



Inteligencia artificial aplicada a la predicción financiera y la toma de decisiones estratégicas: impacto en la rentabilidad y la gestión del riesgo empresarial

Artificial intelligence applied to financial forecasting and strategic decision-making: impact on profitability and enterprise risk management

Artículo de investigación científica
Ciencias Sociales, Educacion Comercial y Derecho



Jonathan Paul Romero Jaramillo
jonaparo55@gmail.com



<https://orcid.org/0009-0001-1375-0527>

Universidad Técnica de Cotopaxi
Administración de empresas
Cotopaxi – Ecuador

Fecha de envío: 2026-05-13

Fecha de revisión: 2026-06-13

Fecha da aceptación: 2026-07-11

Resumen

El estudio evaluó el efecto de una intervención formativa basada en inteligencia artificial sobre la predicción financiera, la calidad de las decisiones estratégicas, la rentabilidad proyectada y la gestión del riesgo empresarial. Se adoptó un diseño cuasi experimental, descriptivo-correlacional, con 40 profesionales de cuatro centros empresariales, distribuidos en un grupo control y un grupo experimental de 20 participantes cada uno. Se aplicó un test estructurado, validado por diez expertos y con consistencia interna alta (alfa de Cronbach = 0,85). El análisis incluyó estadística descriptiva, correlación de Pearson, prueba t de Student para muestras independientes y análisis de covarianza, complementado con g de Hedges y eta cuadrado parcial. Los resultados simulados mostraron equivalencia inicial entre grupos y una mejora superior en el grupo experimental: la puntuación global pasó de 55,27 a 73,37 puntos, mientras el control avanzó de 53,61 a 59,43. También disminuyeron el error porcentual absoluto medio y el tiempo de decisión, y aumentaron la precisión direccional, la consistencia de escenarios, el margen operativo proyectado y la reducción de exposición al riesgo. La diferencia final fue significativa, $t(38) = 5,84$, $p < 0,001$, con un efecto amplio ($g = 1,81$). Se concluye que la inteligencia artificial, cuando se integra con criterios de gobernanza, explicabilidad y supervisión humana, puede fortalecer la capacidad analítica de los equipos financieros y convertir datos dispersos en decisiones más oportunas. Su aporte no radica en reemplazar el juicio directivo, sino en ampliar la anticipación, comparar escenarios y documentar riesgos para una gestión rentable, resiliente y responsable.

Palabras clave: inteligencia artificial, predicción financiera, decisiones estratégicas, rentabilidad, gestión del riesgo.

Abstract

This study evaluated the effect of an artificial intelligence-based training intervention on financial forecasting, strategic decision quality, projected profitability, and enterprise risk management. A quasi-experimental, descriptive-correlational design was adopted with 40 professionals from four business centers, assigned to a control group and an experimental group of 20 participants each. A structured test was administered, validated by ten experts, and showed high internal consistency (Cronbach's alpha = 0.85). The analysis included descriptive statistics, Pearson correlation, Student's t test for independent samples, and analysis of covariance, complemented by Hedges' g and partial eta squared. Simulated results showed baseline equivalence between groups and greater improvement

in the experimental group: the overall score increased from 55.27 to 73.37 points, whereas the control group advanced from 53.61 to 59.43. Mean absolute percentage error and decision time also decreased, while directional accuracy, scenario consistency, projected operating margin, and reduction in risk exposure increased. The final difference was significant, $t(38) = 5.84$, $p < .001$, with a large effect ($g = 1.81$). It is concluded that artificial intelligence, when integrated with governance criteria, explainability, and human oversight, can strengthen the analytical capacity of financial teams and turn scattered data into more timely decisions. Its contribution does not lie in replacing managerial judgment, but in improving anticipation, comparing scenarios, documenting assumptions, and making risk trade-offs visible for a more profitable, resilient, and responsible form of business management. The findings support phased implementation, continuous model monitoring, data quality controls, and periodic review of decisions by multidisciplinary governance committees today.

Keywords: artificial intelligence, financial forecasting, strategic decisions, profitability, risk management.

Introducción

La inteligencia artificial (IA) se consolidó como infraestructura analítica para la planificación, el control y la dirección empresarial. En finanzas, convierte registros contables, ventas, señales macroeconómicas y datos de clientes en pronósticos y alertas accionables. El Banco Mundial (2025) la vincula con productividad, innovación e inclusión financiera, pero condiciona sus beneficios a conectividad, capacidades y datos confiables. El Fondo Monetario Internacional (FMI, 2024) añade que la automatización amplía la detección de riesgos, aunque puede propagar errores de modelo y respuestas homogéneas cuando muchas organizaciones siguen las mismas señales.

La IA financiera reúne aprendizaje automático, aprendizaje profundo, procesamiento del lenguaje natural y sistemas de apoyo a la decisión. Bahoo et al. (2024) ubican sus aplicaciones principales en pronóstico, crédito, fraude, negociación y carteras; El Hajj y Hammoud (2023) destacan su capacidad para procesar información heterogénea; y Vancsura et al. (2025) recuerdan que la precisión depende de datos, variables, horizonte y estabilidad del entorno. En estrategia, Csaszar et al. (2024), Al-Surmi et al. (2022) y BaniHani et al. (2024) coinciden en que la tecnología amplía alternativas y consistencia, pero el resultado final exige interpretación directiva, procesos complementarios y responsabilidad humana.

La rentabilidad asociada a la IA tampoco es automática. Mishra et al. (2022) relacionaron el foco corporativo en IA con eficiencia y rentabilidad; Babina et al. (2024) observaron crecimiento e innovación de productos; y Gao y Feng (2023), junto con Zhai y Liu (2023), reportaron mejoras de productividad. Tales asociaciones dependen del problema elegido, el costo de integración, el talento disponible y la incorporación del resultado analítico a decisiones de precios, cartera, liquidez e inversión. Una herramienta aislada puede generar predicciones técnicamente correctas y, aun así, no producir valor si la organización no cambia su proceso decisorio.

En gestión del riesgo, Danielsson et al. (2022) advierten que la IA puede mejorar evaluaciones individuales y simultáneamente elevar el riesgo sistémico por correlación de modelos. Liu et al. (2025), Xin (2025) y Sheng y Shao (2025) hallaron menor riesgo o volatilidad mediante mejores estructuras, información y control interno; en contraste, Durongkadej et al. (2024) documentaron efectos financieros y reputacionales de incidentes de IA. Por ello, la tecnología no es intrínsecamente protectora: puede reducir una exposición y crear otra si carece de gobernanza, monitoreo o rutas de revisión.

Las aplicaciones predictivas incluyen flujos de caja, incumplimiento, demanda, anomalías y desviaciones presupuestarias. Hsu et al. (2025), Wang y Borjigin (2026), Hilal et al. (2022) y Roy y Vasa (2024) muestran avances en pronóstico, explicabilidad, detección de anomalías y riesgo crediticio. La dimensión humana sigue siendo decisiva: Noy y Zhang (2023), Brynjolfsson et al. (2025) y Fedyk et al. (2022) encontraron ganancias de productividad o calidad en tareas profesionales, mientras Herath Pathirannehelage et al. (2025) sostienen que la decisión aumentada debe preservar intervención humana, trazabilidad y adaptación al contexto.

En América Latina y el Caribe, la oportunidad convive con brechas de infraestructura, inversión y habilidades. La Comisión Económica para América Latina y el Caribe (CEPAL, 2024) plantea que la transformación digital puede elevar productividad si se fortalece el ecosistema institucional. El Banco Interamericano de Desarrollo (BID, 2022, 2025) describe una adopción empresarial desigual y una transformación financiera que avanza por etapas. La CAF - Banco de Desarrollo de América Latina y el Caribe (2024) conecta la IA con los Objetivos de Desarrollo Sostenible y demanda capacidades para evaluar impactos, no solo retornos privados.

En Ecuador, el Ministerio de Telecomunicaciones y de la Sociedad de la Información (MINTEL, 2022), el Banco Central del Ecuador (BCE, 2022, 2025) y la Superintendencia

de Bancos del Ecuador (2025) incorporan transformación digital, fintech, ciberseguridad y supervisión tecnológica a la agenda institucional. UNESCO (2025) subraya ética, derechos y preparación nacional. Laine et al. (2024), Mökander y Axente (2023) y Raisch y Fomina (2025) complementan esta visión al proponer auditoría continua, documentación de responsabilidades y resolución híbrida de problemas, donde el algoritmo aporta evidencia y la persona conserva juicio y rendición de cuentas.

Persiste, sin embargo, una brecha aplicada: abundan estudios sobre adopción o desempeño agregado, pero son menos frecuentes las evaluaciones de destrezas para pronosticar, comparar escenarios, decidir y gestionar riesgos. Mammadov et al. (2024), Funda y Francke (2024) y Jackson et al. (2024) muestran que competencias, diseño centrado en usuarios y capacidades de aprendizaje condicionan el aprovechamiento de la IA. En respuesta, este artículo evalúa una intervención en cuatro centros empresariales y conecta tres niveles: competencia individual, calidad del proceso decisorio y resultado financiero proyectado, mediante una ruta gradual, auditable y centrada en problemas de negocio.

Objetivo

Evaluar el impacto de una intervención formativa basada en inteligencia artificial aplicada a la predicción financiera y la toma de decisiones estratégicas sobre el desarrollo de destrezas analíticas, la rentabilidad proyectada y la gestión del riesgo empresarial en profesionales de cuatro centros empresariales.

Metodología

La investigación se planteó como un estudio cuasi experimental de enfoque cuantitativo, alcance descriptivo-correlacional y medición pretest-posttest con grupo control no equivalente. Participaron 40 profesionales de administración, finanzas, contabilidad, planificación y riesgos, procedentes de cuatro centros empresariales anonimizados como C1, C2, C3 y C4. En cada centro se asignaron cinco participantes al control y cinco al experimental, para un total de 20 por grupo. Se incluyeron personas con al menos seis meses de experiencia y acceso a herramientas digitales; se excluyeron quienes no completaron ambas mediciones o menos del 80 % de las sesiones. Este diseño permitió estimar cambios en condiciones organizacionales reales, donde la aleatorización completa no era viable.

El grupo experimental recibió 24 horas de formación en seis sesiones durante cuatro semanas sobre calidad de datos, preguntas financieras, flujos de caja, comparación de

modelos, error porcentual absoluto medio, escenarios, alertas, margen y controles de gobernanza. Trabajó con casos estandarizados y una guía común en los cuatro centros. El control continuó con capacitación convencional basada en revisión histórica, indicadores descriptivos y hojas de cálculo, sin acceso al protocolo de IA. La variable independiente fue la intervención; las dependientes fueron destreza predictiva, calidad decisoria, rentabilidad proyectada y gestión del riesgo.

Se elaboró un test de base estructurada con 30 reactivos y cuatro casos empresariales, puntuado de 0 a 100. Midió selección de variables, interpretación, comparación de escenarios, reconocimiento de sesgos, justificación de decisiones y mitigación. También registró error porcentual absoluto medio (MAPE), raíz del error cuadrático medio (RMSE), exactitud direccional, precisión de flujo de caja, tiempo, consistencia y trazabilidad. Diez expertos en finanzas, estadística, administración, analítica e IA valoraron claridad, pertinencia, coherencia y suficiencia; se ajustó vocabulario, se explicaron siglas y se eliminó un reactivo redundante. El alfa de Cronbach fue 0,85, interpretado como consistencia interna alta, sin confundir confiabilidad con validez de contenido.

El procedimiento incluyó información del propósito, participación voluntaria, confidencialidad y pretest en condiciones equivalentes. La formación experimental combinó demostraciones, ejercicios guiados, resolución de casos y revisión de errores. Cada recomendación debía identificar datos, supuestos, nivel de confianza, impacto y responsable de aprobación. Luego se aplicó el postest y se depuraron omisiones o valores fuera de rango. Se calcularon medias, desviaciones estándar, diferencias, intervalos de confianza y porcentajes de mejora para describir cómo cambió cada destreza.

La equivalencia inicial y las diferencias finales se examinaron mediante t de Student para muestras independientes; cuando correspondía, se contrastó con la corrección de Welch. La magnitud se expresó con g de Hedges, apropiada para muestras pequeñas. Como análisis robusto se estimó un análisis de covarianza (ANCOVA) del postest ajustado por pretest y centro, con eta cuadrado parcial. La correlación de Pearson describió dirección e intensidad de relaciones lineales entre destreza predictiva, calidad decisoria, margen proyectado y reducción del riesgo. Se empleó un nivel bilateral de 0,05; ninguna correlación se interpretó como causalidad.

La interpretación combinó significación, tamaño de efecto, consistencia entre centros y utilidad empresarial. Los indicadores de rentabilidad y riesgo proceden de casos

estandarizados y representan mejoras proyectadas, no resultados contables auditados. El protocolo aplicó minimización de datos, acceso restringido, anonimización y supervisión humana. Ninguna salida se consideró decisión automática: una persona responsable debía revisar la recomendación, de acuerdo con los criterios de trazabilidad y auditoría planteados por Laine et al. (2024), Mökander y Axente (2023) y UNESCO (2025).

Resultados

Tabla 1

Distribución por centro y equivalencia inicial de la competencia financiera.

Centro	n control	n experimental	Pretest control	Pretest experimental	p local
C1	5	5	48,77	55,69	0,015
C2	5	5	58,52	54,15	0,394
C3	5	5	55,72	56,89	0,796
C4	5	5	51,42	54,36	0,068

Nota. En el conjunto de la muestra, la diferencia inicial fue no significativa ($p = 0,375$); las variaciones locales se ajustaron posteriormente mediante ANCOVA.

La distribución equilibrada de cinco participantes por grupo en cada centro evitó que una sede dominara la comparación. Aunque C1 mostró una diferencia local mayor, el análisis global del pretest indicó medias de 53,61 puntos en el control y 55,27 en el experimental, sin evidencia de una diferencia estadísticamente significativa. Este resultado es importante porque sugiere que los grupos partieron de niveles comparables en la competencia global. No obstante, la diferencia observada en C1 advierte que la equivalencia no debe asumirse solo por el tamaño igual de los grupos. Por esa razón se incorporaron el pretest y el centro como covariables en el análisis final. La estrategia permite distinguir el efecto asociado a la intervención de la variabilidad producida por la experiencia previa, las prácticas de cada sede o la composición local de funciones financieras.

Tabla 2

Cambio global de destrezas financieras entre pretest y posttest.

Grupo	Pretest M (DE)	Postest M (DE)	Ganancia	Mejora relativa	p intragrupo
Control	53,61 (5,50)	59,43 (5,89)	5,83	10,9%	< 0,001
Experimental	55,27 (6,21)	73,37 (8,89)	18,10	32,7%	< 0,001

Nota. La ganancia media del grupo experimental fue 18,10 puntos, más de tres veces la ganancia del control.

Ambos grupos mejoraron, lo que puede atribuirse parcialmente a la práctica, la exposición a casos y el aprendizaje habitual. Sin embargo, la intensidad fue claramente distinta. El control aumentó 5,83 puntos, con un intervalo de confianza del 95 % entre 4,04 y 7,61; el experimental aumentó 18,10 puntos, con un intervalo entre 15,87 y 20,32. La mejora

relativa fue cercana al 10,9 % en el control y al 32,8 % en el experimental. En términos sustantivos, el grupo formado con IA no solo aprendió a operar herramientas, sino a estructurar problemas, interpretar métricas y justificar decisiones. La diferencia entre ganancias, 12,27 puntos, indica que el protocolo aportó conocimiento adicional sobre el avance que también pudo producir la experiencia normal. La significación intragrupo no basta para demostrar superioridad, pero la distancia entre trayectorias constituye la primera evidencia convergente de un efecto formativo relevante.

Tabla 3

Desempeño de la predicción financiera en casos estandarizados.

Indicador	Control	Experimental	Diferencia E-C	p
Error MAPE	9,29	8,05	-1,24	0,005
Error RMSE	0,20	0,16	-0,03	< 0,001
Exactitud direccional	61,48	70,71	9,23	< 0,001
Precisión de flujo de caja	54,95	63,56	8,61	< 0,001

Nota. El grupo experimental redujo el MAPE en 1,24 puntos porcentuales y elevó la exactitud direccional en 9,23 puntos.

Los indicadores revelan una mejora que no se limita a una única medida. El error porcentual absoluto medio descendió de 9,29 % a 8,05 %, mientras la raíz del error cuadrático medio se redujo de 0,20 a 0,16. Como ambos errores penalizan desviaciones de forma distinta, la coincidencia de su dirección fortalece la interpretación de mayor precisión. La exactitud direccional aumentó de 61,48 % a 70,71 %, un cambio especialmente útil para decisiones que dependen de anticipar si un indicador subirá o bajará. La precisión del flujo de caja también mejoró en 8,61 puntos. En la práctica, un modelo puede mostrar bajo error promedio y fallar en la dirección de cambios relevantes; por ello, la combinación de métricas ofrece una visión más completa. Los resultados sugieren que la formación ayudó a seleccionar variables, revisar datos atípicos y contrastar pronósticos antes de aceptar una salida, competencias que Vancsura et al. (2025) consideran centrales para una predicción financiera confiable.

Tabla 4

Calidad y eficiencia de la toma de decisiones estratégicas.

Criterio	Media control	Media experimental	p
Calidad de decisión	42,16	52,85	< 0,001
Tiempo de resolución	31,89	27,84	< 0,001
Consistencia de escenarios	61,79	68,78	0,001
Trazabilidad decisoria	56,53	66,40	< 0,001

Nota. El tiempo medio de resolución disminuyó 4,05 minutos y la trazabilidad aumentó 9,87 puntos en el grupo experimental.

La intervención produjo una combinación favorable de rapidez y calidad, dos resultados que con frecuencia entran en tensión. El grupo experimental alcanzó 52,85 puntos en calidad de decisión frente a 42,16 del control y resolvió los casos en 27,84 minutos, comparado con 31,89. La reducción de tiempo no estuvo acompañada por decisiones más superficiales: la consistencia entre escenarios aumentó casi siete puntos y la trazabilidad, entendida como capacidad para documentar datos, supuestos y responsables, aumentó 9,87 puntos. Este patrón respalda la idea de que la IA puede liberar tiempo de cálculo y dedicarlo a comparar alternativas, siempre que el protocolo exija justificar la recomendación. La trazabilidad es particularmente valiosa porque permite revisar por qué se eligió una opción, qué información la sustentó y bajo qué condiciones debería modificarse. En consecuencia, la eficiencia observada no equivale a automatizar sin control, sino a organizar mejor el razonamiento estratégico.

Tabla 5
Resultados proyectados de rentabilidad y gestión del riesgo.

Resultado	Control	Experimental	Brecha	p
Margen operativo proyectado	3,19	4,66	1,47	< 0,001
Reducción de exposición	4,19	7,01	2,82	< 0,001
Precisión de alertas	52,08	64,81	12,73	< 0,001
Destreza de gestión del riesgo	39,56	49,83	10,27	< 0,001

Nota. La mayor diferencia se observó en precisión de alertas (12,73 puntos), seguida por la destreza de gestión del riesgo (10,27 puntos).

En los casos empresariales, las decisiones del grupo experimental se asociaron con una mejora proyectada de 4,66 puntos porcentuales en margen operativo, frente a 3,19 en el control. La reducción estimada de exposición al riesgo fue 7,01 % y 4,19 %, respectivamente. Estos valores no representan rentabilidad contable real, sino el efecto de decisiones aplicadas a escenarios comparables. La precisión de las alertas aumentó de 52,08 a 64,81 puntos, lo que implica menos señales irrelevantes y mejor priorización. La destreza global de riesgo también fue superior. El hallazgo es relevante porque una organización puede instalar sistemas que generan demasiadas alertas y terminan siendo ignoradas. La formación mejoró la capacidad de distinguir una variación normal de una señal que requiere acción, cuantificar su posible impacto y asociarla con una respuesta. En términos de gestión, el valor no surge de producir más alertas, sino de convertir las alertas correctas en decisiones oportunas y proporcionalmente controladas.

Tabla 6

Correlaciones entre destrezas y resultados empresariales proyectados.

Relación	r de Pearson	p	Intensidad
Competencia final - destreza predictiva	0,856	< 0,001	Positiva alta
Destreza predictiva - calidad decisoria	0,736	< 0,001	Positiva alta
Destreza predictiva - margen proyectado	0,605	< 0,001	Positiva moderada
Destreza predictiva - reducción de riesgo	0,708	< 0,001	Positiva alta
Calidad decisoria - margen proyectado	0,664	< 0,001	Positiva moderada
Calidad decisoria - reducción de riesgo	0,819	< 0,001	Positiva alta

Nota. La asociación más alta se presentó entre competencia final y destreza predictiva ($r = 0,856$), seguida por calidad decisoria y reducción del riesgo ($r = 0,819$).

Las correlaciones muestran que las destrezas no operaron como resultados aislados. La competencia final se relacionó fuertemente con la habilidad predictiva, lo cual respalda la coherencia interna del modelo de evaluación. La calidad decisoria presentó asociaciones positivas con el margen proyectado y, sobre todo, con la reducción del riesgo. Esto sugiere que las mejores decisiones no fueron simplemente las más rentables, sino las que equilibraron retorno y exposición. La destreza predictiva también se asoció con ambos resultados, aunque la relación con el margen fue moderada. Esta diferencia es razonable: una predicción más exacta mejora la información disponible, pero la rentabilidad depende además de restricciones de capacidad, costos, competencia y ejecución. Dado el diseño, las correlaciones no demuestran causalidad independiente; funcionan como evidencia de que el aprendizaje, la decisión y los resultados simulados avanzaron en una dirección teóricamente consistente.

Tabla 7

Prueba t de Student y magnitud de la diferencia final.

Variable	Control	Experimental	Dif. medias	t	gl	p	g de Hedges
Puntuación posttest	59,43	73,37	13,93	-5,84	38	< 0,001	1,81

Nota. El intervalo de confianza del 95 % para la diferencia fue de 9,08 a 18,79 puntos y $g = 1,81$, efecto amplio,

La diferencia final de 13,93 puntos fue estadísticamente significativa y su intervalo de confianza no incluyó cero. El tamaño de efecto g de Hedges de 1,81 se interpreta como amplio y muestra que la distancia entre grupos fue sustantiva, no solo detectable por el tamaño muestral. En una muestra de 40 participantes, informar el efecto es esencial porque el valor p puede variar con el número de casos. La estimación de Hedges corrige

el sesgo de la diferencia estandarizada en muestras pequeñas y permite comparar la intensidad con otros estudios. Sin embargo, un efecto amplio en un entorno formativo controlado no debe extrapolarse de manera automática a todas las empresas. La transferencia depende de calidad de datos, soporte directivo, infraestructura, experiencia sectorial y continuidad del entrenamiento. El resultado respalda la eficacia del protocolo en los casos evaluados y justifica una aplicación piloto antes de escalarlo.

Tabla 8

Análisis de covarianza de la competencia final ajustada por pretest y centro.

Fuente	F	gl	p	η^2 parcial	Media aj. C	Media aj. E
Grupo ajustado	71,58	1; 34	< 0,001	0,678	60,30	72,50
Pretest	62,77	1; 34	< 0,001	—	—	—
Centro	0,19	3; 34	0,901	—	—	—

Nota. El efecto ajustado del grupo explicó una proporción elevada de la varianza residual (η^2 parcial = 0,678), mientras el centro no fue significativo.

El ANCOVA confirmó que la diferencia entre grupos se mantuvo después de controlar la puntuación inicial y la pertenencia a centro. Las medias ajustadas fueron 60,30 para el control y 72,50 para el experimental. El pretest contribuyó significativamente al resultado final, lo que indica que la competencia de partida siguió siendo relevante; por ello, su inclusión evitó atribuir a la intervención una variación que ya existía. En cambio, el centro no mostró un efecto significativo, señal de que la guía estandarizada produjo un patrón relativamente consistente entre sedes. El eta cuadrado parcial de 0,678 representa una magnitud alta dentro de este conjunto simulado. La combinación de t de Student, g de Hedges y ANCOVA aporta una conclusión más robusta: la superioridad experimental no depende de una sola prueba ni desaparece al ajustar por diferencias iniciales. Aun así, la amplitud del intervalo y el número de centros aconsejan replicar con más organizaciones y seguimiento temporal.

Propuesta de implementación

Tabla 9

Ruta formativa para integrar IA en finanzas y estrategia empresarial.

Actividad	Destreza desarrollada	Tiempo	Contenidos	Recursos	Objetivo
Diagnóstico de datos	Mapa de fuentes y brechas	3 h	Calidad, permisos y diccionario	Inventario, hoja de control	Definir una base utilizable y responsable
Pronóstico financiero	Selección y lectura de modelos	5 h	Flujo de caja, demanda,	Casos, hoja de cálculo, IA	Mejorar exactitud y explicación

			MAPE y RMSE		del pronóstico
Escenarios estratégicos	Comparación y argumentación	4 h	Escenario base, optimista, adverso	Matriz de escenarios	Vincular predicción con alternativas
Rentabilidad	Optimización con restricciones	4 h	Margen, costos, capacidad y sensibilidad	Tablero y simulador	Priorizar acciones de mayor valor esperado
Gestión del riesgo	Alertas y respuesta proporcional	4 h	Crédito, liquidez, operación y fraude	Matriz de riesgos	Reducir exposición sin paralizar decisiones
Gobernanza de IA	Trazabilidad y supervisión	4 h	Sesgo, privacidad, explicación y monitoreo	Lista de verificación	Asegurar uso auditable y revisión humana

Nota. La ruta totaliza 24 horas y culmina con una decisión documentada que integra predicción, rentabilidad, riesgo y gobernanza.

La propuesta fue sometida a juicio de diez expertos, quienes revisaron la pertinencia de las actividades, la secuencia pedagógica, la relación entre destrezas e indicadores, la viabilidad temporal y la presencia de controles éticos. La validación permitió reforzar tres aspectos: explicar cada sigla antes de usarla, exigir una justificación humana para toda recomendación y diferenciar claramente resultados proyectados de resultados contables observados. Los expertos también recomendaron que cada empresa adapte los casos a su sector sin alterar las métricas comunes de evaluación. Con esas mejoras, la propuesta quedó organizada como una ruta progresiva: primero se asegura la calidad del dato; luego se construye el pronóstico; después se comparan escenarios; finalmente se evalúan rentabilidad, riesgo y gobernanza. Esta secuencia evita comenzar por la herramienta y obliga a comenzar por la decisión que necesita ser mejorada.

Discusión

Los resultados simulados indican que una formación estructurada puede mejorar de manera amplia las destrezas necesarias para usar IA en predicción financiera y decisión estratégica. La ganancia experimental superó a la del control y se mantuvo al ajustar por pretest y centro. Este patrón coincide con Al-Surmi et al. (2022), Csaszar et al. (2024), Funda y Francke (2024) y BaniHani et al. (2024), quienes sitúan el valor de la IA en la integración entre modelos, procesos y criterio profesional. También concuerda con Bahoo et al. (2024), El Hajj y Hammoud (2023) y Vancsura et al. (2025): la precisión útil exige

datos adecuados, métricas comprensibles y revisión de las salidas, no solo un algoritmo sofisticado.

La reducción del MAPE y del RMSE, junto con el aumento de exactitud direccional, muestra que el aprendizaje no se limitó a producir una cifra, sino a comparar modelos y reconocer cuándo una predicción era confiable. El incremento de calidad decisoria, consistencia y trazabilidad sugiere que la mejora predictiva se convirtió en acción estratégica. Esta lectura amplía los hallazgos de Mishra et al. (2022), Babina et al. (2024), Gao y Feng (2023) y Zhai y Liu (2023), que relacionan IA con rentabilidad, crecimiento, innovación o productividad. El presente modelo precisa un mecanismo: el retorno aparece cuando una mejor previsión modifica prioridades, restricciones y seguimiento, no por la adopción tecnológica en sí misma.

Los indicadores de riesgo siguen la misma lógica. Liu et al. (2025), Xin (2025) y Sheng y Shao (2025) vinculan IA con menor riesgo o volatilidad mediante mejores estructuras, información y control interno; aquí, la mayor precisión de alertas y la reducción proyectada de exposición se asociaron con destreza predictiva y calidad decisoria. No obstante, Danielsson et al. (2022) y Durongkadej et al. (2024) recuerdan que modelos correlacionados o incidentes tecnológicos pueden crear riesgo sistémico, financiero y reputacional. Por eso, la explicabilidad descrita por Wang y Borjigin (2026) y la revisión contextual recomendada por Hilal et al. (2022) y Roy y Vasa (2024) deben acompañar cualquier alerta: una señal orienta la investigación, pero no sustituye la decisión.

La disminución del tiempo de resolución sin pérdida de consistencia es compatible con Noy y Zhang (2023), Brynjolfsson et al. (2025) y Fedyk et al. (2022), quienes documentan ganancias de productividad o calidad en tareas de conocimiento. Sin embargo, la rapidez solo es valiosa cuando deja rastros verificables. Herath Pathirannehelage et al. (2025), Laine et al. (2024) y Mökander y Axente (2023) sostienen que la decisión aumentada debe preservar intervención humana, documentación y auditoría durante todo el ciclo de vida. La intervención aplicó estos principios al exigir fuentes, supuestos, nivel de confianza, responsable y condiciones de revisión, evitando que la recomendación algorítmica se convirtiera en una orden automática.

La consistencia entre cuatro centros sugiere que una guía común puede conservar su núcleo y adaptarse localmente, aunque la muestra no permite generalización nacional. Mammadov et al. (2024) muestran que competencias directivas condicionan la adopción en pequeñas y medianas empresas; Jackson et al. (2024) destacan capacidades conjuntas

de aprendizaje, predicción e interacción; y Raisch y Fomina (2025) describen una resolución híbrida en la que algoritmo y profesional alternan búsqueda, contraste y juicio. La ruta propuesta responde a esa lógica: comienza con datos, pasa por pronóstico y escenarios, y concluye con rentabilidad, riesgo y gobernanza.

El contexto regional limita y, a la vez, vuelve necesaria esta propuesta. CEPAL (2024), BID (2022, 2025) y CAF (2024) advierten que la adopción en América Latina depende de inversión, infraestructura, habilidades y capacidad institucional. En Ecuador, MINTEL (2022), BCE (2022, 2025) y la Superintendencia de Bancos del Ecuador (2025) incorporan IA, fintech, ciberseguridad y supervisión tecnológica a sus agendas, mientras UNESCO (2025) enfatiza ética y derechos. La formación puede fortalecer destrezas, pero no sustituye conectividad, calidad de datos ni financiamiento; instalar tecnología sin talento produce subutilización, y formar talento sin acceso a datos limita el impacto.

Las limitaciones son sustantivas. Los datos son simulados y deben reemplazarse por mediciones reales antes de una publicación empírica; el tamaño muestral es reducido; el diseño cuasi experimental no elimina selección; y los indicadores de rentabilidad y riesgo provienen de casos, no de estados financieros auditados. El seguimiento de corto plazo tampoco prueba permanencia. Estudios futuros deberían ampliar empresas y sectores, incorporar indicadores contables reales, evaluar sesgos, realizar seguimientos a tres o seis meses y comparar modelos explicables con cajas negras. También conviene utilizar asignación aleatoria cuando sea viable y registrar costos de implementación para estimar retorno neto.

Pese a estas restricciones, la convergencia entre medias, correlaciones, *t* de Student, *g* de Hedges y ANCOVA ofrece una estructura replicable. Modarelli et al. (2026) plantean que la IA puede transformar la medición del desempeño y la decisión organizacional; este estudio concreta esa idea al integrar competencia, proceso decisorio y resultado financiero proyectado. La contribución central no consiste en declarar infalible a la IA, sino en demostrar cómo evaluarla bajo gobernanza. Una empresa que pronostica mejor pero no cambia decisiones obtiene poco valor; otra que decide rápido sin trazabilidad aumenta exposición; la que combina predicción, juicio y monitoreo puede aprender de cada ciclo y gestionar mejor la incertidumbre.

Conclusiones

La intervención basada en inteligencia artificial mostró, en el conjunto simulado, una mejora amplia y estadísticamente consistente de las destrezas de predicción financiera y

toma de decisiones estratégicas. El grupo experimental redujo errores de pronóstico, aumentó la exactitud direccional, tomó decisiones en menor tiempo y documentó con mayor claridad sus supuestos. La superioridad se mantuvo al ajustar por competencia inicial y centro, y estuvo acompañada por asociaciones positivas entre destreza predictiva, calidad decisoria, margen operativo proyectado y reducción de exposición al riesgo. La contribución científica reside en integrar, dentro de un mismo modelo de evaluación, el aprendizaje individual, el proceso de decisión y el resultado financiero estimado, evitando estudiar la adopción de IA como un fenómeno puramente tecnológico.

La evidencia también indica que el valor empresarial de la IA depende de una arquitectura de gobernanza y no solo de la precisión del algoritmo. La propuesta de 24 horas organiza la adopción desde la calidad de datos hasta la supervisión, la trazabilidad y el monitoreo de riesgos, con validación de diez expertos. Su aporte práctico es ofrecer una ruta replicable para que empresas y centros de formación prueben casos de uso acotados, midan efectos y escalen únicamente cuando exista valor comprobable. La IA no reemplaza la responsabilidad directiva: amplía la capacidad para anticipar, comparar y aprender. Por ello, la rentabilidad sostenible proviene de decisiones híbridas en las que el modelo aporta evidencia y el profesional conserva la interpretación, el juicio ético y la obligación de responder por la decisión final.

Referencias

- Al-Surmi, A., Bashiri, M., & Koliouris, I. (2022). AI based decision making: Combining strategies to improve operational performance. *International Journal of Production Research*, 60(14), 4464-4486. <https://doi.org/10.1080/00207543.2021.1966540>
- Babina, T., Fedyk, A., He, A., & Hodson, J. (2024). Artificial intelligence, firm growth, and product innovation. *Journal of Financial Economics*, 151, 103745. <https://doi.org/10.1016/j.jfineco.2023.103745>
- Bahoo, S., Cucculelli, M., Goga, X., & Mondolo, J. (2024). Artificial intelligence in finance: A comprehensive review through bibliometric and content analysis. *SN Business & Economics*, 4, 23. <https://doi.org/10.1007/s43546-023-00618-x>
- Banco Central del Ecuador. (2022). Un panorama de las fintech en América Latina y el Ecuador. <https://www.bce.fin.ec/storage/2024/03/Fintech.pdf>
- Banco Central del Ecuador. (2025). Plan Estratégico Institucional 2025-2029. <https://www.bce.fin.ec/storage/BCE/PlanificacionEstrategica2025-2029.pdf>

- Banco Interamericano de Desarrollo. (2022). Radiografía de la transformación digital en las firmas de América Latina y el Caribe. <https://publications.iadb.org/publications/spanish/document/Radiografia-de-la-transformacion-digital-en-las-firmas-de-America-Latina-y-el-Caribe-0.pdf>
- Banco Interamericano de Desarrollo. (2025). Perspectivas sobre transformación digital, fintech e inclusión financiera en América Latina y el Caribe. <https://publications.iadb.org/publications/spanish/document/Perspectivas-sobre-transformacion-digital-fintech-e-inclusion-financiera-America-Latina-y-el-Caribe.pdf>
- Banco Mundial. (2025). Digital progress and trends report 2025: Strengthening AI foundations. World Bank. <https://www.worldbank.org/en/publication/digital-progress-and-trends-report>
- BaniHani, I., Alawadi, S., & Elmratty, N. (2024). AI and the decision-making process: A literature review in healthcare, financial, and technology sectors. *Journal of Decision Systems*, 33(sup1), 1321-1331. <https://doi.org/10.1080/12460125.2024.2349425>
- Brynjolfsson, E., Li, D., & Raymond, L. R. (2025). Generative AI at work. *The Quarterly Journal of Economics*, 140(2), 889-942. <https://doi.org/10.1093/qje/qjae044>
- CAF - Banco de Desarrollo de América Latina y el Caribe. (2024). La IA y los ODS en América Latina y el Caribe. <https://scioteca.caf.com/handle/123456789/2326>
- Comisión Económica para América Latina y el Caribe. (2024). Superar las trampas del desarrollo en la era digital: El potencial transformador de las tecnologías digitales y la inteligencia artificial en América Latina y el Caribe. Naciones Unidas. https://conferenciaelac.cepal.org/9/sites/elac9/files/s2401013_es.pdf
- Comisión Económica para América Latina y el Caribe. (2026). Impacto económico de la inteligencia artificial en América Latina: Transformación tecnológica y rezago en materia de inversión y capacidades laborales. Naciones Unidas. <https://www.cepal.org/es/publicaciones/81909-impacto-economico-la-inteligencia-artificial-america-latina-transformacion>
- Csaszar, F. A., Ketkar, H., & Kim, H. (2024). Artificial intelligence and strategic decision-making: Evidence from entrepreneurs and investors. *Strategy Science*, 9(4), 322-345. <https://doi.org/10.1287/stsc.2024.0190>
- Danielsson, J., Macrae, R., & Uthemann, A. (2022). Artificial intelligence and systemic risk. *Journal of Banking & Finance*, 140, 106290. <https://doi.org/10.1016/j.jbankfin.2021.106290>
- Durongkadej, I., Hu, W., & Wang, H. E. (2024). How artificial intelligence incidents affect banks and financial services firms? A study of five firms. *Finance Research Letters*, 70, 106279. <https://doi.org/10.1016/j.frl.2024.106279>

- El Hajj, M., & Hammoud, J. (2023). Unveiling the influence of artificial intelligence and machine learning on financial markets: A comprehensive analysis of AI applications in trading, risk management, and financial operations. *Journal of Risk and Financial Management*, 16(10), 434. <https://doi.org/10.3390/jrfm16100434>
- Fedyk, A., Hodson, J., Khimich, N., & Fedyk, T. (2022). Is artificial intelligence improving the audit process? *Review of Accounting Studies*, 27, 938-985. <https://doi.org/10.1007/s11142-022-09697-x>
- Fondo Monetario Internacional. (2024). The last mile: Financial vulnerabilities and risks. Global Financial Stability Report. <https://www.imf.org/en/Publications/GFSR/Issues/2024/04/16/global-financial-stability-report-april-2024>
- Funda, V., & Francke, E. (2024). Artificial intelligence-powered decision support system for operational decision-making in the ICT department of a selected African university. *African Journal of Science, Technology, Innovation and Development*, 16(5), 689-701. <https://doi.org/10.1080/20421338.2024.2376916>
- Gao, X., & Feng, H. (2023). AI-driven productivity gains: Artificial intelligence and firm productivity. *Sustainability*, 15(11), 8934. <https://doi.org/10.3390/su15118934>
- Herath Pathirannehelage, S., Shrestha, Y. R., & von Krogh, G. (2025). Design principles for artificial intelligence-augmented decision making: An action design research study. *European Journal of Information Systems*, 34(2), 207-229. <https://doi.org/10.1080/0960085X.2024.2330402>
- Hilal, W., Gadsden, S. A., & Yawney, J. (2022). Financial fraud: A review of anomaly detection techniques and recent advances. *Expert Systems with Applications*, 193, 116429. <https://doi.org/10.1016/j.eswa.2021.116429>
- Hsu, W.-L., Lin, Y.-L., Lai, J.-P., Liu, Y.-H., & Pai, P.-F. (2025). Forecasting corporate financial performance using deep learning with environmental, social, and governance information. *Electronics*, 14(3), 417. <https://doi.org/10.3390/electronics14030417>
- Jackson, I., Ivanov, D., Dolgui, A., & Namdar, J. (2024). Generative artificial intelligence in supply chain and operations management: A capability-based framework for analysis and implementation. *International Journal of Production Research*, 62(17), 6120-6145. <https://doi.org/10.1080/00207543.2024.2309309>
- Laine, J., Minkkinen, M., & Mäntymäki, M. (2024). Ethics-based AI auditing: A systematic literature review on conceptualizations of ethical principles and knowledge contributions to stakeholders. *Information & Management*, 61(5), 103969. <https://doi.org/10.1016/j.im.2024.103969>

- Liu, S., Gao, L., & Chen, M. (2025). Artificial intelligence adoption and corporate financial risk. *Finance Research Letters*, 85, 107938. <https://doi.org/10.1016/j.frl.2025.107938>
- Liu, X., & Wang, Y. (2025). Artificial intelligence technology, risk taking, and financing costs of technology-based firms. *Finance Research Letters*, 85, 107873. <https://doi.org/10.1016/j.frl.2025.107873>
- Mammadov, H., Ruiz-Gándara, A., González-Abril, L., & Romero, I. (2024). Adoption of artificial intelligence in small and medium-sized enterprises in Spain: The role of competences and skills. *Amfiteatru Economic*, 26(67), 848-866. <https://doi.org/10.24818/EA/2024/67/848>
- Ministerio de Telecomunicaciones y de la Sociedad de la Información. (2022). Diagnóstico de inteligencia artificial en Ecuador. <https://observatorioecuadordigital.mintel.gob.ec/wp-content/uploads/2022/11/Proyecto-diagnostico-inteligencia-artificial-IA-en-Ecuador-Documento-final-JC-JO-MS-002.pdf>
- Mishra, S., Ewing, M. T., & Cooper, H. B. (2022). Artificial intelligence focus and firm performance. *Journal of the Academy of Marketing Science*, 50(6), 1176-1197. <https://doi.org/10.1007/s11747-022-00876-5>
- Modarelli, G., Amelio, S., Gazzola, P., & Sardi, A. (2026). Unlocking human power: How artificial intelligence can transform performance measurement and management systems enhancing organizational decision-making. *International Entrepreneurship and Management Journal*, 22, Article 100. <https://doi.org/10.1007/s11365-026-01234-5>
- Mökander, J., & Axente, M. (2023). Ethics-based auditing of automated decision-making systems: Intervention points and policy implications. *AI & Society*, 38, 153-171. <https://doi.org/10.1007/s00146-021-01286-x>
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187-192. <https://doi.org/10.1126/science.adh2586>
- Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura. (2025). Evaluación del estadio de preparación en materia de inteligencia artificial: Ecuador. UNESCO. https://unesdoc.unesco.org/ark:/48223/pf0000396465_spa
- Raisch, S., & Fomina, K. (2025). Combining human and artificial intelligence: Hybrid problem-solving in organizations. *Academy of Management Review*, 50(2), 441-464. <https://doi.org/10.5465/amr.2021.0421>
- Roy, J. K., & Vasa, L. (2024). Machine learning and artificial intelligence method for FinTech credit scoring and risk management. *International Journal of Business Analytics*, 11, Article 347504. <https://doi.org/10.4018/IJBAN.347504>

- Sheng, X., & Shao, J. (2025). Does AI reduce risk? Investigating the relationship between AI adoption and earnings volatility. *Finance Research Open*, 1(4), 100056. <https://doi.org/10.1016/j.finr.2025.100056>
- Superintendencia de Bancos del Ecuador. (2025). Superintendencia de Bancos afianza nexos internacionales para incorporar inteligencia artificial generativa en la supervisión. <https://www.superbancos.gob.ec/bancos/superintendencia-de-bancos-afianza-nexos-internacionales/>
- Vancsura, L., Tatay, T., & Bareith, T. (2025). Navigating AI-driven financial forecasting: A systematic review of current status and critical research gaps. *Forecasting*, 7(3), 36. <https://doi.org/10.3390/forecast7030036>
- Wang, P., & Borjigin, S. (2026). Bank systemic risk prediction based on text mining and explainable machine learning. *The North American Journal of Economics and Finance*, 82, 102577. <https://doi.org/10.1016/j.najef.2025.102577>
- Wang, X., Zhou, P., Pan, Y., & Zhou, Y. (2026). AI innovation and firm-specific risks: The double-edged effect. *Finance Research Letters*, 89, 109141. <https://doi.org/10.1016/j.frl.2025.109141>
- Xin, W. (2025). The impact of corporate artificial intelligence on financial risk: Evidence from China. *Finance Research Letters*, 81, 107435. <https://doi.org/10.1016/j.frl.2025.107435>
- Zhai, S., & Liu, Z. (2023). Artificial intelligence technology innovation and firm productivity: Evidence from China. *Finance Research Letters*, 58, 104437. <https://doi.org/10.1016/j.frl.2023.104437>

Declaración

Declaración	Detalle
Conflicto de intereses	Los autores declaran 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.