

<https://doi.org/10.69639/arandu.v13i3.2481>

Inteligencia artificial explicable en la contabilidad de gestión: revisión sistemática sobre confianza, aceptación y calidad de las decisiones

Explainable Artificial Intelligence in Management Accounting: a Systematic Review of Trust, Acceptance, and Decision Quality

Keny Arnold Mas Villanueva

vilmaskear@outlook.com

<https://orcid.org/0000-0001-9833-0048>

Universidad Nacional de San Martín
Perú – Rioja

Daniel Mijahuanga Chumbe

danielmchumbe@gmail.com

<https://orcid.org/0009-0007-2211-7516>

Universidad Católica Sede Sapientiae
Perú – Rioja

Gianfranco Ramirez Torres

dangianke@gmail.com

<https://orcid.org/0009-0003-3960-7539>

Dirección Regional de Educación
Perú – Moyobamba

Zarita Isabel Mijahuanga Chumbe

zimijahuanga@unsm.edu.pe

<https://orcid.org/0009-0000-8437-3098>

UGEL Bellavista
Perú - Bellavista

Artículo recibido: 10 julio 2026- Aceptado para publicación: 16 agosto 2026
Conflictos de intereses: Ninguno que declarar.

RESUMEN

El estudio tuvo como objetivo analizar críticamente y sintetizar la evidencia empírica publicada entre enero de 2020 y mayo de 2026 sobre la relación entre las modalidades de explicabilidad de la inteligencia artificial (IA), la confianza, la aceptación y la calidad de las decisiones en las principales funciones de la contabilidad de gestión. Se aplicó una revisión sistemática con síntesis crítica narrativa, de acuerdo con los preceptos de PRISMA 2020 y PRISMA-S. Se ejecutaron búsqueda de estudios en Scopus, SciELO y EBSCO, seleccionándose investigaciones arbitradas y de carácter empírico sobre IA explicable o contextos gerenciales transferibles en materia de resultados humanos y decisiones de contabilidad de gestión. Se recopilaron 98 estudios, después de eliminar seis duplicados quedaron 92 registros, posteriormente se desestimaron 81, quedando 11 informes, cinco no eran de acceso y los seis restantes pasaron a una evaluación de texto completo. Finalmente, tres de ellos se ajustaban a los criterios para la síntesis y los otros tres

quedaron fuera. La evidencia directa no va más allá de la estimación de costos. Los trabajos incorporados explican que la transparencia o la explicabilidad son propicias para depositar confianza y hacer uso del consejo de un algoritmo. Conclusivamente, es poca cosa generalizar en cuanto a la presupuestación, el pronóstico, la evaluación del desempeño o el análisis de desviaciones. Hay necesidad de estudios de campo que vayan más allá y ofrezcan una medida objetiva del desempeño, de la confianza calibrada y del uso efectivo, comparando a su vez las modalidades explicativas.

Palabras clave: inteligencia artificial explicable, contabilidad de gestión, confianza, aceptación tecnológica, calidad de las decisiones

ABSTRACT

The objective of this study was to critically analyze and synthesize the empirical evidence published between January 2020 and May 2026 on the relationship between the modalities of artificial intelligence (AI) explainability, trust, acceptance, and decision quality in the main functions of management accounting. A systematic review with a critical narrative synthesis was conducted in accordance with the PRISMA 2020 and PRISMA-S guidelines. Studies were searched for in Scopus, SciELO, and EBSCO, and peer-reviewed, empirical research on explainable AI or transferable managerial contexts related to human outcomes and management accounting decisions was selected. A total of 98 studies were identified; after removing six duplicates, 92 records remained. Subsequently, 81 were excluded, leaving 11 reports; five were inaccessible, and the remaining six proceeded to a full-text evaluation. Finally, three of these met the criteria for the synthesis, while the other three were excluded. Direct evidence does not extend beyond cost estimates. The included studies explain that transparency and explainability foster trust and encourage the use of an algorithm's recommendations. In conclusion, it is unwise to generalize regarding budgeting, forecasting, performance evaluation, or variance analysis. There is a need for field studies that go further and provide an objective measure of performance, calibrated trust, and effective use, while also comparing the various explanatory approaches.

Keywords: explainable artificial intelligence, management accounting, trust, technology acceptance, decision quality

INTRODUCCIÓN

Con la ayuda de la inteligencia artificial y el aprendizaje automático, la contabilidad de gestión ve reforzada su capacidad para estimar costos, hacer pronósticos o analizar desviaciones con el fin de respaldar una mejor asignación de los recursos internos. No obstante, un exceso de complejidad en los modelos puede poner en entredicho la comprensión del decisor sobre el origen de una recomendación y si esta se ajusta al contexto. De hecho, las revisiones de campo dan fe de un avance en el desarrollo de estas herramientas, aunque su uso en materia de control y decisión interna sigue siendo algo fragmentado (Ranta et al., 2023; Abbas, 2026).

Con la digitalización se ve alterado no solo el caudal y la celeridad de los datos, sino la propia arquitectura del juicio contable. De este modo, una porción del análisis se traslada a sistemas de inteligencia de negocios o a modelos de analítica predictiva que redefinen cómo se produce, circula y hace uso de la información interna (Appelbaum et al., 2017). Sin embargo, la literatura de contabilidad de gestión pone de manifiesto que un progreso técnico de estas proporciones no se traduce automáticamente en una mayor prudencia a la hora de decidir; más bien hace necesario repensar el papel del contador y los procedimientos para abordar el fenómeno (Bhimani, 2020; Quattrone, 2016; Rikhardsson & Yigitbasioglu, 2018).

Con la inteligencia artificial explicable (XAI) se ponen de manifiesto las propiedades y los métodos que permiten dar sentido al comportamiento de un sistema de IA. En materia de transparencia se trata de tener acceso a la información o a cómo funciona el sistema; la interpretabilidad otorga la facultad de entender lo que hay detrás de su operación; y la explicabilidad consiste en plantear al usuario razones de utilidad. Estas pueden adoptar diversas formas, ya sean intrínsecas o post hoc, de carácter global o local, y expresarse con narrativas, ejemplos, reglas, importancia de variables u otras vías como las explicaciones contrafactuales (Barredo et al., 2020).

Para evaluar una explicación hay que hacer las debidas distinciones en tres órdenes: la fidelidad técnica con el modelo, el grado de comprensión del usuario y cómo esta se traduce en su comportamiento y capacidad de decisión. En ese sentido, los distintos marcos y taxonomías de XAI están de acuerdo en que no existe una explicación válida a todas luces; su idoneidad depende del contexto, de a quién va dirigida y del fin que se persigue (Miller, 2019; Mohseni et al., 2021; Rai, 2020; Vilone & Longo, 2021). Un matiz de gran relevancia en la contabilidad de gestión, por ejemplo, es que lo que a primera vista parece una explicación clara bien puede resultar irrelevante para el control o mostrar poca fidelidad al modelo.

La explicación en materia de contabilidad de gestión ha de tener un propósito: poner a prueba los supuestos, hallar posibles errores y asentar la responsabilidad profesional. No se trata de una formalidad, pues una argumentación deficiente abre la puerta al rechazo por parte del algoritmo, mientras que una de carácter persuasivo pero carente de rigor puede instilar una

confianza desmedida. Lo que importa es contar con una confianza calibrada, es decir, una que se mida a la competencia y a los límites efectivos del sistema.

Para los efectos de esta revisión, la confianza se define como la predisposición a poner en manos del sistema lo que se necesita aun en situaciones de vulnerabilidad (Lee & See, 2004). En lo que respecta a la aceptación, se equipara con la intención de seguir la recomendación o su empleo de facto. La calidad de la decisión no se infiere de una mayor confianza, sino que se acota a unos parámetros objetivos de resultado tales como el error, la exactitud, el desempeño o la consistencia. Se obedece al precepto normativo de la confianza calibrada: poner fe en la IA en la medida de su competencia y cuestionarla cuando el modelo da muestras de incertidumbre o tiene limitaciones de otro tipo (Glikson & Woolley, 2020; Shin, 2021).

Lo que se desprende de la literatura de referencia es que no existe una relación lineal entre la decisión y el hecho de explicar. El efecto viene matizado por un sinnúmero de factores: la incertidumbre propia de la tarea, la exactitud del modelo o el formato en que se da la explicación, pero también la responsabilidad de quien lo usa y su experiencia. Y es preciso hacer hincapié en que cosas como la aceptación, la confianza o la calidad de la decisión son constructos a parte de la simple utilización del consejo, de modo que cada uno exige ser medido por separado.

Con el marco analítico que se ha adoptado se plantea de este modo una cadena de condicionantes: la calidad y modalidad con que se explica, la calibración de la confianza para aceptar o hacer uso de ello, la comprensión y en última instancia la objetividad de la decisión. Pese a esta secuencia, puede venirse abajo o volverse del revés por la aversión al algoritmo, una sobreconfianza, los incentivos o la experiencia, así como por la índole de la tarea o el hecho de poder incidir en la recomendación (Castelo et al., 2019; Dieta et al., 2018). No cabe considerar la explicabilidad como un estímulo de carácter uniforme cuando la evidencia de la paradoja entre lo humano y la automatización, el control que ejerce el usuario o su dependencia de la tarea se ponen de manifiesto (Burton et al., 2020; Raisch & Krakowski, 2021).

El objetivo general fue analizar críticamente y sintetizar la evidencia empírica publicada entre enero de 2020 y mayo de 2026 sobre la relación entre las modalidades de explicabilidad de la inteligencia artificial, la confianza, la aceptación y la calidad de las decisiones en las principales funciones de la contabilidad de gestión, con el propósito de establecer el estado del conocimiento, identificar vacíos de aplicación y proponer líneas futuras de investigación.

Preguntas de revisión

1. ¿Qué modalidades de explicabilidad se han estudiado en contabilidad de gestión y en contextos gerenciales transferibles?
2. ¿Qué relaciones se observan entre explicabilidad, confianza, aceptación o utilización de la IA y calidad de las decisiones?
3. ¿Qué diseños, medidas y condiciones explican la heterogeneidad de los resultados?

4. ¿Qué funciones de la contabilidad de gestión permanecen insuficientemente investigadas?

MATERIALES Y MÉTODOS

Se realizó una revisión sistemática con síntesis crítica narrativa. Para la identificación, selección y puesta en valor de los estudios se ha hecho acatamiento a PRISMA 2020 (Page et al., 2021) y la documentación de las búsquedas tiene el respaldo de PRISMA-S (Rethlefsen et al., 2021).

Con fecha de 21 de junio se ejecutaron las búsquedas en Scopus, SciELO y las colecciones Academic Search Ultimate, Applied Science & Technology Source Ultimate y Fuente Académica Plus de EBSCO. Por su parte, para localizar datos completos y no como fuente independiente de identificación se empleó ScienceDirect. En cuanto al idioma, no existió restricción; el periodo de elegibilidad comprendió desde el 1 de enero de 2020 hasta el 31 de mayo de 2026.

Con las ecuaciones se han integrado tres bloques: el de XAI, es decir, la transparencia o interpretabilidad del algoritmo (explicabilidad); el de contabilidad de gestión y sus decisiones o control gerencial; y por último, los relativos a la calidad decisional, la adopción o aceptación, la confianza y el uso que se hace del consejo. La búsqueda en Scopus abarcó título, resumen y palabras clave con una proximidad W/6, mientras que para EBSCO se recurrió al campo resumen y N6. En el caso de SciELO los términos se ajustaron al español, inglés o portugués. Todo ello, junto con los conteos y filtros de las ecuaciones, queda de manifiesto en la matriz maestra.

Tabla 1
Criterios de inclusión y exclusión

Dimensión	Inclusión	Exclusión
Periodo	01/01/2020–31/05/2026	Fuera de rango
Fenómeno	XAI, explicabilidad, interpretabilidad o transparencia de IA/ML	IA sin componente explicativo
Resultados	Confianza, aceptación, uso del consejo o calidad/desempeño decisional	Solo rendimiento técnico
Contexto	Contabilidad de gestión/control o decisión gerencial transferible	Aplicación técnica sin decisión humana
Diseño	Estudio empírico primario cuantitativo, cualitativo o mixto	Revisión o propuesta sin datos
Documento	Artículo o trabajo completo arbitrado	Resumen, póster o documento no arbitrado

Habiendo consolidado los CSV, RIS y BibTeX por DOI y título normalizado, se realizó el cribado de títulos y resúmenes y la valoración del texto completo con una matriz estructurada,

para lo cual se consignaba una única razón de exclusión. Con los accesos institucionales y a partir de archivos de acceso legítimo se hizo lo posible por obtener cada uno de los informes. A aquellos que no daban abasto se les anotó como “no recuperados” en el flujo PRISMA, sin que por ello se consideraran exclusiones temáticas o se procediera a extraer datos de sus resúmenes.

A los estudios que se han incluido se les ha tomado el contexto, el tipo de diseño y la muestra, así como la modalidad de explicabilidad, las estimaciones primordiales, los desenlaces a nivel humano, las limitaciones de cada uno y su pertinencia para la contabilidad de gestión. En cuanto a la evidencia, se ha hecho una separación entre lo que emana de contextos gerenciales de carácter general, considerada transferible, y aquella que está en función de lo estrictamente contable.

Para la evaluación de los estudios que figuran en el análisis se ha recurrido Mixed Methods Appraisal Tool (MMAT) versión 2018, tal como prescribe Hong et al. (2018). No se ha procedido a elaborar un puntaje global, sino que se ha dado cuenta de la valoración en términos de si es o no adecuada, o con las reservas del caso, y se ha hecho constar la limitación que la justifique. La integración de los resultados se ha llevado a cabo por una síntesis temática crítica a fin de distinguir entre la modalidad XAI, la confianza, la aceptación o uso, la calidad de la decisión y las condiciones moderadoras.


Asimismo se han recurrido a estudios y revisiones de revistas con arbitraje para dar base a los conceptos y una interpretación de lo hallado. Dado que no se daban a la vez los criterios operativos en materia de diseño, desenlace, el contexto gerencial-contable o el fenómeno XAI, estas fuentes de carácter contextual no figuran entre los estudios incluidos ni han aportado nada a la síntesis de datos. Con ello se ha mantenido la coherencia de las conclusiones empíricas con el corpus y el diagrama PRISMA.

RESULTADOS Y DISCUSIÓN

De las 98 coincidencias que arrojaron las búsquedas, se procedió a exportar 97 registros en tanto la plataforma EBSCO daba cuenta de una repetida sin que se creara un registro de más. Una vez desechados los seis duplicados de por medio, quedaron 92 referencias únicas para su cribado. Del total, 81 fueron descartadas tras el examen del título y el resumen y se solicitó 11 informes. De estos, cinco resultaron imposibles de obtener y se hizo una valoración a texto completo de los seis restantes. De estos seis, tres incumplieron los criterios de elegibilidad y fueron excluidos; los otros tres cumplieron los criterios e integraron la síntesis final. El proceso completo se presenta en la Figura 1.

Figura 1

Diagrama de flujo PRISMA 2020 para la selección de estudios

**Tabla 2**

Razón principal de exclusión en título y resumen

Razón principal	n
Fuera de tema	25
No evalúa resultados humanos	24
No es estudio empírico	19
No aborda XAI/explicabilidad	5
Tipo documental no elegible	4
Fuera del periodo	4
Total	81

Tabla 3*Decisiones sobre los seis textos completos evaluados*

Estudio	Decisión	Fundamento
Hammann y Wouters (2026)	Incluir	Evidencia directa; cumple fenómeno, desenlaces y contexto
Shulner-Tal et al. (2025)	Excluir	Desenlaces no elegibles: justicia y comprensión
Tuncer y Ramirez (2022)	Incluir	Cumple; evidencia gerencial transferible
Avramović et al. (2026)	Excluir	No contrasta la relación objetivo
Volkmar (2022)	Excluir	No proporciona ni manipula una modalidad XAI
Sturm et al. (2023)	Incluir	Cumple; evidencia gerencial transferible

Cinco informes adicionales no se recuperaron mediante los accesos disponibles. Se registraron en PRISMA como informes no recuperados y no se utilizaron para extraer resultados ni evaluar calidad.

Tabla 4*Características de los estudios incluidos*

Estudio	Contexto	Diseño/muestra	Modalidad	Desenlaces	MMAT
Hammann y Wouters (2026)	Costos de productos	Métodos mixtos; 40 expertos, 640 observaciones	Explicabilidad frente a exactitud	Elección del modelo e interacción	Adecuado
Tuncer y Ramirez (2022)	Decisiones gerenciales	Encuesta n=134; cualitativo n=14	Interpretabilidad y confianza informada	Confiabilidad percibida	Con reservas
Sturm et al. (2023)	Decisiones reales	Encuesta retrospectiva; n=239	Transparencia de análisis ML	Uso, calidad y eficiencia	Adecuado

La Tabla 2 resume las exclusiones realizadas durante el cribado, la Tabla 3 documenta las decisiones adoptadas después de evaluar los seis textos completos y la Tabla 4 presenta las características de los tres estudios incluidos.

La única evidencia directamente situada en una función de contabilidad de gestión fue la de Hammann y Wouters (2026). Cuarenta expertos en costos de una empresa automotriz resolvieron 16 viñetas cada uno, para un total de 640 observaciones, y eligieron entre modelos con diferentes niveles de explicabilidad y exactitud. Los participantes tendieron a preferir modelos más explicables aun cuando eran menos exactos. La incertidumbre de la tarea y la necesidad de interacción con el modelo ayudaron a explicar esa preferencia. El estudio ofrece alta pertinencia para estimación de costos, aunque la procedencia de una sola organización limita la generalización.

En un trabajo de Tuncer y Ramirez (2022) se han ocupado de las respuestas de 134 gerentes y ejecutivos, a lo que han añadido para su estudio las notas cualitativas de 14 de los participantes. De sus análisis se desprende que la interpretabilidad va de la mano con una mayor percepción de fiabilidad y confiabilidad en términos de puntuación; asimismo, el hecho de mostrar una medida de confianza del modelo ha sido propicio para distintas aristas de la misma. No obstante, se hallan incongruencias, ya sea en la interpretación de la primera hipótesis como en las pruebas expuestas o en los tamaños de grupo. En vista de ello, se toman los resultados de manera indicativa y se anota la evaluación metodológica con ciertas reservas.

En un trabajo de Sturm et al. (2023) se han planteado el análisis de 239 decisiones organizacionales reales que cuentan con el respaldo del aprendizaje automático, un 13,4 % de ellas en materia de finanzas y controlling. Los resultados de su PLS-SEM ponen de manifiesto una asociación entre la transparencia del análisis y un mayor uso del consejo ($\beta = .14$; $p = .037$). Dicho uso va de la mano con la calidad ($\beta = .61$; $p < .001$) y la eficiencia a la hora de decidir ($\beta = .58$; $p < .001$). Si bien el nivel gerencial modera la relación con la calidad ($\beta = -.14$; $p = .007$), no es así con la eficiencia. Con todo, y para ofrecer el vínculo empírico más exhaustivo entre transparencia, desempeño y la conducta de uso, el estudio tiene sus limitaciones: el hecho de ser de diseño retrospectivo y basarse en medidas autoinformadas no permite establecer causalidad.

De modo que, al tomar los tres estudios en su conjunto, no se puede hacer una estimación del efecto promedio. Hay disparidad en las unidades de análisis, en los desenlaces y en las propias modalidades, sea en la selección de un modelo, en el grado de confianza percibido o en lo que atañe a seguir recomendaciones para decisiones de verdad. Si bien la tendencia de fondo se aviene con que la explicabilidad reporta algún provecho, lo que hay de evidencia no da cuenta de que más explicación vaya a traducirse invariablemente en una mejor decisión, ni de que la confianza que se obtenga tenga la calibración debida.

De lo que se desprende de la revisión, la evidencia empírica de calado en XAI y su vínculo con los resultados de interés para un contable de gestión es aún incipiente. De los estudios que figuran, uno tan solo se ha ocupado de una tarea contable en sentido estricto, a saber, la estimación de los costos de un producto. Los dos restantes ofrecen mecanismos transferibles en materia de uso del consejo o confianza, sin embargo no hay evaluación alguna de la presupuestación, el pronóstico, el análisis de desviaciones o del desempeño.

Se echa de menos esta escasez en la extensa literatura de índole contable y gerencial que versa sobre el consejo algorítmico y la analítica. De hecho, la literatura se presta a matices: Jung y Seiter (2021) han puesto de manifiesto que al hacer un pronóstico la aversión al algoritmo cede ante la presión del tiempo. Cuando se trata de tomar decisiones con el respaldo de la analítica, lo que da credibilidad y se pone en práctica es la congruencia de valencia y tendencia del consejo (Chen et al., 2022; Fehrenbacher et al., 2023). En materia de auditoría, según Commerford et al. (2022), la dependencia de una evidencia en desacuerdo varía en función de si el origen del consejo

es humano o de un algoritmo. Si bien no hay aquí evidencia XAI propiamente dicha, los resultados dejan ver que cualquier explicación que se ofrezca estará sujeta a las señales de la tarea y a de dónde se perciba que viene el consejo.

Los resultados dejan constancia de un orden conceptual que se ajusta a la lógica: con una explicación de la calidad y las características oportunas se predispone a la confianza o a la comprensión, y ello sienta las bases para que haya aceptación o se proceda al uso. En consecuencia, de un buen empleo se deriva una mayor eficiencia y una calidad de la decisión. Pero no hay que tomar por buenas estas relaciones sin más, pues la evidencia no lo ampara; son muchos los elementos que pueden alterar cualquiera de sus eslabones, ya sea la responsabilidad, la exactitud en sí, la incertidumbre, el nivel gerencial o la experiencia de quien lo usa.

No conviene ver la aceptación como una ventaja de por sí. La analítica predictiva tiene el poder de reconfigurar las relaciones de autoridad en la organización (Labro et al., 2023), y hasta los sistemas de apoyo, que se venden como un plus para el factor humano, pueden acabar fomentando una sobrerelancia por parte de la gerencia (Keding & Meissner, 2021). De igual modo, el tipo de incentivos y cómo se plantea la participación de los expertos influyen en la consideración que se da al desempeño y a lo que dicta el algoritmo (Greiner et al., 2026). En definitiva, una XAI de verdad no se mide por su capacidad de generar confianza o adhesión, sino por propiciar una dependencia medida y dar pie a determinar en cada caso si hay que aceptar, poner en duda o desechar lo que se recomienda.

Tabla 5
Vacios de investigación y líneas prioritarias

Vacío	Evidencia en el corpus	Línea prioritaria
1. Aplicación en funciones contables	Solo la estimación de costos cuenta con evidencia directa en el corpus final.	Experimentos y estudios de campo en presupuestación, pronóstico, desviaciones y desempeño.
2. Confianza calibrada y calidad objetiva	Predominan preferencia y autoinforme; falta contrastar confianza con competencia real del sistema.	Medir uso, detección de errores, precisión, tiempo, sesgo de automatización y calibración.
3. Ajuste explicación–tarea–usuario	No existen comparaciones suficientes entre modalidades y perfiles de decisor.	Comparar explicaciones locales/globales, técnicas/narrativas y niveles de detalle según experiencia e incertidumbre.

De lo que se desprende de la Tabla 5, las prioridades radican en extender el alcance de las funciones contables analizadas, cuantificar un desempeño objetivo y la confianza calibrada de un lado, y por otro, ver de qué manera se ajusta la modalidad explicativa a la tarea y al perfil de quien decide.

Los estudios futuros deberían preregistrar hipótesis y separar, como mínimo, cuatro familias de medidas: calidad de la explicación, comprensión comprobada, confianza calibrada y desempeño decisional objetivo. Los diseños factoriales permiten someter a prueba modelos de interpretación intrínseca y todo tipo de explicaciones, sean de índole local o global, con reglas, contrafactuales o ejemplos incluidos; y hacerlo en función de factores como la experiencia, la responsabilidad o la incertidumbre. Por otra parte, hace falta el empleo de muestras de contadores de gestión y tareas contables que se ajusten a la realidad, y un análisis de mediación o moderación para someter a verificación la cadena conceptual, sin conformarse con las meras correlaciones de percepciones (Mohseni et al., 2021; Vilone & Longo, 2021).

No convendría que las organizaciones se limiten a juzgar una herramienta XAI en base a lo clara que parezca su explicación. A la hora de hacer una elección, hay que tener en cuenta otros factores como la fidelidad o la exactitud, la utilidad para el trabajo de campo y si el usuario puede poner en duda la recomendación o bien las repercusiones de un fallo. En el caso de decisiones con un alto grado de responsabilidad, lo que se busca es que la explicación permita la supervisión y la rendición de cuentas, no que sirva de coartada para dar por buena la acción del sistema.

Una gobernanza de múltiples capas es lo que se requiere para una implantación de responsabilidad. De ahí la necesidad de poner a prueba la incertidumbre del modelo y el grado de veracidad en su explicación, o bien de adecuar la interfaz a la tarea y al tipo de usuario. También cabe registrar las recomendaciones, intervenciones o anulaciones que se produzcan, establecer unos parámetros para la revisión por parte de un humano y, a continuación, auditar los patrones de uso y cualquier sesgo o error de que haya constancia. La supervisión ha de contar con una capacidad real de impugnar y corregir en este proceso, no puede quedarse en un formalismo (Lee & See, 2004; Raisch & Krakowski, 2021).

Se advierten cuatro limitaciones primordiales en la revisión. En primer lugar, no ha sido posible dar con cinco de los 11 informes (un 45,5 %) y sus resúmenes no han hecho las veces de texto completo; de ahí un sesgo de disponibilidad que se hace evidente. Por otra parte, el corpus final es de apenas tres estudios, de los cuales uno solo ofrece evidencia contable directa. Tampoco hubo verificación independiente en la labor de evaluación y selección, que corrió a cargo de un único revisor. Por último, Web of Science no figura entre las fuentes de identificación. Con tales restricciones la certeza se ve mermada y hay que tomar los resultados como un mapa crítico de lo que se ha podido recuperar más que una estimación de efectividad de carácter definitivo.

Aun cuando se amplíe el marco conceptual con la literatura de su entorno, las restricciones de rigor y los recuentos PRISMA no se ven alterados. Lo que hace esta ampliación es dar un contexto a los tres estudios que se han incorporado y permitir su interpretación; en consecuencia, lo que se infiere de XAI en materia de contabilidad de gestión se circunscribe al corpus apto para ello y no cabe considerarlo una extrapolación de efectos causales de carácter general.

CONCLUSIONES

De lo que se ha podido recabar en forma de evidencia a mayo de 2026 se desprende que, al pretender una transparencia y explicabilidad de mayor calibre, se tiende a elegir modelos de sencilla interpretación; ello no solo predispone a hacer caso a las recomendaciones de los algoritmos sino que instaura la confianza. La conexión más cabal es la existente entre la transparencia y el hecho de seguir el consejo, un proceder que conlleva por añadidura una mejor calidad y eficiencia a la hora de decidir. Pero hay que tener en cuenta que el corpus de datos no deja de ser de reducidas dimensiones y heterogéneo, y en su mayor parte procedente de transferencias de ámbitos gerenciales de carácter general.

Lo que se detecta como un vacío de aplicación es la escasez de estudios en lo relativo a la presupuestación, el pronóstico, el análisis de desviaciones o la evaluación del desempeño. Tampoco se ha visto una asunción de medidas con la objetividad y confianza debidas, ni las comparaciones explícitas que caben entre los perfiles de usuario, las tareas y las diferentes formas de explicación. Esta revisión viene a subsanar tal deficiencia; en su aportación consiste en dejar constancia de lo que hay de evidencia y a la vez establecer una agenda empírica bien definida para la contabilidad de gestión.

REFERENCIAS

- Abbas, K. (2026). Management accounting and artificial intelligence: A comprehensive literature review and recommendations for future research. *The British Accounting Review*, 58(2), 101551. <https://doi.org/10.1016/j.bar.2025.101551>
- Appelbaum, D., Kogan, A., Vasarhelyi, M. A., & Yan, Z. (2017). Impact of business analytics and enterprise systems on managerial accounting. *International Journal of Accounting Information Systems*, 25, 29–44. <https://doi.org/10.1016/j.accinf.2017.03.003>
- Avramović, N., Marković, A., Čomić, T., Čavoški, S., Zornić, N., & Vujović, V. (2026). PRIME–INSPECT: A socio-technical framework for trustworthy intelligent automation and real-time decision-making in Industry 4.0. *Applied Sciences*, 16(10), 4825. <https://doi.org/10.3390/app16104825>
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Bhimani, A. (2020). Digital data and management accounting: Why we need to rethink research methods. *Journal of Management Control*, 31, 9–23. <https://doi.org/10.1007/s00187-020-00295-z>
- Burton, J. W., Stein, M.-K., & Jensen, T. B. (2020). A systematic review of algorithm aversion in augmented decision making. *Journal of Behavioral Decision Making*, 33(2), 220–239. <https://doi.org/10.1002/bdm.2155>
- Castelo, N., Bos, M. W., & Lehmann, D. R. (2019). Task-dependent algorithm aversion. *Journal of Marketing Research*, 56(5), 809–825. <https://doi.org/10.1177/0022243719851788>
- Chen, C. X., Hudgins, R., & Wright, W. F. (2022). The effect of advice valence on the perceived credibility of data analytics. *Journal of Management Accounting Research*, 34(2), 97–116. <https://doi.org/10.2308/JMAR-2020-015>
- Commerford, B. P., Dennis, S. A., Joe, J. R., & Ulla, J. W. (2022). Man versus machine: Complex estimates and auditor reliance on artificial intelligence. *Journal of Accounting Research*, 60(1), 171–201. <https://doi.org/10.1111/1475-679X.12407>
- Dieta vorst, B. J., Simmons, J. P., & Massey, C. (2018). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them. *Management Science*, 64(3), 1155–1170. <https://doi.org/10.1287/mnsc.2016.2643>
- Fehrenbacher, D. D., Ghio, A., & Weisner, M. M. (2023). Advice utilization from predictive analytics tools: The trend is your friend. *European Accounting Review*, 32(3), 637–662. <https://doi.org/10.1080/09638180.2022.2138934>

- Glikson, E., & Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. *Academy of Management Annals*, 14(2), 627–660. <https://doi.org/10.5465/annals.2018.0057>
- Greiner, B., Grünwald, P., Lindner, T., Lintner, G., & Wiernsperger, M. (2026). Incentives, framing, and reliance on algorithmic advice: An experimental study. *Management Science*, 72(1), 302–322. <https://doi.org/10.1287/mnsc.2022.02777>
- Hammann, D., & Wouters, M. (2026). Explainability versus accuracy of machine learning models: The role of task uncertainty and need for interaction with the machine learning model. *European Accounting Review*, 35(2), 343–375. <https://doi.org/10.1080/09638180.2025.2463961>
- Hong, Q. N., Fàbregues, S., Bartlett, G., Boardman, F., Cargo, M., Dagenais, P., Gagnon, M.-P., Griffiths, F., Nicolau, B., O’Cathain, A., Rousseau, M.-C., Vedel, I., & Pluye, P. (2018). The Mixed Methods Appraisal Tool (MMAT) version 2018 for information professionals and researchers. *Education for Information*, 34(4), 285–291. <https://doi.org/10.3233/EFI-180221>
- Jung, M., & Seiter, M. (2021). Towards a better understanding on mitigating algorithm aversion in forecasting: An experimental study. *Journal of Management Control*, 32, 495–516. <https://doi.org/10.1007/s00187-021-00326-3>
- Keding, C., & Meissner, P. (2021). Managerial overreliance on AI-augmented decision-making processes: How the use of AI-based advisory systems shapes choice behavior in R&D investment decisions. *Technological Forecasting and Social Change*, 171, 120970. <https://doi.org/10.1016/j.techfore.2021.120970>
- Labro, E., Lang, M. H., & Omartian, J. D. (2023). Predictive analytics and centralization of authority. *Journal of Accounting and Economics*, 75(1), 101526. <https://doi.org/10.1016/j.jacceco.2022.101526>
- Lee, J. D., & See, K. A. (2004). Trust in automation: Designing for appropriate reliance. *Human Factors*, 46(1), 50–80. https://doi.org/10.1518/hfes.46.1.50_30392
- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1–38. <https://doi.org/10.1016/j.artint.2018.07.007>
- Mohseni, S., Zarei, N., & Ragan, E. D. (2021). A multidisciplinary survey and framework for design and evaluation of explainable AI systems. *ACM Transactions on Interactive Intelligent Systems*, 11(3–4), 1–45. <https://doi.org/10.1145/3387166>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372(71), 1–9. <https://doi.org/10.1136/bmj.n71>

- Quattrone, P. (2016). Management accounting goes digital: Will the move make it wiser? *Management Accounting Research*, 31, 118–122. <https://doi.org/10.1016/j.mar.2016.01.003>
- Rai, A. (2020). Explainable AI: From black box to glass box. *Journal of the Academy of Marketing Science*, 48, 137–141. <https://doi.org/10.1007/s11747-019-00710-5>
- Raisch, S., & Krakowski, S. (2021). Artificial intelligence and management: The automation–augmentation paradox. *Academy of Management Review*, 46(1), 192–210. <https://doi.org/10.5465/amr.2018.0072>
- Ranta, M., Ylinen, M., & Järvenpää, M. (2023). Machine learning in management accounting research: Literature review and pathways for the future. *European Accounting Review*, 32(3), 607–636. <https://doi.org/10.1080/09638180.2022.2137221>
- Rethlefsen, M. L., Kirtley, S., Waffenschmidt, S., Ayala, A. P., Moher, D., Page, M. J., Koffel, J. B., & PRISMA-S Group. (2021). PRISMA-S: An extension to the PRISMA statement for reporting literature searches in systematic reviews. *Systematic Reviews*, 10, 39. <https://doi.org/10.1186/s13643-020-01542-z>
- Rikhardsson, P., & Yigitbasioglu, O. (2018). Business intelligence & analytics in management accounting research: Status and future focus. *International Journal of Accounting Information Systems*, 29, 37–58. <https://doi.org/10.1016/j.accinf.2018.03.001>
- Shin, D. (2021). The effects of explainability and causability on perception, trust, and acceptance: Implications for explainable AI. *International Journal of Human-Computer Studies*, 146, 102551. <https://doi.org/10.1016/j.ijhcs.2020.102551>
- Shulner-Tal, A., Kuflik, T., Kliger, D., & Mancini, A. (2025). Who made that decision and why? Users’ perceptions of human versus AI decision-making and the power of explainable-AI. *International Journal of Human–Computer Interaction*, 41(7), 4230–4247. <https://doi.org/10.1080/10447318.2024.2348843>
- Sturm, T., Pumplun, L., Gerlach, J. P., Kowalczyk, M., & Buxmann, P. (2023). Machine learning advice in managerial decision-making: The overlooked role of decision makers’ advice utilization. *The Journal of Strategic Information Systems*, 32(4), 101790. <https://doi.org/10.1016/j.jsis.2023.101790>
- Tuncer, S., & Ramirez, A. (2022). Exploring the role of trust during human–AI collaboration in managerial decision-making processes. In J. Y. C. Chen, G. Fragomeni, H. Degen, & S. Ntoa (Eds.), *HCI International 2022—Late Breaking Papers: HCI for Today’s Community and Economy* (Lecture Notes in Computer Science, Vol. 13518, pp. 541–557). Springer. https://doi.org/10.1007/978-3-031-21707-4_39
- Vilone, G., & Longo, L. (2021). Notions of explainability and evaluation approaches for explainable artificial intelligence. *Information Fusion*, 76, 89–106. <https://doi.org/10.1016/j.inffus.2021.05.009>

Volkmar, G. V. (2022). Managerial decisions in marketing: The individual perception of explainable artificial intelligence. In J. L. Reis, E. P. López, L. Moutinho, & J. P. M. dos Santos (Eds.), *Marketing and Smart Technologies* (Smart Innovation, Systems and Technologies, Vol. 279, pp. 15–21). Springer. https://doi.org/10.1007/978-981-16-9268-0_2