (Vasarhelyi et al., 2015; Warren et al., 2015; Appelbaum et al., 2017; Gepp et al., 2018).

La automatización aplicada a auditoría de costos combina automatización robótica de procesos (Robotic Process Automation [RPA]), aprendizaje automático (Machine Learning [ML]), procesamiento de lenguaje natural (Natural Language Processing [NLP]), reconocimiento óptico de caracteres (Optical Character Recognition [OCR]), minería de procesos y analítica de datos. La RPA automatiza tareas repetitivas y basadas en reglas, como extracción de comprobantes, cruce de órdenes de compra, lectura de facturas, validación de campos y actualización de matrices de auditoría; el ML permite

detectar patrones atípicos en registros de costos; el NLP ayuda a interpretar documentos y políticas; el OCR convierte documentos físicos o digitalizados en datos; y la minería de procesos reconstruye el flujo real de aprobaciones y transacciones desde registros de eventos (Moffitt et al., 2018; Van der Aalst, 2016; El-Gharib & Amyot, 2022; Wewerka & Reichert, 2020). Esta convergencia permite pasar de una auditoría episódica a una auditoría continua con alertas tempranas, trazabilidad y pruebas sobre poblaciones completas.

Desde la perspectiva de la calidad de auditoría, la IA no reemplaza el juicio profesional, pero sí puede ampliar su alcance. Appelbaum et al. (2017) sostienen que la analítica avanzada transforma la planificación, la obtención de evidencia y la evaluación de riesgos; Kokina y Davenport (2017) explican que la automatización cambia la distribución del trabajo, trasladando al auditor desde tareas de captura hacia interpretación, escepticismo y validación; Issa et al. (2016) proponen formalizar actividades de auditoría para que los sistemas inteligentes complementen a los equipos humanos; y Dai y Vasarhelyi (2016) imaginan una auditoría 4.0 soportada en sensores, sistemas empresariales y análisis continuo. En costos, estos aportes se traducen en la posibilidad de revisar cada transacción relevante, detectar desviaciones por centro de responsabilidad y priorizar partidas con mayor riesgo financiero antes del cierre contable. Las comisiones y organismos internacionales han insistido en que la transformación digital debe vincularse con productividad, inclusión, gobernanza y capacidades humanas. La Comisión Económica para América Latina y el Caribe (CEPAL, 2025) ubica la IA como un componente crítico para identificar brechas y oportunidades de transformación digital en la región; la Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO, 2021) enfatiza que los sistemas de IA deben operar bajo principios de transparencia, supervisión humana, equidad y rendición de cuentas; la Organización para la Cooperación y el Desarrollo Económicos (OECD, 2026) reporta usos de IA en auditoría pública para detección de anomalías, procesamiento documental, gestión del conocimiento y evaluación predictiva de riesgos; y la Organización Internacional del Trabajo junto con el Banco Mundial muestran que la IA generativa puede transformar una proporción importante de empleos en América Latina, aunque sus beneficios dependen de infraestructura digital y capacitación (Gmyrek et al., 2024). En el plano formativo, el Ministerio de Educación del Perú (MINEDU) y otros sistemas educativos latinoamericanos han promovido competencias digitales como parte de la

preparación para escenarios productivos mediados por tecnologías de información. Esta idea dialoga con la auditoría de costos porque el auditor actual necesita saber leer bases de datos, comprender controles automatizados, interpretar salidas algorítmicas y documentar evidencia digital con criterios éticos. No basta con instalar herramientas; se requiere desarrollar destrezas de validación de datos, interpretación de alertas, evaluación de controles, comunicación de hallazgos y razonamiento estadístico. De allí que esta investigación se organice alrededor de destrezas desarrolladas y no únicamente alrededor de indicadores de eficiencia operacional.

La literatura especializada también advierte riesgos. Brown-Liburd et al. (2015) señalan que el exceso de información puede afectar el juicio si no existen criterios de relevancia; Earley (2015) sostiene que la analítica de datos abre oportunidades, pero exige rediseñar competencias y procedimientos; Richins et al. (2017) indican que la profesión contable puede crear valor si combina datos estructurados y no estructurados con conocimiento del negocio; Sutton et al. (2016) recuerdan que la IA en contabilidad tiene una historia amplia y que sus avances deben evaluarse desde su contribución al razonamiento profesional; y Moll y Yigitbasioglu (2019) explican que las tecnologías de internet reconfiguran el trabajo contable y requieren nuevas agendas de investigación. Por ello, la automatización no debe presentarse como una solución mágica, sino como un sistema sociotécnico que integra datos, procesos, personas, controles y criterios de auditoría.

El contexto empresarial confirma la relevancia del tema. En cadenas globales de manufactura, servicios, retail, energía, banca, telecomunicaciones y tecnología, la automatización financiera se discute en entornos donde participan empresas como Microsoft, Google, Amazon, IBM, Oracle, SAP, Salesforce, Adobe, NVIDIA, Intel, Accenture, Deloitte, PwC, EY, KPMG, McKinsey, Bain, Boston Consulting Group, Siemens, General Electric, Schneider Electric, Toyota, Volkswagen, Ford, Tesla, Walmart, Costco, Carrefour, Nestlé, Unilever, Procter & Gamble, Coca-Cola, PepsiCo, Nike, Adidas, Zara-Inditex, H&M, Maersk, DHL, FedEx, UPS, JPMorgan Chase, Bank of America, BBVA, Santander, Telefónica, Claro, Mercado Libre, Nubank, Petrobras y Vale. La mención de estas organizaciones no pretende atribuir un mismo nivel de adopción a todas, sino mostrar que la auditoría de costos se inserta en ecosistemas empresariales donde los datos, la automatización, la trazabilidad y el control de riesgos son variables estratégicas.

En términos contables, la auditoría de costos requiere verificar consistencia entre documentos fuente, registros del sistema de planificación de recursos empresariales (Enterprise Resource Planning [ERP]), centros de costo, movimientos de inventario, órdenes de producción, costos estándar, costos reales y reportes gerenciales. La IA puede reducir errores en tres niveles: errores de captura, cuando detecta campos incompletos o incoherentes; errores de clasificación, cuando identifica imputaciones erradas a cuentas o centros de costo; y errores de análisis, cuando alerta desviaciones inusuales que no serían visibles en una muestra reducida. No obstante, todo resultado algorítmico exige validación humana, trazabilidad del criterio aplicado y control de sesgos, especialmente cuando las alertas pueden afectar decisiones sobre proveedores, áreas responsables o desempeño laboral.

Los estudios sobre auditoría continua y analítica de datos han mostrado que el valor de la automatización aumenta cuando se integra al ciclo completo de auditoría: comprensión del proceso, identificación de riesgos, extracción de datos, limpieza, pruebas, documentación, revisión de excepciones y comunicación de hallazgos (Alles et al., 2008; Cao et al., 2015; Sun, 2019). La auditoría de costos se beneficia de esta lógica porque su universo de transacciones suele ser voluminoso, repetitivo y altamente estructurado, lo que favorece la automatización de pruebas. Sin embargo, también contiene decisiones de criterio, como la razonabilidad del prorrateo, el análisis de variaciones y la evaluación de causas, que siguen dependiendo de expertos.

A pesar de los avances, persiste una brecha de investigación aplicada en América Latina sobre cómo medir el efecto de una propuesta de automatización de auditoría de costos con IA en destrezas profesionales concretas. Gran parte de la literatura se concentra en auditoría financiera, fraude o transformación digital general, mientras que los costos requieren indicadores específicos: precisión de conciliación, reducción de errores de imputación, rapidez de validación, trazabilidad de hallazgos, lectura de anomalías, confiabilidad del instrumento y efecto práctico de la intervención. Por esta razón, el presente artículo propone y evalúa, mediante un diseño cuasi experimental de enfoque correlacional descriptivo, una intervención orientada a mejorar la precisión y reducir errores en auditoría de costos con asistencia de IA.

El problema central se expresa de la siguiente manera: ¿en qué medida una propuesta de automatización de auditoría de costos con IA mejora la precisión, reduce errores y fortalece las destrezas de validación, conciliación, interpretación y documentación de los

participantes? La pregunta es pertinente porque la transformación digital no solo se mide por adopción tecnológica, sino por resultados verificables en desempeño profesional. En consecuencia, este estudio articula la evidencia científica sobre IA en auditoría, los principios de gobernanza digital de organismos internacionales y una matriz de resultados estadísticos que permite examinar diferencias entre un grupo de control y un grupo experimental.

Objetivo

Analizar la incidencia de una propuesta de automatización de auditoría de costos con inteligencia artificial en la mejora de la precisión, la reducción de errores y el desarrollo de destrezas de validación, conciliación, interpretación de alertas y documentación de evidencia contable en un diseño cuasi experimental con grupo de control y grupo experimental.

Metodología

La investigación se desarrolló como un estudio cuasi experimental de enfoque correlacional descriptivo, con dos grupos: un grupo de control que trabajó con procedimientos convencionales de auditoría de costos basados en revisión manual, hojas de cálculo y muestreo documental, y un grupo experimental que aplicó una propuesta de automatización de auditoría de costos con IA. La muestra estuvo integrada por 80 empresas participantes distribuidos en 40 para el grupo de control y 40 para el grupo experimental. El instrumento de recolección fue un test de base estructurada diseñado para medir destrezas asociadas con auditoría de costos asistida por IA: validación de datos contables, conciliación de costos, identificación de anomalías, clasificación de imputaciones, interpretación de alertas, documentación de evidencia y comunicación de hallazgos. El instrumento se organizó con una escala de 0 a 100 puntos y escenarios prácticos de revisión de transacciones, documentos, centros de costo, cuentas contables y reportes de variaciones. La validez de contenido fue revisada por diez expertos en auditoría, contabilidad de costos, analítica de datos y metodología de investigación, quienes evaluaron pertinencia, claridad, coherencia, suficiencia y aplicabilidad de los ítems. La propuesta de intervención también fue revisada por los expertos en cuanto a secuencia didáctica, alineación con destrezas, pertinencia tecnológica y coherencia con el objetivo de reducción de errores. La confiabilidad del instrumento se estimó mediante el alfa de Cronbach, obteniéndose un coeficiente de 0.89, valor interpretado como muy

confiable porque expresa alta consistencia interna entre los ítems que miden el constructo de destrezas de auditoría de costos. Cronbach (1951) planteó el coeficiente alfa como una medida de consistencia de las respuestas, y Tavakol y Dennick (2011) explican que su interpretación debe relacionarse con la naturaleza del instrumento, el número de ítems y la coherencia conceptual de la escala. En este estudio, el valor de 0.89 sugiere que el test permite medir de manera estable la precisión, la detección de errores y la capacidad de interpretación técnica, sin reducir la evaluación a un único desempeño aislado. Para el análisis estadístico se aplicó la correlación de Pearson con el fin de estimar la relación entre intensidad de uso de la automatización con IA y mejora en el desempeño de auditoría de costos. Esta prueba fue pertinente porque las variables fueron tratadas como cuantitativas continuas y se buscó identificar la fuerza y dirección de asociación entre uso tecnológico y ganancia de desempeño.

Asimismo, se aplicó la prueba t de Student para muestras independientes con la finalidad de comparar los promedios del grupo de control y del grupo experimental en el postest. Esta prueba permitió determinar si las diferencias observadas entre grupos eran estadísticamente significativas y no solo variaciones aleatorias. Se calculó además la d de Cohen para estimar el tamaño del efecto, dado que la significancia estadística no informa por sí sola la magnitud práctica de la diferencia; Cohen (1992) recomienda reportar tamaños del efecto para interpretar la relevancia de los cambios en investigación aplicada. Complementariamente, se empleó análisis de varianza (ANOVA) descriptivo por dimensión para observar qué destrezas concentraron mayor ganancia relativa, especialmente en validación, conciliación, trazabilidad y detección de errores. La intervención aplicada al grupo experimental se estructuró en fases: diagnóstico de errores frecuentes, preparación de datos, automatización de reglas de validación, lectura de alertas generadas por IA, contraste humano de excepciones, documentación de evidencias y elaboración de informe de auditoría de costos. La herramienta de IA fue conceptualizada como una plataforma de apoyo que integra reglas contables, detección de anomalías y clasificación de transacciones, sin sustituir el criterio del auditor. El grupo de control desarrolló los mismos casos prácticos, pero con procedimientos manuales y revisión convencional. Esta comparación permitió observar no solo la mejora de puntajes, sino también la reducción de errores y el fortalecimiento de destrezas profesionales vinculadas con precisión, oportunidad y trazabilidad.

Resultados

La tabla 1 evidencia que ambos grupos iniciaron con niveles similares de desempeño, con medias ubicadas entre 55.60 y 59.10 puntos. Esta equivalencia inicial es relevante porque permite atribuir con mayor cautela las diferencias posteriores a la intervención y no a ventajas previas del grupo experimental.

Tabla 1

Desempeño inicial en destrezas de auditoría de costos antes de la intervención.

Dimensión evaluada	Control M	Control DE	Exp. M	Exp. DE	Brecha inicial
Validación de datos contables	58.40	8.70	57.90	8.50	0.50
Conciliación de costos y documentos	56.80	9.10	57.20	8.80	-0.40
Detección de anomalías	55.60	8.40	56.10	8.20	-0.50
Clasificación de imputaciones	59.10	7.90	58.70	8.10	0.40
Documentación de evidencia	57.30	8.60	57.00	8.30	0.30

Nota. La brecha inicial más baja se ubicó en conciliación de costos y documentos (-0.40), lo que sugiere equivalencia razonable entre los grupos antes de la propuesta.

Desde una lectura técnica, los valores muestran que las destrezas de detección de anomalías y conciliación eran las más débiles al inicio, lo que coincide con la dificultad propia de revisar costos cuando los datos provienen de múltiples fuentes: facturas, órdenes, consumos, centros de costo y reportes del sistema ERP. La ausencia de diferencias marcadas también fortalece la lógica cuasi experimental, pues el grupo experimental no partió con ventaja sustantiva.

Tabla 2

Variación pretest-posttest en precisión de auditoría de costos por grupo.

Indicador de precisión	Control Pre	Control Post	Ganancia Control	Experimental Pre	Experimental Post	Ganancia Exp.
Coincidencia factura-orden	61.20	66.10	4.90	60.80	88.40	27.60
Validación de centro de costo	57.50	62.70	5.20	57.20	84.30	27.10
Cruce inventario-costeo	55.40	61.50	6.10	55.90	82.80	26.90
Identificación de variaciones	54.80	60.20	5.40	55.10	83.60	28.50

Sustento documental	58.30	64.00	5.70	58.00	86.10	28.10
---------------------	-------	-------	------	-------	-------	-------

Nota. La mayor ganancia del grupo experimental fue 28.50 puntos en identificación de variaciones, indicador clave para explicar diferencias entre costos reales y estándar.

La mejora del grupo experimental es amplia y consistente en todos los indicadores. Mientras el grupo de control aumentó entre 4.90 y 6.10 puntos, el grupo experimental aumentó entre 26.90 y 28.50 puntos. Este resultado sugiere que la automatización con IA no solo aceleró el proceso, sino que ayudó a estructurar mejor la revisión. La identificación de variaciones obtuvo la ganancia más alta, lo cual es especialmente importante en auditoría de costos porque las variaciones no explicadas suelen ocultar problemas de imputación, consumo, desperdicio, errores de inventario o asignaciones incorrectas de gastos indirectos. El desempeño experimental también revela que la tecnología fue más útil cuando se integró a reglas de validación y a criterios de interpretación, evitando que las alertas se conviertan en información sin uso práctico.

Tabla 3

Reducción de errores detectados por tipo de inconsistencia contable.

Tipo de inconsistencia	Tasa inicial %	Control final %	Experimental final %	Reducción relativa IA %	Prioridad de auditoría
Imputación errónea a centro de costo	18.60	14.90	4.20	77.42	Alta
Duplicidad de comprobantes	9.40	7.80	1.60	82.98	Alta
Diferencia factura-orden de compra	15.10	12.70	3.90	74.17	Alta
Prorratio inconsistente de indirectos	13.80	11.40	4.80	65.22	Media
Registro fuera de periodo	7.60	6.10	2.10	72.37	Media


Nota. La reducción relativa más significativa fue 82.98 % en duplicidad de comprobantes, un error altamente automatizable por coincidencia de campos críticos.

La tabla muestra que la IA resulta especialmente efectiva en errores con patrones identificables: duplicidad de comprobantes, diferencias factura-orden e imputaciones erróneas. La reducción relativa de 82.98 % en duplicidad es coherente con la naturaleza del problema, pues un algoritmo puede comparar número de documento, proveedor, monto, fecha, cuenta y orden asociada con mayor velocidad que una revisión manual. La reducción en prorratio de indirectos fue menor, aunque todavía importante, porque este

indicador exige mayor juicio contable: no basta con detectar una anomalía, también se debe evaluar la razonabilidad del criterio de distribución. Así, la tabla permite diferenciar tareas altamente automatizables de tareas que requieren acompañamiento experto.

Gráfico 1

Relación entre intensidad de uso de IA y mejora de desempeño en auditoría de costos.



Nota. El coeficiente más significativo fue $r = 0.78$ entre uso de alertas de IA y precisión total, lo que indica una asociación positiva alta.

La correlación de Pearson permite observar que el incremento de desempeño no depende únicamente de tener acceso a la herramienta, sino de usarla de manera guiada. La asociación más alta se ubica entre uso de alertas IA y precisión total, lo que indica que las alertas agregan valor cuando el participante sabe priorizarlas, contrastarlas y documentarlas. La relación entre revisión de excepciones y reducción de errores también es fuerte, lo cual confirma que la supervisión humana sigue siendo esencial. En términos prácticos, la IA funciona como filtro de riesgo, pero el auditor convierte ese filtro en evidencia cuando revisa la excepción, valida el criterio y explica el hallazgo.

Tabla 4

ANOVA descriptivo de ganancia por dimensión desarrollada en la propuesta.

Dimensión desarrollada	Media de ganancia	SC entre	Gl	F	p valor	η^2 parcial
Validación automatizada	27.30	318.40	1	42.18	< 0.001	0.351
Conciliación inteligente	26.80	302.60	1	39.74	< 0.001	0.337
Detección de anomalías	28.10	344.20	1	45.89	< 0.001	0.370
Trazabilidad documental	25.90	281.50	1	35.62	< 0.001	0.313

Comunicación de hallazgos	23.40	210.70	1	27.48	< 0.001	0.260
---------------------------	-------	--------	---	-------	---------	-------

Nota. La dimensión con mayor efecto fue detección de anomalías ($F = 45.89$; η^2 parcial = 0.370), evidenciando alta sensibilidad de la IA para patrones atípicos.

El ANOVA descriptivo confirma que las ganancias no fueron homogéneas: la detección de anomalías tuvo el efecto más alto, seguida por validación automatizada y conciliación inteligente. Esto es lógico porque las técnicas de IA y reglas automatizadas operan con mayor potencia en tareas donde existen patrones de comparación claros. La comunicación de hallazgos, aunque mejora, presenta menor tamaño relativo porque depende más de habilidades de redacción, criterio profesional y argumentación contable. Este resultado es valioso para diseñar futuras capacitaciones: primero se debe fortalecer lectura de datos y alertas, y luego trabajar la capacidad de convertir hallazgos técnicos en informes comprensibles para gerencia o comité de auditoría.

Tabla 5

Indicadores contables de eficiencia y trazabilidad del flujo de auditoría.

Indicador operativo	Convencional	IA	Diferencia	Impacto esperado
Tiempo promedio por lote de 100 registros	145 min	52 min	-93 min	Mayor oportunidad de revisión
Cobertura de transacciones verificadas	28 %	96 %	+68 pp	Pruebas casi poblacionales
Alertas documentadas con evidencia	41 %	89 %	+48 pp	Mejor trazabilidad
Reprocesos por inconsistencia	22 casos	7 casos	-15 casos	Menor costo de corrección
Hallazgos priorizados por riesgo	46 %	91 %	+45 pp	Mejor enfoque auditor

Nota. La cobertura de transacciones verificadas aumentó 68 puntos porcentuales, el cambio operativo más relevante para una auditoría de costos basada en poblaciones amplias.

La automatización muestra un impacto operativo claro: reduce tiempo, aumenta cobertura, mejora documentación y disminuye reprocesos. El aumento de cobertura es el indicador más estratégico porque transforma el alcance de la auditoría. En lugar de revisar una muestra limitada, el equipo puede analizar casi toda la población transaccional y concentrar el juicio profesional en excepciones relevantes. La reducción de 93 minutos por lote de 100 registros no debe interpretarse solo como ahorro de tiempo, sino como

liberación de capacidad analítica: el auditor dispone de más tiempo para comprender causas, conversar con responsables, revisar controles y formular recomendaciones.

Tabla 6

Prueba t de Student para muestras independientes en el postest global.

Comparación	Media Control	DE Control	Media Experimental	DE Experimental	T	gl	p valor
Precisión global	63.70	8.10	84.60	7.20	12.20	78	< 0.001
Reducción de errores	65.30	8.60	86.20	6.90	11.98	78	< 0.001
Trazabilidad de evidencia	64.00	8.30	83.70	7.60	11.08	78	< 0.001
Interpretación de alertas	61.90	8.80	82.40	7.80	11.02	78	< 0.001

Nota. La diferencia más alta se observó en precisión global, con $t = 12.20$ y $p < 0.001$, lo que indica diferencia estadísticamente significativa a favor del grupo experimental.

La prueba t de Student confirma que las diferencias entre grupos en el postest son estadísticamente significativas en todas las dimensiones. Este resultado respalda la hipótesis de que la propuesta de automatización con IA mejora el desempeño frente al procedimiento convencional. La precisión global destaca porque resume la capacidad del participante para validar, conciliar y justificar resultados de auditoría. Desde el punto de vista contable, esta diferencia es relevante porque una mayor precisión reduce la probabilidad de que errores de costos se trasladen a reportes gerenciales, presupuestos o decisiones de precio.

La d de Cohen permite afirmar que las diferencias no solo son estadísticamente significativas, sino también relevantes desde una perspectiva práctica. Los valores superiores a 2.00 evidencian efectos muy altos, especialmente en detección de anomalías y validación de datos. En una auditoría de costos real, un efecto de esta magnitud implicaría que la intervención no se limita a una mejora marginal: cambia la manera en que el participante identifica, prioriza y documenta errores. La lectura práctica es decisiva para gerentes y auditores, porque justifica inversión en capacitación, depuración de datos y herramientas de automatización siempre que se garantice supervisión humana.

Gráfico 2

Tamaño del efecto mediante d de Cohen por destreza desarrollada.



Nota. El mayor tamaño del efecto fue $d = 2.85$ en detección de anomalías, lo cual indica una magnitud práctica muy alta.

Como parte de la intervención, la propuesta fue sometida a validación por diez expertos en auditoría de costos, contabilidad, analítica de datos, control interno y metodología de investigación. La revisión se concentró en la pertinencia de las actividades, claridad de las destrezas desarrolladas, secuencia de implementación, viabilidad de recursos, alineación con la reducción de errores y coherencia entre la automatización propuesta y el juicio profesional del auditor. Los expertos coincidieron en que una automatización responsable debe partir de datos limpios, reglas contables justificadas, supervisión humana y documentación verificable de cada alerta.

Tabla 7

Propuesta de automatización de auditoría de costos con IA según actividades, destrezas, tiempos y recursos.

Actividad	Destrezas desarrolladas	Tiempo	Contenidos	Recursos	Objetivo de la actividad
Diagnóstico de errores frecuentes	Lectura crítica de registros y priorización de riesgos	2 h	Tipos de errores de costos, centros de costo, duplicidades	Base de datos, checklist, matriz de riesgos	Identificar patrones de error antes de automatizar
Preparación y limpieza de datos	Validación de campos,	3 h	ERP, facturas, órdenes,	Hoja de cálculo, extractor,	Asegurar calidad

	consistencia y completitud		inventario, normalización	diccionario de datos	mínima de la información
Configuración de reglas IA	Diseño de criterios de alerta y control	4 h	Reglas de negocio, umbrales, clasificación contable	Plataforma IA, reglas parametrizadas	Automatizar validaciones repetitivas
Revisión de alertas y excepciones	Interpretación, contraste y juicio profesional	4 h	Alertas, falsos positivos, evidencia documental	Panel de alertas, repositorio digital	Convertir alertas en evidencia verificable
Conciliación inteligente	Cruce de documentos y rastreo de diferencias	3 h	Factura-orden, costo estándar-real, inventario	Motor de conciliación, matriz de hallazgos	Reducir errores de conciliación
Informe de auditoría de costos	Comunicación técnica y recomendación	2 h	Hallazgos, causas, impacto, recomendaciones	Plantilla de informe, tablero de control	Presentar resultados trazables y accionables

Nota. La actividad más crítica fue la revisión de alertas y excepciones, porque integra IA, evidencia y juicio profesional.

La propuesta fue validada por diez expertos, quienes revisaron la pertinencia de cada actividad, la secuencia de implementación, la coherencia entre contenidos y destrezas, la viabilidad del tiempo propuesto y la alineación con el objetivo de mejorar precisión y reducir errores. La tabla resume una ruta aplicable y progresiva: no inicia con la herramienta, sino con el diagnóstico y la preparación de datos, porque una automatización alimentada con información deficiente puede multiplicar errores. La fase de revisión de alertas es el núcleo de la propuesta, ya que enseña al participante a no aceptar automáticamente la salida de IA, sino a contrastarla con evidencia y criterio contable.

Discusión

Los resultados simulados muestran una mejora sustantiva del grupo experimental frente al grupo de control, especialmente en precisión de validación, reducción de errores y trazabilidad de hallazgos. Este patrón es coherente con Appelbaum et al. (2017), quienes sostienen que la analítica de datos permite ampliar la evidencia disponible y mejorar la identificación de riesgos; también coincide con Vasarhelyi et al. (2015) y Warren et al. (2015), para quienes el valor del dato masivo en contabilidad reside en convertir registros dispersos en información útil para decisiones. En auditoría de costos, esta utilidad se observa cuando la IA identifica transacciones atípicas, cruza documentos y anticipa desviaciones antes del cierre, reduciendo el peso de tareas manuales que suelen concentrar errores de captura y clasificación.

La mejora observada en conciliación y detección de inconsistencias se relaciona con los aportes de Moffitt et al. (2018), quienes explican que la RPA puede automatizar tareas repetitivas del proceso de auditoría, y con Van der Aalst (2016), quien demuestra que la minería de procesos permite reconstruir flujos reales a partir de registros de eventos. Desde esta lectura, la automatización no actúa únicamente como acelerador operativo, sino como mecanismo de visibilidad: muestra dónde se interrumpe la trazabilidad, qué aprobaciones se repiten, qué cuentas concentran reclasificaciones y qué centros de costo presentan desviaciones recurrentes. El grupo experimental mejora porque aprende a interpretar esas señales y no solo a ejecutar una herramienta.

La reducción de errores de imputación, duplicidad y conciliación dialoga con Cao et al. (2015), quienes plantean que la analítica de datos puede aplicarse a poblaciones completas de transacciones; con Gepp et al. (2018), quienes describen oportunidades de técnicas de big data en auditoría; y con Sun (2019), quien propone marcos de aprendizaje profundo para procedimientos de auditoría. En costos, revisar poblaciones completas ofrece una ventaja decisiva: los errores pequeños pueden acumularse y distorsionar la información gerencial. Por eso, un sistema de IA que alerta importes duplicados, centros de costo inusuales o desviaciones respecto del costo estándar contribuye a prevenir decisiones equivocadas sobre precios, márgenes y presupuestos.

La correlación positiva entre intensidad de uso de IA y mejora de desempeño debe interpretarse con prudencia. Kokina y Davenport (2017) advierten que la IA reconfigura el trabajo del auditor, pero no elimina la necesidad de juicio profesional; Brown-Liburd et al. (2015) recuerdan que el exceso de información puede producir ambigüedad si no hay criterios de relevancia; y Earley (2015) destaca que la analítica requiere competencias para transformar datos en evidencia. En consecuencia, la relación positiva no significa que usar más IA siempre genere mejores resultados, sino que el uso guiado, ético y técnicamente documentado puede fortalecer destrezas cuando se integra con formación, validación humana y control de calidad.

El tamaño del efecto obtenido en las dimensiones de validación, conciliación y detección de anomalías se alinea con la idea de Dai y Vasarhelyi (2016) de que la auditoría 4.0 no se limita a digitalizar documentos, sino que rediseña la lógica de aseguramiento. Issa et al. (2016) ya señalaban que la formalización de procedimientos es clave para que la IA complemente el trabajo profesional. Esta formalización aparece en la propuesta cuando las reglas de negocio, los criterios contables y los umbrales de alerta se convierten en

procedimientos verificables. De este modo, la IA aumenta la consistencia del análisis, mientras el auditor conserva la responsabilidad de revisar la razonabilidad, documentar excepciones y decidir el tratamiento de hallazgos.

Los hallazgos también se relacionan con Richins et al. (2017), Sutton et al. (2016) y Moll y Yigitbasioglu (2019), quienes coinciden en que el contador y el auditor no pierden relevancia ante la automatización si desarrollan capacidades de análisis, interpretación y comunicación. En la práctica, los participantes del grupo experimental no solo reducen errores por apoyo algorítmico, sino porque adoptan una forma distinta de pensar la auditoría: primero comprenden el flujo de datos, luego verifican reglas, después priorizan excepciones y finalmente documentan el juicio. Esta secuencia fortalece destrezas transferibles a distintos entornos empresariales.

El marco de organismos internacionales refuerza la necesidad de implementar IA con gobernanza. La CEPAL (2025) advierte brechas regionales en infraestructura, talento y adopción; UNESCO (2021) exige transparencia, supervisión humana y responsabilidad; OECD (2026) muestra que las instituciones de auditoría pública exploran IA para anomalías, riesgos y documentos; y Gmyrek et al. (2024) evidencian que la IA generativa puede transformar empleos en América Latina, aunque con beneficios condicionados por conectividad y capacidades. En consecuencia, una propuesta de automatización de auditoría de costos debe incluir no solo resultados estadísticos, sino también criterios de trazabilidad, ética, protección de datos, capacitación y revisión humana.

Desde la metodología, el uso del alfa de Cronbach de 0.89 aporta consistencia al instrumento y respalda la medición de destrezas, en línea con Cronbach (1951) y Tavakol y Dennick (2011). La prueba t de Student permite comparar grupos y la d de Cohen permite valorar impacto práctico, siguiendo a Cohen (1992) y Li (2016). Este punto es importante porque en investigaciones de tecnología aplicada es común reportar mejoras porcentuales sin establecer si son estadísticamente relevantes ni si poseen magnitud suficiente para justificar la intervención. La combinación de significancia, tamaño del efecto y análisis por dimensión ofrece una lectura más completa para decidir si la propuesta merece implementación real.

La principal contribución del estudio reside en trasladar el debate general de IA en auditoría hacia una medición concreta de destrezas en auditoría de costos. Mientras trabajos como los de Alles et al. (2008), Moffitt et al. (2018), Appelbaum et al. (2017), Sun (2019) y Gepp et al. (2018) ofrecen fundamentos sobre auditoría continua, analítica

y automatización, este artículo organiza indicadores específicos de costos: conciliación, imputación, variaciones, trazabilidad, duplicidad, evidencias y tiempo de revisión. Esta especificidad facilita que empresas, instituciones formativas y equipos de auditoría adapten la propuesta a casos reales.

Finalmente, los resultados deben leerse como un modelo académico con datos simulados, no como evidencia definitiva. La siguiente etapa debería aplicar la propuesta en empresas reales, con autorización institucional, registros auditables y control de variables como experiencia previa, complejidad del ERP, volumen de transacciones, madurez digital y calidad de datos. También sería pertinente comparar modelos de IA explicables con enfoques de reglas fijas, evaluar sesgos, medir falsos positivos y estimar retorno económico de la automatización. Con esa ampliación, la investigación podría aportar evidencia empírica robusta para la gestión de costos, la auditoría interna y la formación profesional en contabilidad digital.

Conclusiones

La automatización de auditoría de costos con IA constituye una alternativa metodológica relevante para mejorar la precisión, reducir errores y fortalecer destrezas profesionales vinculadas con validación de datos, conciliación, detección de anomalías, interpretación de alertas y documentación de evidencias. Los resultados simulados del modelo muestran diferencias favorables para el grupo experimental, con mejoras en indicadores de desempeño, reducción de errores y tamaños de efecto altos en las dimensiones más críticas del proceso. Esta contribución es significativa porque desplaza el debate desde una visión general de transformación digital hacia una medición específica del desempeño en auditoría de costos, donde la exactitud de los registros y la trazabilidad de los hallazgos inciden directamente en decisiones gerenciales, presupuestales y financieras.

Desde una perspectiva científica y profesional, el estudio evidencia que la IA debe ser comprendida como un sistema de apoyo al juicio auditor y no como sustituto de la responsabilidad humana. La propuesta aporta una ruta para integrar automatización, reglas contables, análisis estadístico, validación por expertos y criterios éticos de transparencia y supervisión. No obstante, al tratarse de un borrador con matriz simulada, su valor principal está en ofrecer una estructura sólida para una investigación aplicable; por ello, antes de publicarse, los indicadores deben ser reemplazados por datos reales

obtenidos en un contexto institucional verificable. La línea futura más importante consiste en validar el modelo en empresas con distintos niveles de madurez digital, comparando impactos en costos de auditoría, tiempo de revisión, calidad de evidencia y reducción efectiva de errores contables.

Referencias

- Alles, M. G., Kogan, A., & Vasarhelyi, M. A. (2008). Putting continuous auditing theory into practice: Lessons from two pilot implementations. *Journal of Information Systems*, 22(2), 195–214. <https://doi.org/10.2308/jis.2008.22.2.195>
- Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big data and analytics in the modern audit engagement: Research needs. *Auditing: A Journal of Practice & Theory*, 36(4), 1–27. <https://doi.org/10.2308/ajpt-51684>
- Bakumenko, A., & Elragal, A. (2022). Detecting anomalies in financial data using machine learning algorithms. *Systems*, 10(5), 130. <https://doi.org/10.3390/systems10050130>
- Brown-Liburd, H., Issa, H., & Lombardi, D. (2015). Behavioral implications of big data's impact on audit judgment and decision making and future research directions. *Accounting Horizons*, 29(2), 451–468. <https://doi.org/10.2308/acch-51023>
- Cao, M., Chychyla, R., & Stewart, T. (2015). Big data analytics in financial statement audits. *Accounting Horizons*, 29(2), 423–429. <https://doi.org/10.2308/acch-51068>
- Cohen, J. (1992). A power primer. *Psychological Bulletin*, 112(1), 155–159. <https://doi.org/10.1037/0033-2909.112.1.155>
- Comisión Económica para América Latina y el Caribe. (2025). Latin American Artificial Intelligence Index (ILIA) 2025: Executive summary. CEPAL. <https://www.cepal.org>
- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334. <https://doi.org/10.1007/BF02310555>
- Dai, J., & Vasarhelyi, M. A. (2016). Imagineering audit 4.0. *Journal of Emerging Technologies in Accounting*, 13(1), 1–15. <https://doi.org/10.2308/jeta-10494>
- Earley, C. E. (2015). Data analytics in auditing: Opportunities and challenges. *Business Horizons*, 58(5), 493–500. <https://doi.org/10.1016/j.bushor.2015.05.002>

- El-Gharib, N. M., & Amyot, D. (2022). Robotic process automation using process mining: A systematic literature review. arXiv. <https://doi.org/10.48550/arXiv.2204.00751>
- Gepp, A., Linnenluecke, M. K., O'Neill, T. J., & Smith, T. (2018). Big data techniques in auditing research and practice: Current trends and future opportunities. *Journal of Accounting Literature*, 40, 102–115. <https://doi.org/10.1016/j.acclit.2017.05.003>
- Gmyrek, P., Winkler, H., & Garganta, S. (2024). Buffer or bottleneck? Employment exposure to generative AI and the digital divide in Latin America. ILO Working Paper 121. <https://doi.org/10.54394/TFZY768101>
- Issa, H., Sun, T., & Vasarhelyi, M. A. (2016). Research ideas for artificial intelligence in auditing: The formalization of audit and workforce supplementation. *Journal of Emerging Technologies in Accounting*, 13(2), 1–20. <https://doi.org/10.2308/jeta-10511>
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of Emerging Technologies in Accounting*, 14(1), 115–122. <https://doi.org/10.2308/jeta-51730>
- Li, J. C. H. (2016). Effect size measures in a two-independent-samples case with nonnormal and nonhomogeneous data. *Behavior Research Methods*, 48, 1560–1574. <https://doi.org/10.3758/s13428-015-0667-z>
- Ministerio de Educación del Perú. (2016). Currículo Nacional de la Educación Básica. MINEDU. <https://www.gob.pe/minedu>
- Moffitt, K. C., Rozario, A. M., & Vasarhelyi, M. A. (2018). Robotic process automation for auditing. *Journal of Emerging Technologies in Accounting*, 15(1), 1–10. <https://doi.org/10.2308/jeta-10589>
- Moll, J., & Yigitbasioglu, O. (2019). The role of internet-related technologies in shaping the work of accountants: New directions for accounting research. *The British Accounting Review*, 51(6), 100833. <https://doi.org/10.1016/j.bar.2019.04.002>
- Organisation for Economic Co-operation and Development. (2026). The state of artificial intelligence in public audit. OECD Publishing. <https://doi.org/10.1787/f4a6c658-en>

- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura. (2021). Recommendation on the ethics of artificial intelligence. UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000380455>
- Richins, G., Stapleton, A., Stratopoulos, T. C., & Wong, C. (2017). Big data analytics: Opportunity or threat for the accounting profession? *Journal of Information Systems*, 31(3), 63–79. <https://doi.org/10.2308/isys-51805>
- Sun, T. (2019). Applying deep learning to audit procedures: An illustrative framework. *Accounting Horizons*, 33(3), 89–109. <https://doi.org/10.2308/acch-52455>
- Sutton, S. G., Holt, M., & Arnold, V. (2016). ‘The reports of my death are greatly exaggerated’: Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*, 22, 60–73. <https://doi.org/10.1016/j.accinf.2016.07.005>
- Tavakol, M., & Dennick, R. (2011). Making sense of Cronbach’s alpha. *International Journal of Medical Education*, 2, 53–55. <https://doi.org/10.5116/ijme.4dfb.8dfd>
- Van der Aalst, W. M. P. (2016). *Process mining: Data science in action* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-662-49851-4>
- Vasarhelyi, M. A., Kogan, A., & Tuttle, B. M. (2015). Big data in accounting: An overview. *Accounting Horizons*, 29(2), 381–396. <https://doi.org/10.2308/acch-51071>
- Warren, J. D., Moffitt, K. C., & Byrnes, P. (2015). How big data will change accounting. *Accounting Horizons*, 29(2), 397–407. <https://doi.org/10.2308/acch-51069>
- Wewerka, J., & Reichert, M. (2020). Robotic process automation: A systematic literature review and assessment framework. arXiv. <https://doi.org/10.48550/arXiv.2012.11951>

Declaración

Declaración	Detalle
Conflicto de intereses	El autor declara que no existe conflicto de interés posible.
Financiamiento	No existió asistencia financiera de partes externas para la elaboración del presente artículo.
Agradecimiento	N/A
Nota	El artículo no es producto de una publicación anterior. Los resultados incluidos corresponden a un modelo académico con matriz simulada y deben reemplazarse por datos reales antes de su envío editorial.