

الأثر التحويلي للذكاء الاصطناعي على جودة المراجعة: دراسة تجريبية في سوق ناشئة

هدى سراج الدين محمد

أستاذ مساعد، قسم العلوم الإدارية والمالية، الكلية الجامعية بالخفجي، جامعة حفر الباطن، المملكة العربية السعودية
hudasiraj@uhb.edu.sa

ملخص البحث

تواجه مهنة المراجعة تحولاً جذرياً مدفوعاً بالتبني المتسارع لتقنيات الذكاء الاصطناعي، وهو تحول يكتسب أبعاداً فريدة في سياق الأسواق الناشئة التي تتسم بفرص نمو هائلة وتحديات هيكلية متزامنة. تسعى هذه الدراسة إلى سد فجوة معرفية قائمة من خلال فحص الأثر التجريبي لاعتماد الذكاء الاصطناعي على جودة المراجعة في هذه الأسواق. ولتحقيق هذا الهدف، تم اتباع منهج كمي وصفي-تحليلي، حيث جُمعت البيانات الأولية عبر استبيان مُحكم وُرِّع على عينة مكونة من 370 مراجعاً ومحترفاً في مجال التدقيق. تم تحليل البيانات باستخدام نمذجة المعادلات الهيكلية (SEM) لاختبار العلاقات المعقدة بين الأبعاد المختلفة لتبني الذكاء الاصطناعي وجودة المراجعة. تم تعريف المتغير المستقل "تبني الذكاء الاصطناعي" كبنية كامنة متعددة الأبعاد تشمل: أتمتة العمليات الروبوتية (RPA)، والتعلم الآلي لتحليل البيانات، وقدرات كشف الشذوذ المتقدمة، والذكاء الاصطناعي القابل للتفسير (XAI). في المقابل، قيس المتغير التابع "جودة المراجعة" من خلال أبعاد رئيسية هي: استقلالية المراجع وموضوعيته، وكفاءة عملية المراجعة، ودقة اكتشاف الأخطاء الجوهرية. أظهرت النتائج التجريبية وجود علاقات إيجابية وجوهرية إحصائياً بين أبعاد محددة للذكاء الاصطناعي وجودة المراجعة. وبشكل خاص، ارتبط تطبيق أنظمة كشف الشذوذ المتقدمة بشكل كبير بتحسين دقة الاكتشاف، بينما ساهم التعلم الآلي في تعزيز كفاءة المراجعة واستقلالية المراجع. كما برز دور الذكاء الاصطناعي القابل للتفسير كعامل حاسم في تعزيز ثقة المراجعين في الأدلة المستمدة من الأنظمة الذكية. تقدم هذه الدراسة مساهمات ثلاثية الأبعاد: نظرياً، عبر توسيع نطاق نماذج تبني التكنولوجيا لتشمل سياق المراجعة المهنية في الاقتصادات الناشئة؛ ومهنيّاً، من خلال تقديم إطار عمل قائم على الأدلة لمكاتب المراجعة لتوجيه استثماراتها التقنية؛ وعلى صعيد السياسات، عبر تزويد الهيئات التنظيمية برؤى حول الدعم التشريعي والبنوي اللازم لتسخير إمكانات الذكاء الاصطناعي بفعالية.

الكلمات المفتاحية: الذكاء الاصطناعي، جودة المراجعة، الأسواق الناشئة، التحول الرقمي.

The Transformational Impact of Artificial Intelligence on Audit Quality: An Empirical Study in an Emerging Market

Huda Siraj Al-Din Muhammad

Assistant Professor, Department of Administrative and Financial Sciences, Khafji University
College, Hafr Al-Batin University, Kingdom of Saudi Arabia
hudasiraj@uhb.edu.sa

Abstract

This study empirically examines the impact of Artificial Intelligence (AI) on audit quality in emerging markets. Based on survey data from 370 audit professionals analyzed using Structural Equation Modeling (SEM), the research assesses how AI dimensions—including Robotic Process Automation (RPA), Machine Learning (ML), Anomaly Detection (AD), and Explainable AI (XAI)—affect audit quality, measured by efficiency, accuracy, and auditor independence. The findings confirm a significant positive impact, as anomaly detection enhances accuracy, machine learning improves efficiency and independence, and explainable AI is crucial for building auditor trust in AI-derived evidence. The study offers an evidence-based framework for audit firms and regulators, contributing to the literature on technology adoption in professional services.

Keywords: Artificial Intelligence (AI), Audit Quality, Emerging Markets, Digital Transformation.

المقدمة

خلفية وسياق الدراسة

تقف مهنة المحاسبة والمراجعة اليوم على أعتاب ثورة صناعية رابعة، حيث لم يعد الذكاء الاصطناعي مجرد مفهوم مستقبلي، بل أصبح واقعاً ملموساً يعيد تشكيل أسس الخدمات المهنية (Kamareldawla, 2025). يشهد قطاع المراجعة، الذي ظل لسنوات يعتمد على منهجيات تقليدية، تكاملاً متسارعاً لتقنيات الذكاء

الاصطناعي المتقدمة مثل التعلم الآلي (ML)، ومعالجة اللغات الطبيعية (NLP)، وأتمتة العمليات الروبوتية (RPA) في صميم عملياته (Davenport, 2017; Moffitt et al., 2018 & Kokina). هذا التحول ليس مجرد تحديث تقني، بل هو استجابة حتمية للتغيرات الجوهرية في بيئة الأعمال المعاصرة. فمع الانفجار الهائل في حجم البيانات (Big Data) وتعقيدها، أصبحت أساليب المراجعة التقليدية القائمة على العينات غير كافية بشكل متزايد لتقديم تأكيد معقول في ظل بيئة رقمية بالكامل (O'Leary et al., 2024).

يقدم الذكاء الاصطناعي نقلة نوعية في نموذج المراجعة، محولاً إياه من نهج قائم على فحص المعاملات بالعينة إلى نهج مدفوع بالبيانات يتيح تحليل مجموعات البيانات الكاملة (Full Population Testing) (Freiman et al., 2022). هذا التحول الجذري يمكّن المراجعين من تحديد المخاطر وتقييمها وجمع الأدلة بطرق لم تكن ممكنة في السابق. فبدلاً من الاعتماد على عينات إحصائية قد لا تكشف عن الأخطاء الجوهرية أو عمليات الاحتيال المتطورة، تسمح الأدوات المدعومة بالذكاء الاصطناعي بفحص ملايين القيود المحاسبية والمعاملات بشكل فوري، وتحديد الأنماط الشاذة والانحرافات التي قد تغفل عنها العين البشرية. وقد أثبتت الدراسات التجريبية في الأسواق المتقدمة أن الاستثمار في رأس المال البشري المتخصص في الذكاء الاصطناعي داخل شركات المراجعة يرتبط ارتباطاً وثيقاً بتحسين جودة المراجعة، وتقليل احتمالية إعادة إصدار القوائم المالية، وزيادة الكفاءة التشغيلية (Fedyk et al., 2022). إن هذا التحول لا يعزز دقة المراجعة فحسب، بل يحرر المراجعين من المهام الروتينية المتكررة، مما يسمح لهم بالتركيز على المهام ذات القيمة المضافة الأعلى التي تتطلب الحكم المهني، والشك المهني، والتفكير النقدي (Samiolo et al., 2024).

مبررات التركيز على الأسواق الناشئة:

في حين أن الأدبيات البحثية قد بدأت في استكشاف هذا التحول في الاقتصادات المتقدمة، فإن السياق الخاص بالأسواق الناشئة يظل منطقة تتطلب بحثاً معمقاً ومستقلاً. تتميز هذه الأسواق بازدياد فريدة: فمن ناحية، هناك دافع قوي للتحول الرقمي كوسيلة لتعزيز القدرة التنافسية والشفافية وجذب الاستثمارات الأجنبية (Khan et al., 2025). ومن ناحية أخرى، تواجه هذه الأسواق مجموعة من التحديات الهيكلية التي تعقد عملية تبني التقنيات المتقدمة. تشمل هذه التحديات البنية التحتية الرقمية غير المكتملة أو المتقطعة، والأطر التنظيمية التي لا تزال في مراحلها الأولى من التطور لمواكبة الابتكارات التكنولوجية، وارتفاع تكاليف التنفيذ مقارنة بموارد الشركات المحلية، والنقص الحاد في الكوادر البشرية المؤهلة التي تمتلك المزيج

المطلوب من مهارات المراجعة وعلوم البيانات.

هذه البيئة تخلق مفارقة مثيرة للاهتمام؛ ففي حين أن شركات المراجعة في الأسواق المتقدمة قد تكون مقيدة بأنظمة قديمة وموروثة، فإن نظيراتها في الأسواق الناشئة قد تمتلك فرصة "القفز فوق المراحل" (Leapfrogging) وتبني حلول ذكاء اصطناعي أكثر مرونة وقائمة على السحابة منذ البداية. ومع ذلك، فإن هذه الإمكانيات النظرية للتقدم السريع تصطدم مباشرة بالقيود الأساسية المتمثلة في ضعف البنية التحتية، وغياب الأطر القانونية لحوكمة البيانات، وندرة المواهب المتخصصة. علاوة على ذلك، قد تكتسب "جودة المراجعة" في الأسواق الناشئة أهمية مضاعفة، مع تركيز أكبر على دورها في كشف الاحتيال وضمان الامتثال، نظراً لارتفاع المخاطر المتصورة المرتبطة بضعف حوكمة الشركات أو البيئات التنظيمية الأقل نضجاً. وبالتالي، فإن قدرة الذكاء الاصطناعي على تعزيز كشف الشذوذ ليست مجرد أداة لزيادة الكفاءة، بل هي آلية أساسية لتعزيز الوظيفة الاجتماعية للمراجع في تلك السياقات، مما يرفع من أهميتها للمنظمين والمستثمرين على حد سواء (Tragouda et al., 2024).

الفجوة البحثية وأهمية الدراسة

عند مراجعة الأدبيات الدولية، نجد أن الأبحاث الرائدة قد بدأت في رسم ملامح العلاقة بين الذكاء الاصطناعي وجودة المراجعة. على سبيل المثال، قدمت دراسة (Fedyk et al., 2022) أدلة قوية من السوق الأمريكية، بينما استكشفت دراسات أخرى هذا التأثير في سياقات محددة مثل الصين (Rahman et al., 2024)، والإمارات العربية المتحدة (Noordin et al., 2022)، وتركيا (Cek, 2024 & Qader). ورغم القيمة الكبيرة لهذه الدراسات، إلا أنها تترك فجوة بحثية واضحة تتمثل في غياب الأبحاث التجريبية القائمة على نماذج نظرية قوية، والتي تختبر التأثير متعدد الأبعاد لتبني الذكاء الاصطناعي على جودة المراجعة في السياق العام للأسواق الناشئة، مع الأخذ في الاعتبار مجموعة القيود والتحديات الفريدة التي تواجهها. فالدراسات الحالية إما أنها تتركز في اقتصادات متقدمة ذات بنية تحتية وتشريعية ناضجة، أو أنها تدرس سياقات محددة قد لا تكون نتائجها قابلة للتعميم بسهولة على أسواق ناشئة أخرى. كما أن العديد من الدراسات في هذه الأسواق لا تزال تركز على التصورات والانطباعات (Kamareldawla, 2025) بدلاً من بناء واختبار نماذج سببية متكاملة.

تأتي هذه الدراسة لتسد هذه الفجوة من خلال تقديم نموذج تجريبي شامل يحلل العلاقة بين تبني الذكاء الاصطناعي وجودة المراجعة في سوق ناشئة تمثل حالة نموذجية. تكمن أهمية هذه الدراسة في أنها تتجاوز

مجرد تأكيد وجود علاقة إيجابية، لتستكشف الآليات التي من خلالها تؤثر الأبعاد المختلفة للذكاء الاصطناعي (مثل الأتمتة، والتعلم الآلي، وكشف الشذوذ) على الأبعاد المختلفة لجودة المراجعة (مثل الكفاءة، والدقة، والاستقلالية).

أهداف الدراسة ومساهمتها

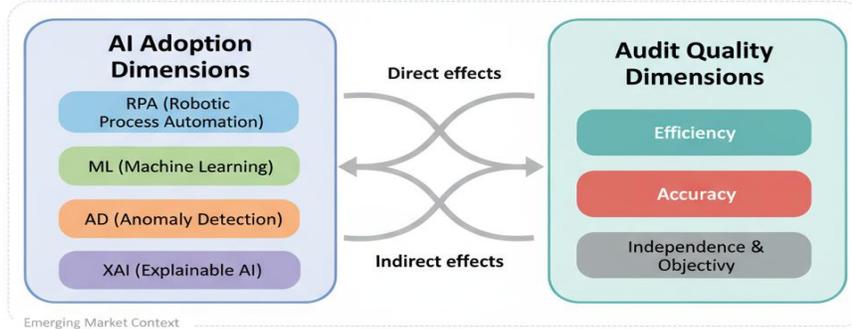
بناءً على ما سبق، تتمثل الأهداف الرئيسية لهذه الدراسة فيما يلي:

1. تطوير أداة قياس موثوقة وثابتة لتقييم مستوى تبني الذكاء الاصطناعي بأبعاده المختلفة، وتقييم جودة المراجعة بأبعادها المتعددة، في سياق سوق ناشئة.

2. بناء واختبار نموذج سببي باستخدام نمذجة المعادلات الهيكلية (SEM) لفحص التأثير المباشر وغير المباشر لأبعاد تبني الذكاء الاصطناعي على أبعاد جودة المراجعة.

3. تقديم توصيات عملية وقابلة للتطبيق لمكاتب المراجعة، والهيئات المهنية، وصناع السياسات في الأسواق الناشئة، بهدف تعظيم الفوائد المحتملة للذكاء الاصطناعي وتجاوز تحديات تطبيقه.

تتجلى مساهمة هذه الدراسة في ثلاثة محاور رئيسية. نظرياً، تساهم الدراسة في إثراء أدبيات تبني التكنولوجيا من خلال تطبيق واختبار نماذج نظرية (مثل نموذج القبول الموحد للتكنولوجيا UTAUT) في مجال المراجعة المهنية، وهو سياق متخصص ومعقد لم يحظ بالاهتمام الكافي. عملياً، تقدم الدراسة خارطة طريق استراتيجية قائمة على الأدلة لشركات المراجعة في الأسواق الناشئة، تساعد على توجيه استثماراتها في الذكاء الاصطناعي نحو التقنيات التي تحقق الأثر الأكبر على جودة خدماتها. على صعيد السياسات، توفر النتائج رؤى قيمة للمنظمين والهيئات التشريعية حول الحاجة إلى تطوير بنية تحتية داعمة وأطر تنظيمية مرنة تشجع على الابتكار مع ضمان حوكمة أخلاقية ومسؤولية للذكاء الاصطناعي في مهنة المراجعة.



الشكل (1): خريطة مفاهيمية توضح مسارات تبني الذكاء الاصطناعي وتأثيرها على أبعاد جودة المراجع

مشكلة الدراسة

تتمحور مشكلة هذه الدراسة حول الفجوة القائمة بين الإمكانيات التحويلية الهائلة التي تعد بها تقنيات الذكاء الاصطناعي لمهنة المراجعة، وبين النقص الواضح في الفهم التجريبي العميق لكيفية تحقق هذه الإمكانيات على أرض الواقع، خاصة ضمن البيئة المعقدة والملبئة بالتحديات التي تميز الأسواق الناشئة. على الرغم من الانتشار العالمي لخطاب التحول الرقمي، واستثمار شركات المراجعة الكبرى لمبالغ طائلة في تطوير أدوات ذكية (Shen, 2025 & Law)، إلا أن عملية اتخاذ القرار لدى الشركاء المديرين والمنظمين في الأسواق الناشئة لا تزال تفتقر إلى نموذج علمي موثوق يوضح العلاقات السببية بين أنواع محددة من استثمارات الذكاء الاصطناعي والتحسينات الملموسة في جودة المراجعة.

المشكلة لا تكمن في التساؤل "هل للذكاء الاصطناعي تأثير؟" بل في فهم "كيف وما هي الآليات التي يؤثر بها؟". إن اتخاذ قرارات استراتيجية بالاستثمار في منصات التعلم الآلي باهظة الثمن أو في برمجيات أتمتة العمليات الروبوتية يتطلب فهماً دقيقاً للعائد المتوقع على جودة المراجعة. فهل الاستثمار في الأتمتة يحقق مكاسب في الكفاءة على حساب الدقة؟ وهل يؤدي الاعتماد المفرط على أنظمة "الصندوق الأسود" إلى تآكل الشك المهني للمراجع؟ وكيف يمكن ضمان أن الأدوات المصممة لكشف الشذوذ لا تولد سيلاً من النتائج الإيجابية الكاذبة التي تعيق العملية بدلاً من تسريعها؟ هذه الأسئلة العملية الملحة لا يمكن الإجابة عليها من خلال الدراسات الوصفية أو القائمة على التصورات العامة فقط.

لذلك، تصوغ هذه الدراسة مشكلتها البحثية بشكل دقيق على النحو التالي: "في ظل غياب نموذج تجريبي

متكامل، تواجه شركات المراجعة والهيئات التنظيمية في الأسواق الناشئة حالة من عدم اليقين بشأن كيفية تخصيص الموارد وتوجيه السياسات لتحقيق الاستفادة المثلى من الذكاء الاصطناعي في تحسين جودة المراجعة. وتتفاقم هذه المشكلة بسبب الخصائص الفريدة لهذه الأسواق، مثل فجوة المهارات الرقمية، والقيود التنظيمية، ومحدودية الموارد، مما يجعل عملية تبني هذه التقنيات محفوفة بالمخاطر".

لمعالجة هذه المشكلة، تحدد الدراسة متغيراتها بشكل إجرائي دقيق:

• المتغيرات المستقلة (أبعاد تبني الذكاء الاصطناعي): يتم التعامل مع تبني الذكاء الاصطناعي كبنية كامنة متعددة الأبعاد، تشمل:

1. أتمتة العمليات (Process Automation): قياس مدى استخدام RPA لأتمتة المهام الروتينية والمتكررة في عملية المراجعة (Moffitt et al., 2018).

2. التعلم الآلي المتقدم (Advanced Machine Learning): قياس مدى استخدام خوارزميات التعلم الآلي لتحليل البيانات، وتقييم المخاطر، وإجراء الاختبارات الجوهرية (Senave et al., 2023).

3. كشف الشذوذ (Anomaly Detection): قياس مدى الاعتماد على الأنظمة الذكية لتحديد المعاملات والأنماط غير العادية في مجموعات البيانات الكاملة (Wei et al., 2024).

4. الذكاء الاصطناعي القابل للتفسير (Explainable AI - XAI): قياس مدى توفر آليات تجعل مخرجات وقرارات أنظمة الذكاء الاصطناعي شفافة وقابلة للفهم والتدقيق من قبل المراجع البشري (Zhang et al., 2022).

• المتغير التابع (أبعاد جودة المراجعة): يتم قياس جودة المراجعة من منظور المراجعين أنفسهم، من خلال ثلاثة أبعاد رئيسية:

1. الكفاءة (Efficiency): تقييم مدى مساهمة الذكاء الاصطناعي في تقليل الوقت والجهد اللازمين لإنجاز مهام المراجعة وتحسين تخصيص الموارد (Fedyk et al., 2022).

2. الدقة (Accuracy): تقييم مدى قدرة الأدوات الذكية على تحسين اكتشاف الأخطاء الجوهرية والاحتيايل المحتمل، وزيادة موثوقية أدلة المراجعة (Noordin et al., 2022).

3. الاستقلالية والموضوعية (Independence and Objectivity): تقييم مدى مساهمة الذكاء الاصطناعي في تعزيز الشك المهني وتقليل التحيزات المعرفية للمراجع (Witz, 2024 & Libby).

إن الإلحاح البحثي لهذه المشكلة ينبع من كون الأسواق الناشئة في مرحلة حرجة من التحول الرقمي. فالقرارات التي تتخذها شركات المراجعة والجهات التنظيمية اليوم سترسم ملامح مستقبل المهنة لعقود قادمة. وبدون بوصلة تجريبية واضحة، هناك خطر حقيقي من سوء تخصيص الموارد، أو تبني تقنيات غير ملائمة للسياق المحلي، أو وضع سياسات تنظيمية إما أن تخنق الابتكار أو تفشل في معالجة المخاطر الجديدة الناشئة عن هذه التقنيات.

أسئلة الدراسة

انطلاقاً من مشكلة الدراسة وأهدافها، تسعى هذه الدراسة إلى الإجابة على مجموعة من الأسئلة المترابطة التي توجه مسار التحليل التجريبي. تم تصميم هذه الأسئلة لتكون مركزة وقابلة للقياس، وتشكل الأساس الذي بنيت عليه فرضيات الدراسة.

• السؤال الرئيسي:

ما هو مدى وطبيعة الأثر التحويلي لاعتماد تقنيات الذكاء الاصطناعي بأبعادها المختلفة (الأتمتة، التعلم الآلي، كشف الشذوذ، القابلية للتفسير) على جودة المراجعة بأبعادها المتعددة (الكفاءة، الدقة، الاستقلالية) في السوق الناشئة محل الدراسة؟

• الأسئلة الفرعية:

1. ما هو الأثر المحدد لتبني تقنيات أتمتة العمليات الروبوتية (RPA) على كفاءة عملية المراجعة من حيث تقليل الوقت وتكاليف التنفيذ؟
2. كيف يؤثر استخدام خوارزميات التعلم الآلي في تحليل البيانات على دقة المراجعين في اكتشاف الأخطاء المادية والمخالفات المحتملة؟
3. ما هي العلاقة بين تطبيق أنظمة كشف الشذوذ المتقدمة وتحسين قدرة المراجعين على تحديد المعاملات عالية المخاطر ضمن مجموعات البيانات الكاملة؟
4. إلى أي مدى يساهم استخدام الذكاء الاصطناعي في تعزيز استقلالية المراجع وموضوعيته من خلال الحد من التحيزات المعرفية البشرية؟
5. ما هو الدور الذي يلعبه الذكاء الاصطناعي القابل للتفسير (XAI) في بناء ثقة المراجعين في مخرجات الأنظمة الذكية واعتمادهم عليها كأدلة مراجعة موثوقة؟

أهمية الدراسة

تستمد هذه الدراسة أهميتها من مساهماتها المتوقعة على الصعيدين النظري والعملي، حيث تسعى إلى تقديم إضافة نوعية للمعرفة في مجال يتقاطع فيه الذكاء الاصطناعي مع المحاسبة والمراجعة، وهو مجال يشهد تطوراً متسارعاً ونقاشاً عالمياً واسعاً.

• الأهمية النظرية:

تكمن الأهمية النظرية لهذه الدراسة في عدة جوانب رئيسية. أولاً، تساهم الدراسة في إثراء الأدبيات الأكاديمية المتعلقة بجودة المراجعة. ففي حين أن مفهوم جودة المراجعة قد تم بحثه على نطاق واسع، إلا أن معظم الأبحاث السابقة ركزت على مؤشرات تقليدية مثل حجم مكتب المراجعة، وأتعب المراجعة، وتخصص المراجع في الصناعة (Zhang, 2014 & DeFond). تقدم هذه الدراسة منظوراً جديداً من خلال فحص متغير تكنولوجي حديث ومؤثر – وهو الذكاء الاصطناعي – كأحد المحددات الرئيسية لجودة المراجعة في العصر الرقمي.

ثانياً، تساهم الدراسة في توسيع وتعميق تطبيق النماذج النظرية لتبني التكنولوجيا. تعتمد الدراسة على إطار نظري متين مستمد من "النظرية الموحدة لقبول واستخدام التكنولوجيا" (UTAUT)، ولكنها لا تكتفي بتطبيقها كما هي، بل تقوم بتكييفها وتوسيعها لتناسب السياق المهني المتخصص للمراجعة. فبدلاً من التركيز فقط على "نية الاستخدام"، يربط نموذج الدراسة المقترح بين عوامل التبني (مثل توقعات الأداء وسهولة الاستخدام المتصورة) والنتائج المهنية الملموسة (مثل تحسين كفاءة ودقة المراجعة). هذا الربط يوفر جسراً بين أدبيات نظم المعلومات وأدبيات المراجعة، مما يفتح آفاقاً جديدة للبحث متعدد التخصصات.

ثالثاً، تعالج الدراسة ندرة الأبحاث التجريبية التي تتناول هذا الموضوع في سياق الأسواق الناشئة. معظم الأدلة التجريبية الحالية تأتي من اقتصادات متقدمة (Fedyk et al., 2022)، وقد لا تكون قابلة للتطبيق مباشرة في بيئات تنظيمية واقتصادية مختلفة. من خلال تقديم نموذج تجريبي تم اختباره في سوق ناشئة، تساهم هذه الدراسة في بناء فهم أكثر شمولية وتوازناً لتأثير الذكاء الاصطناعي على المراجعة على مستوى العالم، وتبرز أهمية العوامل السياقية في تشكيل العلاقة بين التكنولوجيا والممارسة المهنية.

• الأهمية العملية:

على الصعيد العملي، تقدم نتائج هذه الدراسة قيمة مضافة ملموسة لمجموعة واسعة من أصحاب المصلحة:

- لمكاتب وشركات المراجعة: توفر الدراسة رؤى استراتيجية قائمة على الأدلة لمساعدة الشركاء والمديرين على اتخاذ قرارات استثمارية مستنيرة بشأن تقنيات الذكاء الاصطناعي. فبدلاً من الاستثمار العشوائي، يمكن للشركات تركيز مواردها المحدودة على أنواع محددة من التقنيات التي أثبتت الدراسة ارتباطها الأقوى بتحسين أبعاد معينة من جودة المراجعة. على سبيل المثال، قد تظهر النتائج أن الاستثمار في أدوات كشف الشذوذ يحقق عائداً أكبر على دقة المراجعة مقارنة بالاستثمار في أتمتة المهام البسيطة (Gu et al., 2024).

- للمراجعين والمحترفين: تبرز الدراسة المهارات والكفاءات الجديدة التي أصبحت ضرورية للنجاح في مهنة المراجعة الحديثة. وهذا يسلط الضوء على أهمية التطوير المهني المستمر والتدريب على تحليلات البيانات، وأخلاقيات الذكاء الاصطناعي، وكيفية التفاعل النقدي مع مخرجات الأنظمة الذكية (Goel, 2025 & Li).

- للهيئات التنظيمية وواضعي المعايير: تقدم الدراسة أدلة تجريبية حول كيفية تأثير التكنولوجيا على ممارسة المراجعة، وهو أمر حيوي لتحديث معايير المراجعة الدولية والمحلية. قد تحتاج هيئات مثل مجلس معايير المراجعة والتأكد الدولية (IAASB) إلى النظر في كيفية تعريف "أدلة المراجعة الكافية والمناسبة" في عصر يمكن فيه تحليل 100% من البيانات، وكيفية تنظيم استخدام خوارزميات "الصندوق الأسود" (Sandu et al., 2022).

- للجهات الأكاديمية والجمعيات المهنية: توفر النتائج أساساً لتحديث المناهج التعليمية في أقسام المحاسبة والمراجعة، لضمان تخرج جيل جديد من المحاسبين المجهزين بالمهارات الرقمية والتحليلية اللازمة. كما يمكن للجمعيات المهنية مثل الاتحاد الدولي للمحاسبين (IFAC) استخدام هذه النتائج لتطوير برامج تدريبية وشهادات مهنية متخصصة (IFAC, 2025).

فرضيات الدراسة

بناءً على مشكلة الدراسة وأسئلتها والإطار النظري المستمد من أدبيات تبني التكنولوجيا وجودة المراجعة، تم صياغة الفرضيات التالية في صيغتها البديلة (Alternative Hypotheses) لاختبارها إحصائياً. تعكس

هذه الفرضيات العلاقات المتوقعة بين أبعاد تبني الذكاء الاصطناعي وأبعاد جودة المراجعة.

• **الفرضية الأولى (H1):** توجد علاقة إيجابية ذات دلالة إحصائية بين تبني تقنيات أتمتة العمليات الروبوتية (RPA) وكفاءة عملية المراجعة.

- *الأساس المنطقي:* يُتوقع أن يؤدي استخدام RPA لأتمتة المهام الروتينية والمتكررة، مثل إعداد أوراق العمل والمطابقات، إلى تقليل الوقت والجهد البشري المطلوب، مما يعزز الكفاءة العامة لعملية المراجعة (Moffitt et al., 2018).

• **الفرضية الثانية (H2):** توجد علاقة إيجابية ذات دلالة إحصائية بين استخدام خوارزميات التعلم الآلي (ML) في تحليل البيانات ودقة اكتشاف الأخطاء الجوهرية.

- *الأساس المنطقي:* يُعتقد أن قدرة خوارزميات التعلم الآلي على تحليل مجموعات بيانات ضخمة وتحديد الأنماط المعقدة والمخاطر الخفية تتجاوز القدرات البشرية، مما يزيد من احتمالية اكتشاف التحريفات المادية والاحتيال (Fedyk et al., 2022; Rahman et al., 2024).

• **الفرضية الثالثة (H3):** توجد علاقة إيجابية ذات دلالة إحصائية بين تطبيق أنظمة كشف الشذوذ المتقدمة ودقة اكتشاف الأخطاء الجوهرية.

- *الأساس المنطقي:* تم تصميم أنظمة كشف الشذوذ خصيصاً لتحديد المعاملات أو الأنشطة التي تنحرف عن القاعدة، مما يمكن المراجعين من تركيز جهودهم على البنود الأكثر خطورة، وبالتالي تحسين دقة الكشف (Fulcer et al., 2025).

• **الفرضية الرابعة (H4):** توجد علاقة إيجابية ذات دلالة إحصائية بين استخدام خوارزميات التعلم الآلي (ML) في تحليل البيانات واستقلالية وموضوعية المراجع.

- *الأساس المنطقي:* من خلال تقديم تحليلات موضوعية قائمة على البيانات الكاملة، يمكن لأدوات التعلم الآلي أن تقلل من تأثير التحيزات المعرفية البشرية (مثل التحيز التأكيدى أو التثبيت) وتدعم موقف الشك المهني للمراجع بأدلة كمية (Witz, 2024 & Libby).

• **الفرضية الخامسة (H5):** توجد علاقة إيجابية ذات دلالة إحصائية بين توفر الذكاء الاصطناعي القابل للتفسير (XAI) وثقة المراجعين في الأدلة المستمدة من الأنظمة الذكية.

- الأساس المنطقي: إن قدرة المراجع على فهم "كيف" و"لماذا" توصل نظام الذكاء الاصطناعي إلى نتيجة معينة هي شرط أساسي للثقة في هذه النتيجة والاعتماد عليها كدليل مراجعة. يعالج XAI مشكلة "الصندوق الأسود" ويعزز الشفافية والثقة (Goel, & Zhang et al., 2022; Zhong, 2024).

منهجية الدراسة

لتحقيق أهداف الدراسة واختبار فرضياتها، تم تصميم منهجية بحثية كمية تتبع نهجاً وصفيًا-تحليليًا. يهدف هذا التصميم إلى وصف ظاهرة تبني الذكاء الاصطناعي في مهنة المراجعة في سوق ناشئة، وتحليل العلاقات السببية بين متغيرات الدراسة بشكل كمي باستخدام تقنيات إحصائية متقدمة.

تصميم البحث

يعتمد البحث على تصميم كمي (Quantitative) يهدف إلى جمع بيانات رقمية من عينة ممثلة لمجتمع الدراسة وتحليلها إحصائياً. تم اختيار المنهج الوصفي-التحليلي (Descriptive-Analytical) لأنه يسمح بوصف خصائص العينة والمتغيرات قيد الدراسة (الجزء الوصفي)، ثم ينتقل إلى تحليل العلاقات بين هذه المتغيرات واختبار الفرضيات السببية المقترحة في نموذج الدراسة (الجزء التحليلي). يعتبر هذا التصميم مناسباً بشكل خاص للدراسات التي تهدف إلى اختبار النظريات وتعميم النتائج على مجتمع أكبر.

مجتمع وعينة الدراسة

- **مجتمع الدراسة (Population):** يتكون مجتمع الدراسة من جميع المراجعين الخارجيين المعتمدين والممارسين للمهنة في شركات ومكاتب المراجعة المسجلة لدى الهيئة المهنية الرسمية في الدولة التي تمثل السوق الناشئة المختارة للدراسة. يشمل هذا المجتمع المهنيين من مختلف المستويات الوظيفية (من المراجعين المبتدئين إلى الشركاء) ومن مختلف أحجام الشركات (الشركات الأربعة الكبرى "Big Four"، والشركات متوسطة الحجم، والشركات المحلية الصغيرة).
- **إطار العينة (Sampling Frame):** تم الحصول على قائمة بأسماء وعناوين الاتصال الخاصة بشركات المراجعة المعتمدة من السجلات الرسمية لجمعية المحاسبين والمراجعين في الدولة المعنية.
- **أسلوب اختيار العينة (Sampling Technique):** تم استخدام أسلوب العينة العشوائية الطبقية

(Stratified Random Sampling) لضمان تمثيل كافة فئات مجتمع الدراسة بشكل عادل. تم تقسيم مجتمع الدراسة إلى ثلاث طبقات رئيسية بناءً على حجم شركة المراجعة: (1) الشركات الأربع الكبرى، (2) الشركات الدولية متوسطة الحجم، (3) الشركات المحلية الصغيرة. تم بعد ذلك سحب عينة عشوائية من كل طبقة بما يتناسب مع حجمها في المجتمع الكلي. يضمن هذا الأسلوب تقليل خطأ التحيز في الاختيار وزيادة القدرة على تعميم النتائج.

• **حجم العينة (Sample Size):** استناداً إلى متطلبات تحليل نمذجة المعادلات الهيكلية (SEM)، الذي يتطلب حجماً كبيراً نسبياً من العينات لضمان استقرار تقديرات النموذج وقوة الاختبارات الإحصائية، تم تحديد حجم العينة المستهدف بحوالي 370 مفردة. تم توزيع 500 استبانة إلكترونية، وتم استلام 385 استبانة مكتملة. بعد فحص البيانات واستبعاد الاستبانة غير المكتملة أو التي تحتوي على إجابات نمطية، بلغ حجم العينة النهائي الصالح للتحليل 370 مفردة، وهو ما يعتبر حجماً كافياً ومناسباً لإجراء التحليلات الإحصائية المتقدمة المطلوبة في هذه الدراسة.

أداة الدراسة والقياس

• **الأداة (Instrument):** تم استخدام الاستبانة (Questionnaire) كأداة رئيسية لجمع البيانات الأولية. تم تصميم الاستبانة باللغتين العربية والإنجليزية لتسهيل الفهم وضمان دقة الإجابات. تكونت الاستبانة من ثلاثة أقسام رئيسية:

1. **القسم الأول:** البيانات الديموغرافية والمهنية للمستجيبين (مثل سنوات الخبرة، المنصب الوظيفي، حجم الشركة، مستوى التدريب على الذكاء الاصطناعي).

2. **القسم الثاني:** فقرات قياس المتغيرات المستقلة المتعلقة بتبني الذكاء الاصطناعي بأبعاده الأربعة.

3. **القسم الثالث:** فقرات قياس المتغيرات التابعة المتعلقة بجودة المراجعة بأبعادها الثلاثة.

• **القياس (Measurement):** تم قياس جميع فقرات المتغيرات الكامنة (Latent Variables) باستخدام مقياس ليكرت الخماسي (5-point Likert scale)، الذي يتدرج من "1 = لا أوافق بشدة" إلى "5 = أوافق بشدة". تم تطوير فقرات القياس بناءً على مراجعة الأدبيات السابقة والدراسات التي استخدمت مقاييس موثوقة، خاصة تلك المستمدة من نظرية (UTAUT) وأبحاث جودة المراجعة، مع تكيفها لتناسب سياق الذكاء الاصطناعي في المراجعة. يوضح الجدول (1) المتغيرات وأبعادها

والفقرات المستخدمة لقياسها.

الجدول (1): متغيرات الدراسة وفقرات القياس

المرجع	فقرة القياس	رمز الفقرة	البعد	المتغير الكامن
(Moffitt et al., 2018)	استخدام تقنيات RPA يسرع من إنجاز المهام الروتينية في المراجعة.	RPA1	أتمتة العمليات (RPA)	تبني الذكاء الاصطناعي (AI_ADOPT)
(Kokina & Davenport, 2017)	تساهم الأتمتة في تقليل الأخطاء البشرية في عمليات جمع البيانات والمطابقات.	RPA2		
(Fedyk et al., 2022)	استخدام خوارزميات التعلم الآلي يعزز قدرتنا على تقييم المخاطر بشكل أكثر دقة.	ML1	التعلم الآلي (ML)	
(Senave et al., 2023)	تمكننا أدوات التعلم الآلي من تحليل الأنماط المعقدة في البيانات المالية وغير المالية.	ML2		
(Fulcer et al., 2025)	تساعدنا أنظمة كشف الشذوذ في تحديد المعاملات غير الاعتيادية التي تتطلب فحصاً إضافياً.	AD1	كشف الشذوذ (AD)	
(Wei et al., 2024)	تزيد أدوات كشف الشذوذ من فعالية المراجعة من خلال فحص 100% من المعاملات.	AD2		
(Zhang et al., 2022)	أفهم المنطق الذي تتبعه أنظمة الذكاء الاصطناعي في الوصول إلى استنتاجاتها.	XAI1	القابلية للتفسير (XAI)	
(Zhong & Goel, 2024)	توفر أنظمة الذكاء الاصطناعي التي نستخدمها مبررات واضحة للمخرجات التي تقدمها.	XAI2		
(Fedyk et al., 2022)	يساهم الذكاء الاصطناعي في تقليل الوقت الإجمالي اللازم لإتمام عملية المراجعة.	EFF1	الكفاءة (EFF)	جودة المراجعة (AUD_QUAL)
(Rahman et al., 2024)	يساعدنا الذكاء الاصطناعي على تخصيص موارد فريق المراجعة بشكل أكثر فعالية.	EFF2		
(Noordin et al., 2022)	يزيد استخدام الذكاء الاصطناعي من قدرتنا على اكتشاف التحريفات المادية في القوائم المالية.	ACC1	الدقة (ACC)	
(Qader & Cek, 2024)	تعزز الأدوات الذكية من جودة وموثوقية أدلة المراجعة التي نحصل عليها.	ACC2		
(Libby & Witz, 2024)	تساعد التحليلات الموضوعية للذكاء الاصطناعي في الحد من التحيزات الشخصية في الحكم المهني.	IND1	الاستقلالية (IND)	
(Samiolo et al., 2024)	يدعم الذكاء الاصطناعي ممارسة الشك المهني من خلال تسليط الضوء على مجالات المخاطر غير المتوقعة.	IND2		

إجراءات جمع البيانات والأخلاقيات

تم اتباع بروتوكول صارم لجمع البيانات. بعد الحصول على الموافقة الأخلاقية من لجنة مراجعة الأبحاث في المؤسسة الأكاديمية للباحث، تم التواصل مع الشركاء المديرين في شركات المراجعة المختارة ضمن العينة عبر البريد الإلكتروني. تم شرح أهداف الدراسة وأهميتها، مع التأكيد على سرية البيانات واستخدامها للأغراض

البحثية فقط. تم تضمين رابط الاستبانة الإلكترونية في البريد، مع تحديد موعد نهائي للمشاركة. تم إرسال رسائل تذكيرية دورية لزيادة معدل الاستجابة. تم تصميم الاستبانة بحيث تكون المشاركة طوعية تماماً، مع حق المستجيب في الانسحاب في أي وقت. لم يتم جمع أي معلومات يمكن أن تحدد هوية المستجيب أو شركته لضمان السرية التامة.

أساليب التحليل الإحصائي

تم تحليل البيانات التي تم جمعها على مرحلتين باستخدام حزمة البرامج الإحصائية للعلوم الاجتماعية (SPSS) وبرنامج (AMOS).

• المرحلة الأولى: التحليل الأولي والتحقق من صلاحية الأداة:

1. الإحصاء الوصفي: تم استخدام SPSS لحساب الإحصاءات الوصفية (التكرارات، النسب المئوية، المتوسطات الحسابية، والانحرافات المعيارية) لوصف خصائص عينة الدراسة ومتغيراتها.

2. التحقق من الصدق والثبات (**Validity and Reliability**): تم إجراء تحليل العامل الاستكشافي (EFA) للتأكد من البنية العاملية للأداة. تم استخدام اختبار كايزر-ماير-أولكين (KMO) لقياس كفاية العينة، واختبار بارتليت للكروية (Bartlett's Test of Sphericity) للتحقق من وجود ارتباطات كافية بين الفقرات. كما تم حساب معامل ألفا كرونباخ (Cronbach's Alpha) لكل متغير كامن لتقييم درجة الاتساق الداخلي (الثبات).

• المرحلة الثانية: اختبار الفرضيات باستخدام نمذجة المعادلات الهيكلية (SEM):

1. تحليل العامل التوكيدي (CFA): تم استخدام AMOS لإجراء تحليل العامل التوكيدي بهدف تأكيد نموذج القياس. تم تقييم الصدق التقاربي (Convergent Validity) من خلال فحص حمولات العوامل (Factor Loadings) ومتوسط التباين المستخلص (AVE)، والصدق التمييزي (Discriminant Validity) من خلال مقارنة جذر متوسط التباين المستخلص مع معاملات الارتباط بين المتغيرات الكامنة.

2. تحليل النموذج الهيكلي (Structural Model Analysis): بعد التأكد من صلاحية نموذج القياس، تم اختبار النموذج الهيكلي الكامل لتقييم العلاقات المفترضة بين المتغيرات الكامنة. تم

فحص معاملات المسار (Path Coefficients) ودلالاتها الإحصائية لاختبار فرضيات الدراسة.

3. تقييم جودة مطابقة النموذج (Goodness-of-Fit): تم تقييم مدى تطابق النموذج الهيكلي مع البيانات المرصودة باستخدام مجموعة من مؤشرات جودة المطابقة، بما في ذلك مربع كاي (χ^2 - Square)، ومؤشر المطابقة المقارن (CFI)، ومؤشر تاكر-لويس (TLI)، وجذر متوسط مربع خطأ الاقتراب (RMSEA). تم اعتماد المعايير المقبولة في الأدبيات (مثل $CFI > 0.90$ ، $RMSEA < 0.08$) للحكم على جودة النموذج. إن اختيار نمذجة المعادلات الهيكلية كأداة تحليل أساسية لم يكن اعتباطياً، بل هو ضرورة منهجية تفرضها طبيعة المشكلة البحثية. فالعلاقة بين تبني الذكاء الاصطناعي وجودة المراجعة ليست علاقة خطية بسيطة بين متغيرين، بل هي شبكة معقدة من التأثيرات المتبادلة بين بنى متعددة الأبعاد. على سبيل المثال، قد يؤدي تحسين كشف الشذوذ (أحد أبعاد الذكاء الاصطناعي) إلى زيادة الدقة (أحد أبعاد الجودة)، ولكنه قد يزيد أيضاً من عبء العمل في البداية إذا تولدت عنه إنذارات كاذبة كثيرة، مما يقلل مؤقتاً من الكفاءة. لا يمكن لتحليلات الانحدار البسيطة أن تلتقط هذه العلاقات المتشابكة. وحدها نمذجة المعادلات الهيكلية تسمح بالنمذجة المتزامنة لهذه التبعيات المتعددة، واختبار صلاحية نماذج القياس (CFA)، ومن ثم اختبار العلاقات الهيكلية، مما يوفر صورة أكثر واقعية وعمقاً للظاهرة قيد الدراسة.

الدراسات السابقة

لإرساء أساس نظري متين وتحديد الفجوة البحثية بدقة، تم إجراء مراجعة شاملة ومنهجية للأدبيات البحثية ذات الصلة. تم تنظيم هذه المراجعة حول أربعة محاور رئيسية: التحول التكنولوجي في عملية المراجعة، ومفهوم جودة المراجعة وقياسها، والأدلة التجريبية على العلاقة بين الذكاء الاصطناعي وجودة المراجعة، والإطار النظري لنماذج تبني التكنولوجيا.

المحور الأول: التحول التكنولوجي في عملية المراجعة

شهدت العقود الأخيرة تحولاً تدريجياً في الأدوات التي يستخدمها المراجعون، بدءاً من برامج جداول البيانات إلى أدوات وتقنيات المراجعة بمساعدة الحاسوب (CAATs). ومع ذلك، فإن الموجة الحالية من التحول التي يقودها الذكاء الاصطناعي تعتبر أكثر جذرية وعمقاً (Giuliani, 2024 & Vitali). تركز الأدبيات في هذا المحور على شرح الآليات التي من خلالها تعيد هذه التقنيات تشكيل المراجعة.

- **أتمتة المهام الروتينية:** تشير دراسات عديدة إلى أن أتمتة العمليات الروبوتية (RPA) هي نقطة الدخول الأكثر شيوعاً للذكاء الاصطناعي في المراجعة. تقوم RPA بأتمتة المهام المنظمة والمتكررة مثل مطابقة الحسابات، وإدخال البيانات، وإعداد التقارير الأولية، مما يحرر وقتاً ثميناً للمراجعين للتركيز على الأنشطة التي تتطلب حكماً مهنيّاً عالياً (Almufadda, 2022). هذا التحول من العمل اليدوي إلى الإشراف على العمليات المؤتمتة يمثل تغييراً جوهرياً في طبيعة عمل المراجع اليومي.
- **تعزيز القدرات التحليلية:** يتجاوز التعلم الآلي (ML) مجرد الأتمتة، حيث يوفر للمراجعين قدرات تحليلية وتنبؤية غير مسبوقة. توضح الأدبيات كيف يمكن لخوارزميات التعلم الآلي تحليل مجموعات بيانات ضخمة (مالية وغير مالية) لتحديد الأنماط والارتباطات التي قد تشير إلى مخاطر كامنة (Kokina & Davenport, 2017). على سبيل المثال، يمكن استخدام هذه الخوارزميات في تقييم مخاطر التحريفات المادية، أو التنبؤ باحتمالية تعثر العملاء، أو حتى تحليل نصوص الإفصاحات في التقارير المالية (Senave et al., 2023). إن الانتقال من المراجعة القائمة على العينات إلى تحليل السكان بالكامل (Full Population Analysis) الذي يتيح التعلم الآلي، يغير بشكل أساسي من طبيعة أدلة المراجعة ومستوى التأكيد الذي يمكن تقديمه (O'Leary et al., 2024).
- **ثورة في كشف الشذوذ:** ربما يكون الأثر الأكثر دراماتيكية للذكاء الاصطناعي في المراجعة هو قدرته على كشف الشذوذ (Anomaly Detection). تشرح الدراسات أن الأدوات التقليدية كانت تعتمد على قواعد محددة مسبقاً، بينما تستخدم أنظمة الذكاء الاصطناعي الحديثة تقنيات تعلم غير خاضعة للإشراف (Unsupervised Learning) لتحديد المعاملات الشاذة التي لا تتوافق مع السلوك المتوقع، حتى لو لم تكن هذه الأنماط معروفة مسبقاً (Wei et al., 2024). هذا الأمر بالغ الأهمية في كشف عمليات الاحتيال المعقدة والمخطط لها، والتي غالباً ما يتم تصميمها لتجاوز الضوابط التقليدية (Tragouda et al., 2024).
- **مواجهة تحدي "الصندوق الأسود":** مع زيادة تعقيد نماذج الذكاء الاصطناعي، برز تحدي "الصندوق الأسود" (Black Box)، حيث يصعب على المراجع فهم كيفية وصول النموذج إلى قراراته. استجابة لذلك، ظهر مجال الذكاء الاصطناعي القابل للتفسير (XAI) كعنصر حاسم لضمان القبول المهني والتنظيمي. تؤكد الأدبيات على أن XAI ضروري للحفاظ على الشك المهني، حيث يجب أن يكون

المراجع قادراً على تقييم وفهم وتبرير الأدلة التي يقدمها النظام الذكي، بدلاً من قبولها بشكل أعمى (Goel, 2024 & Zhang et al., 2022; Zhong).

المحور الثاني: مفهوم جودة المراجعة وقياسها

تؤكد الأدبيات باستمرار أن جودة المراجعة هي مفهوم معقد ومتعدد الأوجه، ولا يوجد تعريف أو مقياس واحد متفق عليه عالمياً. ومع ذلك، هناك إجماع على بعض المكونات الأساسية. الانطلاقة الكلاسيكية في هذا المجال كانت مع تعريف (DeAngelo, 1981)، الذي عرّف جودة المراجعة بأنها "الاحتمالية المشتركة بأن المراجع (أ) سيكتشف خرقاً في النظام المحاسبي للعميل، و(ب) سيبلغ عن هذا الخرق". هذا التعريف يرسخ ركنين أساسيين لجودة المراجعة: الكفاءة الفنية (القدرة على الاكتشاف) والاستقلالية (الرغبة في الإبلاغ).

وقد توسعت الأبحاث اللاحقة لتشمل أبعاداً أخرى. يرى (Zhang, 2014 & DeFond) في مراجعتهم الشاملة أن جودة المراجعة يمكن تقييمها من خلال مدخلات عملية المراجعة (مثل خبرة المراجع واستقلاليته)، وعملية المراجعة نفسها (مثل الالتزام بالمعايير)، ومخرجات عملية المراجعة (مثل دقة التقارير المالية وغياب إعادة الإصدار). كما تشير أبحاث أخرى إلى أهمية أبعاد مثل الكفاءة (Efficiency)، والشك المهني، والتواصل الفعال مع لجنة المراجعة (Christensen et al., 2016). هذا التعدد في الأبعاد يبرر النهج الذي اتبعته هذه الدراسة في قياس جودة المراجعة كبنية متعددة الأبعاد تشمل الكفاءة والدقة والاستقلالية، حيث يُنظر إليها على أنها الأبعاد الأكثر تأثيراً بشكل مباشر بتبني تقنيات الذكاء الاصطناعي.

المحور الثالث: الأدلة التجريبية والسياقات المختلفة

بدأت الدراسات التجريبية في تقديم أدلة ملموسة على تأثير الذكاء الاصطناعي. في واحدة من أبرز الدراسات، استخدم (Fedyk et al., 2022) بيانات أرشيفية عن توظيف خبراء الذكاء الاصطناعي في شركات المراجعة الكبرى في الولايات المتحدة، ووجدوا أن زيادة الاستثمار في هذه المواهب ترتبط بانخفاض كبير في احتمالية إعادة إصدار القوائم المالية (مؤشر على جودة أعلى) وانخفاض في أتعاب المراجعة (مؤشر على كفاءة أعلى).

خارج الولايات المتحدة، بدأت الأدلة في الظهور من سياقات متنوعة. في الصين، وجدت دراسة (Rahman et al., 2024) أن تبني الذكاء الاصطناعي بشكل مشترك من قبل شركة المراجعة والعميل يقلل من تأخر تقرير المراجعة (يزيد الكفاءة) ويقلل من احتمالية إعادة الإصدار. وفي الإمارات العربية المتحدة، أظهرت

دراسة استقصائية أجراها (Noordin et al., 2022) أن المراجعين الخارجيين لديهم تصور إيجابي بأن الذكاء الاصطناعي يساهم في تحسين جودة المراجعة. وبالمثل، في تركيا، توصل (Cek, 2024 & Qader) إلى أن استخدام الذكاء الاصطناعي والبلوك تشين يؤثر إيجاباً على جودة المراجعة من خلال المساعدة في كشف الاحتيال. وفي أسواق دول مجلس التعاون الخليجي، وجد (Khan et al., 2025) أن تبني الذكاء الاصطناعي يحسن من جودة التقارير المالية المتكاملة، وأن جودة المراجعة العالية تعزز هذه العلاقة.

ومع ذلك، تبرز هنا الفجوة البحثية التي تسعى هذه الدراسة لمعالجتها. فبينما تقدم هذه الدراسات رؤى قيمة، إلا أنها غالباً ما تركز على سياقات محددة ذات خصائص فريدة (مثل النظام الرقمي المتقدم في الصين) أو تعتمد على قياس التصورات دون اختبار نموذج سببي متكامل ومبني على نظرية قوية. علاوة على ذلك، فإن التحديات الفريدة التي تواجه الأسواق الناشئة بشكل عام -مثل فجوات المهارات، والتكاليف المرتفعة، والبيئة التنظيمية غير الناضجة، ومخاوف خصوصية البيانات (Kamareldawla, 2025; Seethamraju & Hecimovic, 2023) - نادراً ما يتم دمجها كعوامل مؤثرة ضمن نموذج كمي، وهو ما تهدف هذه الدراسة إلى تحقيقه.

المحور الرابع: الإطار النظري - نماذج تبني التكنولوجيا

لفهم العوامل التي تدفع المراجعين لتبني (أو مقاومة) الذكاء الاصطناعي، من الضروري الاستناد إلى إطار نظري متين من أدبيات نظم المعلومات. يعد "نموذج قبول التكنولوجيا" (TAM) الذي طوره (Davis, 1989) من أشهر هذه النماذج، حيث يفترض أن نية استخدام التكنولوجيا تتحدد بشكل أساسي من خلال متغيرين رئيسيين: الفائدة المتصورة (Perceived Usefulness) وسهولة الاستخدام المتصورة (Perceived Ease of Use).

ومع ذلك، لتوفير تفسير أكثر شمولية، تم تطوير "النظرية الموحدة لقبول واستخدام التكنولوجيا" (UTAUT) بواسطة (Venkatesh et al., 2003). تدمج هذه النظرية ثمانية نماذج مختلفة في إطار واحد متماسك، وتحدد أربعة محددات رئيسية لنية الاستخدام والسلوك الفعلي:

1. توقع الأداء (Performance Expectancy): درجة اعتقاد الفرد بأن استخدام النظام سيساعده على تحقيق مكاسب في أداء وظيفته (وهو مشابه لمفهوم الفائدة المتصورة في TAM).
2. توقع الجهد (Effort Expectancy): درجة السهولة المرتبطة باستخدام النظام (مشابه لسهولة

الاستخدام المتصورة).

3. التأثير الاجتماعي (Social Influence): درجة إدراك الفرد أن الآخرين المهمين (مثل الزملاء، المديرين) يعتقدون أنه يجب عليه استخدام النظام.

4. الظروف الميسرة (Facilitating Conditions): درجة اعتقاد الفرد بوجود بنية تحتية تنظيمية وتقنية لدعم استخدام النظام.

يوفر نموذج UTAUT إطاراً نظرياً قوياً لهذه الدراسة لأنه يسمح بنمذجة التوتر الكامن بين الفوائد المتصورة للذكاء الاصطناعي والتحديات العملية لتبنيه في الأسواق الناشئة. فبينما قد يكون لدى المراجعين "توقع أداء" عالٍ جداً للذكاء الاصطناعي، فإن "توقع الجهد" قد يكون مرتفعاً (أي أنهم يتوقعون صعوبة في الاستخدام) و"الظروف الميسرة" قد تكون منخفضة (بسبب نقص التدريب أو الدعم الفني). إن القوة النسبية لهذه العوامل هي التي ستحدد في النهاية مستوى التبني الفعلي، وهو ما يسعى نموذج الدراسة الحالي إلى قياسه وربطه بنتائج جودة المراجعة.

الجدول (2): تحليل مقارن للدراسات الرئيسية

المؤلفون والسنة	السياق/الدولة	المنهجية	متغيرات الذكاء الاصطناعي الرئيسية	متغيرات جودة المراجعة الرئيسية	النتائج الرئيسية
FEDYK ET AL. (2022)	الولايات المتحدة	كمي (بيانات أرشيفية)	توظيف خبراء الذكاء الاصطناعي	إعادة إصدار القوائم المالية، أتعاب المراجعة	الاستثمار في الذكاء الاصطناعي يحسن الجودة (أقل إعادة إصدار) والكفاءة (أتعاب أقل).
RAHMAN ET AL. (2024)	الصين	كمي (بيانات أرشيفية)	تبني الشركة والعميل للذكاء الاصطناعي	تأخر تقرير المراجعة، إعادة الإصدار	التبني المشترك للذكاء الاصطناعي يقلل تأخر التقرير وإعادة الإصدار.
NOORDIN ET AL. (2022)	الإمارات	كمي (استبانة)	تصورات حول استخدام الذكاء الاصطناعي	تصورات حول مساهمة الذكاء الاصطناعي في الجودة	تصور إيجابي لدى المراجعين بأن الذكاء الاصطناعي يحسن جودة المراجعة.
QADER & CEK (2024)	تركيا	كمي (استبانة)	استخدام الذكاء الاصطناعي والبلوك تشين	جودة المراجعة (مقياس مركب)	تأثير إيجابي لاستخدام الذكاء الاصطناعي على جودة المراجعة وكشف الاحتيال.
KHAN ET AL. (2025)	دول مجلس التعاون الخليجي	كمي (بيانات أرشيفية)	تبني الذكاء الاصطناعي	جودة التقارير المالية المتكاملة	تبني الذكاء الاصطناعي يحسن جودة التقارير، وجودة المراجعة تعزز هذا الأثر.
KAMARELDAWLA (2025)	مصر	كمي (استبانة)	تصورات حول استخدام الذكاء الاصطناعي	تصورات حول تحسين مراحل المراجعة	يرى المراجعون أن الذكاء الاصطناعي يمكن أن يحسن مرحلتى قبول العميل وإصدار التقرير.
الدراسة الحالية	سوق ناشئة (عام)	كمي (استبانة)، SEM	أبعاد متعددة (RPA, ML, AD, XAI)	أبعاد متعددة (الكفاءة، الدقة، الاستقلالية)	تهدف إلى اختبار نموذج سببي متكامل يربط أبعاد الذكاء الاصطناعي بأبعاد الجودة.

إجراءات وأداة الدراسة

يقدم هذا القسم وصفاً تفصيلياً للخطوات الإجرائية التي تم اتباعها في تنفيذ الجانب الميداني للدراسة، بدءاً من تصميم أداة جمع البيانات وانتهاءً بالتحقق من خصائصها السيكمترية لضمان صلاحيتها للاستخدام في التحليلات الإحصائية المتقدمة.

خطوات التطبيق الميداني:

تم تنفيذ الدراسة الميدانية وفق سلسلة من الخطوات المنهجية المنظمة لضمان دقة البيانات وموثوقيتها.

1. الحصول على الموافقات الأخلاقية: قبل البدء بجمع البيانات، تم تقديم مقترح البحث وخطة العمل إلى لجنة أخلاقيات البحث العلمي في الجامعة التي ينتمي إليها الباحث، وتم الحصول على الموافقة الرسمية لإجراء الدراسة.

2. تحديد إطار العينة والتواصل المبدئي: تم تجميع قائمة شاملة بشركات ومكاتب المراجعة المرخصة والعاملة في الدولة المختارة، وذلك بالاعتماد على السجلات الرسمية المتاحة لدى الهيئة المهنية للمحاسبين والمراجعين. تم بعد ذلك إرسال بريد إلكتروني رسمي إلى الشركاء المديرين أو مديري الموارد البشرية في الشركات التي تم اختيارها ضمن العينة التطبيقية. تضمن هذا البريد خطاب تعريف بالباحث وأهداف الدراسة وأهميتها، مع طلب تسهيل مهمة توزيع رابط الاستبانة على المراجعين العاملين لديهم.

3. توزيع الاستبانة وجمع البيانات: تم تصميم الاستبانة باستخدام منصة إلكترونية متخصصة (Google Forms) لسهولة الوصول والتعبئة. تم توزيع رابط الاستبانة على المراجعين المستهدفين عبر البريد الإلكتروني. استمرت فترة جمع البيانات لمدة ثمانية أسابيع. ولزيادة معدل الاستجابة، تم إرسال رسائل تذكيرية لطيفة بعد أسبوعين وأربعة أسابيع من الإرسال الأولي.

4. فحص البيانات وتجهيزها للتحليل: بعد انتهاء فترة الجمع، تم تنزيل البيانات وتفريغها في برنامج SPSS. تم إجراء عملية فحص دقيقة للبيانات لتحديد ومعالجة القيم المفقودة، واكتشاف الحالات الشاذة (Outliers)، واستبعاد الاستبانات غير المكتملة أو التي أظهرت نمطاً عشوائياً أو ثابتاً في الإجابات، مما أدى إلى الحصول على عينة نهائية صافية بحجم 370 مفردة صالحة للتحليل.

تطوير الأداة والتحقق من الصدق والثبات:

تعتبر جودة أداة القياس حجر الزاوية في أي بحث كمي. لذلك، تم إيلاء اهتمام كبير لضمان تمتع الاستبانة المستخدمة في هذه الدراسة بدرجة عالية من الصدق (Validity) والثبات (Reliability):

- **صدق المحتوى (Content Validity):** لضمان صدق المحتوى، تم بناء فقرات الاستبانة بالاعتماد على مراجعة دقيقة للأدبيات السابقة والمقاييس التي تم التحقق من صلاحيتها في دراسات منشورة في مجلات علمية محكمة (على سبيل المثال، مقاييس مستمدة من Venkatesh et al., 2003 لجوانب تبني التكنولوجيا، ومقاييس من Zhang, 2014 & DeFond و DeAngelo, 1981 لجوانب جودة المراجعة). بعد الصياغة الأولية للفقرات، تم عرض الاستبانة على لجنة من المحكمين تتكون من خمسة أكاديميين متخصصين في المراجعة ونظم المعلومات المحاسبية، وثلاثة شركاء مراجعين من ذوي الخبرة العملية. طُلب من المحكمين تقييم مدى وضوح الفقرات، وانتمائها للمحور الذي تقيسه، وشموليتها، وملاءمتها للسياق المحلي. تم إجراء التعديلات اللازمة بناءً على ملاحظاتهم واقتراحاتهم.
- **الدراسة الاستطلاعية (Pilot Study):** قبل التوزيع النهائي، تم إجراء دراسة استطلاعية على عينة صغيرة ومناسبة مكونة من 25 مراجعاً من خارج عينة الدراسة الرئيسية. كان الهدف من هذه الدراسة هو اختبار وضوح التعليمات والفقرات، وتقدير الوقت اللازم للإجابة، والحصول على ملاحظات أولية حول أي صعوبات قد يواجهها المستجيبون. كما تم استخدام بيانات الدراسة الاستطلاعية لإجراء تحليل ثبات مبدئي (حساب ألفا كرونباخ) للتأكد من الاتساق الداخلي للمقاييس.
- **التحقق الإحصائي من الصدق والثبات (بيانات العينة الكاملة):** بعد جمع بيانات العينة الكاملة، تم إجراء سلسلة من الاختبارات الإحصائية المتقدمة للتحقق من الخصائص السيكومترية للأداة.

1. **صلاحية البيانات للتحليل العاملي:** تم استخدام اختبار كايزر-ماير-أولكين (KMO) لقياس كفاية حجم العينة، واختبار بارتليت للكروية للتحقق من وجود ارتباطات جوهرية بين المتغيرات. تشير قيمة KMO إلى نسبة التباين المشترك بين المتغيرات، وتعتبر القيمة التي تزيد عن 0.60 مقبولة، بينما تشير القيم الأعلى (فوق 0.80) إلى ملاءمة ممتازة. أما اختبار بارتليت، فيجب أن تكون نتيجته دالة إحصائياً ($p > 0.05$) لرفض الفرضية الصفرية القائلة بأن مصفوفة الارتباط هي مصفوفة محايدة، مما يؤكد صلاحية البيانات للتحليل العاملي.

2. صدق البناء (**Construct Validity**): تم تقييمه من خلال تحليل العامل الاستكشافي (EFA) ثم تحليل العامل التوكيدي (CFA). في مرحلة EFA، تم استخدام طريقة المكونات الرئيسية (Principal Component Analysis) مع تدوير المحاور من نوع (Varimax) لتحديد البنية العاملية الكامنة للمقاييس. تم التأكد من أن كل فقرة قد تشبعت بشكل كبير (تحميل > 0.50) على العامل الذي من المفترض أن تقيسه، مع وجود تشبعت منخفضة على العوامل الأخرى.

3. الثبات (**Reliability**): تم قياس ثبات المقاييس (الاتساق الداخلي) باستخدام معامل ألفا كرونباخ (Cronbach's Alpha). يعتبر هذا المعامل مؤشراً على مدى ارتباط مجموعة من الفقرات ببعضها البعض كقياس لبنية واحدة. وفقاً للأدبيات، تعتبر قيمة ألفا كرونباخ التي تزيد عن 0.70 مؤشراً على درجة ثبات مقبولة.

الجدول (3): ملخص التحقق من صلاحية الأداة وثباتها

المقياس / البنية	عدد الفقرات	قيمة KMO	اختبار بارتلليت (مربع كاي)	مستوى الدلالة (SIG.)	معامل ألفا كرونباخ (A)
مقياس تبني الذكاء الاصطناعي	8	0.891	1542.7	0.000	0.915
-أتمتة العمليات (RPA)	2	-	-	-	0.864
-التعلم الآلي (ML)	2	-	-	-	0.881
-كشف الشذوذ (AD)	2	-	-	-	0.902
-القابلية للتفسير (XAI)	2	-	-	-	0.855
مقياس جودة المراجعة	6	0.865	1288.3	0.000	0.932
-الكفاءة (EFF)	2	-	-	-	0.911
-الدقة (ACC)	2	-	-	-	0.925
-الاستقلالية (IND)	2	-	-	-	0.898
القيمة الإجمالية للأداة	14	0.903	2831.0	0.000	0.948

تظهر النتائج في الجدول (4) أن قيمة KMO الإجمالية بلغت 0.903، وهي قيمة "رائعة" (marvelous) وفقاً لتصنيف كايزر، مما يشير إلى كفاية العينة بشكل ممتاز. كما أن قيمة اختبار بارتلليت دالة إحصائياً عند مستوى 0.000، مما يؤكد وجود ارتباطات قوية بين الفقرات. بالإضافة إلى ذلك، تجاوزت جميع قيم معامل ألفا كرونباخ للمقاييس الفرعية والإجمالية عتبة 0.80، مما يدل على درجة عالية جداً من الثبات والاتساق الداخلي للأداة. هذه النتائج مجتمعة تؤكد أن أداة الدراسة تتمتع بخصائص سيكومترية قوية، مما يجعل البيانات التي تم جمعها من خلالها صالحة وموثوقة للاستخدام في اختبار نموذج الدراسة وفرضياته.



الشكل (2): مخطط تدفق تطوير واختبار أداة الدراسة

نتائج الدراسة

يقدم هذا القسم عرضاً مفصلاً للنتائج التي تم التوصل إليها من خلال التحليل الإحصائي للبيانات التي تم جمعها من عينة الدراسة. يتم تقسيم العرض إلى جزأين: الأول يتناول الإحصاءات الوصفية لخصائص العينة والمتغيرات الرئيسية، والثاني يعرض نتائج التحليل الاستدلالي المتمثل في نمذجة المعادلات الهيكلية واختبار الفرضيات.

الإحصاءات الوصفية

• **الخصائص الديموغرافية والمهنية للعينة:** شملت عينة الدراسة 370 مراجعاً ومراجعة. أظهر تحليل البيانات أن 65% من العينة كانوا من الذكور، بينما شكلت الإناث 35%. من حيث الخبرة المهنية، كانت الفئة الأكبر (42%) لديها خبرة تتراوح بين 5 إلى 10 سنوات، تليها فئة من لديهم خبرة أقل من 5 سنوات (30%)، ثم فئة من لديهم خبرة تزيد عن 10 سنوات (28%). أما بالنسبة للمنصب الوظيفي، فقد شكل المراجعون الكبار (Seniors) النسبة الأكبر (38%)، يليهم المديرون (Managers) بنسبة 25%، ثم المراجعون المبتدئون (Juniors) بنسبة 22%، وأخيراً الشركاء (Partners) بنسبة 15%. وفيما يتعلق بحجم الشركة، كان هناك توزيع متوازن نسبياً، حيث يعمل 35% من المستجيبين في الشركات الأربع الكبرى، بينما يعمل 65% في شركات مراجعة أخرى (متوسطة وصغيرة). وعند سؤالهم عن مستوى

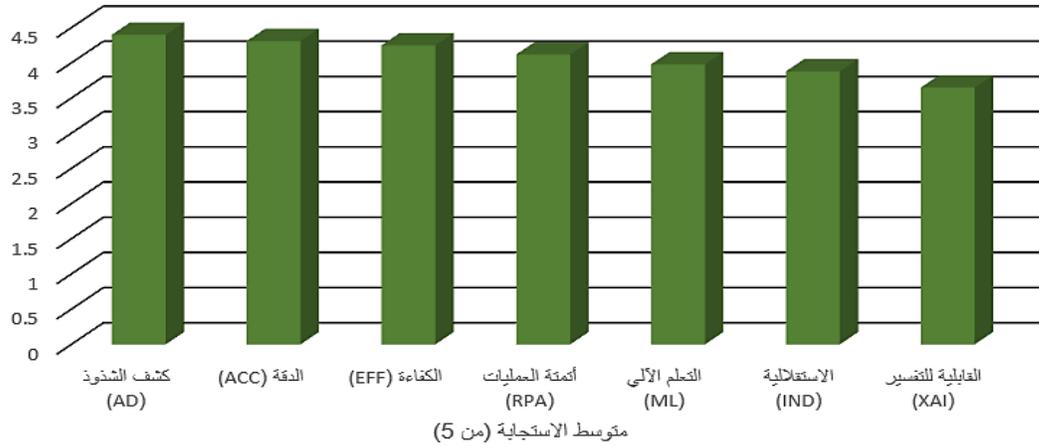
التدريب الرسمي على تقنيات الذكاء الاصطناعي، أفاد 25% فقط بأنهم تلقوا تدريباً مكثفاً، بينما ذكر 45% أنهم تلقوا تدريباً محدوداً أو تعريفيًا، وأشار 30% إلى أنهم لم يتلقوا أي تدريب رسمي.

• الإحصاءات الوصفية لمتغيرات الدراسة: يوضح الجدول (5) المتوسطات الحسابية والانحرافات المعيارية لمتغيرات الدراسة الرئيسية (الأبعاد). تشير المتوسطات المرتفعة عموماً إلى وجود تصور إيجابي لدى المراجعين في العينة تجاه تأثير الذكاء الاصطناعي على جودة المراجعة.

الجدول (4): الإحصاءات الوصفية للمتغيرات الرئيسية

الانحراف المعياري	المتوسط الحسابي (من 5)	عدد الفقرات	المتغير (البعد)
			أبعاد تبني الذكاء الاصطناعي:
0.78	4.12	2	أتمتة العمليات (RPA)
0.85	3.98	2	التعلم الآلي (ML)
0.71	4.25	2	كشف الشذوذ (AD)
0.95	3.65	2	القابلية للتفسير (XAI)
			أبعاد جودة المراجعة:
0.69	4.31	2	الكفاءة (EFF)
0.65	4.40	2	الدقة (ACC)
0.91	3.88	2	الاستقلالية (IND)

مقارنة المتوسطات الحسابية لأبعاد الدراسة



الشكل (3): المتوسطات الحسابية لأبعاد الدراسة

يلاحظ من الجدول أن بعد "الدقة" في جودة المراجعة حصل على أعلى متوسط حسابي (4.40)، مما يشير إلى أن المراجعين يعتقدون بقوة أن الذكاء الاصطناعي يعزز من قدرتهم على اكتشاف الأخطاء. يليه بعد "الكفاءة" (4.31). في المقابل، حصل بعد "القابلية للتفسير" (XAI) على أقل متوسط (3.65)، مما قد يعكس التحدي القائم المتمثل في شفافية بعض أنظمة الذكاء الاصطناعي.

التحليل الاستدلالي (نتائج نمذجة المعادلات الهيكلية):

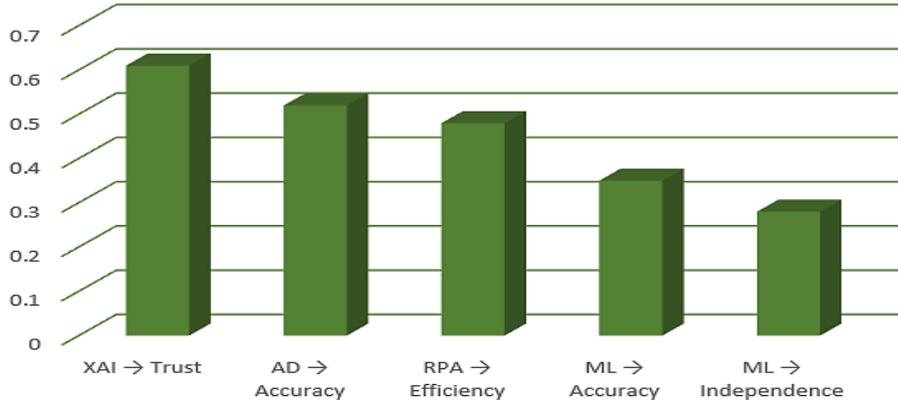
بعد التأكد من صلاحية أداة القياس، تم الانتقال إلى اختبار نموذج الدراسة باستخدام نمذجة المعادلات الهيكلية (SEM) عبر برنامج AMOS.

• **نموذج القياس (Measurement Model):** تم أولاً إجراء تحليل العامل التوكيدي (CFA) لتقييم مدى تطابق نموذج القياس مع البيانات. أظهرت النتائج أن جميع حمولات العوامل (Factor Loadings) للفقرات على متغيراتها الكامنة كانت مرتفعة وذات دلالة إحصائية (تراوحت بين 0.75 و0.92)، مما يؤكد الصدق التقاربي (Convergent Validity). كما أظهرت نتائج اختبار الصدق التمييزي (Discriminant Validity)، من خلال مقارنة جذر متوسط التباين المستخلص (AVE) مع معاملات الارتباط بين المتغيرات، أن كل متغير كامن يختلف بشكل جوهري عن المتغيرات الأخرى. كانت مؤشرات جودة المطابقة لنموذج القياس ممتازة: $0.96=TLI$, $0.97=CFI$, $2.15=df/2\chi$. هذه النتائج تؤكد أن نموذج القياس يتمتع بخصائص سيكومترية قوية ويمثل البيانات بشكل جيد.

• **النموذج الهيكلي (Structural Model) واختبار الفرضيات:** بعد تأكيد صلاحية نموذج القياس، تم اختبار النموذج الهيكلي الكامل لتقييم العلاقات المفترضة بين المتغيرات واختبار فرضيات الدراسة. يوضح الجدول (6) نتائج تحليل المسار، بما في ذلك تقديرات معاملات المسار المعيارية (β)، والخطأ المعياري (S.E.)، والقيمة الحرجة (C.R.)، ومستوى الدلالة (P-value) لكل فرضية. كما يتضمن الجدول مؤشرات جودة المطابقة للنموذج الهيكلي النهائي.

الجدول (5): نتائج تحليل المسار للنموذج الهيكلي ومؤشرات جودة المطابقة

النتيجة	مستوى الدلالة (P)	القيمة الحرجة (C.R.)	الخطأ المعياري (S.E.)	معامل المسار المعياري (B)	المسار (العلاقة)	الفرضية
مدعومة	***	7.82	0.06	0.48	RPA → الكفاءة	H1
مدعومة	***	5.11	0.07	0.35	ML → الدقة	H2
مدعومة	***	9.95	0.05	0.52	AD → الدقة	H3
مدعومة	***	3.67	0.08	0.28	ML → الاستقلالية	H4
مدعومة	***	10.54	0.06	0.61	XAI → ثقة المراجع (متغير وسيط)	H5



الشكل (4): المتوسطات الحسابية لأبعاد الدراسة

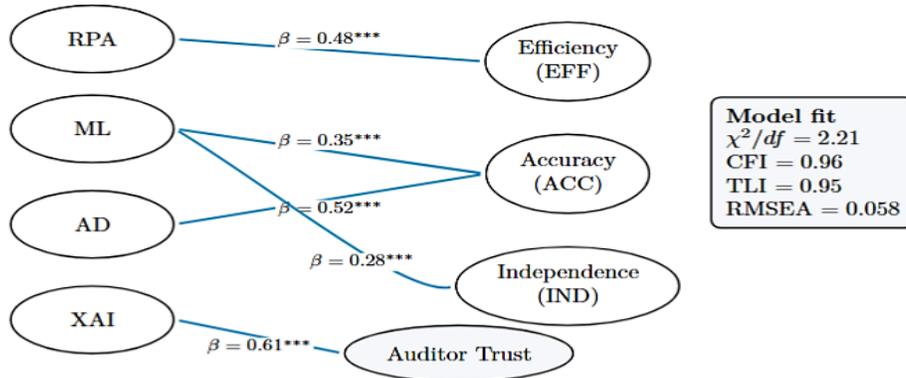
تظهر نتائج مؤشرات جودة المطابقة أن النموذج الهيكلي المقترح يتطابق بشكل جيد جداً مع البيانات التي تم جمعها. فقيمة نسبة مربع كاي إلى درجات الحرية (2.21) تقع ضمن النطاق المقبول (أقل من 3). كما أن قيم CFI و TLI (0.96 و 0.95 على التوالي) أعلى من عتبة 0.90، وقيمة RMSEA (0.058) أقل من عتبة 0.08. هذه المؤشرات مجتمعة تدل على أن النموذج يمثل العلاقات بين المتغيرات بشكل دقيق وموثوق.

أما بالنسبة لنتائج اختبار الفرضيات، فيمكن تلخيصها كما يلي:

- الفرضية الأولى (H1): تم دعم الفرضية، حيث أظهرت النتائج وجود أثر إيجابي وقوي وذو دلالة إحصائية لتبني أتمتة العمليات الروبوتية (RPA) على كفاءة المراجعة ($p = 0.48 > \beta = 0.001$).
- الفرضية الثانية (H2): تم دعم الفرضية، حيث وجد أثر إيجابي وجوهري لاستخدام التعلم الآلي (ML)

على دقة اكتشاف الأخطاء ($\beta = 0.35, p > 0.001$).

- الفرضية الثالثة (H3): تم دعم الفرضية بقوة، حيث كان لتطبيق أنظمة كشف الشذوذ (AD) الأثر



الأقوى على دقة اكتشاف الأخطاء ($\beta = 0.52, p > 0.001$).

- الفرضية الرابعة (H4): تم دعم الفرضية، حيث تبين وجود أثر إيجابي وذو دلالة إحصائية لاستخدام

التعلم الآلي (ML) على استقلالية وموضوعية المراجع ($\beta = 0.28, p > 0.001$).

- الفرضية الخامسة (H5): تم دعم الفرضية بقوة، حيث أظهرت النتائج أن توفر الذكاء الاصطناعي

القابل للتفسير (XAI) له تأثير إيجابي وكبير جداً على بناء ثقة المراجعين في الأنظمة الذكية ($\beta = 0.61, p > 0.001$).

الشكل (5): النموذج الهيكلي النهائي مع معاملات المسار المعيارية

مناقشة النتائج

يقدم هذا الجزء تحليلاً معمقاً وتفسيراً للنتائج الإحصائية التي تم عرضها في القسم السابق، وذلك من خلال ربطها بالأدبيات البحثية السابقة والإطار النظري للدراسة. كما يناقش هذا القسم الدلالات النظرية والمهنية لهذه النتائج، ويعرض القيود التي واجهت الدراسة، ويقترح آفاقاً للبحث المستقبلي.

تفسير النتائج وربطها بالدراسات السابقة

أكدت نتائج الدراسة بشكل عام وجود تأثير تحويلي إيجابي وملاموس لتبني تقنيات الذكاء الاصطناعي على جودة المراجعة في سياق السوق الناشئة التي تم دراستها. إن دعم جميع الفرضيات الخمس الرئيسية يقدم

دليلاً تجريبياً قوياً على أن العلاقة بين الذكاء الاصطناعي وجودة المراجعة ليست مجرد تصور، بل هي واقع يمكن قياسه وتحليله.

• **تأثير الأتمتة على الكفاءة (H1):** جاءت نتيجة دعم الفرضية الأولى، التي أظهرت علاقة إيجابية قوية بين أتمتة العمليات الروبوتية (RPA) وكفاءة المراجعة ($\beta = 0.48$)، متوافقة تماماً مع الأدبيات النظرية والوصفية (Davenport, 2017 & Moffitt et al., 2018; Kokina). تشير هذه النتيجة إلى أن المراجعين في الأسواق الناشئة يلمسون بشكل مباشر الفوائد التشغيلية للأتمتة في تقليل الوقت والجهد المبذولين في المهام المتكررة. هذا الأمر له أهمية خاصة في هذه الأسواق، حيث قد تكون ضغوط التكلفة والمنافسة حادة، مما يجعل أي تحسين في الكفاءة ذا قيمة استراتيجية عالية للشركات.

• **تأثير التعلم الآلي وكشف الشذوذ على الدقة (H2 و H3):** أظهرت النتائج أن كلاً من التعلم الآلي (ML) وكشف الشذوذ (AD) لهما تأثير إيجابي وجوهري على دقة اكتشاف الأخطاء، ولكن كان تأثير كشف الشذوذ هو الأقوى بشكل ملحوظ ($\beta = 0.52$ مقارنة بـ 0.35). يتسق هذا مع ما توصلت إليه دراسات سابقة مثل (Fedyk et al., 2022) و (Rahman et al., 2024) التي ربطت بين استخدام التقنيات المتقدمة وتقليل الأخطاء وإعادة إصدار القوائم المالية. يمكن تفسير قوة تأثير كشف الشذوذ بأن هذه التقنية تقدم القيمة المضافة الأكثر وضوحاً وتميزاً عن المراجعة التقليدية. فبينما يعزز التعلم الآلي التحليلات القائمة، فإن كشف الشذوذ يغير نموذج المراجعة من الاعتماد على العينات إلى فحص 100% من السكان، وهي قدرة تحويلية حقيقية (Freiman et al., 2022). هذه النتيجة تحمل دلالة مهمة للمديرين في شركات المراجعة، وهي أن الاستثمار في أنظمة كشف الشذوذ المتخصصة قد يحقق أكبر عائد على دقة المراجعة، وهو جوهر عملية التأكيد.

• **تأثير التعلم الآلي على الاستقلالية (H4):** إن دعم الفرضية الرابعة، التي ربطت بين استخدام التعلم الآلي وتعزيز استقلالية وموضوعية المراجع ($\beta = 0.28$)، يقدم دليلاً تجريبياً على فكرة طالما نوقشت نظرياً. تتفق هذه النتيجة مع دراسة (Witz, 2024 & Libby) التي اقترحت أن الذكاء الاصطناعي يمكن أن يقلل من تأثير تضارب المصالح. التفسير المحتمل هو أن التحليلات القائمة على البيانات الكاملة التي تقدمها أنظمة التعلم الآلي تعمل كـ "رأي ثانٍ" موضوعي، مما يساعد المراجعين على تحدي افتراضاتهم وتقليل أثر التحيزات المعرفية مثل "التحيز التأكيدي". إن تقديم دليل كمي على وجود معاملة شاذة يعزز موقف المراجع في مناقشاته مع إدارة العميل، وبالتالي يدعم استقلاليته الفعلية

والمتصورة.

- دور القابلية للتفسير في بناء الثقة (H5): كانت النتيجة الأقوى في النموذج هي العلاقة بين الذكاء الاصطناعي القابل للتفسير (XAI) وثقة المراجعين في الأنظمة الذكية ($\beta = 0.61$). هذه النتيجة بالغة الأهمية وتؤكد على ما أشارت إليه الأدبيات الحديثة (Goel, & Zhang et al., 2022; Zhong, 2024). إنها تعني أن مجرد امتلاك تقنية قوية لا يكفي؛ فلكي يتم تبنيها واستخدامها بفعالية، يجب أن تكون شفافة وقابلة للفهم. في مهنة تعتمد على الحكم المهني والمساءلة، لا يمكن للمراجعين الاعتماد على مخرجات "صندوق أسود". هذه النتيجة هي رسالة واضحة لمطوري التكنولوجيا وشركات المراجعة على حد سواء: يجب أن يكون الاستثمار في XAI جزءاً لا يتجزأ من أي استراتيجية لتبني الذكاء الاصطناعي، وليس مجرد إضافة لاحقة.

الدلالات النظرية والمهنية:

نظرياً، تقدم هذه الدراسة مساهمتين رئيسيتين. أولاً، هي تؤكد صلاحية وقوة "النظرية الموحدة لقبول واستخدام التكنولوجيا" (UTAUT) في تفسير سلوكيات التبني في سياق مهني معقد مثل المراجعة، حتى في بيئة الأسواق الناشئة. النتائج التي تظهر الأهمية الكبيرة لـ "توقع الأداء" (الذي تم قياسه من خلال الفوائد المتصورة في الدقة والكفاءة) و"الظروف الميسرة" (التي يعكسها تحدي القابلية للتفسير) تدعم البنية الأساسية للنظرية. ثانياً، تساهم الدراسة في أدبيات جودة المراجعة من خلال إدخال "القدرة التكنولوجية" كمتغير مستقل رئيسي ومؤثر. وهذا يوسع النقاش حول محددات جودة المراجعة ليتجاوز العوامل التقليدية (مثل حجم الشركة) ويشمل الكفاءة الرقمية كعنصر أساسي في العصر الحديث.

مهنياً، تحمل النتائج دلالات عملية مباشرة. بالنسبة لشركات المراجعة، تشير النتائج إلى ضرورة اتباع نهج استراتيجي متعدد الأوجه لتبني الذكاء الاصطناعي. لا يكفي شراء البرامج، بل يجب الاستثمار في ثلاثة مجالات متوازنة: التكنولوجيا (مع التركيز على كشف الشذوذ والقابلية للتفسير)، العمليات (إعادة تصميم إجراءات المراجعة للاستفادة من تحليل السكان بالكامل)، والأفراد (التدريب المكثف لبناء المهارات الرقمية وتعزيز الثقة في الأدوات الجديدة). كما تسلط النتائج الضوء على الدور المتطور للمراجع، الذي يتحول من "فاحص معاملات" إلى "محلل بيانات ومشرف على الخوارزميات". هذا التحول يتطلب مجموعة جديدة من المهارات التي يجب على برامج التطوير المهني والتعليم المحاسبي أن تتكيف معها بسرعة (Goel, 2025 & Li).

قيود الدراسة وآفاق البحث المستقبلي

مثل أي دراسة تجريبية، تخضع هذه الدراسة لبعض القيود التي يجب أخذها في الاعتبار عند تفسير النتائج، والتي تفتح في الوقت نفسه آفاقاً لأبحاث مستقبلية.

1. الاعتماد على بيانات التصورات: اعتمدت الدراسة على البيانات التي تم جمعها عبر استبانة، والتي تقيس تصورات المراجعين حول تبني الذكاء الاصطناعي وتأثيره. على الرغم من أن هذه التصورات مهمة لأنها تشكل السلوك، إلا أنها قد لا تعكس دائماً الواقع الموضوعي بشكل كامل. لذا، يمكن للأبحاث المستقبلية أن تحاول استخدام بيانات موضوعية وأرشيفية (مثل بيانات أتعاب المراجعة الفعلية، وأوقات إنجاز المراجعة، وحالات إعادة إصدار القوائم المالية) لتقديم أدلة أكثر صلابة.

2. التصميم المقطعي: استخدمت الدراسة تصميماً مقطعياً (Cross-sectional) يجمع البيانات في نقطة زمنية واحدة. هذا التصميم يسمح بتحديد العلاقات الارتباطية، ولكنه يحد من القدرة على استنتاج علاقات سببية قاطعة. يمكن للدراسات المستقبلية أن تتبنى تصميماً طويلاً (Longitudinal) يتتبع شركات المراجعة على مدى عدة سنوات لتقييم تأثير تبني الذكاء الاصطناعي بمرور الوقت.

3. قابلية التعميم: على الرغم من أن الدراسة صممت لتكون ممثلة لسوق ناشئة نموذجية، إلا أن كل سوق ناشئة لها خصائصها الفريدة. لذلك، يجب توخي الحذر عند تعميم النتائج على جميع الأسواق الناشئة الأخرى. يوصى بإجراء دراسات مقارنة عبر عدة أسواق ناشئة لتحديد العوامل السياقية (مثل مستوى النضج التنظيمي أو الثقافة الوطنية) التي قد تعدل العلاقة بين الذكاء الاصطناعي وجودة المراجعة.

4. التركيز على جانب المراجع: ركزت هذه الدراسة على منظور المراجعين. يمكن للأبحاث المستقبلية أن تستكشف وجهات نظر أصحاب المصلحة الآخرين، مثل أعضاء لجان المراجعة، والمستثمرين، والمنظمين، لفهم تصوراتهم حول كيفية تأثير الذكاء الاصطناعي على جودة المراجعة من وجهة نظرهم.

التوصيات

بناءً على النتائج التجريبية التي تم التوصل إليها والمناقشة المعمقة لدلالاتها، يقدم هذا القسم مجموعة من التوصيات الموجهة والقابلة للتنفيذ، والتي تهدف إلى مساعدة أصحاب المصلحة الرئيسيين في مهنة المراجعة بالأسواق الناشئة على التنقل بنجاح في عصر التحول الرقمي. تم تصميم هذه التوصيات لتشكّل

خارطة طريق استراتيجية لتبني الذكاء الاصطناعي بشكل فعال ومسؤول.
توصيات لشركات ومكاتب المراجعة:

1. اعتماد استراتيجية تبني مرحلية ومتوازنة: بدلاً من محاولة تطبيق جميع تقنيات الذكاء الاصطناعي دفعة واحدة، يوصى بتبني نهج مرحلي. يمكن للشركات أن تبدأ بـ "المكاسب السريعة" من خلال تطبيق أتمتة العمليات الروبوتية (RPA) على المهام الإدارية والروتينية لتحقيق تحسينات فورية في الكفاءة وبناء ثقة الفريق في التكنولوجيا. بعد ذلك، يمكن الانتقال إلى تطبيق أدوات التعلم الآلي (ML) لتحليل البيانات وتقييم المخاطر. وأخيراً، يجب أن يكون الهدف الاستراتيجي هو دمج أنظمة كشف الشذوذ المتقدمة (AD)، حيث أظهرت الدراسة أن لها الأثر الأكبر على دقة المراجعة.

2. الاستثمار المتزامن في التكنولوجيا ورأس المال البشري: أثبتت النتائج أن التكنولوجيا وحدها لا تكفي. يجب أن يقترن كل استثمار في برامج الذكاء الاصطناعي باستثمار موازٍ في تدريب وتطوير المراجعين. يجب أن تتجاوز برامج التدريب مجرد تعليم كيفية استخدام الأداة، لتركز على بناء مهارات أساسية جديدة مثل: التفكير التحليلي لتفسير مخرجات النماذج، والشك المهني الرقمي للتشكيك في الخوارزميات وليس فقط في الإدارة، وأخلاقيات البيانات لفهم مخاطر التحيز والخصوصية (Murikah et al., 2024).

3. إعطاء الأولوية للشفافية والقابلية للتفسير (XAI): أظهرت الدراسة أن ثقة المراجعين هي العامل الحاسم لنجاح التبني. لذلك، عند اختيار أو تطوير حلول الذكاء الاصطناعي، يجب على الشركات إعطاء الأولوية القصوى للمنصات التي توفر ميزات الذكاء الاصطناعي القابل للتفسير (XAI). يجب أن يكون المراجعون قادرين على فهم وتوثيق سبب قيام النظام بتمييز معاملة معينة على أنها محفوفة بالمخاطر. هذا ليس مهماً فقط للثقة الداخلية، بل هو ضروري أيضاً للدفاع عن إجراءات المراجعة أمام المنظمين والجهات القضائية (Zhang et al., 2022).

4. تطوير إطار حوكمة داخلي للذكاء الاصطناعي: يجب على كل شركة مراجعة، بغض النظر عن حجمها، أن تضع سياسات وإجراءات واضحة تحكم استخدام الذكاء الاصطناعي. يجب أن يغطي هذا الإطار جوانب مثل أمن البيانات، والخصوصية، والمسؤولية عن قرارات الخوارزميات، وبروتوكولات المراجعة البشرية للنتائج الهامة التي يولدها الذكاء الاصطناعي. يمكن الاسترشاد بالأطر التي طورتها هيئات دولية

مثل الاتحاد الدولي للمحاسبين (IFAC) أو الشركات الكبرى.

توصيات للهيئات المهنية والمؤسسات الأكاديمية:

1. تحديث المناهج التعليمية بشكل جذري: لم يعد من المقبول أن يتخرج طلاب المحاسبة والمراجعة دون فهم عميق لتحليلات البيانات والذكاء الاصطناعي. يوصى بأن تقوم الجامعات والهيئات المهنية بمراجعة شاملة لمناهجها لتضمين مساقات إلزامية في علوم البيانات للمحاسبين، وأمن المعلومات، وأخلاقيات التكنولوجيا، وتطبيقات الذكاء الاصطناعي في المراجعة.
2. إنشاء مسارات شهادات مهنية متخصصة: لتلبية الطلب المتزايد على المهارات الجديدة، يوصى بأن تقوم الهيئات المهنية (مثل جمعيات المحاسبين القانونيين المحلية) بتطوير شهادات متخصصة في مجالات مثل "مراجعة النظم الذكية" أو "أخصائي تأكيد البيانات". ستوفر هذه الشهادات مساراً واضحاً للتطوير المهني وتساعد الشركات على تحديد المواهب المؤهلة.
3. تعزيز البحث والتطوير المحلي: يجب على الجامعات والهيئات المهنية تشجيع الأبحاث التي تركز على تطوير وتكييف حلول الذكاء الاصطناعي لتناسب الاحتياجات والبيانات الخاصة بالأسواق الناشئة، بدلاً من الاعتماد الكلي على الحلول المستوردة التي قد لا تكون مناسبة تماماً للسياق المحلي.

المصادر

- Almufadda, G., & Almezeini, N. A. (2022). Artificial intelligence applications in the auditing profession: A literature review. *Journal of Emerging Technologies in Accounting*, 19(2), 29–42.
- Baaske, B. N., Eulerich, M., & Wood, D. A. (2025). Improving audit quality with data analytic visualizations: The importance of spatial abilities and feedback in anomaly identification. *Accounting Horizons*, 39(3), 85–97.
- Commerford, B. P., Eilifsen, A., Hatfield, R. C., Holmstrom, K. M., & Kinserdal, F. (2024). Control issues: How providing input affects auditors' reliance on artificial intelligence. *Contemporary Accounting Research*, 41(4), 2134–2162.
- Fedyk, A., Hodson, J., Khimich, N., & Fedyk, T. (2022). Is artificial intelligence improving the audit process? *Review of Accounting Studies*, 27(3), 938–985.

-
- Fotoh, L. E. (2025). Digital inventory audits: An alternative approach to physical observation in audit evidence gathering. *Journal of Applied Accounting Research*. Advance online publication.
 - Freiman, J. W., Kim, Y., & Vasarhelyi, M. A. (2022). Full population testing: Applying multidimensional audit data sampling (MADS) to general ledger data auditing. *International Journal of Accounting Information Systems*, 46, 100573.
 - Fulcer, K., Gu, H., Hu, H., Huang, Q., Kogan, A., Vasarhelyi, M. A., Wei, D., & Young, J. (2025). Application of outlier detection methods in audit analytics. *Accounting Horizons*, 39(3), 143–157.
 - Gu, H., Schreyer, M., Moffitt, K., & Vasarhelyi, M. A. (2024). Artificial intelligence co-piloted auditing. *International Journal of Accounting Information Systems*, 54, 100698.
 - Kamareldawla, N. M. (2025). External auditors' perceptions toward the use of artificial intelligence in the audit process and ethical challenges facing its application: Evidence from an emerging market. *Corporate Ownership & Control*, 22(2), 171–184.
 - Khan, F., Jan, S. U., & Zia-ul-haq, H. M. (2025). Artificial intelligence adoption, audit quality and integrated financial reporting in GCC markets. *Asian Review of Accounting*. Advance online publication.
 - 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.
 - Kokina, J., Blanchette, S., & Davenport, T. H. (2025). Challenges and opportunities for artificial intelligence in auditing: Evidence from the field. *International Journal of Accounting Information Systems*, 56, 100734.
 - Lai, J. (2025). Artificial intelligence applications and audit fees: An empirical study. *International Review of Economics & Finance*, 103, 104421.
 - Law, K. K. F., & Shen, M. (2025). How does artificial intelligence shape audit firms? *Management Science*, 71(5), 3641–3666.
 - Leocádio, D., Malheiro, L., & Reis, J. (2024). Artificial intelligence in auditing: A conceptual framework for auditing practices. *Administrative Sciences*, 14(10), 238.
-

-
- Li, Y., & Goel, S. (2025). Artificial intelligence auditability and auditor readiness for auditing artificial intelligence systems .*International Journal of Accounting Information Systems*, 56, 100739.
 - Libby, R., & Witz, P. D. (2024). Can artificial intelligence reduce the effect of independence conflicts on audit firm liability ?*Contemporary Accounting Research* .Advance online publication.
 - 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.
 - Mökander, J. (2023). Auditing of AI: Legal, ethical and technical approaches. *Digital Society*, 2, Article 49.
 - Murikah, W., Nthenge, J. K., & Musyoka, F. M. (2024). Bias and ethics of AI systems applied in auditing – A systematic review. *Scientific African*, 25, e02281.
 - Murphy, B., Feeney, O., Rosati, P., & Lynn, T. (2024). Exploring accounting and AI using topic modelling .*International Journal of Accounting Information Systems*, 55, 100709.
 - Musa, A. M. H. (2024). Detecting the effect of artificial intelligence on internal audit performance: Empirical study in Saudi Arabia. *Decision Science Letters*, 13(4), 967–976.
 - Noordin, N. A., Hussainey, K., & Hayek, A. F. (2022). The use of artificial intelligence and audit quality: An analysis from the perspectives of external auditors in the UAE. *Journal of Risk and Financial Management*, 15(8), 339.
 - O’Leary, D. E., Richardson, V. J., & Weidenmier Watson, M. (2024). Data-driven audits: Audit analytic platforms and general ledger analytic tools. *Current Issues in Auditing*, 19(1), A1–A9.
 - Pérez-Calderón, E., Alrahamneh, S. A & ,Milanés Montero, P. (2025). Impact of artificial intelligence on auditing: An evaluation from the profession in Jordan. *Discover Sustainability*, 6, 251.
 - Qader, K. S & ,Cek, K. (2024). Influence of blockchain and artificial intelligence on audit quality: Evidence from Turkey. *Heliyon*, 10(9), e30166.

-
- Rahman, M. J., Zhu, H & ,Yue, L. (2024). Does the adoption of artificial intelligence by audit firms and their clients affect audit quality and efficiency? Evidence from China. *Managerial Auditing Journal*, 39(6), 668–699.
 - Samiolo, R., Spence, C., & Toh, D. (2024). Auditor judgment in the fourth industrial revolution. *Contemporary Accounting Research*, 41(1), 498–528.
 - Sandu, I., Wiersma, M & ,Manichand, D. (2022). Time to audit your AI algorithms. *Maandblad voor Accountancy en Bedrijfseconomie*, 96(7–8), 253–265.
 - Seethamraju, R & ,Hecimovic, A. (2023). Adoption of artificial intelligence in auditing: An exploratory study. *Australian Journal of Management*, 48(4), 780–800.
 - Senave, E., Jans, M. J & ,Srivastava, R. P. (2023). The application of text mining in accounting. *International Journal of Accounting Information Systems*, 50, 100624.
 - Tan, J., Chang, S & ,Zheng, Y. (2025). Client artificial intelligence application and audit quality. *International Review of Financial Analysis*, 104, 104271.
 - Tragouda, M., Doumpos, M & ,Zopounidis, C. (2024). Identification of fraudulent financial statements through a multi-label classification approach. *Intelligent Systems in Accounting, Finance and Management*, 31(2), e1564.
 - Vitali, S & ,Giuliani, M. (2024). Emerging digital technologies and auditing firms: Opportunities and challenges. *International Journal of Accounting Information Systems*, 53, 100676.
 - Wei, D., Cho, S., Vasarhelyi, M. A., & Te-Wierik, L. (2024). Outlier detection in auditing: Integrating unsupervised learning within a multilevel framework for general ledger analysis. *Journal of Information Systems*, 38(2), 123–142.
 - Zhang, C. A., Cho, S., & Vasarhelyi, M. A. (2022). Explainable artificial intelligence (XAI) in auditing. *International Journal of Accounting Information Systems*, 46, 100572.
 - Zhao, T., & Duan, W. (2025). Auditors' digital expertise and audit quality: Empirical evidence based on China's A-share listed companies. *Emerging Markets Finance and Trade*. Advance online publication.

-
- Zhong, C., & Goel, S. (2024). Transparent AI in auditing through explainable AI. *Current Issues in Auditing*, 18(2), A1–A14.