المجلة العربية للعلوم الإدارية

مجلد 30، عدد 1، يناير 2023، 13 - 67
Doi: 10.34120/ajas.v30i1.213

# الدور الوسيط للذكاء الاصطناعي القابل للتفسير في العلاقة بين حوكمة البيانات والأداء المؤسسي

*مديح نابر الجداوي*
*معهد الإدارة العامة*
*المملكة العربية السعودية*

**الملخص**

**هدف الدراسة:** تهدف الدراسة إلى تعرّف أثر حوكمة البيانات في الأداء المؤسسي عبر الذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً.

**تصميم/ منهجية/طريقة الدراسة:** تنتمي هذه الدراسة إلى الدراسات الوصفية التحليلية؛ إذ تساعد في تحليل الظاهرة محل الدراسة من خلال الحصول على معلومات عنها، ووصف متغيراتها، وتحديد العلاقة بين هذه المتغيرات.

**عينة الدراسة وبياناتها:** اعتمدت هذه الدراسة على منهج المسح الاجتماعي بطريقة العينة لآراء عينة عشوائية، قوامها 384 من المديرين التنفيذيين لتقنية المعلومات الملمين بتقنيات الذكاء الاصطناعي، وجمعت البيانات باستخدام أداة الاستبانة.

**نتائج الدراسة:** توصلت الدراسة إلى استنتاجات عدة، أهمها أن الممارسات المتعلقة بمتغيرات الدراسة الثلاثة متوافرة بدرجة مرتفعة في المنظمات، ووجود اختلاف معنوي في تقديرات الخبراء نحو درجة ممارسة منظماتهم للذكاء الاصطناعي القابل للتفسير وفقاً لاختلاف عدد سنوات الخبرة، وأن الذكاء الاصطناعي القابل للتفسير يلعب دور الوساطة الجزئية المكملة في علاقة حوكمة البيانات بالأداء المؤسسي؛ إذ بلغ التأثير غير المباشر من خلال الذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً (0.144) والتأثير المباشر لحوكمة البيانات على الأداء المؤسسي (0.452)؛ مما يعني أن التأثير الكلي قدره 0.596.

**أصالة الدراسة:** لم يتم قياس تأثير الذكاء الاصطناعي القابل للتفسير متغيراً وسيطاً بين المتغير المستقل (حوكمة البيانات) والمتغير التابع (الأداء المؤسسي) في الدراسات العربية والإنجليزية السابقة، على قدر علمنا.

**حدود الدراسة وتطبيقاتها:** الحدود البشرية: طبقت الدراسة على عدد من المديرين التنفيذيين لتقنية المعلومات الملمين بتقنيات الذكاء الاصطناعي.

الحدود الزمنية: أجريت الدراسة خلال فترة زمنية محددة استغرقت ثلاثة أشهر.

الحدود الموضوعية: اقتصرت الدراسة على ثلاثة متغيرات، هي: حوكمة البيانات، والذكاء الاصطناعي القابل للتفسير، والأداء المؤسسي.

**الكلمات المفتاحية:** حوكمة البيانات، الذكاء الاصطناعي القابل للتفسير، الأداء المؤسسي.

**تصنيف JEL: O14**

تم تسلم البحث في 2023/11/4، التعديل الأول في 2023/11/25، التعديل الثاني في 2023/12/6، أُجيز للنشر في 2023/12/25.

**تصدر عن مجلس النشر العلمي بجامعة الكويت. جميع الحقوق محفوظة للمجلة.**

**الإشارة المرجعية:** الجداوي، مديح نابر. (2023). الدور الوسيط للذكاء الاصطناعي القابل للتفسير في العلاقة بين حوكمة البيانات والأداء المؤسسي. *المجلة العربية للعلوم الإدارية*، *30*(1)، 13-67.
https://doi.org/10.34120/ajas.v30i1.213

## ABSTRACT

### The Relationship between Data Governance and Organizational Performance: The Mediating Effect of Explainable Artificial Intelligence



Madeeh N. Elgedawy
*Institute of Public Administration, KSA*



**Purpose:** This study uses explainable artificial intelligence as a mediator to examine how data governance affects organizational performance.

**Study design/methodology/approach:** This study belongs to descriptive analytical studies, as it helps in analyzing the phenomenon under study, describing its variables, and determining the relationship among them.

**Sample and data:** This study relied on a random sample of 384 IT executives' familiar with artificial intelligence techniques, and the data was collected using an electronic questionnaire.

**Results:** The results showed that explainable artificial intelligence plays a complementary role in the relationship of data governance to organizational performance. The indirect impact of explainable artificial intelligence as an intermediate variable was (0.144), and the direct impact of data governance on institutional performance was (0.452). In addition, the data governance variable was able to explain 40.6% of the change in the explainable artificial intelligence variable.

**Originality/value:** The effect of explainable artificial intelligence as a mediating variable between the independent variable (data governance) and the dependent variable (organizational performance) has not been measured in previous studies, as far as we know.

**Research limitations/implications:** Human limitations: The study was applied to a number of IT executives who are familiar with artificial intelligence techniques. Time limitations: The study was conducted within a specific period of time that lasted four months. Scope limitations: The study was limited to three variables: data governance, explainable artificial intelligence, and organizational performance.



***Keywords*:** Data Governance, Explainable AI, Organizational Performance.



***Published by the Academic Publication Council of Kuwait University. All rights reserved.***



**To cite:** Elgedawy, M. N. (2023). The relationship between data governance and organizational performance: The mediating effect of explainable Artificial Intelligence. *Arab Journal of Administrative Sciences, 30*(1), 13-67. https://doi.org/10.34120/ajas.v30i1.213

**المقدمة**

بدأ الذكاء الاصطناعي في تغيير طريقة عمل المنظمات. لقد قدرت شركة IDC أن ما يقرب من نصف مشاريع مبادرات التحول الرقمي في عام 2019 قامت باستخدام خدمات الذكاء الاصطناعي، وأن 75% من تطبيقات الأعمال اعتمدت على الذكاء الاصطناعي في عام 2021 (Crews, 2019)، ومن المتوقع أن يحسن الذكاء الاصطناعي أداء المنظمات ومستوى كفاءتها؛ إذ يساعد الذكاء الاصطناعي المنظمة على فهم موظفيها وعملائها وأصحاب المصلحة (Bosco, 2020). لقد قدم الذكاء الاصطناعي تقنيات جديدة للمساعدة في إدارة المنظمات، وهذا يمثل تحدّياً كبيراً يتطلب تغييراً في الثقافة وتعلم مهارات معقدة (Di Francescomarino & Maggi, 2020)؛ ونظراً للتأثير العميق لاستخدام تقنيات الذكاء الاصطناعي، فإنه يصعب التعامل بنجاح مع تحدياته دون القدرة على تفسير نتائجه وحوكمة بيانات نماذجه والوقوف على مدى تأثيرها في تحسين الأداء.

في هذا العصر الرقمي، تعد البيانات هي النفط الجديد والذكاء الاصطناعي هو الكهرباء الجديدة (Grover et al., 2022). لقد أجرت شركة IBM مسحاً شاملاً أفاد بأن أكثر من 60% من المسؤولين يشعرون بعدم الارتياح تجاه النهج التقليدي إزاء نماذج الذكاء الاصطناعي التي تعتمد على منهج "الصندوق الأسود"؛ وهي تلك النماذج ذات الهيكلية المبهمة التي لا تمتاز بالشفافية في فهم العمليات الداخلية للنموذج؛ ولذا يصعب التحقق من جودة نتائجها ودقتها (What is explainable AI?, n.d.). يهدف الذكاء الاصطناعي القابل للتفسير إلى جعل أنظمة الذكاء الاصطناعي أكثر شفافية وقدرة على تقديم التفسيرات للبشر؛ مما يحسن الثقة ويساعد المستخدمين في اتخاذ قرارات أفضل؛ استناداً إلى التوصيات التي تولدها نماذج الذكاء الاصطناعي، كما يساعد في تحسين الأداء المؤسسي وتعزيزه من خلال توفير الرؤى والتعليقات والإرشادات لعمليات صنع القرار التي تعتمد على البيانات بشكل رئيسي؛ مما يتطلب جودة البيانات وجودة التفسير الذي يقدَّم لأصحاب المصلحة، ومواءمة البيانات وأنظمة الذكاء الاصطناعي وتكاملها مع الأهداف التنظيمية؛ مما يعني أن حوكمة البيانات أمر حتمي لضمان جودة التفسيرات التي تستخلص من أنظمة الذكاء الاصطناعي.

يرى Wulff and Finnestrand (2023) أن الذكاء الاصطناعي القابل للتفسير يخدم نوعين من الأهداف: فهم النمط (Pattern Goals) (ويشمل العدالة والوعي بالخصوصية والسببية وقابلية النقل والثقة) وتقديم تجربة مستخدم جيدة (Experience Goals) (ويشمل تحقيق الهدف أو عدم تحقيقه والوصولية والإفادة والتفاعلية والموثوقية)، وأكد Wulff and Finnestrand أن بعض هذه الأبعاد قد تكون مرتبطة بأداء المؤسسة؛ ومن ثم، فإن تتبع العلاقة بين القدرة على تفسير نماذج الذكاء الاصطناعي والأداء المؤسسي يعدّ من أولويات صناع القرار وأصحاب المصلحة في المنظمات.

إن الأداء المؤسسي موضوع مهمّ في الإدارة، يتعلق بمدى نجاح المنظمة في تحويل مواردها إلى نتائج جيدة، ويتضمن ذلك تحقيق الأهداف ومقارنة النتائج الفعلية بما هو متوقع (Ondoro, 2015)، كما يشير إلى قدرة المنظمة على تحقيق أهدافها المالية والتشغيلية ومدى الفعالية (Pokorná & Částek, 2013). إن القدرة التفسيرية لنماذج الذكاء الاصطناعي عامل رئيسي في تحقيق أهداف المنظمات (Bauer et al., 2021)؛ إذ تساعد متخذي القرار على فهم الوضع الراهن واتخاذ قرارات أفضل لتحسين الأداء؛ مما يستلزم حوكمة بيانات المنظمة لضمان جودة وموثوقية البيانات التي تستخدم في هذه النماذج المعقدة. إن الأداء المؤسسي مرتبط ارتباطاً وثيقاً بأهداف الذكاء الاصطناعي القابل للتفسير وحوكمة البيانات؛ فقد ذكر Srihari (2020) أن هناك أربعة أهداف للذكاء الاصطناعي القابل للتفسير، وهي: التبرير (القدرة على شرح القرار للآخرين؛ مما يساعد أصحاب المصلحة على اتخاذ القرار بثقة)، السيطرة (الامتثال للتشريعات التي تنص على ضرورة حوكمة البيانات وحماية البيانات الشخصية)، التحسين (معرفة نقاط الضعف واكتشاف التحيزات وتمكين صناع القرار من اتخاذ قرارات أفضل لصالح المنظمة)، والاكتشاف (استخلاص رؤى جديدة تعزز فعالية المنظمة). إذا تمت حوكمة البيانات بشكل صحيح، فستكون البيانات أثمن أصول المنظمة؛ مما يساعدها على التنافسية وتلبية احتياجات العملاء بشكل استباقي والحفاظ على تكاليفها تحت السيطرة؛ مما يؤدي إلى تحسن الأداء (Panian, 2010)، وهو ما يتفق مع رأي Benfeldt (2017)؛ إذ ذكر أن البيانات يمكن أن تحسن عملية اتخاذ القرار وزيادة الفاعلية بشكل أفضل، وذلك بشرط حوكمة البيانات.

من ناحية أخرى، تعد حوكمة البيانات وسيلة مهمة للمنظمات تستطيع من خلالها الحفاظ على جودة بياناتها (Otto, 2011)، وأن تعزز عملية اتخاذ القرار بشكل أفضل؛ مما يساعد على تحقيق مستوى عالٍ من التنافسية؛ حيث تعتبر البيانات العالية الجودة شرطاً أساسياً لمواكبة المتطلبات المتغيرة وتحقيق الأهداف المؤسسية، وعند عدم تحديد سياسات وقواعد وضوابط واضحة داخل المنظمة بشأن البيانات، فإن جودة البيانات سوف تتدهور؛ مما يؤثر سلباً على عمليات اتخاذ القرار (Steinfield et al., 2011)، وعلى الرغم من هذه الأهمية المتزايدة فإن ثلثي الدراسات التي تتعلق بحوكمة البيانات هي في تخصص علوم الحاسب ونظم المعلومات، وليس في علوم الإدارة (Benfeldt, 2017). إن حوكمة البيانات تضمن تقديم قرارات موثوق بها عند استخدام تحليلات البيانات المتقدمة (BDAS) التي تستخدم بدورها كلاًّ من الذكاء الاصطناعي (AI) والبيانات الضخمة والمفتوحة والمترابطة (BOLD)، وذكر Janssen et al. (2020) أنه من المهم إيلاء حوكمة البيانات اهتماماً كبيراً لإنشاء نماذج ذكاء صناعي عادلة وخاضعة للمساءلة وشفافة (Fair, Accountable and Transparent) (FAT)؛ مما يساهم في تحسين الأداء المؤسسي.

بعد فحص الدراسات السابقة، تبين لنا أن أقرب الدراسات الكمية لهذه الدراسة هي دراسة Abueed and Aga (2019)، التي تقيس العلاقة بين حوكمة البيانات والأداء المؤسسي، وكان

المتغير الوسيط هو إنشاء المعرفة؛ إذ تبين من الدراسة أن إنشاء المعرفة يتوسط العلاقة بين حوكمة البيانات والأداء المؤسسي، كما أضافت الدراسة متغيراً مستقلاً آخر وهو شفافية المعلومات، وتبين من نتائجها أن إنشاء المعرفة يتوسط العلاقة بين حوكمة البيانات وشفافية المعلومات. إن شفافية المعلومات لها علاقة وطيدة بقابلية التفسير التي هي المستهدف الرئيسي من استخدام الذكاء الاصطناعي القابل للتفسير. في دراسة Abueed and (2019) Aga لم يُتناول الذكاء الاصطناعي القابل للتفسير، ولم تُقس العلاقة بين شفافية المعلومات والأداء المؤسسي، كما لم يعدّ متغير الشفافية متغيراً وسيطاً بل عدّ متغيراً مستقلاً، وأما عن أقرب الدراسات النظرية لهذه الدراسة؛ فهي دراسة Janssen et al. (2020) التي قدمت إطاراً مقترحاً لحوكمة البيانات معد خصيصاً للذكاء الاصطناعي القابل للتفسير، وأشارت إلى أن حوكمة البيانات تعد عاملاً مهمّاً لنجاح نظم تحليل البيانات الضخمة (BDAS)، وأن لها تأثيراً إيجابياً على أداء المنظمات التي تطبق هذه النظم، وعلى الرغم من مرور أكثر من عشرين عاماً، لا تزال الأبحاث العلمية في حقل الذكاء الاصطناعي القابل للتفسير محدودة، وهناك حاجة ماسّة لمزيد من الأبحاث المتخصصة في هذا المجال الواعد؛ خصوصاً مع وجود فجوات بحثية في الأدبيات السابقة؛ فبينما قامت عدة دراسات بقياس أثر حوكمة البيانات على الأداء المؤسسي، فإنها قامت بدراسة عوامل وسيطة مختلفة؛ مثل جودة البيانات (Ibrahim et al., 2021)، وقدرات المنظمة الديناميكية (Mikalef et al., 2020)، وغاب أثر الذكاء الاصطناعي القابل للتفسير عن هذه العلاقات، بل حتى لم تتم محاولة الوقوف على الأثر المباشر لحوكمة البيانات على الذكاء الاصطناعي القابل للتفسير بشكل كمي.

تقدم هذه الدراسة العديد من الإسهامات على الجانب النظري والعملي: على الجانب النظري، هذه هي أول دراسة (على قدر علمنا) تقيس الأثر الوسيط للذكاء الاصطناعي القابل للتفسير على العلاقة بين متغيرين مهّمين وهما: حوكمة البيانات والأداء المؤسسي، وعلى الجانب العملي تقدم الدراسة للمنظمات فهماً تاماً لتأثير البيانات بوصفها أصلاً حقيقيّاً وتؤكد ضرورة التعامل معها بطريقة متسقة مع تقنيات الذكاء الاصطناعي القابل للتفسير. وعليه؛ تهدف هذه الدراسة إلى معرفة التأثير المباشر لحوكمة البيانات على الأداء المؤسسي، ومدى تأثر العلاقة بينهما بالذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً، وذلك من خلال استطلاع وجهة نظر عينة من المديرين التنفيذيين لتقنية المعلومات، ذوي الخبرة في مجال الذكاء الاصطناعي.

رُتبت أجزاء هذه الدراسة على النحو الآتي: بعد هذه المقدمة، تستعرض أسئلة الدراسة، ثم الدراسات السابقة وفروض الدراسة؛ إذ تناقش متغيرات الدراسة؛ والعلاقات البينية بالتفصيل، ثم ينتقل الحديث إلى منهجية الدراسة؛ فتوضّح المنهج والمجتمع والعينة وأدوات الدراسة وتقييم الاعتمادية وصلاحية المقاييس المستخدمة، وبعد ذلك يأتي الحديث عن نتائج الدراسة بدءاً بالإحصاء الوصفي، مروراً باختبار الفروض وانتهاء بمناقشة النتائج، وبعدها تستعرض خلاصة الدراسة.

**أسئلة الدراسة**

1. ما مستوى ممارسة حوكمة البيانات في المنظمات؟
2. ما مستوى ممارسة الذكاء الاصطناعي القابل للتفسير في المنظمات؟
3. ما مستوى ممارسة الأداء المؤسسي في المنظمات؟
4. ما أثر حوكمة البيانات على الأداء المؤسسي في المنظمات؟
5. ما أثر حوكمة البيانات على الذكاء الاصطناعي القابل للتفسير في المنظمات؟
6. ما أثر الذكاء الاصطناعي القابل للتفسير على الأداء المؤسسي في المنظمات؟
7. ما طبيعة الدور الذي يقوم به الذكاء الاصطناعي القابل للتفسير –بوصفه متغيراً وسيطاً– في العلاقة بين حوكمة البيانات والأداء المؤسسي؟

**الدراسات السابقة وفروض الدراسة**

في هذا القسم، استعرض الباحث كل متغير من متغيرات الدراسة على حدة (حوكمة البيانات، الذكاء الاصطناعي القابل للتفسير، الأداء المؤسسي)، ثم ناقش العلاقات الثنائية والكلية بين المتغيرات الثلاثة (حوكمة البيانات والذكاء الاصطناعي القابل للتفسير، الذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، حوكمة البيانات والأداء المؤسسي، حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي)، ويوضح جدول (1) المتغيرات التي تناولتها الدراسات السابقة وأهم استنتاجاتها ذات العلاقة بمتغيرات هذه الدراسة.

**جدول 1**

**المتغيرات التي تناولتها الدراسات السابقة وأهم استنتاجاتها ذات العلاقة بمتغيرات الدراسة الحالية**

| المرجع | النتائج والاستنتاجات | المتغيرات ذات العلاقة التي تم تناولها | | |
|---|---|---|---|---|
| | | الأداء المؤسسي | الذكاء الاصطناعي القابل للتفسير | حوكمة البيانات |
| Janssen et al. (2020) | قدمت الدراسة إطاراً نظريًّا مقترحاً لحوكمة البيانات معدًّا خصيصا للذكاء الاصطناعي القابل للتفسير، وأشارت إلى أن حوكمة البيانات تعد عاملاً مهمًّا لنجاح نظم تحليل البيانات الضخمة | ✓ | ✓ | ✓ |
| Harrison et al. (2019) | أشار إلى أهمية حوكمة البيانات في سياق الذكاء الاصطناعي | | ✓ | ✓ |
| (Wang et al., 2023) | يعد الذكاء الاصطناعي القابل للتفسير تتمة لأهداف حوكمة البيانات؛ لأنه وسيلة لفهم وتفسير القرارات التي تتخذها نماذج الذكاء الاصطناعي | | ✓ | ✓ |
| (Khordad-pour, 2023) | تلعب حوكمة البيانات دوراً مهمًّا في إنشاء معايير للبيانات والسياسات والإجراءات لجمع البيانات وتخزينها ومعالجتها لدعم الذكاء الاصطناعي القابل للتفسير | | ✓ | ✓ |
| Lai and Tan (2019) | أكدت الدراسة قدرة الذكاء الاصطناعي القابل للتفسير على تحسين الأداء وزيادة ثقة العملاء | ✓ | ✓ | |
| Buçinca et al. (2020) | هذه الدراسات الثلاث ذكرت أن قابلية التفسير لا تحسن من الأداء البشري، وأن فهم قرارات أنظمة الذكاء الاصطناعي ليست مؤشراً على مستوى أداء اتخاذ القرار الفعلي؛ ويرى الباحث أن ذلك في الأساس يرجع إلى التحيزات المعرفية عند اتخاذ القرار، ومن الملاحظ أن وجهة نظر المخالفين تكمن في تشكيكهم في قدرة التفسير على تحسين أداء اتخاذ القرار البشري تحديداً، وليس الأداء المؤسسي | ✓ | ✓ | |
| Zhang et al. (2020) | | ✓ | ✓ | |
| Alufaisan et al. (2021) | | ✓ | ✓ | |
| Bauer et al. (2021) | أكدت الدراسة أن القدرة التفسيرية لنماذج الذكاء الاصطناعي هي عامل رئيسي في تحقيق أهداف المنظمات | ✓ | ✓ | |
| Lachuer and Jabeur (2022) | من خلال استخدام الذكاء الاصطناعي القابل للتفسير، قامت الدراسة باستخراج رؤى حول العوامل التي تؤثر في الأداء المالي. | ✓ | ✓ | |

**تابع / جدول 1**

**المتغيرات التي تناولتها الدراسات السابقة وأهم استنتاجاتها ذات العلاقة بمتغيرات الدراسة الحالية**

| المرجع | النتائج والاستنتاجات | المتغيرات ذات العلاقة التي تم تناولها | | |
|---|---|---|---|---|
| | | الأداء المؤسسي | الذكاء الاصطناعي القابل للتفسير | حوكمة البيانات |
| Wulff and Finnestrand (2023) | أوضحت الدراسة أن بعض أبعاد الذكاء الاصطناعي القابل للتفسير قد تكون مرتبطة بالأداء المؤسسي | ✓ | ✓ | |
| Weber et al. (2009) | بخلاف الطرح التقليدي، أوضحت النتائج أن الأداء المؤسسي يؤثر على حوكمة البيانات، وليس العكس | ✓ | | ✓ |
| Panian (2010) | تساعد حوكمة البيانات على تحسن الأداء | ✓ | | ✓ |
| Steinfield et al. (2011) | أثبت أن البيانات التي تتم حوكمتها بشكل سيئ قد تتسبب في خسائر للمنظمة | ✓ | | ✓ |
| Neff et al. (2013) | قام بعمل تسع دراسات حالة استكشافية في منظمات من مختلف القطاعات، وأشارت النتائج إلى أن حوكمة البيانات لها أثر إيجابي على أداء عمليات المنظمة | ✓ | | ✓ |
| Mikalef et al. (2020) | قامت الدراسة بقياس أثر حوكمة البيانات على الأداء المؤسسي، وقدرات المنظمة كعامل وسيط | ✓ | | ✓ |
| Abueed and Aga (2019) | أثبتت الدراسة وجود أثر لحوكمة البيانات على كل من الأداء المؤسسي وشفافية المعلومات، وأن إنشاء المعرفة متغير وسيط في هذه العلاقة.<br>(لاحظ الباحث العلاقة الوثيقة بين شفافية المعلومات وقابلية التفسير التي تعد ثمرة نماذج الذكاء الاصطناعي القابل للتفسير وإن لم يذكر ذلك صراحة في تلك الدراسة) | ✓ | | ✓ |
| Wamba-Taguimdje et al. (2020) | قامت الدراسة بمراجعة 500 دراسة حالة من مواقع عالمية، وأكدوا أهمية الذكاء الاصطناعي في تحسين أداء المنظمات المختلفة، وأن التحدي الرئيسي الذي يواجه المنظمات الآن هو حوكمة نماذج الذكاء الاصطناعي. | ✓ | | ✓ |
| Ibrahim et al. (2021) | قامت الدراسة بقياس أثر حوكمة البيانات على الأداء المؤسسي، وجودة البيانات كعامل وسيط | ✓ | | ✓ |

يوضح جدول (1) أنه يوجد عدد من الدراسات التي قامت ببحث العلاقة بين حوكمة البيانات والأداء المؤسسي، بعضها كان دراسات حالة (Neff et al., 2013; Wamba-Taguimdje et al., 2020)، والآخر استخدم متغيرات أخرى بين هذين المتغيرين؛ مثل قدرات المنظمة (Mikalef et al., 2020) وإنشاء المعرفة (Abueed & Aga, 2019)، وجودة البيانات (Ibrahim et al., 2021)، وبعض الدراسات الأخرى بحثت العلاقة بين الذكاء الاصطناعي القابل للتفسير والأداء، وبينما كان الاتجاه العام هو وجود علاقة طردية بين هذين المتغيرين؛ فإن هناك ثلاث دراسات -على وجه التحديد- كان لها موقف مخالف وأكدت أنه لا توجد علاقة بينهما (Alufaisan et al., 2021; Bucinca et al., 2020; Zhang et al., 2020)، ومن الملاحظ أن الدراسات الثلاث كانت تركز على الأداء البشري وليس الأداء المؤسسي، كما يوجد عدد أقل من الدراسات التي بحثت في العلاقة بين حوكمة البيانات والذكاء المؤسسي، وأشارت إلى أهمية حوكمة البيانات في سياق الذكاء الاصطناعي القابل للتفسير، ولم يجد الباحث دراسة تناولت المتغيرات الثلاثة مجتمعة، التي عرضت لها هذه الدراسة، بخلاف دراسة Janssen et al. (2020)، التي قدمت إطاراً نظريّاً لحوكمة البيانات خصص في سياق الذكاء الاصطناعي القابل للتفسير، وفي طيات شرح هذا الإطار، أشير إلى حوكمة البيانات كعامل مهمّ يسهم في نجاح آلية تنفيذ الإطار النظري في المنظمات. وعليه؛ فإن هذه الدراسة هي الأولى في تقديم قياس كمي للمتغيرات الثلاثة معاً، وفي دراسة الأثر المباشر وغير المباشر لحوكمة البيانات على الأداء المؤسسي من خلال الذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً.

**أولاً: حوكمة البيانات**

تحظى حوكمة البيانات باهتمام بالغ؛ نظراً لحرص المنظمات المتزايد على دقة البيانات وصحتها؛ بغية استخدامها لتحسين الأداء (Watson & McGivern, 2016)، كما تعد حوكمة البيانات أمراً ضرورياً لإدارة بيانات المنظمات بفعالية وكفاءة، واتخاذ القرارات المستنيرة، وضمان موثوقية البيانات (Kostoska & Kocarev, 2019). تشير حوكمة البيانات إلى الإدارة والسيطرة العامة على أصول البيانات في المنظمة، من خلال العمليات والسياسات والإجراءات التي تضمن جودة البيانات وسلامتها والامتثال للقوانين، كما تتضمن إنشاء إطار لتحديد المسؤوليات الخاصة بأنشطة إدارة البيانات (Weber et al., 2009)، وعرفها Cohen (2006) بأنها العملية التي تضمن بها المنظمة اتساق البيانات وأمنها وقابليتها للاستخدام، ووفقًا لما ذكره Weber et al. (2009)، فإن حوكمة بيانات المنظمة هي ظاهرة ثلاثية الأبعاد، تشمل أنشطة تمتد من الممارسات الهيكلية (تخصيص أدوار حوكمة البيانات)، والممارسات الإجرائية أو التشغيلية (صنع القرار بشأن استخدام البيانات)، والممارسات العلائقية (تطوير العلاقات بين الإدارات فيما يتعلق بمشاركة البيانات)، وتتبع أهمية حوكمة البيانات من أمور عديدة، وهي:

**أولاً:** تضمن حوكمة البيانات جودة وسلامة البيانات (Mikalef et al., 2018)، مما يسهم في اتخاذ القرارات الصحيحة (Bozkurt et al., 2022) وتحقيق النتائج الإيجابية (Hikmawati et al., 2021).

**ثانياً:** تعزز حوكمة البيانات التعاون بين أصحاب المصلحة (Knapton, 2020).

**ثالثاً:** إن حوكمة البيانات أصبحت ضرورة ملحّة في ظل الاتجاهات الحديثة؛ مثل البيانات الضخمة وإنترنت الأشياء والذكاء الاصطناعي؛ حيث تولد هذه التقنيات كميات هائلة من البيانات مما يتطلب ضمان الاستخدام المسؤول والأخلاقي لها (De Prieëlle et al., 2020)، كما تتعامل حوكمة البيانات مع التحديات المتعلقة بجودة البيانات والتحيز في التقنيات الناشئة (Fadler & Legner, 2021).

إن الاعتراف بالبيانات أصولاً للمنظمة يتطلب حوكمة البيانات بشكل فعال (Cheong & Chang, 2007)؛ إذ تسمح للمنظمات بالاحتفاظ بالبيانات والسيطرة على العمليات واستخدام المعرفة (Abueed & Aga, 2019). ويمكن تعريف البيانات على أنها "المواد الخام"، وأما المعلومات؛ فهي "البيانات في سياق الموضوع" (Boisot & Canals, 2004)، وغالباً ما يستخدم الاثنان بشكل متبادل، ولا يتم التفريق بين حوكمة البيانات وحوكمة المعلومات (Ladley, 2019). كما تختلف حوكمة البيانات عن الحوكمة المؤسسية (Corporate Governance) وحوكمة تقنية المعلومات (Information Technology Governance)؛ فهي ثلاثة مفاهيم متمايزة، تلعب دورًا مهمًا في المنظمات. وعلى الرغم من أن الحوكمة المؤسسية وحوكمة تقنية المعلومات وحوكمة البيانات هي مفاهيم مختلفة، فإنها مترابطة ويعزز بعضها بعضاً؛ إذ تتطلب الحوكمة المؤسسية الفعالة وجود حوكمة قوية لتقنية المعلومات لضمان الإدارة والتحكم السليم في الموارد التقنية. كما أن لحوكمة البيانات تأثيراً إيجابياً على الحوكمة المؤسسية، وأن حوكمة تقنية المعلومات توضع لتنسجم مع الحوكمة المؤسسية (Gheorghe, 2010). ومن ناحية أخرى، ينظر لحوكمة البيانات باعتبارها جزءاً من حوكمة تقنية المعلومات (Smallwood, 2014). كما ترتبط حوكمة البيانات بشكل وثيق بمجالات حوكمة أخرى أكثر تخصصاً؛ مثل حوكمة الذكاء الاصطناعي (Mäntymäki et al., 2022)؛ إذ يمكن دعم تنفيذ حوكمة البيانات بواسطة مختلف التقنيات الحديثة والناشئة.

وطبقاً لما ذكره Weber et al. (2009)، هناك ثلاثة أبعاد رئيسية لحوكمة البيانات، وهي: أدوار جودة البيانات، ومجالات القرار، والمسؤوليات، وهي تشكل معًا ما يعرف بمصفوفة تعيين المسؤوليات (Responsibility Assignment Matrix)، التي تساعد على توثيق أدوار وتفاعلات المشاركين المختلفين في أنشطة حوكمة البيانات، كما أضاف Kostoska and Kocarev (2019) بُعد القدرة على مراجعة استخدام البيانات وإدارتها، مع ضمان الشفافية والعدالة في عمليات صنع القرار، وأما Koltay (2016) فأكد بُعد تنفيذ العمليات بشكل

موحـد وقابـل للتكـرار لتمكين الشـفافية وتقليل التكاليـف، وسـلط Khatri and Brown (2010) الضـوء علـى سـبعة أبعـاد مختلفة لحوكمـة البيانات، وهـي: جودة البيانـات، والأمان، والهندسـة المعماريـة، ودورة حيـاة البيانـات، والبيانـات الوصفية، وتخزيـن البيانات، والبنيـة التحتية. تمثل هذه الأبعاد جوانب مختلفة من إدارة البيانات وحوكمتها يجب معالجتها لتحقيق حوكمة البيانات بشـكل فعال، وأما Mikalef and Krogstie (2018)؛ فقد تبنيا أبعاد Weber et al. (2009) التي سـبقت الإشـارة إليها (الممارسـات الهيكلية والممارسـات الإجرائية أو التشـغيلية والممارسـات العلاقية) وقاما بوضع تسـعة أسـئلة، تقيس حوكمة البيانات طبقاً لهذه الأبعاد، وتمتاز بالوضوح وعدد الأسئلة المحدود؛ ومن ثم اعتمدت في هذه الدراسة.

لقد سلط Cornforth and Simpson (2002) الضوء على الحاجة إلى أخذ عامل حجم المنظمة بعين الاعتبار في أبحاث الحوكمة بصفتها أحد المؤشرات التنظيمية المهمة، كما أشار Ahmadi et al. (2022) إلى أثر حجم المنظمة على تحديد نطاق حوكمة البيانات وآلياتها. فضلاً عن ذلك، قد يلعب المستوى التعليمي والخبرة العملية للموظفين دورًا حيويًا في نجاح حوكمة البيانات، وهو ما أكده Smith (2016)؛ إذ أبرز أهمية التعليم والخبرة في حوكمة البيانات بشكل فعال. وعليه؛ صيغ الفرض الأول على النحو الآتي:

**الفرض الأول:** *يوجد اختلاف ذو دلالة إحصائية في تقديرات الخبراء لدرجة ممارسة حوكمة البيانات في المنظمات التي يعملون بها، وفقاً لاختلاف خصائصهم الديمغرافية.*

**ثانياً: الذكاء الاصطناعي القابل للتفسير**

وجهت كتابات آلان تورنج (Alan Turing)؛ مثل "الآلات الذكية" في عام 1948 و "الحوسبة والآلة الذكية" في عام 1950 – مستقبل البحث العلمي في مجال الذكاء الاصطناعي (Tur-ing, 2009)، ومع مرور الوقت تطور الذكاء الاصطناعي، ولا يزال هناك جدل مستمر حول ماهية الذكاء في الآلات (Legg & Hutter, 2007). لقد أسهم توفر قواعد البيانات الضخمة؛ مثل ImageNet وSports1M وCOMPAS وCensus وHMDB51 و20Newsgroup وزيادة سرعة المعالجات وتطوير البرمجيات المتخصصة؛ مثل Pytorch وTensorflow وKeras في حدوث طفرات ملموسة ومتواترة في مجال الذكاء الاصطناعي (Samek et al., 2017)؛ إذ بدأت الموجة الأولى من الذكاء الاصطناعي بالنهج المبني على المعرفة وطرق التعلم الآلي المعتادة، ثم كانت الموجة الثانية مع مفهوم التعلم العميق؛ حيث يتم تعلم العوامل البسيطة في النموذج ثم تقوم الطبقات الإضافية الأعمق باستخراج عوامل أكثر تجريدًا، وبعدها تقوم الطبقات النهائية بتعيين المخرجات، وأما الموجة الثالثة؛ فيطلق عليها "الذكاء الاصطناعي العصبي الرمزي"، وهي مزيج من التعلم العميق والاستدلال الرمزي (Srihari, 2020). يشمل الذكاء الاصطناعي مجموعة متنوعة من المجالات الفرعية، بما في ذلك التعلم الآلي (Machine Learning)، والتعلم العميق (Deep Learning)؛ إذ يمكن التعلم الآلي الآلات من

التعلم من البيانات وتحسين أدائها مع مرور الوقت، وذلك من خلال تعرّف الاتجاهات داخل مجموعات البيانات (Datasets) واستخدامها لأغراض التنبؤ (Nabi et al., 2021)، وأما التعلم العميق؛ فهو جزء من التعلم الآلي، يستخدم الشبكات العصبية الاصطناعية (Artificial Neural Networks) لمعالجة البيانات وتحليلها؛ مما يمكن الآلات من اتخاذ قرارات معقدة وأداء المهام بدقة عالية، وهي نماذج معقدة جداً وعسيرة الفهم؛ ومن ثم تشبّه هذه النماذج بالصناديق السوداء (Sorantin et al., 2022).

إن الذكاء الاصطناعي القابل للتفسير (XAI) يسعى إلى تقديم تفسيرات تتسم بالشفافية وسهولة الفهم من قبل البشر (Arrieta et al., 2020). هذه التفسيرات توضح العلاقات السببية بين المتغيرات في نموذج الذكاء الاصطناعي (Mittelstadt et al., 2019)؛ إن هدف الذكاء الاصطناعي القابل للتفسير هو توفير تفسيرات لقرارات وسلوكيات نماذج الذكاء الاصطناعي؛ مما يمكن المستخدمين من فهم النتائج والوثوق بالتوصيات الناتجة من هذه الأنظمة (Sharma et al., 2022)؛ حيث يتضمن الذكاء الاصطناعي القابل للتفسير مجموعة من الإستراتيجيات التي تحسن مرونة النماذج وقابليتها للتفسير، وهو هدف عسير؛ إذ تدرّب نماذج الذكاء الاصطناعي باستخدام عدد ضخم من المتغيرات التي يصعب تتبعها (Chauhan & Palivela, 2021).

على الرغم من الاهتمام المتزايد بالذكاء الاصطناعي القابل للتفسير، فإنه ليس هناك اتفاق بشأن التعريفات والعلاقات بين مفاهيمه الرئيسية؛ مثل الشفافية (Transparency)، والتفسيرية (Interpretability)، والقابلية للتفسير (Explainability)، والقابلية للفهم (Understandability) (Verhagen et al., 2022). بداية وطبقاً لكارناب (Carnap) فالتفسير هو الاستبدال بمفهوم غامض وغير دقيق مفهوماً حديثاً أكثر وضوحاً ودقةً. قام Carnap بذكر عدد من معايير "كفاية المعلومات" التي يمكن تفسيرها، وهي التشابه (Similarity) (وجود كثير من العناصر المشتركة بين الموضوع الذي يستفسر عنه والتفسير) والدقة (Exactness) (تضمين التفسير في إطار لغوي واضح) والغني (Fruitfulness) (التفسير يجب أن يكون مفيداً وقابلاً للاستخدام في مجموعة متنوعة من التفسيرات الأخرى) (Carnap & Schilpp, 1963). كما أن هناك فرقاً جوهرياً بين التفسير والإجابة عن الأسئلة وفقاً لنظرية أشنشتاين (Achinstein theory), Achinstein (1983)، ويتمثل هذا الفرق في لهجة الخطابة (illocution)، التي تظهر في نية (Intent) المتحدث من الإجابة؛ إذ لا يتضمن التفسير إجابات عن السؤال الرئيسي فقط بل عن أسئلة أخرى أيضاً ذات علاقة، وهي الأسئلة التي تجيب عن الآتي: لماذا، لماذا لا، كيف، ماذا، ماذا لو، من، متى، أين، وكم؟ (Sovrano & Vitali, 2022). إن القابلية للتفسير تشير إلى قدرة خوارزميات ونماذج الذكاء الاصطناعي على تقديم تفسيرات قابلة للفهم والتفسير لقراراتها وتوقعاتها (Graziani et al., 2023)؛ مما يعزز عمليات اتخاذ القرار (Tiwari, 2023). من ناحية أخرى، تشير التفسيرية إلى التمثيل القابل للفهم لسلوك النموذج أو منطقه، وتوفير خطوات أو قواعد واضحة وشفافة تشرح عملية اتخاذ القرار

(Chaddad et al., 2023). كما ناقش Nyrup and Robinson (2022) حساسية التفسير للسياق، وأكدوا ضرورة اعتبار التفسير ظاهرة تتأثر بالسياق والجمهور المستهدف والغرض من نظام الذكاء الاصطناعي، وأما عن الشفافية في سياق الذكاء الاصطناعي القابل للتفسير؛ فيرى عبد الله والدياشي (2021) أن الشفافية هي مدى تقاسم المعلومات والمكاشفة بين الأطراف المعنية، واقترح Lipton (2018) إطاراً لمستويات الشفافية في أنظمة الذكاء الاصطناعي، ويتكون هذا الإطار من ثلاثة مستويات: مستوى الصندوق الزجاجي أو قابلية تحليل النظام إلى عناصره (Decomposability) (العمليات الداخلية لنظام الذكاء الاصطناعي مفهومة تمامًا للمستخدم)، ومستوى الصندوق الرمادي أو "شفافية الخوارزمية" (Algorithmic Transparency) (بينما قد لا يكون للمستخدم القدرة على الوصول إلى جميع تفاصيل النموذج، إلا أن لديه بعض التصور عن كيفية عمل النموذج)، ومستوى الصندوق الأسود (العمليات الداخلية لنظام الذكاء الاصطناعي مبهمة تماماً بالنسبة للمستخدم، ويطلق الممارسون مصطلح (Pedagogical) على هذا النوع من النماذج)، ولذلك عرّف Adadi and Berrada (2018) النموذج الشفاف بأنه "قابل للمحاكاة" (Simulatability)؛ بعبارة أخرى، الشفافية هي المضاد لمفهوم الصندوق الأسود (Sokol & Flach, 2021).

تواجه الذكاء الاصطناعي القابل للتفسير العديد من التحديات. أحد التحديات الرئيسية يتعلق بكيفية الحساب؛ إذ إن قياس قابلية التفسير يتطلب قياس جودة اختيار النماذج المرجعية، وإسناد القوة التفسيرية المناسبة للتدرجات الناتجة من النماذج الأصلية، ومدى توفير هياكل البيانات الملائمة، وعرض النتائج على المستخدمين بشكل سهل ومناسب (Xing & Sieber, 2023). تحدّ آخر هو وجود فجوة معرفية بين المطورين لنماذج الذكاء الاصطناعي والمستخدمين النهائيين؛ فمن العسير بناء هذه النماذج دون فهم عميق لمجال التطبيق؛ وذلك للتحقق من منطقية النتائج في كل خطوة من خطوات العمل (Salih et al., 2023). كما تثير الاعتبارات الأخلاقية تحديات أيضاً للذكاء الاصطناعي القابل للتفسير؛ إذ يشترط جودة البيانات وإدارة أصول البيانات والبيانات الوصفية عند دمج البيانات من مصادر متعددة للحصول على نتائج مسؤولة وموثوق بها (Fritzsche et al., 2023). أضف إلى ذلك أن تفسير النتائج قد يتطلب الاستبدال بنماذج عسيرة الفهم عالية الدقة أخرى أسهل في الفهم وأقل دقة، أو إضافة طبقة إضافية لتفسير النتائج إلى النموذج الأصلي؛ مما يؤدي إلى بطء الأنظمة، ومن المهم أيضاً أن نلاحظ أن استخدام التفسيرات في الذكاء الاصطناعي يمكن أن يكون له تأثيرات سلبية؛ فبينما يمكن أن تزيد التفسيرات من أداء المستخدمين والموثوقية في نظام الذكاء الاصطناعي، يمكن أيضاً أن تؤدي إلى الثقة العمياء والاعتماد عليها بشكل غير مناسب (Bansal et al., 2021).

بعض منهجيات الذكاء الاصطناعي القابل للتفسير تعمل قبل تدريب (Training) أو نشر النموذج (Deployment) ويطلق عليها (Ante-hoc) مثل RETAIN و (Srihari, BDL 2020)، وأما منهجيات (Post-Hoc) الأكثر شيوعاً؛ فتشير إلى مجموعة من المنهجيات تقوم بشرح النماذج

القائمة بالفعل كصناديق مغلقة؛ مثل SA و LRP و LIME (Delaunay et al., 2022)، ويمكن تصنيف منهجيات (Post–Hoc) إلى فئتين: الأساليب غير المعتمدة على النموذج (Model-Agnos-tic Methods)، والأساليب المعتمدة على النموذج (Model–Specific Methods). تهدف الأساليب غير المعتمدة على النموذج؛ مثل LIME و SHAP و GradCAM و LRP إلى توفير تفسيرات غير مرتبطة بهيكلية نموذج معين، وهي تركز على التقاط الأنماط المعقدة والخروج بتفسيرات عامة، ويعرض جدول (2) توصيفاً مختصراً لهذه المنهجيات.

**جدول 2**

**أهم منهجيات الذكاء الاصطناعي القابل للتفسير التي تناولتها الدراسات السابقة**

| المنهجية | الوصف |
|---|---|
| BDL | تستخدم المنطق البايزي (Bayesian Reasoning) في معاقبة نماذج التعلم العميق المفرطة في التعقيد. |
| GradCAM | تقوم بتصويرالمنطقة التي يركز عليها النموذج عند إجراء التنبؤات في شكل خريطة حرارية. |
| LIME | تقوم بإنشاء تفسيرات محلية؛ مما يعني أنها تشرح قرار النموذج المعقد بالنظر إلى نقطة بيانات معينة. |
| LRP | طريقة لقياس مدى تأثير المدخلات على نتيجة التصنيف النهائية من خلال حساب مدى ملاءمة كل طبقة من المخرجات لكل مدخل من المدخلات. |
| RETAIN | تعتمد على استخدام مفهوم الانتباه (Attention)، وهو أحد مفاهيم نماذج التعلم العميق المعقدة، وتساعد على إبراز أجزاء البيانات التي ساهمت في التنبؤ. |
| SA | إطار من ثلاثة مستويات لتطوير وتقييم التفسيرات حول سلوك نظام الذكاء الاصطناعي اعتماداً على الاحتياجات المعلوماتية للمستخدمين. |
| SHAP | توفر تفسيرات شاملة؛ مما يعني أنها تشرح السلوك العام للنموذج لمجمل الحالات. |

تشمل أبعاد الذكاء الاصطناعي القابل للتفسير الجوانب التقنية، والأخلاقية، والمساءلة، والتحقق. يتضمن البعد التقني تطوير وتطبيق التقنيات التي تجعل خوارزميات الذكاء الاصطناعي أكثر شفافية وقابلية للتفسير (تحويل الصندوق الأسود إلى صندوق أبيض)، ويشمل عدداً من العناصر، وهي: شفافية النموذج، ووظائف النموذج، وتصوير النموذج، ودمج التقنيات المختلفة (Hussain et al., 2021). يرتبط البُعد الأخلاقي بشكل وثيق بأغراض أصحاب

المصلحة والمخاوف المتعلقة بالعدالة والتحيز في أنظمة الذكاء الاصطناعي. إن دمج الأبعاد التقنية والأخلاقية ضروري لضمان تطوير الذكاء الاصطناعي المسؤول (McDermid et al., 2021)، وأما بعد المساءلة؛ فيعني وضوح الخطوات التي تتخذها خوارزميات الذكاء الاصطناعي للوصول إلى نتائجها، وهذا أمر ضروري لمشرعي القوانين، ومقدمي الخدمات، والمستخدمين على حدّ سواء (Hussain et al., 2021)، ويتضمن بعد التحقق اختبار وتقييم مكونات طرق الذكاء الاصطناعي القابل للتفسير؛ مثل الاستدلال المستهدف (Target Inference)، والتفسير (Explanation)، ونموذج التفسير (Explainer Model) ونموذج المفسّر لأجله (Explainee Model) (Di Martino & Delmastro, 2022). كما قدم Vilone et al. (2020) ستة عناصر لقياس مدى القدرة التفسيرية للنماذج القائمة على القواعد (Rule-based) بشكل كمي، وهي: الاكتمال، الصحة، الموثوقية، المتانة، عدد القواعد، متوسط طول القاعدة، ويعيب هذه الطريقة في القياس أنها لا تصلح لكل نماذج الذكاء الاصطناعي القابل للتفسير. اختصر Turek (2018) العناصر التي يمكن استخدامها في قياس قابلية تفسير نماذج الذكاء الاصطناعي في التالي: رضا المستخدم، ووضوح التفسير، وفائدة التفسير، وفهم النموذج، وتقييم مواطن القوة والضعف، والقدرة على توقع النتيجة المحتملة، وفهم كيفية تنفيذ الحلول المقترحة، وتحسن الأداء، والقدرة على تحديد الأخطاء وتصحيحها.

لقد أكد Malik et al. (2022) أن خبرة الموظفين تؤدي دوراً حاسماً في فهم نماذج الذكاء الاصطناعي، كما أبرز Nesterenko and Olefirenko (2023) وجود فرق ذي دلالة إحصائية في فهم مخرجات الذكاء الاصطناعي بين الذكور والإناث، ولم تكن هذه هي الإشارة الأولى لعامل الجنس؛ إذ سلط Frennert (2021) الضوء على التقاطع بين الجنسين والأنظمة القائمة على الذكاء الاصطناعي في سياق الصحة والرعاية الاجتماعية. وعليه؛ صيغ الفرض الثاني على النحو الآتي:

**الفرض الثاني:** *يوجد اختلاف ذو دلالة إحصائية في تقديرات الخبراء لدرجة ممارسة الذكاء الاصطناعي القابل للتفسير في المنظمات التي يعملون بها، وفقاً لاختلاف خصائصهم الديمغرافية.*

**ثالثاً: الأداء المؤسسي**

يعد الأداء المؤسسي العامل الأكثر أهمية الذي تبحث عنه المنظمات وتسعى جاهدة إلى تحقيقه من خلال تنفيذ الإستراتيجيات والممارسات المبتكرة (أبو الفتوح، 2022أ)، ويشير الأداء المؤسسي إلى الفعالية (Effectiveness) والكفاءة العامة (Efficiency) للمنظمة في تحقيق أهدافها، ويمكن فهم الأداء المؤسسي من منظورات مختلفة، بما في ذلك الأداء المالي، والكفاءة التشغيلية، ورضا العملاء، وإنتاجية الموظفين، والابتكار (Antony & Bhattacharyya, 2010). كما أن هناك عدة سمات للأداء المؤسسي تسهم في فعالية المنظمة ونجاحها، ويمكن أن تختلف هذه السمات اعتمادًا على الصناعة وحجم المنظمة وأهدافها، وتشمل هذه

السمات الأداء المالي ورضا العملاء وإنتاجية الموظفين والابتكار والمسؤولية الاجتماعية. اقترح Neely et al. (2002) إطار عمل ذي شهرة واسعة يطلق عليه "منشور الأداء" (Performance PRISM)، يعكس تعقيدات المنظمات وتعددية العلاقات مع أصحاب المصلحة؛ فعلى عكس بطاقة الأداء المتوازن، فإنه يعتمد على أصحاب المصلحة في تطوير إستراتيجية المنظمة، ويتكون من خمسة جوانب – الجوانب العلوية والسفلية هي رضا أصحاب المصلحة ومساهمة أصحاب المصلحة على التوالي، وأما الجوانب الثلاثة الجانبية؛ فهي الإستراتيجيات والعمليات والقدرات، وأما Zuriekat (2008)؛ فقد أكد أن بطاقة الأداء المتوازن تتعرض لسوء الفهم والتباسات في تفسير بعض الجوانب؛ مما يؤدي إلى الارتباك عند اتخاذ القرار، وأما Ondoro (2015)؛ فيرى أن بطاقات الأداء المتوازن ومنشور الأداء أصبحا غير كافيين لقياس الأداء المؤسسي؛ إذ يغيب عنهما مفهوم الاستدامة التي تعكسها الممارسات البيئية والاجتماعية والحوكمة المؤسسية (ESG) ويؤكد أن المنظمات التي تتجه نحو معالجة قضايا الاستدامة تحقق نموًّا أفضل وتقلص التكاليف وتحقق ربحية أعلى وتعزز علاقاتها مع أصحاب المصلحة وتحسن سمعتها؛ لذا قام Ondoro بتقديم نموذج تتكامل فيه عناصر بطاقات الأداء المتوازن مع أبعاد الاستدامة؛ فجعل الممارسات البيئية والاجتماعية والحوكمة المؤسسية في قلب هذا النموذج، ويحيط بقلب النموذج عناصر بطاقات الأداء المتوازن: العملاء والعمليات والابتكار والأداء المالي، ويعيب هذا النموذج التعقيد الشديد وصعوبة التنفيذ.

إن الأداء المؤسسي هو موضوع متعدد الجوانب، وقد قامت العديد من الأبحاث بدراسة جوانبه المختلفة، ولعل المقاييس المالية للأداء التي تتناول الربحية أو نمو المنظمة؛ مثل نمو المبيعات وعائد الاستثمار وعائد المبيعات وعائد حقوق الملكية وأرباح الأسهم وحصة السوق، هي أقدم هذه المقاييس (Woo & Wilard, 1983)، كما وجدت دراسة Agha et al. (2012) أن الكفاءة (Competence) لها تأثير قوي وإيجابي على الميزة التنافسية والأداء المؤسسي، وأضافت Saad (2008) عدد المنافسين كمتغير مهمّ يؤثر على أداء المنظمة. كما اقترح Sally and Jessica (2004) نموذجاً متعدد الأبعاد للأداء التنظيمي يؤكد تقييم بعدين رئيسيين: أداء الإدارة وأداء البرامج، ودعت الدراسة إلى استخدام مقاييس إدراكية وموضوعية لقياس الأداء بشكل كامل، وأفادت بوجود علاقات (Interconnections) بين أبعاد الإدارة وأبعاد البرنامج عند قياس الأداء المؤسسي، وقام Severgnini et al. (2018) بدراسة تأثير نظام قياس الأداء والتكيف التنظيمي على الأداء المؤسسي، وأظهرت نتائج الدراسة أن أبعاد التكيف التنظيمي: "تركيز الاهتمام" و "التشريع" و "اتخاذ القرارات الإستراتيجية" تؤثر في الأداء المؤسسي، وأن بعدي نظام قياس الأداء: "الاستكشاف" و "الاستغلال" يؤثران أيضاً في الأداء المؤسسي، كما قام Antony and Bhattacharyya (2010) بتحديد العديد من أبعاد الأداء المؤسسي، بما في ذلك الابتكار والتنافسية والإبداع والفعالية والإنتاجية والكفاءة والربحية، كما أكدا ضرورة قياس الأداء المؤسسي على كلٍّ من المستويين التنظيمي ووحدات العمل، واستخدم Gavrea et al. (2011)

عشـرة متغيـرات لقيـاس أداء المنظمة، وهي: الإسـتراتيجية والقيادة والهيـكل والجودة والابتكار والتطويـر وتقنيـة المعلومـات وقياس الأداء والموظفـون والحوكمة المؤسسـية والبيئة الخارجية، ومن بين هذه المتغيرات العشرة، لم يكن لمتغير الهيكل علاقة معنوية على الأداء المؤسسي. من ناحية أخرى، قارنت دراسة McCracken (2001) بين التصورات الذاتية لكبار المسؤولين وبيانات الأداء المالي الموضوعية لمستشـفيات بلغ عددها 60، وعلى الرغم من اختلاف الارتباطات بين المقاييس الذاتية والموضوعية، فإن عائد الأصول (ROA) وهامش التشغيل كانا أكثر المتغيرات المالية الذاتية قدرة على قياس الأداء. استخدم Hair et al. (2021) استبانة بسيطة تحتوي على بعدين للأداء المؤسسـي، وهما: الكفاءة الإدارية (ويشـمل فقرتين فقط: "المنظمة مُدارة بشـكل جيد" و "المنظمة لديها رؤية واضحة حول المستقبل") والأداء الاقتصادي (ويشمل ثلاث فقرات: "المنظمـة مسـتقرة اقتصاديـاً"، "المخاطـر التـي تواجه المنظمـة مقبولة مقارنة بمنافسـيها"، و "المنظمـة لديهـا إمكانـات للنمـو")، ويـرى الباحـث أن هذين البعديـن غير كافيين لقيـاس الأداء المؤسسـي مـن كافـة الجوانـب؛ إذ يفتقـر إلـى قيـاس رضـا العمـلاء والابتـكار. قامـت دراسـة Vorhies and Morgan (2005) بتعييـن ثلاثـة أبعـاد لـلأداء المؤسسـي، وهـي: رضـا العمـلاء، والفعاليـة فـي السـوق، والربحية، وتمتاز هذه الدراسـة بتقديم عدد مـن العناصر المحدودة ذات الصياغـة الواضحـة والقصيـرة، وأمـا Abueed and Aga (2019)؛ فقـد قامـا باسـتخدام ثلاثـة أبعـاد، وهـي: الأداء الابتكاري، والأداء السـوقي، والأداء المالـي، وتمتاز أيضاً بوجود عدد محدود مـن العناصـر. مـن خلال النظر في هذه الأبعاد كافة، يـرى الباحث أن ضم البعد الابتكاري الذي اقترحه Abueed and Aga إلى الأبعاد الثلاثة التي قدمها Vorhies and Morgan (رضا العملاء، والفعالية في السـوق، والربحية) سـيكون بمثابة قياس واقعي للأداء المؤسسـي؛ حيث تركز هذه الأبعـاد علـى المخرجـات والنتائج المباشـرة؛ وذلك بخلاف باقـي الأبعاد؛ مثل: القيـادة والهيكل والتعلم التنظيمي والثقافة التنظيمية وإنتاجية الموظف والدافعية والدعم التنظيمي والمسؤولية الاجتماعية وتقنية المعلومات والتغذية العكسـية والاسـتدامة والتكيف التنظيمي والإستراتيجية. ومن ناحية أخرى، فإن أكثر الأبعاد ذكراً في الدراسات السابقة، هي: رضا العملاء، والفعالية في السـوق، والربحية، والابتكار، والقيادة؛ إلا أن القيادة جاءت دوماً في سـياق الحديث عن الجودة، وليس الأداء المؤسسي.

أكدت العديد من الدراسات أن المستوى التعليمي للموظفين يؤثر على الأداء المؤسسي؛ مثل دراسة أبو الفتوح (2022ب) التي قاموا فيها بعمل تحليل لـ 130 دراسة، ووجد الباحثون أن الموظفين الذين يمتلكون مؤهلات أعلى يقومون بأداء مهامهم بشكل أفضل ويتمتعون بمستوى أعلى من الإنتاجية، كما أكد Donaldson (2001) على أن العوامل الموقفية (Contingency Factors) للمنظمة مثل حجم المنظمة ونشاطها قد يكون لها أثر على كفاءة المنظمة وأدائها. بالإضافة إلى ذلك، تشير دراسة الزواوي وآخرين (2019) إلى أن الموظفين الذين يمتلكون مؤهلات أعلى يميلون إلى البقاء في الوظائف لفترات أطول؛ مما يؤدي إلى تحسين الاستقرار المؤسسي وتحسن الأداء

المؤسسي في النهاية، وأما Saidu (2019)، فقد أكد أن المستوى التعليمي للإدارة العليا يتناسب مع الأداء المؤسسي؛ ومن ثم صيغ الفرض الثالث على النحو الآتي:

**الفرض الثالث:** *يوجد اختلاف ذو دلالة إحصائية في تقديرات الخبراء لدرجة ممارسة الأداء المؤسسي في المنظمات التي يعملون بها، وفقاً لاختلاف خصائصهم الديمغرافية.*

**رابعاً: العلاقة بين حوكمة البيانات والذكاء الاصطناعي القابل للتفسير**

تشير حوكمة البيانات إلى إدارة البيانات والتحكم فيها داخل المنظمة وضمان امتثالها للمتطلبات القانونية والتنظيمية (Khordadpour, 2023)، بينما يهدف الذكاء الاصطناعي القابل للتفسير إلى تطوير نماذج الذكاء الاصطناعي القادرة على تقديم تفسيرات مفهومة لأصحاب المصلحة (Arrieta et al., 2020). لذا، يمكن ملاحظة أن العلاقة بين حوكمة البيانات والذكاء الاصطناعي القابل للتفسير تكمن في هدفهما المشترك المتمثل في ضمان الشفافية والعدالة والمساءلة؛ إذ تلعب حوكمة البيانات دوراً مهماً في إنشاء معايير للبيانات والسياسات والإجراءات لجمع البيانات وتخزينها ومعالجتها لدعم الذكاء الاصطناعي القابل للتفسير (Khordadpour). لقد استخدم Zhu (2022) برنامج Citespace لإجراء تحليل ببليومتري على 1130 دراسة من عام 2010 إلى عام 2020؛ بهدف استكشاف الوضع الراهن لحوكمة البيانات في الصين، وأظهرت النتائج أن الكلمات المفتاحية المتعلقة بحوكمة البيانات تتضمن: البيانات الضخمة، جودة البيانات، معايير البيانات، إدارة البيانات، مشاركة البيانات، أصول البيانات، الذكاء الاصطناعي. وأشار Harrison et al. (2019) إلى أهمية حوكمة البيانات في سياق الذكاء الاصطناعي، وقدم Janssen et al. (2020) إطاراً مخصصاً لذلك.

لقد أكد Cath (2018) أن هناك ثلاثة جوانب لحوكمة الذكاء الاصطناعي؛ وهي الحوكمة القانونية والأخلاقية والتقنية، وهي مكمل بعضها بعضاً؛ فمن خلال تنفيذ ممارسات قوية لحوكمة البيانات (الحوكمة التقنية)، يمكن للمنظمات التأكد من دقة وموثوقية البيانات المستخدمة في نماذج الذكاء الاصطناعي (الحوكمة الأخلاقية والقانونية). بالإضافة إلى ذلك، يعد الذكاء الاصطناعي القابل للتفسير تتمة لأهداف حوكمة البيانات؛ لأنه وسيلة لفهم وتفسير القرارات التي تتخذها نماذج الذكاء الاصطناعي؛ مما يزيد من ثقة المستخدمين (Wang et al., 2023)، ويساعد أصحاب المصلحة وصانعي القرار على فهم المنطق وراء نتائج نماذج الذكاء الاصطناعي؛ مما يضمن العدالة والمساءلة (Javed et al., 2023). فضلاً عن ذلك، يسهم الذكاء الاصطناعي القابل للتفسير في معالجة التحديات الأمنية المرتبطة بحوكمة البيانات في تطبيقات الذكاء الاصطناعي؛ على سبيل المثال، يمكن أن يساعد الذكاء الاصطناعي القابل للتفسير في ضمان المصداقية (Authentication)، والنزاهة (Integrity)، واختبار مصادر البيانات والتحقق من نتائج أنظمة الذكاء الاصطناعي (Javed et al., 2023). من خلال توفير تفسير نتائج نماذج الذكاء الاصطناعي، يمكن تعزيز أمان الأنظمة والتطبيقات وموثوقيتها، وضمان استخدامها وفقًا

للمتطلبات القانونية والتنظيمية (Khordadpour)، وأكد Wulff and Finnestrand (2023) على أثر جودة البيانات في جودة النتائج المستخرجة من نماذج الذكاء الاصطناعي وقدرتها على التفسير الصحيح.

وعليه؛ فإن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير يعملان معاً لضمان استخدام الذكاء الاصطناعي بطريقة أخلاقية ومسؤولة؛ إذ تضمن حوكمة البيانات تدريب نماذج الذكاء الاصطناعي على البيانات الدقيقة، ويقوم الذكاء الاصطناعي القابل للتفسير بشرح نتائج نماذج الذكاء الاصطناعي ومبرراتها؛ بحيث يمكن مساعدة ومحاسبة القائمين على هذه النماذج ومتخذي القرار؛ ومن ثم فإن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير يوفران الشفافية والمساءلة والموثوقية، ومن خلالهما يمكن للمنظمات بناء الثقة مع المستخدمين وأصحاب المصلحة وتحسين عملية اتخاذ القرار وتقليل المخاطر.

**خامساً: العلاقة بين حوكمة البيانات والأداء المؤسسي**

إن ممارسات حوكمة البيانات الفعالة؛ مثل تقييم جودة البيانات وتوحيدها وتحسينها تسهم في تحسين جودة بيانات المنظمة (Ibrahim et al., 2021)، وتعد هذه الجودة العالية ضرورية لاتخاذ القرارات الصحيحة وتحسين أداء المنظمة؛ ولذا عندما تنفذ المنظمات حوكمة البيانات بفعالية، يمكنها تحقيق أهدافها بمزيد من الكفاءة (Knapton, 2020). فضلاً عن ذلك، تؤدي حوكمة البيانات دورًا مهماً في تعزيز قدرات المنظمة وتحقيق المكاسب في ظل الأسواق التنافسية (Mikalef et al., 2018). لقد أثبت Abueed and Aga (2019) وجود أثر لحوكمة البيانات على كل من الأداء المؤسسي وشفافية المعلومات، وأن إنشاء المعرفة متغير وسيط في هذه العلاقة. بالإضافة إلى ذلك، فإن حوكمة البيانات أمر ضروري لحماية خصوصية الأفراد؛ إذ تحتاج المنظمات إلى إجراءات قانونية وتقنية لضمان هذه الخصوصية (Sun & Whittington, 2023)؛ فمن خلال إدارة حوكمة البيانات بفعالية، يمكن للمؤسسات الحفاظ على ثقة أصحاب المصلحة وتجنب المخاطر والإشكالات القانونية. وبالعكس، أثبتت دراسة Steinfield et al. (2011) أن البيانات التي تتم حوكمتها بشكل سيئ قد تتسبب في خسائر للمنظمة؛ إذ يمكن أن تؤدي البيانات غير الكاملة أو غير الصحيحة إلى تنفيذ عمليات غير فعالة وفقدان الميزة التنافسية. وقدم Weber et al. (2009) نموذج حوكمة البيانات الموقفية (Contingency Approach for Data Governance)؛ حيث قام بدراسة أثر نموذج حوكمة البيانات في المنظمة على إدارة جودة البيانات في ظل وجود سبعة متغيرات وسيطة، وهي: إستراتيجية الأداء (متمثلاً في الربح، استخدام الأصول، النمو)، إستراتيجية التنافس، تنوع النطاق، توحيد العمليات، هيكل المنظمة، تنظيم السوق وإستراتيجية صنع القرار؛ وهو طرح مختلف، إذ يشير النموذج إلى أن الأداء المؤسسي يؤثر على حوكمة البيانات، بخلاف الطرح التقليدي الذي يفترض أن حوكمة البيانات تؤثر على الأداء المؤسسي، وقام Neff et al. (2013) بتسع دراسات حالة استكشافية في منظمات من مختلف القطاعات،

وأشارت النتائج إلى أن حوكمة البيانات لها أثر إيجابي على أداء عمليات المنظمة من خلال "ارتباط البيانات ببقية المتغيرات التنظيمية" (Data Relatedness) بوصفه متغيراً وسيطاً. وعليه؛ يمكن اختصار مظاهر أهمية حوكمة البيانات فيما يخص الأداء المؤسسي في تحسين عملية اتخاذ القرار، وزيادة الكفاءة، وتحسين الخدمات، وتقليل المخاطر؛ ويتم ذلك من خلال تعزيز حوكمة البيانات لجودتها وامتثالها في المنظمة، ومواءمة إستراتيجيتها مع إستراتيجية الأعمال وأهداف المنظمة (Charles et al., 2022). وعليه؛ صيغ الفرض الرابع على النحو الآتي:

**الفرض الرابع:** *هناك تأثير ذو دلالة إحصائية لحوكمة البيانات على الأداء المؤسسي بأبعاده المختلفة (رضا العملاء، الفعالية في السوق، الربحية، والأداء الابتكاري) مجتمعة.*

**سادساً: العلاقة بين الذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

اسكتشفت العلاقة بين الذكاء الاصطناعي القابل للتفسير والأداء المؤسسي في سياقات مختلفة. على سبيل المثال، في مجال المسؤولية الاجتماعية للشركات (Corporate Social Responsibility)، استخدم الذكاء الاصطناعي القابل للتفسير في فهم الأداء المالي (Lachuer & Jabeur, 2022)؛ فمن خلال استخدام الذكاء الاصطناعي القابل للتفسير، تم استخراج رؤى حول العوامل التي تؤثر في الأداء المالي.

تشير الدراسات بوضوح إلى قدرة الذكاء الاصطناعي القابل للتفسير على تحسين الأداء وزيادة ثقة العملاء (Lai & Tan, 2019)، هناك ثلاث دراسات ذكرت أن قابلية التفسير لا تحسن من الأداء البشري، وأن فهم قرارات أنظمة الذكاء الاصطناعي ليست مؤشراً على مستوى أداء اتخاذ القرار الفعلي (Alufaisan et al., 2021; Buçinca et al., 2020; Zhang et al., 2020)؛ ويرجع ذلك في الأساس إلى التغيرات المعرفية عند اتخاذ القرار؛ فالثقافة القائمة على البيانات عند اتخاذ القرار لم تتغلغل في نفوس كثير من قادة المنظمات الذين يميلون إلى الاعتماد على حدسهم وخبراتهم الشخصية عند اتخاذ القرار بدلاً من الشواهد والقرائن التي تمدهم بها أنظمة الذكاء الاصطناعي (Kahneman, 2011). إضافة إلى ذلك، وجد الباحث أن بعض هذه الدراسات لم تستخدم عينات احتمالية، بل اعتمدت على تطوع المشاركين من خلال خدمة التعهيد الجماعي (Amazon Mechanical Turk)، كما لم تحدّد شروط قبول المشاركين، وقامت إحدى هذه التجارب باستخدام أدوات غير قياسية يصعب التحقق منها؛ مثل الأداة jsPsych. من الملاحظ أن وجهة نظر المخالفين تكمن في تشكيكهم في قدرة التفسير على تحسين أداء اتخاذ القرار البشري تحديداً، وليس الأداء المؤسسي. لقد أكد Oliver (2019) أن نماذج الذكاء الاصطناعي القائمة على البيانات قادرة على تحسين عملية اتخاذ القرار؛ ومن ثم الأداء المؤسسي؛ فهو يرى أن التاريخ قد أظهر أن قرارات الإنسان ليست مثالية؛ إذ تخضع لتضارب المصالح والفساد والأنانية والتحيزات الإدراكية؛ مما يؤدي إلى عمليات ونتائج غير عادلة أو غير فعالة.

**سابعاً: العلاقة بين حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

قدمت دراسة Janssen et al. (2020) إطاراً مقترحاً لحوكمة البيانات معداً خصيصاً للذكاء الاصطناعي القابل للتفسير، وأكدت أن لحوكمة البيانات تأثيراً إيجابياً على أداء المنظمات. بشكل عام، يتعاون كل من حوكمة البيانات والذكاء الاصطناعي القابل للتفسير لتحقيق أداء مؤسسي متميز من خلال تحسين جودة البيانات والشفافية وقابلية التفسير لأنظمة الذكاء الاصطناعي. وقام Wamba-Taguimdje et al. (2020) بمراجعة 500 دراسة حالة من مواقع عالمية، وأكدوا أهمية الذكاء الاصطناعي في تحسين أداء المنظمات المختلفة، وأن التحدي الرئيسي الذي يواجه المنظمات الآن هو حوكمة نماذج الذكاء الاصطناعي.

لقد قام Abueed and Aga (2019) بتطبيق نمذجة المعادلات الهيكلية بطريقة المربعات الجزئية (PLS-SEM) على 180 شركة مدرجة في سوق عمان المالية، وأظهرت النتائج أن حوكمة بيانات هذه الشركات تؤثر تأثيراً مباشراً على أدائها الابتكاري والمالي والسوقي، كما أن حوكمة البيانات تؤثر تأثيراً مباشراً على شفافية المعلومات المؤسسية. يرى الباحث أن دراسة Abueed and Aga هي الأقرب إلى هذه الدراسة؛ نظراً للعلاقة الوثيقة بين شفافية المعلومات وقابلية التفسير التي تعد ثمرة نماذج الذكاء الاصطناعي القابل للتفسير. وعليه؛ صيغ الفرض الخامس على النحو الآتي:

**الفرض الخامس:** *يوجد تأثير ذو دلالة إحصائية للذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً على العلاقة بين حوكمة البيانات والأداء المؤسسي.*

في ضوء ما أسفرت عنه نتائج الدراسات السابقة وصياغة الفروض السابقة، يمكن اقتراح النموذج النظري للبحث في شكل (1).

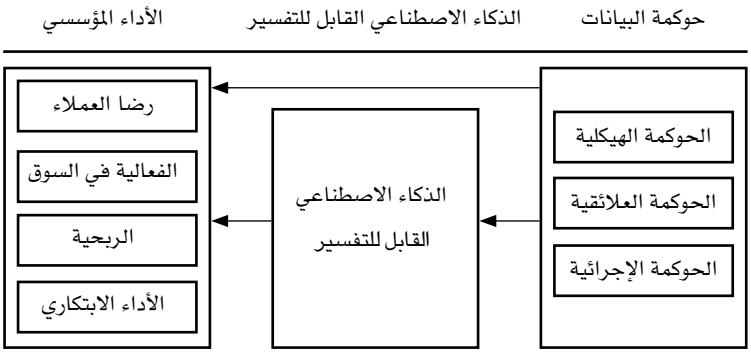


**شكل 1: النموذج البحثي المقترح**

**منهجية الدراسة**

**أولاً: منهج الدراسة**

صممت الدراسة وفق الأسلوب الكمي؛ بغرض اختبار الفروض التي سبق تناولها في الإطار النظري، ويتمثل في اختبار تأثير المتغير المستقل (حوكمة البيانات) في المتغير التابع (الأداء المؤسسي)، ومدى تأثير المتغير الوسيط (الذكاء الاصطناعي القابل للتفسير) على هذه العلاقة. استخدم المنهج الوصفي التحليلي من خلال اختبار فروض تفسر طبيعة العلاقة بين المتغيرات الثلاثة للمساعدة في التنبؤ بالنتائج، وتتمثل الظاهرة المستهدف وصفها ومعرفة مسبباتها في الأداء المؤسسي من خلال دراسة تأثير حوكمة البيانات والذكاء الاصطناعي القابل للتفسير، وتم ذلك من خلال جمع البيانات باستخدام أداة الاستبانة لغرض قياس تلك المتغيرات، واختبار الفروض الموضوعة باستخدام الاختبارات الإحصائية.

**ثانياً: مجتمع الدراسة**

يضم مجتمع البحث جميع المديرين التنفيذيين لتقنية المعلومات الذين ذكروا مهارة الذكاء الاصطناعي على موقع LinkedIn، وهو عدد غير معلوم لدينا ولكنه يقدر بالآلاف.

**ثالثاً: عينة الدراسة**

اعتمد الباحث على عينة عشوائية بسيطة، قوامها 384 مفردة من الخبراء، وحُسب حجم العينة وفقاً للمعادلة التالية (Zikmund et al., 2013):

$$\text{حجم العينة} = \frac{Z^2 \times p \times (1-p)}{e^2}$$

حيث إن:

Z= الدرجة المعيارية المقابلة لمعامل الثقة الذي اختير وهو 95%.

P= نسبة توافر الخاصية في المجتمع ولصعوبة قياسها نفترض أنها تمثل 50%.

e= هامش الخطأ المسموح به وهو 5%.

$$\text{لذا، فإن حجم العينة} = \frac{0.5 \times 0.5 \times (1.96)^2}{0.05 \times 0.05} = 384 \text{ مفردة}$$

وقد حرص الباحث على اتباع إجراءات المعاينة بشكل إحصائي سليم؛ إذ حُدّد المجتمع المستهدف (جميع المديرين التنفيذيين لتقنية المعلومات الملمين بتقنيات الذكاء الاصطناعي)، وتحديد مجتمع الدراسة المتاح (جميع المديرين التنفيذيين لتقنية المعلومات على موقع LinkedIn الذين ذكروا مهارة الذكاء الاصطناعي في صفحاتهم)، كما اعتمد على عينة عشوائية بسيطة لتجانس هذا المجتمع، وحُدّد حجمها بناء على القواعد الإحصائية لتحديد حجم العينة

العشوائية البسيطة لمجتمع لا محدود، واختيرت مفردات تلك العينة بشكل عشوائي باستخدام تطبيق (Apollo.io)، وهو تطبيق مدفوع يسمح للمستخدمين بالبحث في قاعدة بيانات LinkedIn بشروط محددة، والحصول على عينات عشوائية بسيطة؛ مما يعني الحصول على أعلى درجة ممكنة في تمثيل مجتمع الدراسة، وقد حُدّد المجتمع المتاح من خلال اختيار "تقنية المعلومات" من قائمة الإدارات والقطاعات، واختيرت كل الفئات الوظيفية ذات العلاقة بالإدارة الوسطى والعليا من الخيار المستوى الوظيفي، وأيضاً تحديد الذكاء الاصطناعي من قائمة التقنيات.

**جدول 3**

**خصائص عينة الدراسة**

| المتغير | | العدد | النسبة % |
|---|---|---|---|
| **الجنس** | ذكر | 270 | 70.3% |
| | أنثى | 114 | 29.7% |
| **الخبرة في الذكاء الاصطناعي القابل للتفسير** | أقل من سنة | 86 | 22.4% |
| | سنة إلى أقل من ثلاث سنوات | 90 | 23.4% |
| | ثلاث إلى أقل من خمس سنوات | 100 | 26% |
| | خمس سنوات فأكثر | 108 | 28.1% |
| **المؤهل العلمي** | بكالوريوس | 209 | 54.4% |
| | ماجستير | 143 | 37.2% |
| | دكتوراه | 32 | 8.3% |
| **عدد الموظفين في المنظمة التي تعمل بها** | أقل من 100 | 50 | 13% |
| | من 100 إلى 500 | 231 | 60.2% |
| | أكثر من 500 | 103 | 26.8% |
| **الدولة المقر للمنظمة التي يعمل بها الخبير*** | الولايات المتحدة | 89 | 23.2% |
| | الهند | 89 | 23.2% |
| | ألمانيا | 20 | 5.3% |
| | فرنسا | 18 | 4.6% |
| | كندا | 17 | 4.3% |
| | البرازيل | 15 | 3.8% |
| | أسبانيا | 10 | 2.7% |
| | الصين | 10 | 2.7% |
| | إيطاليا | 9 | 2.5% |
| | تركيا | 9 | 2.2% |
| | أخرى | 98 | 25.4% |

* حُصل على قيم هذا المتغير من Apollo.io وليس من استجابات المبحوثين.

**تابع/ جدول 3**

**خصائص عينة الدراسة**

| المتغير | | العدد | النسبة % |
|---|---|---|---|
| نشاط المنظمة التي يعمل بها الخبير* | تقنية المعلومات | 126 | 32.8% |
| | الاتصالات | 45 | 11.7% |
| | الخدمات المالية | 42 | 10.9% |
| | التسويق والإعلان | 30 | 7.8% |
| | الصحة والأدوية | 27 | 7% |
| | الاستشارات الإدارية | 21 | 5.5% |
| | أخرى | 93 | 24.1% |

* حُصل على قيم هذا المتغير من Apollo.io وليس من استجابات المبحوثين.

**رابعاً: أدوات الدراسة**

اعتمدت الدراسة الاستبانة كأداة، وهي من أكثر الأدوات المستخدمة في جمع البيانات. وُزّعت الاستبانة على عينة الدراسة من خلال تحويلها إلى استبانة إلكترونية باستخدام تطبيق SurveyMonkey، وقد صدرت بيانات العينة من الأداة Apollo.io واستوردت في الأداة SurveyMonkey، وهي الأداة المستخدمة في تصميم الاستبانة الإلكترونية وإرسلت- من خلال الأداة نفسها - عبر البريد الإلكتروني إلى مفردات العينة؛ ومن ثم جمعت الاستجابات، وعلى الرغم من الأداة Apollo.io توفر القدرة على إرسال البريد الإلكتروني وجمع الاستجابات فإنها لم تكن قوية (Robust) في هذا الشأن بالشكل الكافي؛ إذ تظهر كثيراً في مجلد البريد غير المرغوب (Junk) لدى المستجيبين؛ مما اضطر الباحث إلى استخدام وسيلة أفضل لإرسال الاستجابات وحفظها من خلال SurveyMonkey.

قسمت الأداة إلى جزأين: الجزء الأول يتعلق بالبيانات الشخصية والوظيفية ويضم: الجنس، عدد سنوات الخبرة في الذكاء الاصطناعي القابل للتفسير، أعلى مؤهل علمي، عدد الموظفين في المنظمة التي يعمل بها الخبير. أما الجزء الثاني؛ فيضم 34 عبارة مقسمة إلى ثلاثة محاور:

1. **المحور الأول:** حوكمة البيانات، ويضم 9 عبارات (من العبارة 1 إلى العبارة 9).
2. **المحور الثاني:** يتعلق بقياس الذكاء الاصطناعي القابل للتفسير، ويضم 8 عبارات (من العبارة 10 إلى العبارة 17)؛ واعتمد على القائمتين اللتين قدمهما Hoffman et al. (2023)، بناء على فحصهم للدراسات السابقة كما هو موضح في جدول (4)، فالقائمة الأولى تتحقق من جودة التفسيرات التي يقدمها الذكاء الاصطناعي القابل للتفسير، وتضم سبعة عناصر توجه إلى علماء البيانات في المقام الأول، والقائمة الثانية تتحقق من رضا أصحاب المصلحة عن هذه التفسيرات، وتضم أيضاً سبعة عناصر وتختلف في بعض عناصرها عن القائمة الأولى، وتوجه هذه الأسئلة إلى المستخدم النهائي في الأساس، ويرى الباحث أن هاتين القائمتين هما الأكثر واقعية وقابلية للتطبيق والأكثر حداثة.

**جدول 4**

**قائمة التحقق من جودة التفسير**

| طبقاً لخبراء الذكاء الاصطناعي | طبقاً لأصحاب المصلحة |
|---|---|
| الشرح يساعدني على فهم كيفية عمل النموذج. | من الشرح أعرف كيف يعمل النموذج. |
| شرح كيفية عمل النموذج مرضٍ. | شرح كيفية عمل النموذج مرضٍ. |
| شرح النموذج مفصل بما فيه الكفاية. | شرح طريقة عمل النموذج مفصل بما فيه الكفاية. |
| شرح كيفية عمل النموذج كامل بما فيه الكفاية. | هناك شرح كامل لكيفية عمل النموذج. |
| الشرح يساعدني على معرفة كيفية استخدام النموذج. | هناك شرح لكيفية استخدام النموذج. |
| الشرح يخبرني بمدى دقة النموذج. | هذا الشرح لكيفية عمل النموذج مفيد لأهدافي. |
| الشرح يخبرني بمدى موثوقية النموذج. | يوضح شرح النموذج مدى دقته. |

المصدر: Hoffman et al. (2023)

3. **المحور الثالث والأخير:** يتعلق بقياس الأداء المؤسسي، ويضم 17 عبارة (من العبارة 18 إلى العبارة 34).

تم الاعتماد على مقياس (Likert) الخماسي الذي يتدرج وفق الإجابات التالية: لا أوافق بشدة (1)، لا أوافق (2)، محايد (3)، أوافق (4)، أوافق بشدة (5). جدول (5) يوضح أبعاد الاستبانة والمصادر المعتمدة. للتأكد من الصدق الظاهري للاستبانة عرضت على (5) من المحكمين في مجال المنهجيات والإحصاء والإدارة وتحليل البيانات لتحديد مدى وضوح العبارات وملازمتها للأبعاد التي تقيسها.

**جدول 5**

**أبعاد الاستبانة والمصادر المعتمدة**

| المحور (الأبعاد) | المصادر | معامل الثبات |
|---|---|---|
| **حوكمة البيانات** | (Mikalef & Krogstie, 2018) | 0.94 |
| **الذكاء الاصطناعي القابل للتفسير** | (Hoffman et al., 2023) | 0.94 |
| **رضا العملاء** | | 0.82 |
| **الفعالية في السوق** | (Vorhies & Morgan, 2005) | 0.85 |
| **الربحية** | | 0.82 |
| **الأداء الابتكاري** | (Abueed & Aga, 2019) | 0.83 |

**خامساً: تقييم الاعتمادية والصلاحية للمقاييس المستخدمة في الدراسة**

تمثلت الخطوة الأولى في عملية تحليل البيانات الأولية الخاصة بهذه الدراسة في تقييم الاعتمادية Reliability والصدق Validity للمقاييس التي اعتمدت عليها الدراسة؛ بهدف تقليل أخطاء القياس العشوائية وزيادة درجة الثبات في المقاييس المستخدمة من ناحية، والتوصل إلى مقاييس يمكن الاعتماد عليها في دراسات مستقبلية من ناحية أخرى.

**تقييم الثبات**

استخدم أسلوب معامل الارتباط ألفا Alpha Correlation Coefficient، باعتباره أكثر أساليب تحليل الاعتمادية دلالة في تقييم درجة التناسق الداخلي بين محتويات أو بنود المقياس الخاضع للاختبار، وفي تحديد مدى تمثيل محتويات أو بنود المقياس للبنية الأساسية المطلوب قياسها وليس شيئاً آخر، علما بأن الحد المقبول لمعامل الارتباط ألفا (0.60) وفقاً لمستويات تحليل الاعتمادية في العلوم الاجتماعية (إدريس، 2012). وطبق أسلوب الارتباط ألفا على المتغيرات حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، وذلك بصورة إجمالية للمتغيرات ككل ولكل بعد من الأبعاد التي يتكون منها المتغير على حدة. وجدول (6) يوضح درجة الاتساق الداخلي لمحتويات المتغيرات المستخدمة في الدراسة.

**جدول 6**

**تقييم درجة الاتساق الداخلي بين محتويات المقاييس المستخدمة في الدراسة (مخرجات تحليل الاعتمادية (Reliability Analysis)*)**

| المتغيرات | عدد العبارات | معامل الثبات (Alpha) |
|---|---|---|
| الحوكمة الهيكلية | 2 | 0.79 |
| الحوكمة العلائقية | 2 | 0.75 |
| الحوكمة الإجرائية | 5 | 0.89 |
| **إجمالي مقياس حوكمة البيانات** | **9** | **0.94** |
| الذكاء الاصطناعي القابل للتفسير | 8 | 0.94 |
| رضا العملاء | 4 | 0.82 |
| الفعالية في السوق | 4 | 0.85 |
| الربحية | 4 | 0.82 |
| الأداء الابتكاري | 5 | 0.83 |
| **إجمالي مقياس الأداء المؤسسي** | **17** | **0.83** |

* طبق هذا الأسلوب على كل بعد من أبعاد المقياس على حدة، بالإضافة إلى المقياس الإجمالي.

أظهرت نتائج تحليل الاعتمادية في جدول (6)، أن معامل ألفا لمقياس حوكمة البيانات ككل يمثل نحو (0.94)، ومعامل ألفا الذكاء الاصطناعي القابل للتفسير يمثل نحو (0.94)، ومعامل ألفا للأداء المؤسسي ككل يمثل نحو (0.83)، وهي مؤشرات لدرجة عالية من الاعتمادية، وبناءً على نتائج التحليل السابق، فإن المقاييس المستخدمة في الدراسة تتمتع بدرجة عالية من الاتساق الداخلي بين محتوياتها، ويمكن الاعتماد عليها في المراحل اللاحقة من التحليل في هذه الدراسة، وتظهر الأشكال (2،3،4) توزيع استجابات المبحوثين في محاور الدراسة وأسئلتها، وهو ما يعرف بشكل بلتيير (Peltier)؛ أحد أفضل الرسوم البيانية لعرض استجابات المبحوثين وأكثرها تقدماً.

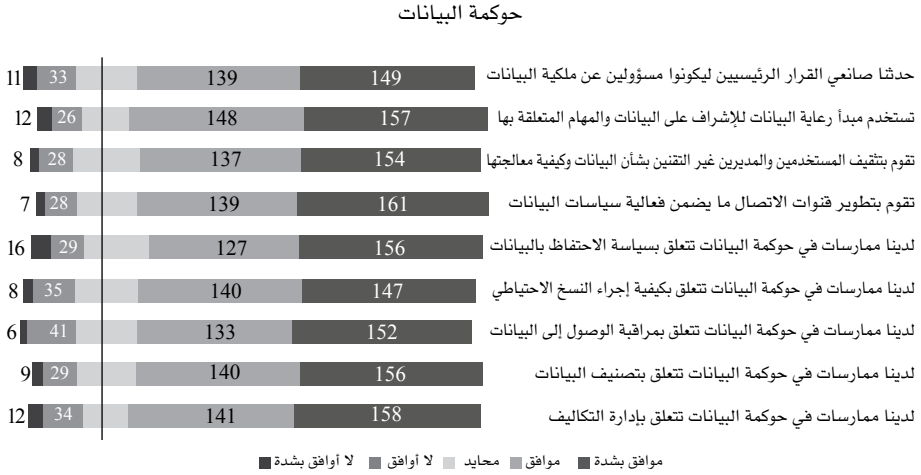


**شكل 2: توزيع استجابات المبحوثين في أسئلة متغير حوكمة البيانات**

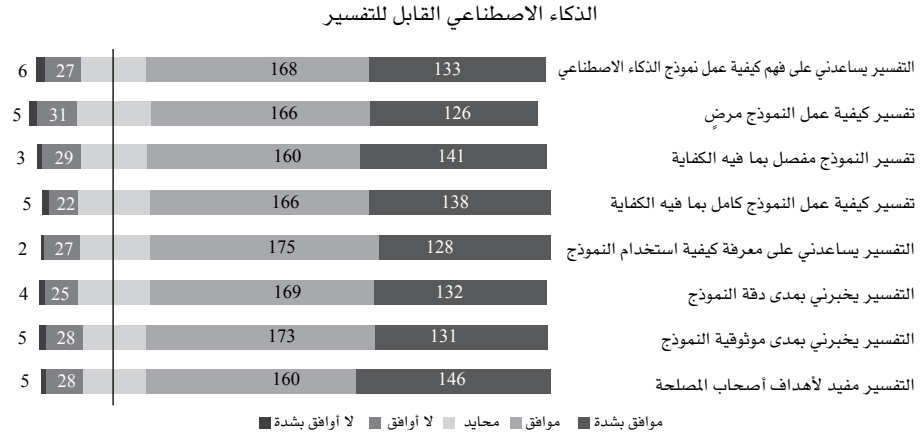


**شكل 3: توزيع استجابات المبحوثين في أسئلة متغير الذكاء الاصطناعي القابل للتفسير**

**شكل 4: توزيع استجابات المبحوثين في أسئلة متغير الأداء المؤسسي**

### تقييم الصدق والصلاحية

بالنسبة للتحقق من صدق المقاييس المستخدمة في الدراسة (قياس المفاهيم الأساسية التي من المفترض قياسها وليس شيئاً آخر، ولغرض زيادة التحقق من درجة مصداقية المقياس الخاضع للاختبار، استخدم الصدق البنائي :Construct Validity؛ وتعني تلخيص المتغيرات أو اختصارها في عدد أقل من العوامل أو تقسيم المتغيرات إلى مجموعات يطلق على كل منها اسم (عامل) ويعد التحليل العاملي الاستكشافي Exploratory Factor Analysis (AFE) أفضل

الأساليب لاختبار صلاحية بنية المقياس؛ من حيث قدرته على اقتراح الأبعاد الحقيقية للمقياس الخاضع للاختبار والتحقق مما إذا كانت هذه الأبعاد تتفق مع الأبعاد الأصلية في المقياس الأصلي الذي استخدم في الاستقصاء، إضافة إلى دوره في تخفيض البيانات من خلال استبعاد محتويات المقياس التي تحصل على معاملات تحميل أقل من المعاملات التي يقررها الباحث أو تكون محملة على أكثر من عامل من العوامل المستخرجة (إدريس، 2012).

أظهر التحليل – كما هو موضح في ملحق الدراسة – أن العوامل الرئيسية المستخرجة من الفقرات الأصلية الخاصة بالأداء المؤسسي تتمثل في أربعة عوامل (أبعاد) تضم 17 فقرة، وقد حددت الفقرات لتشكل العوامل الأربعة (الأبعاد) على أساس معاملات التحميل، التي تقرر أن تكون 0.50 أو أكثر لأي فقرة بشرط أن يكون التحميل على عامل واحد فقط (Hair et al., 2021). وفي ضوء ذلك لم تستبعد أي فقرة؛ نظراً لتمتع كل منها بمعامل تحميل أكبر من 0.50 على كل عامل من العوامل التي أمكن استخراجها. وأسهمت العوامل المستخرجة في تفسير نحو 65% من التباين الكلي في الفقرات الأصلية التي خضعت للتحليل؛ ومن ثم، فإن هذه النتيجة تشير إلى نجاح التحليل العاملي في استخراج العوامل الرئيسية الخاضعة للتحليل، وتعكس هذه النتيجة نجاح أسلوب التحليل العاملي في التحقق من مدى مصداقية المقياس الخاضع للاختبار على النحو الذي يساعد على تقليل احتمالات أخطاء القياس.

وبالنسبة لمقياس حوكمة البيانات، أظهرت النتائج أن العوامل الرئيسية المستخرجة من الفقرات الأصلية الخاصة بحوكمة البيانات تتمثل في عامل واحد يضم الفقرات التسعة كلها، وفي ضوء ذلك ضُمّت أبعاد متغير حوكمة البيانات الثلاثة (الحوكمة الهيكلية، الحوكمة العلائقية، الحوكمة الإجرائية) معاً واكتفي بالمتغير العام ككل، وأسهم هذا العامل في تفسير نحو 68.3% من التباين الكلي في الفقرات الأصلية التي خضعت للتحليل.

وبالنسبة لمقياس الذكاء الاصطناعي القابل للتفسير، أظهرت النتائج أن العوامل الرئيسية المستخرجة من الفقرات الأصلية الخاصة بالذكاء الاصطناعي القابل للتفسير تتمثل في عامل واحد، يضم 8 فقرات، وقد حُدّدت الفقرات التي تشكل هذا العامل على أساس معاملات التحميل التي تقرر أن تكون (0.50) أو أكثر لأي فقرة، بشرط أن يكون التحميل على عامل واحد فقط (Hair et al., 2021). وفي ضوء ذلك لم تستبعد أي فقرة، وأسهمت العوامل المستخرجة في تفسير نحو 68.8% من التباين الكلي في الفقرات الأصلية التي خضعت للتحليل.

وتأسيساً على ما توصل إليه من نتائج أسلوب التحليل العاملي، اتضح أن المقاييس الخاضعة للدراسة تتمتع بدرجة عالية من الصدق لمحتوياتها في قياس الذكاء الاصطناعي القابل للتفسير، وأبعاد الأداء المؤسسي؛ ومتغير حوكمة البيانات بعد ضم أبعاده معاً.

**نتائج الدراسة**

اعتمد الباحث على عدد من أساليب التحليل الإحصائية المناسبة لطبيعة متغيرات وبيانات الدراسة المتوافرة في برنامج SPSS 28 و SPSS Process Add-on، الذي يقدم أشهر الطرق لتحليل كل من المتغير الوسيط والوسيط التفاعلي (المعدل) في النماذج البسيطة؛ مثل هذا النموذج الذي لا يحتوي إلا على متغير وسيط واحد (Preacher & Hayes, 2008)، وذلك بعد اكتشاف العديد من المشكلات في طريقة Baron and Kenny (1986)، ولا ينصح أبداً بتطبيقه في أي دراسة حديثة (Bullock & Green, 2021)، وبينما من اليسير تطبيق ذلك النموذج القديم من خلال برنامج SPSS نفسه، نجد أن ذلك صار أكثر صعوبة باستخدام نموذج Hayes، وتقوم برمجية (Process) التي هي إضافة مجانية على برنامج SPSS بتنفيذ هذا التحليل وعرض النتائج، وتضمنت أساليب التحليل الإحصائية كلاً من:

– أسلوب تحليل التباين أحادي الاتجاه One Way ANOVA لتحديد مدى وجود اختلاف في تقديرات الخبراء نحو درجة ممارسات حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي في المنظمات.

– أسلوب تحليل الانحدار والارتباط المتعدد Multiple Regression and Correlation للتحقق من العلاقات بين المتغيرات الثلاثة للدراسة.

– استخدام اختبار t لعينتين مستقلتين بالنسبة لمتغير الجنس (ذكر وأنثى).

**أولاً: نتائج الإحصاء الوصفي لمتغيرات الدراسة**

يناقش هذا الجزء نتائج التحليل الإحصائي الوصفي الخاص بالإجابة عن الأسئلة الأول والثاني والثالث المتعلقة بتقديرات الخبراء لدرجة ممارسة منظماتهم لحوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، ويوضح جدول (7) أن متوسط ممارسات حوكمة البيانات بلغت (4.03)، وفيما يتعلق بالذكاء الاصطناعي القابل للتفسير، فبلغ المتوسط الإجمالي (4.04). وأما عن أبعاد الأداء الموسسي؛ فقد بلغ متوسط الأداء الابتكاري (4.05) محتلاً بذلك المرتبة الأولى، ويأتي رضا العملاء في المرتبة الثانية بمتوسط (4.03)، وفي المرتبة الثالثة الربحية بمتوسط (4.02)، وفي المرتبة الأخيرة كانت الفعالية في السوق بمتوسط (3.97). وبصفة عامة، فإن المتوسط الإجمالي لدرجة ممارسة الأداء المؤسسي بلغ (4.02). وهي جميعها تعبر عن مستويات عالية.

**جدول 7**

**التوصيف الإحصائي لمتغيرات الدراسة**

| المتغيرات | المتوسط | الانحراف المعياري | المستوى |
|---|---|---|---|
| حوكمة البيانات | 4.03 | 0.86 | مرتفع |
| الذكاء الاصطناعي القابل للتفسير | 4.04 | 0.77 | مرتفع |
| رضا العملاء | 4.03 | 0.75 | مرتفع |
| الفعالية في السوق | 3.97 | 0.84 | مرتفع |
| الربحية | 4.02 | 0.77 | مرتفع |
| الأداء الابتكاري | 4.05 | 0.70 | مرتفع |
| **إجمالي مقياس الأداء المؤسسي** | **4.02** | **0.76** | **مرتفع** |

**ثانياً: نتائج اختبار الفروض: الأول والثاني والثالث (توصيف تقديرات الخبراء نحو درجة ممارسة منظماتهم لحوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، وفقاً لاختلاف خصائصهم الديمغرافية):**

يناقش هذا الجزء نتائج التحليل الإحصائي الخاص باختبار الفروض: الأول والثاني والثالث، التي تتعلق بتحديد مدى وجود اختلاف في تقديرات العاملين نحو درجة ممارسة منظماتهم لحوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، وفقاً لاختلاف خصائصهم الديمغرافية (الجنس، عدد سنوات الخبرة، أعلى مؤهل دراسي، الوظيفة الحالية، وعدد الموظفين في المنظمة).

ولتحقيق ذلك، طبق اختبار T.Test لعينتين مستقلتين بالنسبة لمتغير الجنس (ذكر وأنثى)، وأسلوب تحليل التباين أحادي الاتجاه One-Way ANOVA، وذلك بالنسبة للمتغيرات الديمغرافية الأخرى، وهو موضح في جدول (8):

**جدول 8**

**تقديرات خبراء الذكاء الاصطناعي عن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

| المتغيرات | | الخصائص الديمغرافية | المتوسط | الانحراف المعياري | قيمة الاختبار * | مستوى الدلالة |
|---|---|---|---|---|---|---|
| حوكمة البيانات | الجنس | ذكر | 3.99 | 0.89 | 2.12 | 0.15 |
| | | أنثى | 4.13 | 0.78 | | |
| الذكاء الاصطناعي القابل للتفسير | | ذكر | 4.06 | 0.76 | 0.14 | 0.71 |
| | | أنثى | 4.00 | 0.80 | | |
| الأداء المؤسسي | | ذكر | 4.02 | 0.77 | 0.54 | 0.46 |
| | | أنثى | 4.02 | 0.73 | | |
| حوكمة البيانات | عدد سنوات الخبرة في مجال الذكاء الاصطناعي | أقل من سنة | 3.94 | 0.91 | 0.71 | 0.55 |
| | | سنة إلى أقل من ثلاث سنوات | 4.01 | 0.83 | | |
| | | ثلاث إلى أقل من خمس سنوات | 4.12 | 0.81 | | |
| | | خمس سنوات فأكثر | 4.03 | 0.90 | | |
| الذكاء الاصطناعي القابل للتفسير | | أقل من سنة | 3.82 | 0.87 | 3.76 | 0.01 |
| | | سنة إلى أقل من ثلاث سنوات | 4.05 | 0.71 | | |
| | | ثلاث إلى أقل من خمس سنوات | 4.19 | 0.75 | | |
| | | خمس سنوات فأكثر | 4.08 | 0.72 | | |
| الأداء المؤسسي | | أقل من سنة | 3.99 | 0.73 | 0.52 | 0.67 |
| | | سنة إلى أقل من ثلاث سنوات | 3.97 | 0.76 | | |
| | | ثلاث إلى أقل من خمس سنوات | 4.08 | 0.78 | | |
| | | خمس سنوات فأكثر | 4.03 | 0.75 | | |

* قيمة T للجنس وقيمة F لباقي الخصائص الديمغرافية.

**تابع/ جدول 8**

**تقديرات خبراء الذكاء الاصطناعي عن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

| المتغيرات | | الخصائص الديمغرافية | المتوسط | الانحراف المعياري | قيمة الاختبار * | مستوى الدلالة |
|---|---|---|---|---|---|---|
| حوكمة البيانات | أعلى مؤهل علمي | بكالوريوس | 4.00 | 0.88 | 0.26 | 0.77 |
| | | ماجستير | 4.06 | 0.83 | | |
| | | دكتوراه | 4.07 | 0.90 | | |
| الذكاء الاصطناعي القابل للتفسير | | بكالوريوس | 4.02 | 0.78 | 0.20 | 0.82 |
| | | ماجستير | 4.07 | 0.77 | | |
| | | دكتوراه | 4.06 | 0.72 | | |
| الأداء المؤسسي | | بكالوريوس | 3.99 | 0.75 | 0.54 | 0.58 |
| | | ماجستير | 4.06 | 0.75 | | |
| | | دكتوراه | 4.05 | 0.72 | | |
| حوكمة البيانات | عدد الموظفين في المنظمة | أقل من 100 | 3.89 | 0.90 | 1.12 | 0.33 |
| | | من 100 إلى 500 | 4.08 | 0.86 | | |
| | | أكثر من 500 | 3.99 | 0.85 | | |
| الذكاء الاصطناعي القابل للتفسير | | أقل من 100 | 3.99 | 0.69 | 0.70 | 0.50 |
| | | من 100 إلى 500 | 4.08 | 0.75 | | |
| | | أكثر من 500 | 3.98 | 0.85 | | |
| الأداء المؤسسي | | أقل من 100 | 3.95 | 0.74 | 0.34 | 0.71 |
| | | من 100 إلى 500 | 4.04 | 0.75 | | |
| | | أكثر من 500 | 4.01 | 0.77 | | |

* قيمة T للجنس وقيمة F لباقي الخصائص الديمغرافية.

**تابع/ جدول 8**

**تقديرات خبراء الذكاء الاصطناعي عن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

| المتغيرات | | الخصائص الديمغرافية | المتوسط | الانحراف المعياري | قيمة الاختبار * | مستوى الدلالة |
|---|---|---|---|---|---|---|
| حوكمة البيانات | | الولايات المتحدة | 3.97 | 0.90 | | |
| | | الهند | 3.99 | 0.92 | | |
| | | ألمانيا | 4.09 | 0.80 | | |
| | | فرنسا | 4.44 | 0.58 | | |
| | | كندا | 4.05 | 0.50 | | |
| | | البرازيل | 3.71 | 1.03 | 0.73 | 0.69 |
| | | أسبانيا | 4.03 | 0.80 | | |
| | | الصين | 4.01 | 0.91 | | |
| | | إيطاليا | 4.09 | 1.19 | | |
| | | تركيا | 3.99 | 0.97 | | |
| | | أخرى | 4.08 | 0.81 | | |
| الذكاء الاصطناعي القابل للتفسير | الدولة المقر للمنظمة التي يعمل بها الخبير | الولايات المتحدة | 4.06 | 0.74 | | |
| | | الهند | 4.02 | 0.73 | | |
| | | ألمانيا | 4.03 | 0.46 | | |
| | | فرنسا | 4.34 | 0.61 | | |
| | | كندا | 3.91 | 0.70 | | |
| | | البرازيل | 3.68 | 0.90 | 0.87 | 0.56 |
| | | أسبانيا | 3.94 | 0.93 | | |
| | | الصين | 4.30 | 0.64 | | |
| | | إيطاليا | 4.08 | 0.89 | | |
| | | تركيا | 3.83 | 1.27 | | |
| | | أخرى | 4.08 | 0.82 | | |
| الأداء المؤسسي | | الولايات المتحدة | 3.95 | 0.73 | | |
| | | الهند | 4.00 | 0.66 | | |
| | | ألمانيا | 4.02 | 0.49 | | |
| | | فرنسا | 4.27 | 0.43 | | |
| | | كندا | 4.00 | 0.48 | | |
| | | البرازيل | 3.82 | 0.82 | 1.01 | 0.44 |
| | | أسبانيا | 3.82 | 0.92 | | |
| | | الصين | 4.21 | 0.60 | | |
| | | إيطاليا | 4.03 | 1.08 | | |
| | | تركيا | 3.78 | 0.99 | | |
| | | أخرى | 4.11 | 0.52 | | |

* قيمة T للجنس وقيمة F لباقي الخصائص الديمغرافية.

**تابع/ جدول 8**

**تقديرات خبراء الذكاء الاصطناعي عن حوكمة البيانات والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي**

| المتغيرات | | الخصائص الديمغرافية | المتوسط | الانحراف المعياري | قيمة الاختبار * | مستوى الدلالة |
|---|---|---|---|---|---|---|
| حوكمة البيانات | | تقنية المعلومات | 3.98 | 0.88 | | |
| | | الاتصالات | 3.99 | 0.98 | | |
| | | الخدمات المالية | 4.19 | 0.80 | | |
| | | التسويق والإعلان | 3.99 | 0.78 | 0.79 | 0.58 |
| | | الصحة والأدوية | 4.00 | 0.83 | | |
| | | الاستشارات الإدارية | 3.80 | 1.24 | | |
| | | أخرى | 4.13 | 0.74 | | |
| الذكاء الاصطناعي القابل للتفسير | نشاط المنظمة التي يعمل بها الخبير | تقنية المعلومات | 4.06 | 0.74 | | |
| | | الاتصالات | 4.01 | 0.77 | | |
| | | الخدمات المالية | 4.11 | 0.56 | | |
| | | التسويق والإعلان | 3.86 | 0.84 | 0.59 | 0.74 |
| | | الصحة والأدوية | 4.08 | 0.72 | | |
| | | الاستشارات الإدارية | 3.88 | 1.04 | | |
| | | أخرى | 4.09 | 0.82 | | |
| الأداء المؤسسي | | تقنية المعلومات | 3.95 | 0.71 | | |
| | | الاتصالات | 4.03 | 0.67 | | |
| | | الخدمات المالية | 4.09 | 0.50 | | |
| | | التسويق والإعلان | 3.95 | 0.68 | 1.03 | 0.41 |
| | | الصحة والأدوية | 4.02 | 0.72 | | |
| | | الاستشارات الإدارية | 3.86 | 0.97 | | |
| | | أخرى | 4.13 | 0.50 | | |

* قيمة T للجنس وقيمة F لباقي الخصائص الديمغرافية.

من خلال جدول (8) يتبين وجود اختلاف معنوي في تقديرات الخبراء نحو درجة ممارسة منظماتهم للذكاء الاصطناعي القابل للتفسير، وفقاً لاختلاف عدد سنوات الخبرة؛ إذ إن قيمة ($F$) معنوية عند مستوى دلالة ($p < 0.05$)؛ وهذا يعني أن درجة ممارسة منظماتهم للذكاء الاصطناعي القابل للتفسير يختلف باختلاف عدد سنوات الخبرة، ويتضح ذلك من خلال خط الاتجاه (Trendline) في شكل (5).

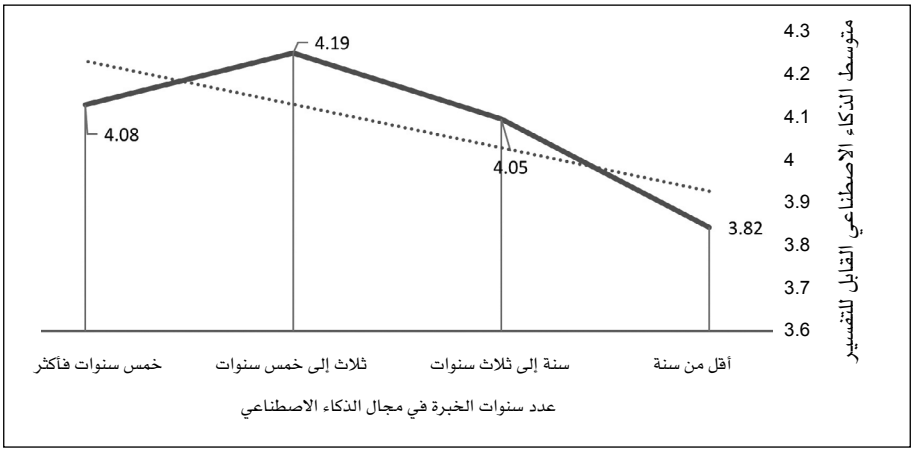


**شكل 5: متوسطات الذكاء الاصطناعي القابل للتفسير طبقاً لعدد سنوات الخبرة في مجال الذكاء الاصطناعي**

**ثالثاً: نتائج اختبار الفرضين: الرابع والخامس (العلاقة بين ممارسة حوكمة البيانات والأداء المؤسسي وتأثير الذكاء الاصطناعي القابل للتفسير على العلاقة بين حوكمة البيانات والأداء المؤسسي):**

لاختبار فروض الدراسة قام الباحث بإجراء أربعة مسارات انحدار منفصلة، وجدول (9) يبين ذلك.

**جدول 9**

**نتائج اختبار مسارات الانحدار المباشرة والأثر الوسيط**

| المتغيرات المستقلة | المتغيرات التابعة | | | |
|---|---|---|---|---|
| | الأداء المؤسسي (نموذج 1) | الذكاء الاصطناعي القابل للتفسير (نموذج 2) | الأداء المؤسسي (نموذج 3) | الأداء المؤسسي (نموذج 4) |
| الثابت | 1.615 | 1.753 | 1.688 | 1.170 |
| حوكمة البيانات | 0.596*** | 0.568*** | | 0.452*** |
| الذكاء الاصطناعي القابل للتفسير | | | 0.577*** | 0.254*** |
| F-Value | 612.717 | 260.553 | 323.127 | 384.630 |
| $R^2$ | 0.616 | 0.406 | 0.458 | 0.669 |
| VIF | | | | |
| حوكمة البيانات | 1.312 | 1.924 | | 1.682 |
| الذكاء الاصطناعي القابل للتفسير | | | 1.576 | 2.328 |

*** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$

تشير نتائج جدول (9) المتعلقة بتحليل انحدار النموذج الأول إلى وجود أثر معتبر لحوكمة البيانات على الأداء المؤسسي؛ إذ بلغت قيمة المعامل (0.596) عند مستوى الدلالة ($p < 0.001$) وبقيم ($R^2 = 0.616, F = 612.717$)؛ وهو ما يدعو إلى قبول الفرض الرابع للدراسة، وإثبات أثر حوكمة البيانات على الأداء المؤسسي. وتشير نتائج التحليل لانحدار النموذج في الجدول ذاته إلى وجود أثر معتبر لحوكمة البيانات على الذكاء الاصطناعي القابل للتفسير (المتغير الوسيط)؛ إذ بلغت قيمة المعامل (0.568) عند مستوى الدلالة ($p < 0.001$)، وبقيم ($R^2 = 0.406, F = 260.553$). كما يشير التحليل لانحدار النموذج الثالث على وجود أثر معتبر للذكاء الاصطناعي القابل للتفسير (المتغير الوسيط) على الأداء المؤسسي، وبلغت قيمة معامل الانحدار (0.577) عند مستوى الدلالة ($p < 0.001$)، وبقيم ($R^2 = 0.458, F = 323.127$). أما في نموذج الانحدار الرابع، الذي يضم حوكمة البيانات والذكاء الاصطناعي القابل للتفسير (المتغير الوسيط) كمتغيرات مستقلة لاختبار الأثر المباشر؛ فنلاحظ أن لحوكمة البيانات أثراً مباشراً معتبراً على الأداء

المؤسسي؛ إذ بلغت قيمة المعامل (0.452) عند مستوى دلالة ($p < 0.001$)، وهذه القيمة للمعامل تمثل انخفاضاً عن الأثر المباشر للعامل نفسه الذي كان (0.596) في نموذج الانحدار الأول؛ وهو ما يعني أن المتغير الوسيط (الذكاء الاصطناعي القابل للتفسير) يؤثر جزئياً في العلاقة بين حوكمة البيانات والأداء المؤسسي.

ولحساب الأثر غير المباشر، وطبقاً لرأي Hayes (2018)، يجب ضرب معامل المتغير الوسيط (الذكاء الاصطناعي القابل للتفسير) على المتغير التابع (الأداء المؤسسي) في ظل وجود المتغير المستقل بمعامل انحدار المتغير المستقل على المتغير الوسيط، وقيمة الأول (0.254). ويمكن استخلاصها من نموذج الانحدار الرابع، أما قيمة الثاني؛ فهي (0.568)؛ ويمكن استخلاصها من نموذج الانحدار الثاني. وبذلك تصبح قيمة الأثر غير المباشر لحوكمة البيانات في الأداء المؤسسي بوجود الذكاء الاصطناعي القابل للتفسير متغيراً وسيطاً (0.144)؛ وبالنظر إلى الحد الأدنى والحد الأعلى من فترة الثقة للأثر غير المباشر الموضحة في جدول (10)، يتبين أن قيمة (صفر) لا تمر من خلال هذه الفترة؛ مما يعني قبول الفرض الخامس (Hayes)، وأن الذكاء الاصطناعي القابل للتفسير يعمل متغيراً وسيطاً بين حوكمة البيانات والأداء المؤسسي، وأن هذه الوساطة هي وساطة جزئية مكملة؛ إذ إن جميع المعاملات موجبة. يبين جدول (10) نتائج اختبار الوساطة، والشكلان (6) و (7) يوضحان الأثر المباشر والأثر غير المباشر لذلك.

**جدول 10**

**نتائج اختبار الوساطة طبقا الفرض الخامس لطريقة Hayes (2018)**

| الأثر الإجمالي | الأثر المباشر | الأثر غير المباشر | مجال الثقة 95% | معامل T | المعنوية p |
|---|---|---|---|---|---|
| 0.596 | 0.452 | 0.144 | [0.24, 0.08] | 7.01 | 0.001 |

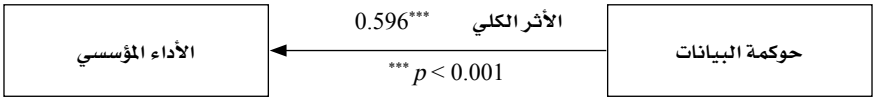


**شكل 6: الأثر الكلي للنموذج**

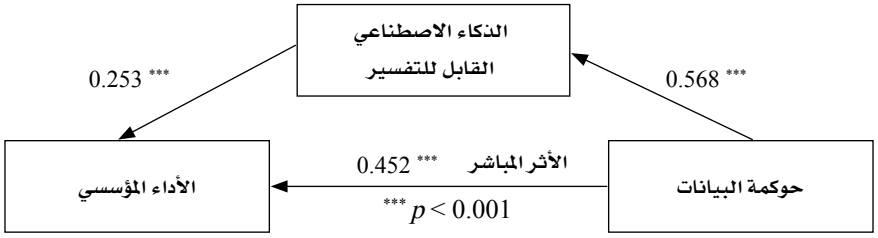


**شكل 7: الأثر المباشر وغير المباشر للنموذج**

**رابعاً: مناقشة النتائج**

تقدم هذه الدراسة العديد من الإسهامات على الجانب النظري والعملي: على الجانب النظري، هذه هي أول دراسة (على قدر علمنا) تقيس الأثر الوسيط للذكاء الاصطناعي القابل للتفسير على العلاقة بين متغيرين مهمين، هما: حوكمة البيانات والأداء المؤسسي، وهذه الدراسة تثري المكتبة العربية ولعلها تكون بداية مشاريع بحثية لدراسات حول دور التقنيات الناشئة في تحسين الأداء المؤسسي؛ إذ يعتبر الذكاء الاصطناعي القابل للتفسير متغيراً جديداً وسيطاً بين حوكمة البيانات والأداء المؤسسي. على الجانب العملي، تقدم الدراسة للمنظمات فهماً تاماً لتأثير البيانات بوصفها أصلاً حقيقياً، وتؤكد ضرورة التعامل معها بطريقة متسقة مع تقنيات الذكاء الاصطناعي القابل للتفسير، وذلك من خلال إستراتيجية مؤسسية كاملة لإدارة البيانات، حتى يمكنها استخدام هذه البيانات بشكل أفضل وأكثر ذكاء للوصول إلى نجاح أعمالها وتحسين أدائها، وتؤكد النتائج أيضاً أهمية شرح هدف النموذج وتصميمه ووظيفته الأساسية وتوفير جميع التفاصيل ذات العلاقة لأصحاب المصلحة؛ بحيث تصل المنظمات إلى قدر كاف من الشفافية المقبولة التي تلبي متطلبات حوكمة البيانات وحوكمة الذكاء الاصطناعي. اختبرت الدراسة دور حوكمة البيانات في تحقيق الأداء المؤسسي بوجود المتغير الوسيط (الذكاء الاصطناعي القابل للتفسير) وقد أثبتت ذلك وتوصلت الدراسة إلى النتائج الآتية:

1- تتوافر ممارسات حوكمة البيانات بدرجة مرتفعة في المنظمات التي يعمل بها خبراء الذكاء الاصطناعي بوسط حسابي بلغ (4.03).

2- تتوافر ممارسات الذكاء الاصطناعي القابل للتفسير بدرجة متوسطة وبوسط حسابي بلغ (4.04).

3- جاءت ممارسات الأداء المؤسسي بدرجة توافر مرتفعة وبوسط حسابي بلغ (4.02)، وجاء بعد الأداء الابتكاري في المرتبة الأولى وبفارق بسيط عن بعدي رضا العملاء والربحية، كما جاء بعد الفعالية في السوق في المرتبة الأخيرة؛ مما يدل على إمكانية تحسين هذا البعد المهمّ وضرورة إيلائه الاهتمام الكافي، خاصة لتأكيد الدراسات السابقة أهميته (Vorhies & Morgan, 2005).

4- دمجت أبعاد حوكمة البيانات الثلاثة (الحوكمة الهيكلية، الحوكمة العلائقية، الحوكمة الإجرائية) طبقاً لنتائج أسلوب التحليل العاملي الاستكشافي، وذلك بخلاف دراسة (2009) Weber et al. التي اقترحت تقسيم حوكمة البيانات إلى هذه الأبعاد الثلاثة.

5- أوضحت نتائج اختبار الفرض الأول أنه لا يوجد اختلاف حقيقي في اتجاهات المديرين التنفيذيين لتقنية المعلومات نحو حوكمة البيانات طبقاً لخصائصهم الديمغرافية، وهذا يخالف نتائج دراسة (2022) .Ahmadi et al التي أشارت إلى وجود أثر لحجم المنظمة على تحديد نطاق حوكمة البيانات وآلياتها، كما يخالف رأي (2016) Smith حول أهمية التعليم والخبرة في حوكمة البيانات بشكل فعال.

6- أوضحت نتائج اختبار الفرض الثاني أنه يوجد اختلاف حقيقي في اتجاهات المديرين التنفيذيين لتقنية المعلومات نحو الذكاء الاصطناعي القابل للتفسير وفقاً لعدد سنوات الخبرة في مجال الذكاء الاصطناعي، ويعتقد الباحث أن الاختلاف يرجع إلى زيادة سنوات الخبرة في هذا المجال؛ مما يجعل الخبير أكثر قدرة على ضبط تحيزاته النفسية مع تقنيات الذكاء الاصطناعي، ويجعله أكثر حنكة في عدم الإفراط أو التفريط في استخدام هذه التقنيات، وأكثر علماً بكيفية الاستخدام الصحيح ومواطن الخطر؛ وبذلك تتفق نتائج الدراسة مع نتائج (2022) .Malik et al التي أكدت على أن خبرة الموظفين تؤدي دوراً حاسماً في فهم نماذج الذكاء الاصطناعي. كما لا يوجد اختلاف معنوي في اتجاهات المديرين التنفيذيين لتقنية المعلومات ذوي الخبرة في الذكاء الاصطناعي في أي من الخصائص الديمغرافية الأخرى خلافاً لنتائج (2023) Nesterenko and Olefirenko اللذين ذكرا وجود فرق ذي دلالة إحصائية في فهم مخرجات الذكاء الاصطناعي بين الذكور والإناث.

7- أوضحت نتائج اختبار الفرض الثالث أنه لا يوجد اختلاف حقيقي في اتجاهات المديرين التنفيذيين لتقنية المعلومات نحو الأداء المؤسسي طبقاً لخصائصهم الديمغرافية، وهذا يخالف دراسة (2001) Donaldson الذي ذكر أن العوامل الموقفية للمنظمة؛ مثل حجم المنظمة ونشاطها، قد يكون لها أثر على كفاءة المنظمة وأدائها، ويخالف أيضاً نتائج (2019) Saidu الذي ذكر أن المستوى التعليمي للإدارة العليا يتناسب مع الأداء المؤسسي.

8- أوضحت نتائج اختبار الفرض الرابع وجود أثر ذي دلالة إحصائية لحوكمة البيانات بوصفها متغيراً مستقلاً في الأداء المؤسسي بوصفه متغيراً تابعاً في المنظمات التي يعمل بها خبراء الذكاء الاصطناعي، وقد استطاعت حوكمة البيانات تفسير 61.6% من التباين في متغير الأداء المؤسسي، وذلك عند دلالة ($p < 0.01$)، وذلك يتوافق مع الاتجاه العام في الدراسات السابقة (Abueed & Aga, 2019; Charles et al., 2022; Sun & Whittington, 2023)؛

إذ أكدت دراسة Sun and Whittington قدرة حوكمة البيانات على مساعدة المنظمات في تجنب المخاطر وزيادة ثقة العملاء، ويتوافق مع دراسة Ibrahim et al. (2021) الذي أكد أثر حوكمة البيانات في الأداء المؤسسي من خلال جودة البيانات بوصفها متغيراً وسيطاً، ومع دراسة Knapton (2020) الذي أكد أثر حوكمة البيانات في الأداء المؤسسي من خلال الابتكار والقدرات التنظيمية والتكيف التنظيمي بوصفها متغيرات وسيطة، ومع دراسة Charles et al. (2022) الذي أكد أثر حوكمة البيانات في الأداء المؤسسي من خلال ارتباطية البيانات بالمتغيرات التنظيمية (Data Relatedness) بوصفها متغيراً وسيطاً، وتبقى دراسة Neff et al. (2013) مخالفة للاتجاه العام في الدراسات السابقة ونتائج هذه الدراسة؛ إذ أكدت أثر الأداء المؤسسي في حوكمة البيانات، وهو الاتجاه المعاكس للعلاقة.

9- أوضحت النتائج وجود أثر ذي دلالة إحصائية لحوكمة البيانات بوصفها متغيراً مستقلاً في الذكاء الاصطناعي القابل للتفسير (المتغير الوسيط) بوصفه متغيراً تابعاً؛ إذ استطاعت حوكمة البيانات تفسير 40.6% من التباين في متغير الذكاء الاصطناعي القابل للتفسير، وذلك عند دلالة ($p < 0.01$)، ويتوافق بذلك مع الاتجاه العام في الدراسات السابقة (Arrieta et al., 2020; Javed et al., 2023; Khordadpour, 2023) التي أوضحت أن العلاقة بين حوكمة البيانات والذكاء الاصطناعي القابل للتفسير تكمن في هدفهما المشترك المتمثل في ضمان الشفافية والعدالة والمساءلة؛ إذ تؤدي حوكمة البيانات دوراً حاسماً في توفير البنية التحتية والعمليات اللازمة لدعم الذكاء الاصطناعي القابل للتفسير، وتعد هذه هي الدراسة الكمية الأولى التي تقيس هذه العلاقة الثنائية (على قدر علمنا).

10- بينت النتائج وجود أثر ذي دلالة إحصائية للذكاء الاصطناعي القابل للتفسير (المتغير الوسيط) في الأداء المؤسسي بوصفه متغيراً تابعاً في المنظمات التي يعمل بها خبراء الذكاء الاصطناعي؛ إذ استطاع الذكاء الاصطناعي القابل للتفسير تفسير 45.8% من التباين في متغير الأداء المؤسسي، وذلك عند دلالة ($p < 0.01$)، متوافقاً بذلك مع الاتجاه العام في الدراسات السابقة (Lachuer & Jabeur, 2022; Lai & Tan, 2019)، وخصوصاً دراسة Lachuer and Jabeur (2022)، وهي الدراسة الكمية الوحيدة التي قامت بقياس العلاقة بين الذكاء الاصطناعي القابل للتفسير وأحد أبعاد الأداء المؤسسي المهمة (الأداء المالي)، كما أن النتائج التي توصلت إليها الدراسة تعد رداً شافياً على الشكوك التي أثارتها الدراسات الثلاث (Alufaisan et al., 2021; Buçinca et al., 2020; Zhang et al., 2020) المخالفة للاتجاه العام في المجتمع البحثي التي تثبت هذه العلاقة، وتؤكد أن النتائج المخالفة كانت بسبب التحيزات المعرفية للمبحوثين واستخدام عينات غير احتمالية.

11- بينت نتائج اختبار الفرض الخامس أن وجود الذكاء الاصطناعي القابل للتفسير بوصفه متغيراً وسيطاً يؤثر في العلاقة بين حوكمة البيانات والأداء المؤسسي، وكان تأثيره جزئياً، وبلغت قيمة الأثر غير المباشر (0.1442)، وأما الأثر الكلي؛ فبلغت قيمته (0.596).

**الخلاصة**

لقد أثبتت نتائج الدراسة أن حوكمة البيانات تعد من المؤشرات المهمة التي يجب على المنظمات إعطاؤها جُلّ الاهتمام؛ لما لها من أثر كبير في تميزها في عصر البيانات، وتؤيد نتائج الدراسة بشكل مباشر المؤشرات النظرية الكثيرة والكمية المحدودة للغاية التي تُوضّح دور حوكمة البيانات في تحقيق الأداء المؤسسي، وأهمية الذكاء الاصطناعي القابل للتفسير في تحقيق الأداء المؤسسي المنشود، وهو ما يُعدّ إسهاماً للدراسة وخاصة في ظل عدم وجود دراسات كمية توضح طبيعة العلاقة بين حوكمة البيانات والأداء المؤسسي بوجود الذكاء الاصطناعي القابل للتفسير متغيراً وسيطاً في المنظمات؛ إذ خفض قيمة الأثر المباشر لحوكمة البيانات في الأداء المؤسسي وبقي أثره دالاً إحصائياً؛ وهو ما يعني ضرورة الاهتمام بالمتغير المستقل (حوكمة البيانات) والمتغير الوسيط (الذكاء الاصطناعي القابل للتفسير)، وأنه كلما كان الذكاء الاصطناعي القابل للتفسير أكبر عظمت فائدته وزاد دوره في تحقيق الأداء المؤسسي، وهو يتوافق مع ما أشارت إليه دراسة Janssen et al. (2020)؛ حيث ذكرت أنه من خلال تطبيق حوكمة البيانات الفعالة، يمكن للمؤسسات تحسين جودة البيانات المستخدمة في نظم الذكاء الاصطناعي القابل للتفسير؛ مما يؤدي إلى تحسين دقة هذه النظم وأدائها، وهذه الدراسة الكمية تؤكد ذلك، كما تتوافق أيضاً مع نتائج دراسة Abueed and Aga (2019)، اللذين أكدا أثر حوكمة البيانات بوصفها متغيراً مستقلاً على كل من الأداء المؤسسي وشفافية المعلومات بوصفهما متغيرين مستقلين.

وتمثلت أهم قيود الدراسة في الحدود الموضوعية والزمنية والبشرية وقيود المجتمع المتاح؛ إذ اقتصرت الدراسة على ثلاثة متغيرات، هي: حوكمة البيانات، والذكاء الاصطناعي القابل للتفسير والأداء المؤسسي، وكما أسلفنا في الدراسات السابقة، يمكن إضافة عدد من المتغيرات الوسيطة الأخرى للنموذج؛ مثل قدرات المنظمة (Mikalef et al., 2020)، وإنشاء المعرفة (Abueed & Aga, 2019)، وجودة البيانات (Ibrahim et al., 2021) والخروج بنموذج أكثر شمولاً، أما الحدود الزمنية؛ فقد أجريت الدراسة خلال فترة زمنية محددة استغرقت ثلاثة أشهر من السابع من مايو 2023 حتى الحادي عشر من يوليو 2023، وتمثلت الحدود البشرية في المديرين التنفيذيين لتقنية المعلومات الملمين بتقنيات الذكاء الاصطناعي، وأخيراً تمثل قيد المجتمع المتاح في جميع المديرين التنفيذيين لتقنية المعلومات ذوي الخبرة في مجال الذكاء الاصطناعي على موقع (LinkedIn) دون غيرهم. وعلى الرغم من بعض الانتقادات الموجهة

للاعتماد على مواقع التواصل الاجتماعي في المعاينة للبحوث والدراسات فإن هناك بعض الحالات التي يمكن للباحث فيها الاعتماد على المواقع وخاصة التي تتسم بدرجة من الجدية؛ مثل موقع LinkedIn، كما أشارت الدراسات الرصينة إلى إمكانية استخدامها في حال صعوبة الوصول إلى مفردات مجتمع الدراسة (Dusek et al., 2015; Leighton et al., 2021)، وهو الحال عند استقصاء رأي خبراء الذكاء الاصطناعي القابل للتفسير؛ حيث وجد الباحث صعوبة شديدة في الوصول إليهم بالطرق التقليدية. إن جميع المبحوثين يحتلون مناصب إدارية متوسطة أو عليا في المنظمات التابعين لها؛ بما يضمن قدرتهم على الإجابة الدقيقة عن جميع محاور الاستبانة.

تفتح هذه الدراسة مجالات بحثية مستقبلية عديدة، لعل أبرزها إجراء دراسات نوعية تقوم بتحليل جميع المتغيرات المحتملة من واقع الدراسات السابقة وتستخدم منهجيات؛ مثل النظرية المجذرة أو التحليل الموضوعي أو حتى التنقيب في البيانات، خاصة مع توافر أدوات، مثل Leximancer، التي تستخدم أدوات تعلم الآلة في تحليل النتائج ودراسة العلاقات بين المتغيرات والوصول إلى المتغيرات الأكثر أهمية وحساب أوزانها النسبية، ويقترح الباحث أيضاً أن تركز الأبحاث المستقبلية على قابلية التفسير طبقاً لأدوار أصحاب المصلحة وعلى كيفية صياغة التفسيرات بالتبعية، كما يقترح دراسة أثر الذكاء الاصطناعي القابل للتفسير على سمعة المنظمة وصورتها الذهنية من ناحية، وعلى مقاومة التغيير من ناحية أخرى. ويقترح أيضاً دراسة بعض المتغيرات الوسيطة الأخرى؛ كتصوير البيانات والميتافيرس، ودراسة أثر أنماط القيادة بوصفها متغيراً وسيطاً تفاعلياً معدلاً على نموذج الدراسة.

**المراجع**

أبو الفتوح، محمد السيد. (2022أ). أثر ممارسات مشاركة وتمكين العاملين على مستوى الأداء المؤسسي للمنظمات العامة. *مجلة كلية الاقتصاد والعلوم السياسية، 23*(1)، 205–255.

أبو الفتوح، محمد السيد. (2022ب). متطلبات تطبيق إستراتيجيات التحول الرقمي بالجامعات السعودية في مدينة الرياض وأثرها على فاعلية الأداء المؤسسي من وجهة نظر أعضاء هيئة التدريس. *مجلة الإدارة العامة، 63*(2)، 367–444.

إدريس، ثابت عبد الرحمن. (2012). *بحوث التسويق: أساليب القياس والتحليل واختبار الفروض*، الدار الجامعية، الإسكندرية.

الزواوي، شيماء مصطفى، عبد السلام، رمضان محمود، الطبلاوي، أسامة السيد. (2019). أثر التطوير التنظيمي في فاعلية الأداء المؤسسي دراسة تطبيقية على الجامعة العمالية في مصر. *مجلة الدراسات التجارية المعاصرة، 5*(6)، 223–264.

عبد الله، وضاح أحمد، الدياشي، محمد علي. (2021). نهج مفهوم الشفافية وإتاحة المعلومات. *مجلة ابن خلدون للدراسات والأبحاث*، *1*(1)، 114–126.

Abueed, R., & Aga, M. (2019). Sustainable knowledge creation and corporate outcomes: Does corporate data governance matter? *Sustainability*, *11*(20), 5575. https://doi.org/10.3390/su11205575

Achinstein, P. (1983). *The nature of explanation*. Oxford University Press.

Adadi, A., & Berrada, M. (2018). Peeking inside the black box: A survey on explainable Artificial Intelligence (XAI). *IEEE Access*, *6*, 52138-52160. https://doi.org/10.1109/ACCESS.2018.2870052

Addagada, T. (2022). *The impact of data governance on corporate governance and financial performance in firms.* SSRN. https://dx.doi.org/10.2139/ssrn.4364941

Agha, S., Alrubaiee, L., & Jamhour, M. (2012). Effect of core competence on competitive advantage and organizational performance. *International Journal of Business and Management*, *7*(1), 192. https://doi.org/10.5539/ijbm.v7n1p192

Ahmadi, S., Tavana, M., Shokouhyar, S., & Dortaj, M. (2022). A new fuzzy approach for managing data governance implementation relevant activities. *The TQM Journal*, *34*(5), 979-1012. http://dx.doi.org/10.1108/TQM-01-2021-0015

Alufaisan, Y., Marusich, L. R., Bakdash, J. Z., Zhou, Y., & Kantarcioglu, M. (2021). Does explainable Artificial Intelligence improve human decision-making? *Proceedings of the AAAI Conference on Artificial Intelligence*, *35*(8), 6618-6626. https://doi.org/10.1609/aaai.v35i8.16819

Antony, J., & Bhattacharyya, S. (2010). Measuring organizational performance and organizational excellence of SMEs–Part 2: An empirical study on SMEs in India. *Measuring Business Excellence*, *14*(3), 42-52. http://dx.doi.org/10.1108/13683041011074209

Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., & 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

Bansal, G., Wu, T., Zhou, J., Fok, R., Nushi, B., Kamar, E., & Weld, D. (2021). *Does the whole exceed its parts? The effect of AI explanations on complementary team performance*. In Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems, Japan.

Baron, R., & Kenny, D. (1986). The moderator–mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, *51*(6), 1173. http://dx.doi.org/10.1037//0022-3514.51.6.1173

Bauer, K., Hinz, O., Van der Aalst, W., & Weinhardt, C. (2021). Expl (AI) n it to me–explainable AI and information systems research. *Business & Information Systems Engineering*, *63*, 79-82. https://doi.org/10.1007/s12599-021-00683-2

Benfeldt, O. (2017). A comprehensive review of data governance literature. *Selected Papers of the IRIS, 8*, 120-133.

Boisot, M., & Canals, A. (2004). Data, information, and knowledge: Have we got it right? *Journal of Evolutionary Economics*, *14*, 43-67.

Bosco, M. (2020). A study on Artificial Intelligence interaction with organizational performance. *International Journal of Research in Engineering, Science and Management*, *3*(2), 483-486.

Bozkurt, Y., Rossmann, A., & Pervez, Z. (2022). *A literature review of data governance and its applicability to smart cities*. In Proceedings of the 55th Hawaii International Conference on System Sciences (HICSS 2022).

Buçinca, Z., Lin, P., Gajos, K. Z., & Glassman, E. (2020). *Proxy tasks and subjective measures can be misleading in evaluating explainable AI systems*. In Proceedings of the 25th International Conference on Intelligent User Interfaces, Italy.

Bullock, J., & Green, D. (2021). The failings of conventional mediation analysis and a design-based alternative. *Advances in Methods and Practices in Psychological Science*, *4*(4). https://doi.org/10.1177/25152459211047227

Carnap, R., & Schilpp, P. (1963). *The philosophy of Rudolf Carnap*. Cambridge University Press.

Cath, C. (2018). Governing Artificial Intelligence: Ethical, legal, and technical opportunities and challenges. *Philosophical Transactions of the Royal Society: A Mathematical, Physical and Engineering Sciences*, *376*(2133). https://doi.org/10.1098/rsta.2018.0080

Chaddad, A., Peng, J., Xu, J., & Bouridane, A. (2023). Survey of explainable AI techniques in healthcare. *Sensors*, *23*(2), 634. https://doi.org/10.3390/s23020634

Charles, V., Rana, N., & Carter, L. (2022). Artificial Intelligence for data-driven decision-making and governance in public affairs. *Government Information Quarterly, 39*(4). https://doi.org/10.1016/j.giq.2022.101742

Chauhan, T., & Palivela, H. (2021). *Study on significant drift in the domain of explainable Artificial Intelligence.* Preprints. https://doi.org/10.20944/preprints202110.0324.v1

Cheong, L., & Chang, V. (2007). *The need for data governance: A case study*. 18th Australasian Conference on Information Systems (ACIS), Australia.

Cohen, R. (2006). What's in a name? Data governance roles, responsibilities, and results factors. *DM Review*, *8*.

Cornforth, C., & Simpson, C. (2002). Change and continuity in the governance of nonprofit organizations in the United Kingdom: The impact of organizational size. *Nonprofit Management and Leadership*, *12*(4), 451-470.

Crews, C. (2019). What machine learning can learn from foresight: A human-centered approach: For machine learning–based forecast efforts to succeed, they must embrace lessons from corporate foresight to address human and organizational challenges. *Research-Technology Management*, *62*(1), 30-33. https://doi.org/10.1080/08956308.2019.1541725

De Prieëlle, F., De Reuver, M., & Rezaei, J. (2020). The role of ecosystem data governance in adoption of data platforms by Internet-of-Things data providers: Case of Dutch horticulture industry. *IEEE Transactions on Engineering Management*, *69*(4), 940-950. https://doi.org/10.1109/tem.2020.2966024

Delaunay, J., Galárraga, L., & Largouët, C. (2022). *When should we use linear explanations?* In Proceedings of the 31st ACM International Conference on Information & Knowledge Management, USA.

Di Francescomarino, C., & Maggi, F. (2020). Preface to the special issue on Artificial Intelligence for Business Process Management 2018. *Journal on Data Semantics*, *9*(1), 1-1. http://dx.doi.org/10.1007/s13740-020-00111-w

Di Martino, F., & Delmastro, F. (2022). Explainable AI for clinical and remote health applications: A survey on tabular and time series data. *Artificial Intelligence Review*, *56*(6), 5261–5315. https://doi.org/10.1007/s10462-022-10304-3

Donaldson, L. (2001). *The contingency theory of organizations*. Sage.

Dusek, G., Yurova, Y., & Ruppel, C. (2015). Using social media and targeted snowball

sampling to survey a hard-to-reach population: A case study. *International Journal of Doctoral Studies*, *10*, 279–299. https://doi.org/10.28945/2296

Fadler, M., & Legner, C. (2021). *Toward big data and analytics governance: Redefining structural governance mechanisms*. Hawaii International Conference on System Sciences. http://dx.doi.org/10.24251/HICSS.2021.691

Frennert, S. (2021). Gender blindness: On health and welfare technology, AI, and gender equality in community care. *Nursing Inquiry*, *28*(4). https://doi.org/10.1111/nin.12419

Fritzsche, M., Akyüz, K., Cano Abadía, M., McLennan, S., Marttinen, P., Mayrhofer, M., & Buyx, A. (2023). Ethical layering in AI-driven polygenic risk scores—New complexities, new challenges. *Frontiers in Genetics*, *14*. https://doi.org/10.3389/fgene.2023.1098439

Gavrea, C., Ilies, L., & Stegerean, R. (2011). Determinants of organizational performance: The case of Romania. *Management & Marketing*, *6*(2), 285-300.

Gheorghe, M. (2010). Audit methodology for IT governance. *Informatica Economica*, *14*(1), 32 - 42.

Graziani, M., Dutkiewicz, L., Calvaresi, D., Amorim, J. P., Yordanova, K., Vered, M., & Müller, H. (2023). A global taxonomy of interpretable AI: Unifying the terminology for the technical and social sciences. *Artificial Intelligence Review*, *56*(4), 3473-3504. https://doi.org/10.1007/s10462-022-10256-8

Grover, P., Kar, A., & Dwivedi, Y. (2022). Understanding Artificial Intelligence adoption in operations management: Insights from the review of academic literature and social media discussions. *Annals of Operations Research*, *308*(1-2), 177-213. https://doi.org/10.1007/s10479-020-03683-9

Hair, J., Hult, G., Ringle, C., & Sarstedt, M. (2021). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Sage Publications.

Harrison, T. F., Luna-Reyes, L., Pardo, T., De Paula, N., Najafabadi, M., & Palmer, J. (2019). *The data firehose and AI in government: Why data management is a key to value and ethics*. In Proceedings of the 20th annual International Conference on Digital Government Research, Dubai.

Hayes, A. (2018). Partial, conditional, and moderated moderated mediation: Quantification, inference, and interpretation. *Communication Monographs*, *85*(1), 4-40. https://doi.org/10.1080/03637751.2017.1352100

Hikmawati, S., Santosa, P., & Hidayah, I. (2021). Improving data quality and data governance using master data management: A review. *IJITEE (International Journal of Information Technology and Electrical Engineering)*, *5*(3), 90-95. https://doi.org/10.22146/ijitee.66307

Hoffman, R., Mueller, S., Klein, G., & Litman, J. (2023). Measures for explainable AI: Explanation goodness, user satisfaction, mental models, curiosity, trust, and human-AI performance. *Frontiers in Computer Science*, *5*. https://doi.org/10.3389/fcomp.2023.1096257

Hussain, F., Hussain, R., & Hossain, E. (2021). *Explainable Artificial Intelligence (XAI): An engineering perspective*. arXiv Preprint. https://doi.org/10.48550/arXiv.2101.03613

Ibrahim, A., Mohamed, I., & Satar, N. (2021). Factors influencing master data quality: A systematic review. *International Journal of Advanced Computer Science and Applications*, *12*(2). https://doi.org/10.14569/ijacsa.2021.0120224

Janssen, M., Brous, P., Estevez, E., Barbosa, L., & Janowski, T. (2020). Data governance: Organizing data for trustworthy Artificial Intelligence. *Government Information Quarterly*, *37*(3), 101493. https://doi.org/10.1016/j.giq.2020.101493

Javed, A., Ahmed, W., Pandya, S., Maddikunta, P., Alazab, M., & Gadekallu, T. (2023). A survey of explainable Artificial Intelligence for smart cities. *Electronics*, *12*(4), 1020. https://doi.org/10.3390/electronics12041020

Kahneman, D. (2011). *Thinking fast and slow*. Macmillan.

Khatri, V., & Brown, C. (2010). Designing data governance. *Communications of the ACM*, *53*(1), 148-152. https://doi.org/10.1145/1629175.1629210

Khordadpour, P. (2023). *The Security of Data Governance in the Digital World*. TechRxiv. https://doi.org/10.36227/techrxiv.22129160.v1

Knapton, K. (2020). *Exploring mid-market strategies for big data governance* [Doctoral dissertation, Walden University]. Walden University.

Koltay, T. (2016). Data governance, data literacy, and the management of data quality. *IFLA Journal, 42*(4), 303-312. https://doi.org/10.1177/0340035216672238

Kostoska, O., & Kocarev, L. (2019). A novel ICT framework for sustainable development goals. *Sustainability*, *11*(7), 1961. https://doi.org/10.3390/su11071961

Lachuer, J., & Jabeur, S. (2022). Explainable Artificial Intelligence modeling for corporate social responsibility and financial performance. *Journal of Asset Management*, *23*(7), 619-630. https://doi.org/10.1057/s41260-022-00291-z

Ladley, J. (2019). *Data governance: How to design, deploy, and sustain an effective data governance program*. Academic Press.

Lai, V., & Tan, C. (2019). *On human predictions with explanations and predictions of machine learning models: A case study on deception detection*. In Proceedings of the Conference on Fairness, Accountability, and Transparency, USA.

Legg, S., & Hutter, M. (2007). Universal intelligence: A definition of machine intelligence. *Minds and machines*, *17*(4), 391-444.

Leighton, K., Kardong-Edgren, S., Schneidereith, T., & Foisy-Doll, C. (2021). Using social media and snowball sampling as an alternative recruitment strategy for research. *Clinical Simulation in Nursing*, *55*, 37-42.

Lipton, Z. (2018). The mythos of model interpretability: In machine learning, the concept of interpretability is both important and slippery. *Queue*, *16*(3), 31-57. https://doi.org/10.1145/3236386.3241340

Malik, A., Thevisuthan, P., & De Sliva, T. (2022). *Artificial Intelligence, employee engagement, experience, and HRM*. In A. Malik (Ed.), Strategic human resource management and employment relations: An international perspective (pp. 171-184). Cham: Springer International Publishing.

Mäntymäki, M., Minkkinen, M., Birkstedt, T., & Viljanen, M. (2022). Defining organizational AI governance. *AI and Ethics*, *2*(4), 603-609. https://doi.org/10.1007/s43681-022-00143-x

McCracken, M., McIlwain, T., & Fottler, M. (2001). Measuring organizational performance in the hospital industry: An exploratory comparison of objective and subjective methods. *Health Services Management Research*, *14*(4), 211-219.

McDermid, J., Jia, Y., Porter, Z., & Habli, I. (2021). Artificial Intelligence explainability: The technical and ethical dimensions. *Philosophical Transactions of the Royal Society A*, *379*(2207), 1-18.. https://doi.org/10.1098/rsta.2020.0363

Mikalef, P., & Krogstie, J. (2018). *Big data governance and dynamic capabilities: The moderating effect of environmental uncertainty*. In Twenty-Second Pacific Asia Conference on Information Systems (PACIS), Japan.

Mikalef, P., Krogstie, J., Pappas, I., & Pavlou, P. (2020). Exploring the relationship between big data analytics capability and competitive performance: The mediating roles of dynamic and operational capabilities. *Information & Management*, *57*(2), 103169. https://doi.org/10.1016/j.im.2019.05.004

Mikalef, P., Pappas, I., Krogstie, J., & Giannakos, M. (2018). Big data analytics capabilities: A systematic literature review and research agenda. *Information Systems and E-Business Management*, *16*(3), 547-578. https://doi.org/10.1007/s10257-017-0362-y

Mittelstadt, B., Russell, C., & Wachter, S. (2019). *Explaining explanations in AI.* In Proceedings of the Conference on Fairness, Accountability, and Transparency, USA.

Nabi, W., Bansal, A., & Xu, B. (2021). Applications of Artificial Intelligence and machine learning approaches in echocardiography. *Echocardiography*, *38*(6), 982-992. https://doi.org/10.1111/echo.15048

Neely, A., Adams, C., & Kennerley, M. (2002). *The performance prism: The scorecard for measuring and managing business success*. Pearson Education.

Neff, A., Schosser, M., Zelt, S., Uebernickel, F., & Brenner, W. (2013*). Explicating performance impacts of IT governance and data governance in multi-business organisations*. Proceedings of the 24th Australasian Conference on Information Systems (ACIS), Australia.

Nesterenko, V., & Olefirenko, O. (2023). The impact of AI development on the development of marketing communications. *Marketing and Management of Innovations*, *14*(1), 169-181. https://doi.org/10.21272/mmi.2023.1-15

Nyrup, R., & Robinson, D. (2022). Explanatory pragmatism: A context-sensitive framework for explainable medical AI. *Ethics and Information Technology*, *24*(1), 13. https://doi.org/10.1007/s10676-022-09632-3

Oliver, N. (2019). *Governance in the era of data-driven decision-making algorithms*. In A. Gonzalez, M. Jansen (Ed.), Women Shaping Global Economic Governance (pp. 171-180). CEPR Press.

Ondoro, C. (2015). Measuring organization performance: From balanced scorecard to balanced ESG framework. *International Journal of Economics, Commerce and Management, 3*(11), 715-725.

Otto, B. (2011). *A morphology of the organisation of data governance*. The European Conference on Information Systems (ECIS) Proceedings at AIS Electronic Library (AISeL*)*. https://core.ac.uk/download/pdf/301351687.pdf

Panian, Z. (2010). Some practical experiences in data governance. *World Academy of Science, Engineering, and Technology*, *62*(1), 939-946.

Pokorná, J., & Částek, O. (2013). How to measure organizational performance in search for factors of competitiveness. *Acta Universitatis Agriculturae Et Silviculturae Mendelianae Brunensis*, *61*(2), 451-461.

Preacher, K., & Hayes, A. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in multiple mediator models. *Behavior Research Methods*, *40*(3), 879-891.

Saad W. (2008). Factors affecting the performance of retail stores among SMEs in Lebanon: An empirical analysis. *Arab Journal of Administrative Sciences*, *15*(3), 457-477.

Saidu, S. (2019). CEO characteristics and firm performance: Focus on origin, education, and ownership. *Journal of Global Entrepreneurship Research*, *9*(1), 29. https://doi.org/10.1186/s40497-019-0153-7

Salih, A., Boscolo Galazzo, I., Gkontra, P., Lee, A., Lekadir, K., Raisi-Estabragh, Z., & Petersen, S. (2023). Explainable Artificial Intelligence and Cardiac Imaging: Toward more interpretable models. *Circulation: Cardiovascular Imaging*, *16*(4), 346-356. https://doi.org/10.1161/circimaging.122.014519

Sally, C., & Jessica, E. (2004). Testing a multi-dimensional model of organizational performance: Prospects and problem. *Journal of Public Administration Research and Theory*, *14*(3), 395-416.

Samek, W., Wiegand, T., & Müller, K. (2017). *Explainable Artificial Intelligence: Understanding, visualizing, and interpreting deep learning models*. arXiv Preprint arXiv:1708.08296.

Severgnini, E., Vieira, V., & Cardoza Galdamez, E. (2018). The indirect effects of performance measurement system and organizational ambidexterity on performance. *Business Process Management Journal*, *24*(5), 1176-1199. https://doi.org/10.1108/bpmj-06-2017-0159

Sharma, J., Mittal, M., & Soni, G. (2022). Condition-based maintenance using machine learning and role of interpretability: A review. *International Journal of System Assurance Engineering and Management*, *15*(2), 1-16.

Smallwood, R. (2014). *Information governance, IT governance, data governance: What's the difference?* Information Governance: Concepts, Strategies, and Best Practices. Wiley.

Smith, D. (2016). *Governing data and data for governance: The everyday practice of Indigenous sovereignty*. In Kukutai T., Taylor J. (Ed.). Indigenous Data Sovereignty: Toward an Agenda, 117-135.

Sokol, K., & Flach, P. (2021). *Explainability is in the mind of the beholder: Establishing the foundations of explainable Artificial Intelligence*. arXiv Preprint arXiv:2112.14466.

Sorantin, E., Grasser, M., Hemmelmayr, A., Tschauner, S., Hrzic, F., Weiss, V., & Holzinger, A. (2022). The augmented radiologist: Artificial Intelligence in the practice of radiology. *Pediatric Radiology*, *52*(11), 2074–2086. https://doi.org/10.1007/s00247-021-05177-7

Sovrano, F., & Vitali, F. (2022). Generating user-centred explanations via illocutionary question answering: From philosophy to interfaces. *ACM Transactions on Interactive Intelligent Systems*, *12*(4), 1-32. https://doi.org/10.1145/3519265

Srihari, S. (2020). Explainable Artificial Intelligence. *Journal of the Washington Academy of Sciences*, *106*(4), 9-38.

Steinfield, C., Markus, M., & Wigand, R. (2011). Through a glass clearly: Standards, architecture, and process transparency in global supply chains. *Journal of Management Information Systems*, *28*(2), 75-108. https://doi.org/10.2753/mis0742-1222280204

Sun, F., & Whittington, J. (2023). *The challenge for cities of governing spatial data privacy.* In B. Frischmann, M. Madison, M. Sanfilippo (Ed.), Governing Smart Cities as Knowledge Commons (pp. 29-57). Cambridge University Press.

Tiwari, R. (2023). Explainable AI (XAI) and its applications in building trust and understanding in AI decision-making. *International J. Sci. Res. Eng. Manag*, *7*(1), 1-13. https://doi.org/10.55041/ijsrem17592

Turek, M. (2018). *Explainable Artificial Intelligence (XAI*). Defense Advanced Research Projects Agency.

Turing, A. (2009). *Computing machinery and intelligence*. In Epstein, R., Roberts, G., & Beber G. (Ed.). Parsing the Turing Test (pp. 23-65). Springer Netherlands.

Verhagen, R., Neerincx, M., & Tielman, M. (2022). The influence of interdependence and a transparent or explainable communication style on human-robot teamwork. *Frontiers in Robotics and AI*, *9,* Article 993997. https://doi.org/10.3389/frobt.2022.993997

Vilone, G., Rizzo, L., & Longo, L. (2020). *A comparative analysis of rule-based, model-agnostic methods for explainable Artificial Intelligence*. Proceedings for the 28th AIAI Irish Conference on Artificial Intelligence, Ireland.

Vorhies, D., & Morgan, N. (2005). Benchmarking marketing capabilities for sustainable competitive advantage. *Journal of Marketing*, *69*(1), 80-94.

Wamba-Taguimdje, S., Fosso Wamba, S., Kala Kamdjoug, J., & Tchatchouang Wanko, C. (2020). Influence of Artificial Intelligence (AI) on firm performance: The business value of AI-based transformation projects. *Business Process Management Journal*, *26*(7), 1893-1924. https://doi.org/10.1108/bpmj-10-2019-0411

Wang, R., Bush-Evans, R., Arden-Close, E., Bolat, E., McAlaney, J., Hodge, S., & Phalp, K. (2023). Transparency in persuasive technology, immersive technology, and online marketing: Facilitating users' informed decision making and practical implications. *Computers in Human Behavior, 139*, 1-15. https://doi.org/10.1016/j.chb.2022.107545

Watson, H., & McGivern, M. (2016). Getting started with business-driven data governance. *Business Intelligence Journal, 21*(1), 4-7.

Weber, K., Otto, B., & Österle, H. (2009). One size does not fit all: A contingency approach to data governance. *Journal of Data and Information Quality (JDIQ)*, *1*(1), 1-27.

What is explainable AI? IBM. (n.d.). https://www.ibm.com/topics/explainable-ai

Woo, C., & Willard, G. (1983). *Performance representation in business policy research: Discussion and recommendation.* In 23rd annual national meetings of the academy of management, Dallas.

Wulff, K. & Finnestrand, H. (2023). Creating meaningful work in the age of AI: Explainable AI, explainability, and why it matters to organizational designers. *AI & SOCIETY*, 1-14. https://doi.org/10.1007/s00146-023-01633-0

Xing, J., & Sieber, R. (2023). The challenges of integrating explainable Artificial Intelligence into GeoAI. *Transactions in GIS*, *27*(3), 626–645.

Zhang, Y., Liao, Q., & Bellamy, R. (2020). *Effect of confidence and explanation on accuracy and trust calibration in AI-assisted decision making*. In Proceedings of the 2020 conference on fairness, accountability, and transparency, Spain.

Zhu, Q. (2022). Visual measurement analysis of domestic data governance research based on citespace. *Frontiers in Business, Economics and Management*, *4*(1), 1-5. https://doi.org/10.54097/fbem.v4i1.393

Zuriekat M. (2008). The balanced scorecard approach in Jordanian manufacturing companies: A contingency approach. *Arab Journal of Administrative Sciences*, *15(3),* 423-455.

**مديح نايل الجداوي**، أستاذ نظم المعلومات المساعد وخبير الدراسات التطبيقية بمعهد الإدارة العامة بالرياض، والباحث بمركز المعلومات ودعم اتخاذ القرار برئاسة مجلس الوزراء المصري. حصل على درجة الدكتوراه في نظم المعلومات عام 2013 من كلية حاسبات ومعلومات، جامعة القاهرة، وهو مهتم بعلوم البيانات وعلاقتها بالعلوم الإدارية.
(gedawym@ipa.edu.sa)

مجلة فصلية أكاديمية
محكّمة تعنى بنشر البحوث
والدراسات القانونية والشرعية

# مجلة الحقوق

جامعة الكويت
KUWAIT UNIVERSITY

تصدر عن مجلس النشر العلمي - جامعة الكويت

رئيس التحرير

**أ. د. عبدالرحمن عبدالواحد الرضوان**

صدر العدد الأول في
يناير ١٩٧٧

## الاشتراكات

| | في الكويت | في الدول العربية | في الدول الأجنبية |
|---|---|---|---|
| الأفراد | ٣ دنانير | ٤ دنانير | ١٥ دولاراً |
| المؤسسات | ١٥ ديناراً | ١٥ ديناراً | ٦٠ دولاراً |

## المراسلات

**توجه جميع المراسلات إلى رئيس التحرير على العنوان الآتي:**

مجلة الحقوق - جامعة الكويت - ص.ب: ٦٤٩٨٥ الشويخ - ب 70460 الكويت

تلفون: ٢٤٩٨٤٧٦١ / ٢٤٩٨٤٧٦٣ ٩٦٥+ - موبايل: ٩٧٤٤٨٥٩٦ ٩٦٥+

**البريد الإلكتروني: jol@ku.edu.kw**

**jol.ku.kw@gmail.com**

**عنوان المجلة على شبكة الإنترنت: journals.ku.edu.kw/jol**

**P-ISSN: 1029 - 6069**
**E-ISSN: 2960 - 2742**