

أثر اعتماد مراقب الحسابات على نموذج هجين
من أدوات الذكاء الاصطناعي على تحسين جودة
حكمه بشأن الاستمرارية: دراسة تطبيقية على الشركات
المقيدة بالبورصة المصرية

د/ عصام حمدي مصطفى أمين

أستاذ المحاسبة والمراجعة المساعد

كلية التجارة - جامعة دمنهور

ملخص البحث

استهدف البحث دراسة واختبار مدى تأثير اعتماد مراقب الحسابات على نموذج هجين من أدوات الذكاء الاصطناعي على تحسين جودة حكمه بشأن الاستمرارية دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية خلال الفترة من 2018 وحتى 2021.

وقد توصل البحث، في ظل التحليل الأساسي، إلى وجود تأثير معنوي لاستخدام خوارزمية البحث التطويري (Evolutionary Search (EA) في تصميم نموذج نهائي لحكم مراقب الحسابات بشأن استمرارية الشركات، فضلا عن وجود تأثير إيجابي وتحسن وارتفاع في نتائج دقة النموذج النهائي لخوارزميات الذكاء الاصطناعي المختلفة على رأسهم خوارزمية الغابات العشوائية ثم الجار الأقرب يليها الشبكات العصبية الاصطناعية مقارنة بالاساليب التقليدية متمثلا في الانحدار اللوجستي.

كما توصل البحث في ظل اختبار للتنبؤ لعام (2021)، إلى تحقيق اعتماد مراقب الحسابات على نموذج هجين من أدوات الذكاء الاصطناعي نتائج دقة مرتفعة خاصة بالتنبؤ بحكم مراقب الحسابات باستمرارية / عدم استمرارية الشركات لعام (2021) مقارنة بالانحدار اللوجستي، وهو ما يؤكد التأثير الإيجابي لاستخدام أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن الاستمرارية.

الكلمات المفتاحية: الذكاء الاصطناعي، حكم مراقب الحسابات بشأن الاستمرارية، نموذج هجين، خوارزمية البحث التطويري، الغابات العشوائية، الشبكات العصبية الاصطناعية، الجار الأقرب

The Effect of Auditor Dependence on Hybrid Models From Artificial Intelligence Tools on Enhancing Auditor Going Concern Opinion Quality: An Applied Study on a Sample of Egyptian Stock Listed Companies

Abstract

The Research aims to study and test The Effect of Auditor Dependence on Hybrid Models From Artificial Intelligence Tools on Enhancing Auditor Going Concern Opinion Quality: An Applied Study on a Sample of Egyptian Stock Listed (EGX) Companies during the period from 2018 to 2021.

The results of fundamental analysis concluded that there is a significant effect for using Evolutionary Search (ES) algorithms for modeling the final model for predicting auditor going concern opinion, in addition to the positive effect and increase in the final model prediction accuracy rate using different artificial intelligence tools, where the random forest algorithm achieved the highest rate, followed by K-Nearest Neighbor (KNN) and finally Artificial Neural Network Algorithm (ANN) compared to traditional analysis tools, mainly logistic regression.

According to the prediction accuracy analysis for 2021, the research found that the artificial intelligence tools achieved the highest prediction rate for the auditor.

Based on the Predication Accuracy Analysis for 2021, the research found that Auditor Dependence on Hybrid Models From Artificial Intelligence Tools achieved the highest predication rate for Auditor Going Concern Opinion for Egyptian companies for 2021 compared with Logistic Regression, which assures the positive effect of using Artificial Intelligence tools on the Auditor Going Concern Predication Quality.

Keywords: Artificial Intelligence, Auditor Going Concern, Hybrid Model, Evolutionary Search, Random Forest, Artificial Neural Network, K-Nearest Neighbor, Logistic Regression

1- المقدمة

تساند التكنولوجيا معظم الشركات الكبرى وصولاً إلى الشركات متوسطة وصغيرة الحجم، كما تستخدم مؤسسات القطاعين العام والخاص تقنيات الذكاء الاصطناعي (AI) **Artificial Intelligence** للامتثال التنظيمي والمراقبة، وتقييم جودة البيانات، والكشف عن الغش (Sartori, Mazzucchelli, & Fraud, 2016). وعليه فقد زاد اهتمام الباحثين في مختلف المجالات العلمية وأيضاً في بيئة الأعمال وشركات الخدمات المالية بمجال الذكاء الاصطناعي بغرض تجميع البيانات وتحليلها وإتخاذ قرارات أفضل في بيئة العمل التنافسية (Joseph & Gaba, 2020; Lehner, Ittonen, Silvola, Ström, & Wührleitner, 2022)، وأدى تطور برامج المحاسبة وتطبيقات الذكاء الاصطناعي إلى تحول كامل في أنظمة المحاسبة حيث أن أجهزة الكمبيوتر والإنترنت وبرمجيات الحاسوب والنظم الخبيرة قد أثرت إيجاباً على أداء العمليات المحاسبية، وتمثل ذلك في زيادة الدقة والسرعة، وتحسين التقارير الداخلية والخارجية وزيادة المرونة والكفاءة (Fabris, Magalhães, & Freitas, 2017).

وبالنظر لمجال المحاسبة والمراجعة، فقد زاد الاعتماد على أدوات الذكاء الاصطناعي لتسهيل إجراء المعاملات المحاسبية في العديد من المجالات فضلاً عن زيادة سرعة معالجة البيانات مقارنة بالعمل البشري (Raisch & Krakowski, 2021) بالإضافة إلى تخفيض الوقت والجهد والمال المطلوب لأداء مهام المحاسبة والمراجعة وتوفير المعلومات وتحسين جودتها، وتجنب الغش وتقليل الأخطاء مما يزيد من كفاءة المحاسبين ومراقب الحسابات (Chi & Chu, 2021; Leitner-Hanetseder, Lehner, Eisl, & Forstenlechner, 2021; Nnenna & Amaka, 2020).

ومن منظور مراقب الحسابات فإن أدوات الذكاء الاصطناعي تساعد في العديد من المهام منها زيادة كمية البيانات المطلوب تحليلها، تقليل الوقت المطلوب للتحليل، والتغلب على القيود الداخلية لهيكل الرقابة الداخلية، فوفقاً للطرق التقليدية للمراجعة، يقوم مراقب الحسابات بتحليل جزء فرعي من البيانات بدلاً من البيانات جميعها، والتي تضمن احتمالية وجود مخاطر جوهرية لا يمكن اكتشافها وبالتالي الذكاء الاصطناعي يحسن من اختبار قاعدة البيانات كاملة في وقت قصير جداً لاكتشاف التحريفات الجوهرية بالاعتماد على تحليل المخاطر بدلاً من الطرق التقليدية للمراجعة وتقييم مدى انحراف البيانات عن مسار البيانات الأساسي، على سبيل المثال، اكتشاف تكرار المصروفات والعمليات المشبوهة والمصروفات المبالغ فيها (Alareeni & Hamdan, 2022). وأخيراً، تساهم أدوات الذكاء الاصطناعي في تحسين جودة عملية المراجعة من خلال دعم أحكام مراقب الحسابات بصفة عامة وبشأن استمرارية الشركة بصفة خاصة (Chu & Yong, 2021; Verhoeven, Mantelaers, & Zoet, 2022).

يشير افتراض الاستمرارية **Going Concern** أن الشركة قادرة على الاستمرار لفترة لا تقل عن 12 شهر من تاريخ الميزانية مع عدم وجود أية أدلة تشير إلى احتمالية أن تقوم الشركة بتخفيض نشاطها أو التصفية سواء كانت إجبار أو اختياري وفي ذلك الأمر، على مراقب الحسابات أن يقوم بإبداء حكمه الفني المحايد في مدى قدرة الشركة على الاستمرار، وهو الأمر الذي اعتبره العديد من مراقبي الحسابات غير مناسب نظرا لظروف عدم التأكد المحيطة بذلك الافتراض (حسن، 2021). وفي ذلك السياق، تم إصدار معيار المراجعة المصري رقم (570) الاستمرارية والذي يتطابق مع معيار المراجعة الدولي ISA570 (غير المعدل) لتحديد مدى مسؤولية الإدارة ومراقب الحسابات عن تقييم مدى سلامة افتراض الاستمرارية، والذي تعد على أساسه القوائم المالية، وذلك لمواكبه توقعات متخذي القرارات والمستفيدين من تقارير مراقبي الحسابات (معايير المراجعة المصري، 2008) ويعتبر السبب الرئيسي لفشل عملية المراجعة هو عدم سلامة حكم مراقب الحسابات بشأن استمرارية الشركة، والتي يرتبط بالحكم المهني لمراقب الحسابات فقد يكون مراقب الحسابات تحت ضغط الوقت والحوافز، والتي تؤثر على حكمه الخاص باستمرارية الشركة (Chen, 2019; Goo, Chi, & Shen, 2016).

ظل استخدام مراقب الحسابات لأساليب المراجعة التقليدية لعقود من الزمن، إلا أن ثورة التقدم التكنولوجي وتطلعات أصحاب المصالح، كان لزاما على مراقب الحسابات تطوير طرق المراجعة التقليدية تماشيا مع متطلبات التكنولوجيا وأصحاب المصالح (Jacky & Sulaiman, 2022) وارجعت بعض الدراسات خطأ التقدير والتنبؤ باستمرارية الشركة نتيجة الاعتماد على الوسائل التقليدية مثل تحليل الانحدار والتحليل التمييزي لإتخاذ حكم مراقب الحسابات بشأن استمرارية الشركة إلا أنها يعاب عليها نسبة الخطأ المرتفعة في التنبؤ (Chye Koh & Kee Low, 2004; M. A. Geiger, Gold, & Wallage, 2021; Zdolšek, Jagrič, & Kolar, 2022). في ذلك السياق، حاولت الدراسات تخفيض نسبة التنبؤ الخاطئة المرتفعة في حكم مراقب الحسابات لاستمرارية الشركة من خلال الدمج بين أدوات الذكاء الاصطناعي المختلفة، على سبيل المثال قامت (Chi & Shen (2022 باستخدام شجرة الغابات Support Vector Random Forest Trees في التنبؤ، والبعض اعتمد على تقنية الدعم الآلي Artificial Neural Network Machine (Goo et al., 2016)، والشبكات العصبية الاصطناعية Evolutionary Search (EA) للتعلم على عيوب الأساليب التقليدية (Jan, 2021) والبحث التطويري (Jan, 2021) لتحسين أحكام مراقب الحسابات بشأن استمرارية الشركة.

وبناء على ما سبق، فإن السؤال الأكثر منطقية هل يؤثر تصميم نموذج هجين باستخدام أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن استمرارية الشركات مقارنة بالأساليب التقليدية؟، هذا ماسيجيب عنه البحث الحالي نظريا وعمليا.

2- مشكلة البحث

أظهرت الدراسات السابقة وجود تأثير لادوات الذكاء الاصطناعي المختلفة على جودة حكم مراقب الحسابات بشأن الاستمرارية سواء كمرحلة أولية لاختيار المتغيرات الأكثر تأثيرا (Fernández, Sánchez (Serrano, Alaminos Aguilera, & Casado, 2018; Salehi & Fard, 2013) أو زيادة التنبؤ (Goo et al., 2016; Yeh, Chi, & Lin, 2014) لجودة حكم مراقب الحسابات بشأن استمرارية الشركة ولتحقيق هدف البحث تتمثل مشكلة البحث في الإجابة على السؤال التالي نظريا وعمليا: هل يؤثر استخدام أدوات الذكاء الاصطناعي لتصميم نموذج هجين على جودة حكم مراقب الحسابات بشأن الاستمرارية؟

3- هدف البحث

يهدف البحث استخلاص ما انتهت إليه الدراسات السابقة بشأن العلاقة بين استخدام أدوات الذكاء الاصطناعي وتحسين جودة حكم مراقب الحسابات بشأن الاستمرارية واختبار مدى تأثير تصميم نموذج هجين باستخدام أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن الاستمرارية مقارنة بالأساليب التقليدية.

4- أهمية البحث

تتبع أهمية البحث الأكاديمية من مسيرته للبحوث التي عنيت بدراسة واختبار العلاقة لتأثير نموذج هجين باستخدام أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن الاستمرارية. كما تكمن أهمية البحث العملية في كونه يسعى الى اختبار ذلك التأثير في الشركات غير المالية، المقيدة بالبورصة المصرية، وهو مجال بحثي يعاني من ندرة نسبية في مصر خاصة في ظل استخدام أدوات الذكاء الاصطناعي والتنبؤ بحكم مراقب الحسابات بشأن استمرارية الشركات المصرية.

ورغم كثرة دوافع البحث الان أن أهمها، مسايرة الجدل الأكاديمي حول مدى تأثير أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن استمرارية الشركات المقيدة بالبورصة، ومدى اختلاف هذه العلاقة باختلاف الأدوات المختلفة للذكاء الاصطناعي والأساليب التقليدية. فضلا عن ايجاد دليل عملي على مدى تأثير أدوات الذكاء الاصطناعي من عدمه من خلال اتباع منهجية متكاملة، وأخيرا مسايرة اتجاه البحوث الأجنبية، ذات الصلة، بإجراء تحليل أساسي وكذا اختبار تنبؤ لأدوات الذكاء الاصطناعي المختلفة والأساليب التقليدية لعام مستقبلي.

5- حدود البحث

يقتصر هذا البحث على دراسة واختبار اثر أدوات الذكاء الاصطناعي على جودة حكم مراقب الحسابات بشأن استمرارية الشركات، وذلك في عينة من هذه الشركات في الفترة من 2018 وحتى 2021. وبالتالي يخرج عن نطاق البحث اختبار تلك العلاقة بالشركات غير المقيدة بالبورصة المصرية، وتلك التي تعد قوائمها المالية بعملة أجنبية، وكذا المؤسسات المالية، وكذلك باقى الأدوات الأخرى المختلفة للذكاء الاصطناعي منها خوارزمية تقنية الدعم الألى، وخوارزميات مختلفة لشجرة القرارات وخوارزميات أخرى لم يتم استخدامها وأخيرا فإن قابلية نتائج البحث للتعميم مشروطة بضوابط تحديد مجتمع وعينة الدراسة.

6- خطة البحث

سوف يستكمل هذا البحث على النحو التالي:

- 1-6 الذكاء الاصطناعي: المفهوم، المميزات، الأدوات والمنظور المهني لأدوات الذكاء الاصطناعي.
- 2-6 دور حكم مراقب الحسابات بشأن الاستمرارية: المفهوم، والأهمية والمحددات.
- 3-6 تحليل العلاقة بين استخدام أدوات الذكاء الاصطناعي وجودة حكم مراقب الحسابات بشأن الاستمرارية.
- 4-6 منهجية البحث
- 5-6 النتائج والتوصيات ومجالات البحث المقترحة.

6-1 الذكاء الاصطناعي: المفهوم، المميزات، الادوات.

6-1-1 مفهوم أدوات الذكاء الاصطناعي

يعرف الذكاء الاصطناعي بأنه تطبيق أدوات حسابية لمعالجة المهام المحاسبية وجعل الآلة قادرة على اجراء المهام التي كان يمكن اجراؤها بواسطة الإنسان (Rohmah, Arisudhana, & Nurhantoro, 2022). أيضا، عرف (Munoko, Brown-Liburud, & Vasarhelyi (2020) الذكاء الاصطناعي بأنه نظام ذكي تم إنشاؤه لاستخدام البيانات وتحليل البيانات وكذلك أداء مهام معينة دون الحاجة إلى البرمجة. ويتمتع الذكاء الاصطناعي بقدرة قوية على إنشاء أساس لإتخاذ القرار (Abdulameer et al., 2022) وقد أوضح كل من (Ahmed, Mahmood, & Islam, 2016; Albashrawi & Lowell, 2016) أنه يمكن تصنيف التعلم في أدوات الذكاء الاصطناعي، إلى نوعين للتعلم من البيانات حتى تكون قادرة على استخلاص المعلومات أو التنبؤ بمخرجات النموذج كالتالي:

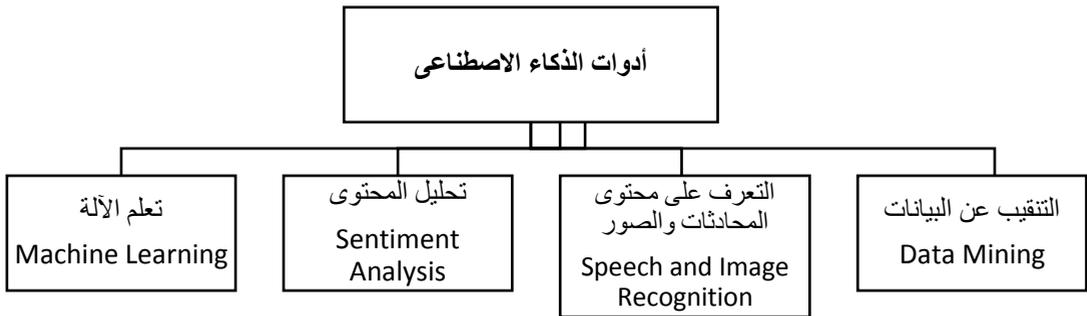
أولاً: التعلم الخاضع للرقابة Supervised Learning

في ظل التعلم الخاضع للرقابة يقوم الإنسان بتزويد الخوارزمية بعدد كبير من المدخلات للتنبؤ بقيمة المخرجات المطلوبة، بالإضافة إلى تزويد مدى دقة التنبؤات أثناء تدريب الخوارزمية، وبمجرد تنتهي الخوارزمية من التعلم، سوف يتم تطبيق ما تعلمته على بيانات جديدة. ويتضمن تفسير أو تصنيف العنصر المعين المستهدف في البيانات (المتغير التابع) بالاعتماد على بيانات تدريب مسبقه، وهي فعالة في البيانات التي تحتاج إلى درجة عالية من الدقة والسرعة والقدرة على التكيف مع الظروف المتغيرة.

ثانياً: التعلم غير الخاضع للرقابة Unsupervised Learning

في ظل التعلم غير الخاضع للرقابة لا توجد حاجة لتدريب الخوارزمية مع المخرجات المطلوبة وتستخدم في مهام معالجة أكثر تعقيداً من أنظمة التعلم الموجه. ويتضمن تفسير أو تصنيف العنصر المعين المستهدف في البيانات بدون الاعتماد على بيانات تدريب مسبقه، وغالباً تستخدم لتحديد الحالات أو المجموعات المتماثلة مثل قواعد الارتباط.

وفي ذلك السياق، أوضحت دراسة (Abdulameer et al., 2022) وجود تطورات كبيرة في أدوات الذكاء الاصطناعي مقارنة بالأعوام السابقة لتتضمن أدوات التنقيب عن البيانات (Gepp, Linnenluecke, O'Neill, & Smith, 2018) وخوارزميات التعلم الآلي وتحليل المحتوى (Kellogg, Valentine, & Christin, 2020; Lindebaum, Vesa, & Den Hond, 2020) للتعلم من البيانات والتي تستخدم لأداء أنشطة مختلفة ومعقدة، والتي يمكن توضيحها في الشكل رقم (1) التالي:



شكل 1: أنواع أدوات الذكاء الاصطناعي

المصدر: (Abdulameer et al., 2022)

أوضحت دراسة (Hahn, 2019) أن التعلم الآلي يسمح للتطبيقات البرمجية أن تصبح أكثر دقة في التنبؤ بالنتائج دون القيام ببرمجتها بشكل صريح، حيث يمكن بناء آليات لمعالجة البيانات والتعلم من تلقاء نفسها دون الحاجة إلى التوجيه المستمر وهو أسلوب تحليلي متعلق بالذكاء الاصطناعي، ويمكن تطبيق التعلم الآلي على مجالات مختلفة من الحوسبة لتصميم وبرمجة خوارزميات صريحة مع مخرجات عالية الأداء، على سبيل المثال تداول الأسهم عبر الإنترنت واكتشاف الغش ببطاقات الائتمان والتنبؤ باستمرارية الشركة، كلها أمثلة واقعية لتطبيق الذكاء الاصطناعي (Alzubi, Nayyar, & Kumar, 2018).

يخلص الباحث مما سبق إلى أن الذكاء الاصطناعي هو إعداد برامج مبنية على خوارزميات تحاكي القدرات الذهنية البشرية وأنماط عملها من خلال نوعان من التعلم والاستنتاج، سواء كان الخاضع للرقابة وغير الخاضع للرقابة، لإتخاذ قرار بناء على التدريب والتعلم وتطوير نفسها ذاتياً دون تدخل الإنسان بصورة أعلى كفاءة وفعالية ودقة من قرارات الإنسان.

6-1-2 مميزات الذكاء الاصطناعي

نظراً للأهمية الكبيرة لنظم الذكاء الاصطناعي وتكنولوجيا المعلومات الحديثة، وذلك لما توفره من مزايا وتسهيلات بناء على خصائصها التي تميزها، حيث تمثل دوراً كبيراً في تطوير العمل بالشركات والارتقاء بأدائها، وعليه ترى العديد من الدراسات منها (Biswas, Sinha, Purakayastha, & Marbaniang, 2014; Dhall, Kaur, & Juneja, 2020) أن أهم مزايا استخدام الذكاء الاصطناعي تتمثل في الآتي:

- إمكانية تمثيل المعرفة Knowledge representation

إن برامج الذكاء الاصطناعي على عكس البرامج الإحصائية تحتوي على أسلوب لتمثيل المعلومات إذ تستخدم هيكلية خاصة لوصف المعرفة، وهذه الهيكلية تتضمن الحقائق والعلاقات بين هذه الحقائق والقواعد التي تربط هذه العلاقات، ومجموعة الهياكل المعرفية تكون فيما بينها قاعدة المعرفة وهذه القاعدة توفر أكبر قدر ممكن من المعلومات عن المشكلة المراد إيجاد حل لها (Biswas et al., 2014).

- قابلية التعامل مع المعلومات الناقصة Imputation Missing Data

من الصفات الأخرى التي تستطيع برامج الذكاء الاصطناعي القيام بها هي قابليتها على إيجاد بعض الحلول حتى لو كانت المعلومات غير متوفرة بأكملها في الوقت الذي يتطلب فيه الحل، وإن تبعات عدم تكامل المعلومات يؤدي إلى استنتاجات أقل واقعية وأقل جدارة ولكن من جانب آخر قد تكون الاستنتاجات صحيحة (Mahapatra, Nayak, & Rout, 2020).

- القابلية على التعلم Ability to learn

من الصفات المهمة للذكاء الاصطناعي القابلية على التعلم من الخبرات والممارسات السابقة فضلا عن القابلية لتحسين الأداء من خلال الاخذ بعين الاعتبار الأخطاء السابقة، هذه القابلية ترتبط بالقابلية على تعميم المعلومات واستنتاج حالات مماثلة وانتقائية وإهمال بعض المعلومات الزائدة (Dutta, Dutta, & Raahemi, 2017).

- قابلية الاستدلال Reasoning Abilities

هي القدرة على استنباط الحلول الممكنة لمشكلة معينة ومن واقع المعطيات المعروفة والخبرات السابقة وتستخدم للمشكلات التي لا يمكن معها استخدام الوسائل التقليدية المعروفة للحل، هذه القابلية تتحقق على الحاسوب حيث يخزن جميع الحلول الممكنة إضافة إلى استخدام قوانين أو استراتيجيات الإستدلال وقوانين المنطق (Heye, 2021).

يخلص الباحث مما سبق إلى أنه على الرغم من تعدد مزايا الذكاء الاصطناعي من تمثيل المعرفة، التعامل مع البيانات الناقصة، التعلم والاستدلال على الحلول إلا أن الهدف الأساسي من استخدامها هو الحصول على المعلومات الصحيحة لإتخاذ القرار ولا تقدم جميع أدوات الذكاء الاصطناعي جميع المزايا إلا أن بعض الأدوات تخدم ميزة واحدة على الأقل ولا تجتمع جميع المزايا في خوارزمية واحدة مما أدى إلى ظهور النماذج الهجينة أو المختلطة من خوارزميات الذكاء الاصطناعي.

6-1-3 أدوات الذكاء الاصطناعي

يتطلب النجاح في بيئة الاعمال الحالية استيعاب دور الأساليب التكنولوجية الحديثة وكيفية تطبيقها على الممارسات المحاسبية ويعد أدوات الذكاء الاصطناعي أحد الأدوات التحليلية المتطورة التي تمكن من استنتاج المعرفة من كميات هائلة من البيانات (Heye, 2021)، ومن أدوات الذكاء الاصطناعي المنتشرة هي الشبكات العصبية الاصطناعية، شجرة القرارات وتقنية الدعم الآلي، والاستدلال المبني على الحالات السابقة والنماذج الهجينة بين الأدوات المختلفة. وتعتبر أدوات الذكاء الاصطناعي من اهم الآليات التي يمكن استخدامها بقوة في دعم الحكم المهني لمراقب الحسابات، فضلا عن التكامل والدمج بين هذه الأدوات وممارسات المحاسبة يؤدي إلى تحسين الأداء المالي والتشغيلي للشركة (Zhang, Cho, & Vasarhelyi, 2022).

- خوارزمية الجار الأقرب (K-Nearest Neighbor (KNN)

تعد خوارزمية الجار الأقرب هي تقنية تصنيف تعتمد على دقة البيانات حيث تحسب الحالات المتشابهة لكل صنف وتخصص الحالة الجيدة إلى نفس الصنف الذي تنتمي إليه معظم جيرانها. كما تطبق خوارزمية الجار الأقرب لقياس المسافة الأقرب بين الصفات المتشابهة وتكون سهلة عندما يكون هناك عدد قليل من المتغيرات المتبناة (Mateos-García, García-Gutiérrez, & Riquelme-Santos, 2016) وتستخدم عادة في حالات التصنيف والتعلم غير الخاضع للرقابة.

- الشبكات العصبية الاصطناعية (Artificial Neural Network (ANN)

تعد الشبكات العصبية الاصطناعية من أهم تقنيات الذكاء الاصطناعي التي أثبتت قدرتها على التنبؤ، وحل المشكلات بدقة وسهولة مقارنة بالأساليب الإحصائية التقليدية، حيث يطبق أسلوب هذه الشبكات بدون الحاجة إلى افتراضات مسبقة ودون النظر إلى علاقة المتغيرات مع بعضها البعض، على عكس الطرق التقليدية (Chen, 2019). تعرف الشبكات العصبية الاصطناعية بأنها شبكات ذات ترابط كثيف فيما بينها، وتضم عناصر بسيطة ومتوازية، وعادة ما تكون قابلة للتكيف وذات تنظيم هرمي، حيث تتفاعل مع الواقع الفعلي بالطريقة التي يتفاعل بها النظام العصبي الطبيعي (البيولوجي) مع العالم الحقيقي (Ding, 2022). فهي عبارة عن تقنيات محاسبية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة موزعة على التوازي ومكونة من وحدات معالجة بسيطة، وهذه الوحدات عبارة عن عناصر حسابية تسمى نيرونات أو عقد والتي لها خاصية عصبية حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان (Fedorova, Gilenko, & Dovzhenko, 2013)

- خوارزمية الغابات العشوائية (Random Forest)

هي خوارزمية اقترحها العالم Brieman عام 2000 لبناء مجموعة من أشجار القرارات التي تنمو في اتجاهات فرعية مختلفة عشوائيا من البيانات، وتعتبر الغابة العشوائية مصنف يتكون من مجموعة من المصنفات الهيكلية في شكل شجرة موزعة بشكل عشوائي متماثل وكل شجرة تقوم بالتصويت للمتغير الأكثر شعبية في الإدخال، تعتمد دقة الغابات العشوائية على قوة مصنفات الأشجار الفردية وقياس الاعتماد فيما بينها بغرض التنبؤ بالعدد الأمثل للأشجار (Yıldırım, Okay, & Özdemir, 2021) وتعتمد طريقة انشاء غابة من الأشجار غير مترابطة على خوارزمية التصنيف والانحدار وتستخدم لتصنيف المتغيرات لحل مشكلة التصنيف، وتحتاج معلمتين لتحديد ههما وعدد الأشجار وعدد الميزات التي تم

تقييمها من أجل جودة الانقسام عند كل عقدة في الشجرة، وبصورة عامة يتم تعيين عدد الأشجار من بين 100 إلى 500 شجرة (Elyan & Gaber, 2017)

- الخوارزميات التطورية (Evolutionary Algorithm (EA)

هي جزء من علم الذكاء الاصطناعي تعمل محاكاة للتطور الجيني في الطبيعة من خلال تمثيل العمليات الجينية حيث تبحث الخوارزمية التطورية عن احتمالات لإيجاد العملية المثلى وتستخدم لأغراض التصنيف لتمثل سلوك متخذ القرار في حالات مثل الغش، وهي تستخدم أيضا في تقييم مدى ملائمة الأساليب الأخرى في الذكاء الاصطناعي وتعتمد الخوارزميات التطورية على عملية التبادل والتغيير والاختيار لتحديد أفضل المتغيرات المستخدمة في النموذج والقضاء على المتغيرات غير الجيدة (Yang & Nazareth, 2022)، وتبدأ مراحل الخوارزمية باختيار مجموعة من المتغيرات بحيث تمثل حلا للمشكلة، بعدها تتم عملية إحداق طفرة على المتغيرات لينتج نماذج جديدة يتم اضافتها للمتغيرات السابقة، ثم يتم اختيار أقرب المتغيرات للحصول على الحل المثالي وإهمال باقي الحلول (النماذج) ويتم تكرار هذه العملية لإنتاج نماذج جديدة متعاقبة كل منها تتضمن مجموعة من المتغيرات حتى الوصول إلى أفضل نموذج (Pradhan, Pathak, & Singh, 2011; Sexton & Gupta, 2000).

ويخلص الباحث مما سبق أن السبب الأساسي في تعدد العديد من الخوارزميات هو إختلاف الأهداف المرجوة منها من التصنيف والتنبؤ، والتجميع أو التقسيم للبيانات والتعميم أو الربط بين التسلسلات للبيانات، ويظل استخدامها بناء على الهدف المرجو منها بناء على نوعية التعلم سواء الخاضع للرقابة أو غير الخاضع للرقابة.

6-1-4 المنظور المهني لأدوات الذكاء الاصطناعي في المحاسبة والمراجعة

في سياق ما تقدم فقد اثارت أدوات الذكاء الاصطناعي تحفيز مهام ودوافع الجهات المهنية ومكاتب المحاسبة والمراجعة على الصعيد الدولي، وهذا ما أكدته دراسة كل من (Kokina & Davenport, 2017; Munoko et al., 2020) ان استخدام أدوات الذكاء الاصطناعي يعمل على توجيه مراقب الحسابات بشكل فعال نحو المناطق ذات المخاطر المرتفعة. ومن منظور اخر، أوضحت دراسة (Loughran & Mcdonald (2016 إمكانية أدوات الذكاء الاصطناعي من معالجة المستندات باستخدام معالجة اللغة الطبيعية (Natural Language Processing (NLP وتحليل المحتوى بشكل أسرع من أي وقت سابق وأوضحت دراسة خلف (2017) ان استخدام نظم الذكاء الاصطناعي يؤدي الى زيادة استقلالية عملية المراجعة وجودة الأداء وفعالته من حيث سرعة إكتشاف الأخطاء وتقليلها وإتمام مهام المراجعة بسرعة ودقة، فضلا عن إتمام العمليات في وقت أقل وبفاعلية أكبر وبتكلفة منخفضة. وبالنظر

لأدوات الذكاء الاصطناعي منفصلة، تساعد شجرة القرارات مراقب الحسابات في إبداء حكم بمدى استمرارية الشركات (Kirkos, Spathis, Nanopoulos, & Manolopoulos, 2007)، بينما تقنية الشعاع الداعم تساعد مراقب الحسابات لتحديد الشركات التي تدير الأرباح باستخدام الإستحقاقات التقديرية (Goo et al., 2016)، في حين تساعد الشبكات العصبية الاصطناعية مراقب الحسابات في إكتشاف التحريفات الجوهرية وغش الإدارة فضلاً عن تقييم مخاطر الرقابة الإدارية ودعم أحكام الاستمرارية والتنبؤ بأتعاب المراجعة ومساعدة مراقبي الحسابات في التحليل المنطقي عند التخطيط لمهام المراجعة فضلاً عن توفير الوقت والجهد (Goo et al., 2016; Tsai & Chiou, 2009).

على النقيض، فقد اشارت دراسة (Gepp et al., 2018) وجود جدل فيما يخص تخفيض أدوات الذكاء الاصطناعي لأتعاب عملية المراجعة، فعلى الرغم من زيادة كفاءة وفاعلية عملية المراجعة والتي بدورها تقلل التدخل البشري ثم اتعاب عملية المراجعة إلا أنها مازالت تحت الجدل لعدة أسباب منها، أن تخفيض الوقت المطلوب في عملية المراجعة نتيجة استخدام أدوات الذكاء الاصطناعي قد يتساوى مع المرتب المطلوب من الموظف القائم باستخدام أدوات الذكاء الاصطناعي في عملية المراجعة، بالإضافة قيام مكاتب المراجعة بإعادة توزيع ساعات عملية المراجعة فبدلاً من وضع التركيز على التحليل نتيجة استخدام أدوات الذكاء الاصطناعي يتم وضع ساعات أكثر لفحص المناطق الأكثر خطورة لتحسين عملية المراجعة. في حين توصلت دراسة (Munoko et al., 2020) قيام مكاتب المحاسبة والمراجعة بالاعتماد على الذكاء الاصطناعي لتخفيض قرار إعادة اصدار القوائم المالية لعميل المراجعة وتخفيض وقت تأخير حكم مراقب الحسابات، وفي سياق متصل، أوضحت دراسة (Sherwood, Nagy, & Zimmerman 2020) تساعد أدوات الذكاء الاصطناعي في إكتشاف المخاطر غير المعروفة على سبيل المثال قيام مكتب Ernst and Young باستخدام أدوات الذكاء الاصطناعي لإكتشاف القيم الشاذة في الفواتير.

ويخلص الباحث مما سبق إلى أن أدوات الذكاء الاصطناعي تحسن من أدوات مراقب الحسابات في أداء عملية المراجعة، مما يسهم في تطوير إجراءات عملية المراجعة بكفاءة وفاعلية بصورة وقتية فضلاً عن تحليل كامل للبيانات لتقييم التحريفات والغش في القوائم المالية، وعليه يحسن من أحكام مراقب الحسابات وتكلفة المراجعة بافتراض ثبات العوامل الأخرى، مما بدورها في النهاية تحسن من جودة عملية المراجعة.

6-2 دور حكم مراقب الحسابات بشأن الاستمرارية: المفهوم، والأهمية والمحددات

6-2-1 مفهوم افتراض الاستمرارية

يمكن تعريف افتراض الاستمرارية بصفة عامة أنه النظر للشركة على أنها مستمرة في نشاطها إلى أجل غير مسمى ما لم يوجد ما يشير إلى عكس ذلك، أي أنه يفترض استمرار الشركة إلى أجل غير محدد، وذلك في المستقبل القريب والذي عادة ما يكون بفترة 6 أشهر من تاريخ تقارير مراقب الحسابات أو سنة من تاريخ الميزانية حتى تحقق أهدافها وما بنيت لأجله، وذلك في ظل عدم وجود أية أدلة تشير إلى إمكانية واحتمال ان تقوم الشركة بتخفيض نشاطها أو التصفية سواء كانت إجبار أو اختيارية (حسن، 2021) وهذا ما أكدته كل من دراسة (عبد الرحيم، 2020؛ Agostini, 2018) أنه يقع على عاتق إدارة الشركة مسؤولية تقييم الاستمرارية والذي أصبح مطلباً أساسياً ويعتبر من مسؤوليات الإدارة لفترة عام من تاريخ نشر التقارير المالية.

ويتفق في ذلك السياق معيار المراجعة رقم (570) "الاستمرارية" بشأن مسؤوليات الإدارة ومراقب الحسابات بشأن الاستمرارية، فقد أشار المعيار على متطلب واضح من الإدارة للقيام بتقييم محدد لمدى قدرة الشركة على الاستمرار، وفيما يتعلق بمسؤوليات مراقب الحسابات فإنها تتمثل في دراسة مدى ملاءمة تطبيق الإدارة لافتراض الاستمرارية عند إعداد القوائم المالية، وفي حالة وجود أحداث أو ظروف قد تؤدي إلى شك جوهرى في مدى قدرة الشركة على الاستمرار، فيجب على مراقب الحسابات أن يقوم بمجموعة من إجراءات المراجعة الإضافية لتحديد ما إذا كان هناك تأكيد جوهرى فيما يتعلق بأحداث أو ظروف قد تؤدي منفردة أو مجتمعة إلى شك جوهرى في مدى قدرة الشركة على الاستمرار (مشابط، 2020).

ويشير افتراض الاستمرارية في المراجعة إلى أن يقوم مراقب الحسابات بإبداء حكمه الفني المحايد في مدى قدرة الشركة على الاستمرار، وهو الأمر الذي اعتبره العديد من مراقبي الحسابات غير مناسب نظراً لظروف عدم التأكد المحيطة بذلك الافتراض (M. A. Geiger et al., 2021). ويتطلب افتراض الاستمرارية بأن ينظر مراقب الحسابات إلى الشركة على أنها مستمرة في النشاط ما لم توجد أدلة تشير إلى عكس ذلك، وهو ما يجعل افتراض الاستمرارية معلقاً على شرط عدم وجود أدلة تشير إلى أن الشركة لن تضطر أو تختار تصفية نشاطها في المستقبل المنظور (Chi & Shen, 2022; Shirata & Sakagami, 2008).

ويخلص الباحث مما سبق أن مفهوم افتراض الاستمرارية يعتبر الركيزة الأساسية للمبادئ المحاسبية المتعارف عليها و يعد مبدأً رئيسياً في إعداد القوائم المالية وتعتبر مسؤولية كل من إدارة الشركة الحكم عن مدى استمرارية الشركة لعام قادم على الأقل، في حين على مراقب الحسابات الحكم المهني على مدى

ملائمة تطبيق الإدارة لافتراض الاستمرارية للشركة لما له من تأثير هام على قرارات أصحاب المصالح واعمال الشركة بصفة عامة.

6-2-2 أهمية حكم مراقب الحسابات عن الاستمرارية

يعتبر حكم مراقب الحسابات عن استمرارية الشركة من الأمور الحيوية والهامة حيث الحكم الخاطئ في استمرارية الشركة يؤدي إلى الفشل في اكتشاف افلاس الشركة مما يؤدي إلى خسائر ضخمة لمستخدمي القوائم المالية وأصحاب المصالح (Chen, 2019). وتشير الدراسات المحاسبية على سبيل المثال أشار كل من (Carson et al., 2013; Jan, 2021) إلى أهمية النتائج المترتبة على حكم مراقب الحسابات بشأن الاستمرارية، فإذا أصدر حكم معدل بشأن الاستمرارية وظلت الشركة باقية لاحقا لمدة عام مالي على الأقل، فقد يترتب على ذلك عدم إرضاء إدارة الشركة عن مراقب الحسابات وانتهاء الارتباط به، كما أنه يجعل من إفلاس الشركة، أما إذا اصدر حكم غير معدل بشأن الاستمرارية لشركة فد أفلست لاحقا خلال عام مالي على الأقل، يترتب عليه مقاضاة مراقب الحسابات من قبل أصحاب المصلحة والاضرار بسمعته. يجدر بالإشارة أنه بالرغم من أهمية هذه الفرضية إلا أنه لا يعنى اعتبارها كأحد المسلمات، حيث يجب البحث أولاً عن أية عوامل أو مؤشرات تدل على عدم قدرة الشركة على الاستمرار، فإذا لم توجد تلك المؤشرات فيستنتج ان الشركة قادرة على الاستمرار (مشابط،2020).

ولا توجد قواعد محددة لإلزام مراقب الحسابات بإجراء مراجعة خصيصا للتأكد من مدى قدرة الشركة على الاستمرار، ولكنها تطالبه بإجراءات إضافية في حالة وجود شك أساسي في قضية الاستمرارية، ولذلك قدمت المعايير مؤشرات وظروف واحداث، إذا اجتمعت أو منفردة تؤدي إلى الشك في قدرة الشركة على الاستمرار، وتشمل هذه المؤشرات كل من مؤشرات مالية مثل نسب الربحية والسيولة وغيرها، ومؤشرات التشغيل مثل فقدان الشركة لأسواق رئيسية أو مورد رئيسي، أو اختناقات مستمرة في الانتاج، ومؤشرات أخرى وتتضمن عدم إلزام الشركة بسداد رأس المال المطلوب، وجود دعاوى قضائية ضد الشركة ذات تأثير على حجم نشاطها (محمد، 2018).

يخلص الباحث مما سبق إلى أن حكم مراقب الحسابات يخضع للحكم الشخصي وعليه أن يبحث عن أي أدلة تشير إلى عدم الاستمرارية، وعدم وجوده لهذه الأدلة يستنتج أن الشركة مستمرة في اعمالها، ولذلك من الضروري قيام مراقب المحاسب بتصميم إجراءات واختبارات أساسية وإضافية تتضمن برامج وأساليب حديثة للتنبؤ باستمرارية أو عدم استمرارية الشركة من خلال الاعتماد على مزيج من المؤشرات سواء مالية أو غير مالية فضلا عن أدوات حديثة للذكاء الاصطناعي.

6-2-3 محددات حكم مراقب الحسابات بشأن استمرارية الشركة

من المنظور المهني، تناول المعايير الدولي المعدل ISA No 570 مجموعة من المؤشرات التي تكون شكاً جوهرياً بشأن الاستمرارية، فقد تناول مجموعة من المؤشرات (مالية، تشغيلية، أخرى) التي تعكس نقص السيولة، وبالتالي عدم القدرة على سداد التزاماتها، بالإضافة إلى انخفاض قدرتها على الحصول على تمويل، نظراً لانخفاض أدائها، أي تعثر الشركة مالياً. ومن المؤشرات المالية: رأس المال العامل السالب، انخفاض نسبة التداول السريعة، صافي التدفقات النقدية السالبة من الأنشطة التشغيلية، وغيرها من المؤشرات الأخرى، وعليه إذا اعتقد مراقب الحسابات بوجود شك جوهرى بشأن الاستمرارية، فعليه القيام بمجموعة إجراءات إضافية على الحصول على معلومات حول الخطط المستقبلية وتقييم احتمالية تنفيذ هذه الخطط بفعالية والقيام بإجراءات إضافية للحصول على أدلة مراجعة كافية لتأكيد أو استبعاد الشك الجوهرى (IAASB, 2015) وعلى الرغم من البيانات المالية تحسن بصورة معنوية نتائج التنبؤ باستمرارية الشركة، إلا أنها بصعوبة تتضمن كافة البيانات المطلوبة للتنبؤ باستمرارية الشركات، وعليه قامت العديد من الدراسات السابقة منها (Hajek, Olej, & Myskova, 2014) باستخدام البيانات الغير مالية، والبيانات النصية غير المهيكلة من التقارير المالية وبصورة خاصة من قسم افصاح الإدارة (Mai, Tian, Lee, & Ma, 2019).

في ذلك السياق، لقد قامت العديد من الدراسات منها على سبيل المثال (Carson et al., 2013; Koh & Low, 2004) باختبار أدوات التي تؤثر على تقييم استمرارية الشركة، وقد ركزت على تحليل العناصر في القوائم المالية وإستخراج النسب المالية بينما الجزء الاخر من الدراسات اختبر المؤشرات غير المالية، تتضمن مؤشرات السوق، الخطط الاستراتيجية للمؤسسة، مؤشرات القطاع وهيكل الملكية، إلا يواجه مراقب الحسابات العديد من المعوقات نتيجة الاعتماد على المؤشرات المالية أو غير المالية منها درجة التحفظ التي تم اعداد القوائم المالية عليها، أسلوب الإدارة في اعداد القوائم المالية من اجل إدارة الأرباح، وأخيراً اختلاف درجة التأثير للعوامل المؤثرة على استمرارية الشركة من شركة لأخرى.

وعليه يعتمد مراقب الحسابات على البيانات المالية من عملية المراجعة لتشخيص الحالة المالية للشركة وتقييم استمرارية الشركة عادة يقوم مراقب الحسابات بالاعتماد على المتغيرات المالية وغير المالية في انشاء نماذج للتنبؤ باستمرارية الشركة، والذي يعتبر مرجع لمراقب الحسابات لإعطاء حكم استمرارية الشركة (Vasquez, 2021; Yeh et al., 2014)، إلا نتيجة العديد من الأخطاء في التنبؤ والحكم عن الاستمرارية أوضحت دراسة (Tsao, 2021) ان اعتماد مراقب الحسابات على خوارزميات الذكاء الاصطناعي أكثر دقة وكفاءة من الحكم البشرى في اصدار حكم بشأن استمرارية الشركة. وفى ذلك السياق، اعتمد الاستخدام الأولى لأدوات الذكاء الاصطناعي في تقييم استمرارية الشركة في العديد من

الدراسات منها (Rudra Kumar & Kumar Gunjan, 2020; Sun & Li, 2008) على البيانات المالية المهيكلة مثل نسب الربحية، نسب النمو ونسب المديونية بالإضافة إلى إنشاء نماذج تعلم إحصائية مثل الانحدار اللوجستي، والتي تطورت إلى نماذج التعلم المراقبة بالاعتماد على الشبكات العصبية الاصطناعية وتقنية الدعم الآلي (Chi & Shen, 2022)، على الرغم من تحقيق نتائج تنبؤ لاستمرارية الشركة جيدة بأدوات الذكاء الاصطناعي منفردا إلا أن سعت العديد من الدراسات إلى إنشاء نماذج مختلطة من أدوات مختلفة من الذكاء الاصطناعي للوصول إلى نتائج دقة أعلى تتضمن تقنيات التعلم غير المراقب والجينات الوراثية (Fieberg, Hesse, Loy, & Metko, 2022).

يخلص الباحث مما سبق إلى أنه بالرغم من أن الذكاء الاصطناعي يتم استخدامه بصورة قوية في مجالات أخرى، إلا أن تطبيقها في المراجعة يعتبر في مرحلة البداية ويرجع ذلك إلى أن مجال المراجعة مقارنة بالمجالات الأخرى خاضع إلى قواعد وقوانين صارمة وقوية والتي لم تدرج كاملا في استخدامات الذكاء الاصطناعي (Issa, Sun, & Vasarhelyi, 2016)، وبالتالي فإن استخدام أنظمة الذكاء الاصطناعي في المراجعة لا يكتفى فقط بتحقيق الفاعلية والكفاءة لعملية المراجعة ولكن يجب أن تتماشى مع كافة القوانين والقواعد المطلوبة من المشرعين (Munoko et al., 2020).

6-3 تحليل العلاقة بين استخدام أدوات الذكاء الاصطناعي وجودة حكم مراقب الحسابات

بشأن الاستمرارية

اعتمدت معظم الدراسات السابقة على أساليب التحليل الإحصائية التقليدية مثل التحليل العاملي، تحليل الانحدار، التحليل التمييزي والتحليل العنقودي من أجل إصدار أحكام مراقب الحسابات بشأن الاستمرارية، إلا أنه يوجد العديد من القيود والثغرات في عملية البحث والحكم مما يزيد من احتمالية الخطأ (Chen, 2021; Jan, 2021; Goo et al., 2016; 2019)، حيث تؤدي النماذج الإحصائية التقليدية إلى خطأ التقدير في استمرارية الشركة وبالتالي حكم خاطئ لمراقب الحسابات عن استمرارية الشركة والتي بدورها تؤثر بصورة عكسية على استدامة ونمو الشركة وتطوير الشركة وقرارات المستثمرين وعليه فإن عدد من الدراسات السابقة منها (Chen, 2019; Jan, 2021; Salehi & Fard, 2013) أوضحت أن كل من خوارزميات التعلم الآلي والتعلم العميق، أكثر دقة وصلابة مقارنة بالأساليب التقليدية الإحصائية لتحقيقها نتائج دقة أعلى ونسبة خطأ أقل، نتيجة لمساوئ النماذج الإحصائية التقليدية في إصدار تنبؤ خاص باستمرارية الشركة، اتجهت العديد من الدراسات لإنشاء نماذج لإصدار حكم خاص باستمرارية الشركة، الاعتماد على تقنيات التنقيب عن البيانات، والذكاء الاصطناعي، والتي تضمن شجرة القرارات، الشبكات

العصبية الاصطناعية، تقنية الدعم الآلي، والذي يتم استخدامهم بكثرة في العديد من المجالات الأخرى (ابوالخير، 2019).

على سبيل المثال، اعتمدت العديد من الدراسات على استخدام الشبكات العصبية الاصطناعية في التنبؤ بإستمرارية الشركات (Derks, de Swart, van Batenburg, Wagenmakers, & Wetzels, 2013; Goo et al., 2016; Salehi & Fard, 2013) بينما عدد من الدراسات الأخرى اعتمد على شجرة القرارات (Chi & Shen, 2022; Goo et al., 2016)، ودراسات أخرى اعتمدت على تقنية شبكة معتقد بايزن (Salehi & Fard, 2013) Baysen Beliefe Network (BBNs) وأخرى باستخدام تقنية الدعم الآلي (Fernández et al., 2018). في ذلك السياق، أوضحت دراسة Leitner-Hanetseder et al., (2021) أنه من أهداف استخدام الذكاء الاصطناعي في مهنة المحاسبة والمراجعة جعل العمليات الروتينية من ضمنها تسجيل العمليات المالية على النظام بصورة آلية، فضلا عن أن العديد من المحاسبين ومراقبي الحسابات يستخدمون العديد من الملفات والأوراق لتحليل بيانات الشركة والتي تتم باستخدام أدوات ذكاء الاعمال التي تستطيع اجراء عمليات التحليل وتصدير البيانات بسهولة، وبناء عليه فقد تقوم شركات المراجعة كبيرة الحجم بالاعتماد على أدوات الذكاء الاصطناعي على سبيل المثال، شركة Ernst and Young تعتمد على برنامج Canvas ليتيح التواصل بين العملاء ومراقبي الحسابات من خلال أدوات الية تتيج تعديلها وفقا لرغبات العميل، في حين شركة PwC تعتمد على برنامج Cash.ai بالاعتماد على أدوات الذكاء الاصطناعي والتعلم الآلي لإجراء المراجعة على العمليات التي تتم بواسطة الشركات المالية، وأيضا شركة KPMG تعتمد على برنامج Clara الذي يستخدم الذكاء الاصطناعي أيضا في القيام بالمراجعة الذكية من خلال تحليل البيانات واكتشاف التحريفات (Abdulameer et al., 2022).

في نفس السياق، قامت دراسة (Chye Koh & Kee Low (2004) نموذج مختلط من شجرة القرارات CART وشجرة القرارات من نوع CHAID والشبكات العصبية الاصطناعية للتنبؤ بحكم استمرارية الشركة، ووجدت الدراسة ان أفضل نموذج للدمج كان الشبكات العصبية الاصطناعية مع شجرة الانحدار والتصنيف CART-NN بنسبة 96.77% وقد اختبرت دراسة (Saif et al., (2012) نموذج استخراج متغيرات للتنبؤ بحكم مراقب الحسابات بالاعتماد على تقنية الدعم الآلي svm و شجرة القرارات وتوصلت الدراسة إلى أهمية استخدام النسبة الجارية والنسبة السريعة للتنبؤ بسيولة الشركة، في حين الاعتماد على نسبة السيولة للمركز المالي للشركة. في حين قامت دراسة (Yeh et al., (2014) بإنشاء نموذج مختلط بين شجرة الغابات العشوائي Random Forest ونظرية Rough set theory للتنبؤ بحكم مراقب الحسابات بشأن الاستمرارية، ووجدت الدراسة معدل نسبة الدقة في التنبؤ 96.10%.

في نفس السياق، قامت دراسة (Goo et al., 2016) بتقليل متغيرات نموذج التنبؤ بحكم مراقب الحسابات بشأن استمرارية لشركة، مع الدمج مع أدوات الذكاء الاصطناعي الأخرى لزيادة دقة التنبؤ مثل الشبكات العصبية الاصطناعية، شجرة الانحدار والتصنيف CART وتقنية الدعم الآلي SVM. وتوصلت الدراسة ان نموذج تقنية الدعم الآلي مع الدمج مع أداة LASSO يحقق نسبة تنبؤ 89.79% والذي تتفوق على باقي النماذج. وقد قامت دراسة (Barboza et al., 2017) باستخدام أدوات التعلم الآلي (تقنية الدعم الآلي، الشبكات العصبية الاصطناعية، خوارزمية الغابات العشوائية) للتنبؤ باستمرارية الشركة ومقارنة اداءها مع نتائج الانحدار اللوجستي والتحليل التمييزي، وتوصلت الدراسة إلى تفوق أدوات التعلم الآلي بزيادة تقريبا 10% من الدقة مقارنة بالنماذج التقليدية، وقد تفوق نموذج خوارزمية الغابات العشوائية بنسبة دقة 87% على الانحدار اللوجستي بنسبة دقة 69% والتحليل التمييزي بدقة 50%. في حين قامت دراسة (Gepp et al., 2018) نموذج جديد للتنبؤ باستمرارية الشركة لعين من الفنادق بالاعتماد على طرق اختيار المتغيرات بالاعتماد على أداة Ada Boost من خوارزمية Boosting وهي خوارزمية فعالة لتحسين نتائج الخورزميات التعليمية مثل الشبكات العصبية وذلك للحصول على قيمة خطأ أصغر في مشكلة التنبؤ ومعدلات خطأ أقل في مشاكل التصنيف وقد وصلت نسبة الدقة في الدراسة إلى 100% في التنبؤ بالاعتماد على 12 نسبة مالية وغير مالية. تعتبر دراسة (Tang, Li, Tan, & Shi (2020) من ضمن الدراسات النادرة التي قامت بمقارنة تنبؤات لعدد من السنوات باستخدام عدد كبير من أدوات الذكاء الاصطناعي المختلفة في التنبؤ بالأداء المستقبلي لاستمرارية الشركة بداية من الانحدار اللوجستي البسيط إلى تقنية الدعم الآلي إلى الشبكات العصبية الاصطناعية العميقة بالتركيز على التداخل والتلاعب بالمتغيرات وأنواع البيانات وفترة التنبؤ، وأكدت الدراسة على أهمية الاعتماد على التعلم العميق والتي تظهر أهميته في معالجة البيانات المهيكلة وغير المهيكلة على التوالي.

وبالنظر إلى التعلم العميق، قامت دراسة (Jan (2021) باختبار عينة من الشركات من 2002-2019 والتي قامت بدمج كل من الشبكات العصبية الاصطناعية العميقة، الشبكة العصبية الاصطناعية الراجعة، وشجرة التحليل والانحدار CART لإنشاء نموذج للتنبؤ بحكم مراقب الحسابات بشأن استمرارية الشركات. وتوصلت الدراسة إلى تفوق أداة CART بنسبة دقة 95.28% مقارنة بباقي الأدوات. ومن منظور اخر قامت دراسة (Fukas et al., 2021) بتطبيق أداة Gradient boosting method للتنبؤ باستمرارية الشركات، وتوصلت الدراسة ان استخدام الأداة لإزالة القيم الشاذة من عينة التدريب في الشركات، يساعد على زيادة التنبؤ الصحيح باستمرارية الشركات. في حين، قامت دراسة (Chi & Chu (2021 باستخدام خوارزميات التعلم العميق والتي تضمن خوارزمية الذاكرة طويلة-قصيرة المدى (LSTM) وخوارزمية بوابة الوحدة المتكررة (GRU) Gated Recurrent Unit والتي تعتبر احد أنواع الشبكات العصبية الاصطناعية

للتعلم والتدريب من أجل انشاء نموذج تنبؤ عالي الدقة باستمرارية الشركة، بالاعتماد على عينة من الشركات من عام 2004-2019 والتي تضمن 20 متغير من ضمنها 4 متغيرات غير مالية، وتوصلت الدراسة ان كل من نماذج LSTM و GRU لديها أداء مرتفع بنسبة دقة تنبؤ 96.15% و 94.23% على التوالي.

قامت دراسة (Nasir et al., 2021) بتطوير نظام لإتخاذ حكم مراقب الحسابات لاكتشاف ضعف في هيكل الرقابة الداخلي، وقد تم استخدام الجينات الوراثية لاختيار أهم المتغيرات المستخدمة والتي اثبتت كفاءة أكثر من الأدوات الأخرى المستخدمة. على النقيض، فقد اشارت دراسة (Albawwat et al., 2021) على الرغم من الإيجابيات التي تحدثها أدوات الذكاء الاصطناعي إلا أنها تعتبر خطوة إلى الوراء لأن العديد من مراقبي الحسابات سيكون من الصعب عليهم التكيف مع هذه التكنولوجيا الحديث، مما يبطئ من أداء مهامهم بشكل كبير، مما يخفض من جودة عملية المراجعة. قامت دراسة (Verhoeven et al., 2022) بجعل عملية تقييم استمرارية الشركة تتم ألياً بواسطة خوارزمية Gradient boosting وتوصلت لنسبة دقة 97.45% بينما شجرة القرارات 96.79%. في حين قامت دراسة (Yang & Nazareth 2022) باستخدام نموذج هجين من الجينات الوراثية بهدف تحديد أهم المتغيرات التي يمكن استخدامها لمراقب الحسابات في تقييم استمرارية الشركة وتقنية الدعم الآلي للتنبؤ بالاستمرارية وقد نجحت الجينات الوراثية في تخفيض المتغيرات إلى 8 متغيرات من مجموعة تضمنت 35 متغير بنسبة دقة 98.6% والتي حققت نتائج أفضل من كافة التقنيات الأخرى المستخدمة.

وقد هدفت دراسة (Chi & Shen 2022) بدمج أدوات الذكاء الاصطناعي مع تقنيات التعلم الآلي، من خلال مرحلتين، المرحلة الأولى، تتضمن عدد من المتغيرات الهامة تم اختيارها باستخدام شجرة القرارات وشجرة القرارات المبنية على الانحدار والتصنيف CART وتقنية الاكتشاف الآلي للتدخل Chi-Squared و automatic interaction detector (CHAID)، بينما المرحلة الثانية، تتضمن نماذج التصنيف بالاعتماد على أداة الشبكات العصبية الاصطناعية، تقنية الدعم الآلي وشجرة القرارات نوع C5.0 للتنبؤ بالتطبيق على عينة من الشركات التايوانية في الفترة من 2000-2019. وتوصلت الدراسة إلى نموذج CHAID-C5.0 حصل على أعلى دقة تنبؤ مالي للاستمرارية الشركات بدقة (95.65%) ثم نموذج CART-C5.0 بدقة (92.77%).

قامت دراسة (Awad 2022) باستخدام عدد من أدوات الذكاء الاصطناعي والتي تضمن شجرة القرارات، وخوارزمية الكشف السريع للدخلاء (ID3) Intrusion Detection وخوارزمية الشبكات العصبية الاصطناعية Naïve Bayes وخوارزمية الغابات العشوائية Radom forest في البحث في بيانات 13 بنك تجاري لاختيار النسب المالية التي يمكن الاعتماد عليها في التنبؤ باستمرارية البنك لحكم مراقب

الحسابات. وتوصلت الدراسة ان شجرة القرارات وخوارزمية ID3 حققت نسبة تنبؤ 100% صحيحة. وقد صممت دراسة (Ding (2022) نموذج للذكاء الاصطناعي لاجراء المراجعة الذكية للمؤسسة ككل بهدف إدارة مصروفات وارباح الشركة بصورة وقتية وصحيحة، وذلك من خلال عدة مراحل أولاً معالجة البيانات الخاصة بالمراجعة من خلال خوارزمية شبكات العصبية الديناميكية كنوع من التعلم العميق للشبكات العصبية، ثم اجراء نموذج الذاكرة طويلة-قصيرة المدى LSTM لتحليل دقة التصنيف لعملية المراجعة، وفي النهاية تم استخدام الجينات الوراثية لاعطاء وزن نسبي لنيرونات الشبكات العصبية العميقة ووصلت معدل دقة التنبؤ 93.6% مقارنة باستخدام تقنية الدعم الآلي منفردا بنسبة 81.6%.

وبناء على ما سبق، **يخلص الباحث إلى** إمكانية استخدام أدوات الذكاء الاصطناعي للعديد من الأهداف لمساعدة مراقب الحسابات في التنبؤ باستمرارية الشركات، حيث يمكن استخدامها كمرحلة أولية لاختيار متغيرات النموذج التي يتم الاعتماد عليها في التنبؤ كما هو الحال في (Nasir et al., 2021; Salehi & Fard, 2013)، في حين، يمكن الاعتماد على أدوات الذكاء الاصطناعي في مرحلة التنبؤ فقط مع بقاء المتغيرات المستخدمة لمراقب الحسابات كما هي كما هو الحال في (Awad, 2022; Chi & Chu, 2021)، على الجانب الاخر، يمكن الدمج بين المرحلتين لتكوين نموذج مختلف يقوم باختيار المتغيرات الهامة في تقييم استمرارية الشركة ثم رفع معدل التنبؤ بالاعتماد على أدوات أخرى للذكاء الاصطناعي (Barboza et al., 2017; Ding, 2022; Jan, 2021)، وتعتبر هذه من اهم تطورات الذكاء الاصطناعي للحصول على أفضل نسبة تنبؤ باقل عدد من المتغيرات مما يسهم في توفير الوقت من جميع بيانات وتحليل والحصول على نتائج أسرع وأعلى دقة. ويمكن أيضا الوصول، إلى مرحلة أبعد من النماذج الهجينة وهي الاعتماد على التعلم العميق مع النماذج الهجينة والتي تصل إلى أبعد الحدود الممكنة من التعلم من البيانات بأقل المتغيرات المستخدمة .

وأخيرا، يرى الباحث أهمية اعتماد مراقب الحسابات على أدوات الذكاء الاصطناعي في إصدار حكم مهني على مدى ملائمة تطبيق الإدارة لافتراض الاستمرارية من خلال تحسين حكم مراقب الحسابات بالتنبؤ باستمرارية الشركة مما يزيد جودة عملية المراجعة مع ثبات العوامل الأخرى لعملية المراجعة وبناء على ماسبق، يمكن اشتقاق فرض البحث التالي:

فرض البحث

يؤثر اعتماد مراقب الحسابات على النموذج الهجين من أدوات الذكاء الاصطناعي معنوياً على جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية.

الفرض الفرعي الاول H1a

يؤثر اعتماد مراقب الحسابات على خوارزمية البحث التطويري معنوياً على جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية.

الفرض الفرعي الثاني H1b

يؤثر اعتماد مراقب الحسابات على أدوات الذكاء الاصطناعي (الغابات العشوائية، تقنية الدعم الألى، الشبكات العصبية الاصطناعية، الجار الأقرب) معنوياً على جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية.

4-6 منهجية البحث

تحقيقاً لهدف البحث، ومن ثم اختبار فروضه، سيتم القيام بدراسة تطبيقية. وفيما يلي يعرض الباحث لكل من، أهداف الدراسة، مجتمع وعينة الدراسة، توصيف وقياس متغيرات الدراسة، أدوات وإجراءات الدراسة، أدوات التحليل الإحصائي، وأخيراً نتائج الدراسة التطبيقية. وذلك على النحو التالي:

1-4-6 أهداف الدراسة التطبيقية

تستهدف الدراسة التطبيقية اختبار فرض البحث، للتحقق من مدى تأثير اعتماد مراقب الحسابات على نموذج هجين من أدوات الذكاء الاصطناعي على تحسين جودة حكمه بشأن الاستمرارية للشركات المصرية المقيدة بالبورصة قياساً على (على، 2020؛ مشابط، 2020؛ حسين، 2021)

2-4-6 مجتمع وعينة الدراسة

يتكون مجتمع الدراسة من كافة الشركات المدرجة في سوق الأوراق المالية المصرية، وذلك خلال الفترة (2018-2021) وقد بلغ عدد هذه الشركات 200 شركة وتم اختيار عينة تحكمية من هذه الشركات روعي فيها الاتي:

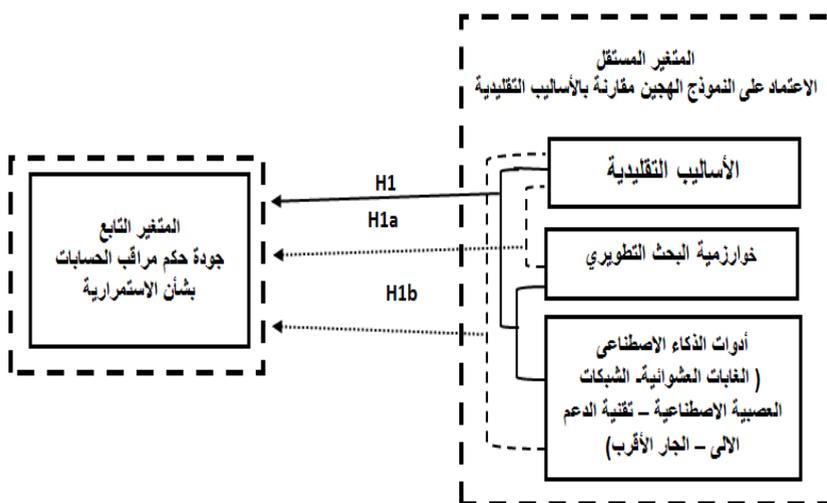
- استبعاد البنوك، وشركات التأمين، والشركات العاملة في مجال الأوراق المالية، نظراً لطبيعتها الخاصة.
 - اختيار الشركات التي توفر بيانات الدراسة، وأن تقوم بنشر قوائمها بالجنبة المصري.
- وبذلك بلغ عدد شركات العينة محل الدراسة (121) شركة، بحجم مشاهدات (461 مشاهدة) على مدار الفترة (2018-2021).

6-4-3 نموذج البحث وتوصيف وقياس متغيرات الدراسة

فيما يلي نموذج البحث، وتوصيف وقياس المتغيرات:

- نموذج البحث

يتضح من تتبع فروض البحث، أن متغيرات الدراسة تضمنت: 24 متغيراً مستقلاً، من متغيرات مالية وغير مالية لبناء النموذج المبدئي (الأولى) للتنبؤ بحكم مراقب الحسابات بشأن الاستمرارية ويمكن توضيحهم في الجدول رقم (1)، ومتغيراً تابعاً، وهو حكم مراقب الحسابات بشأن استمرارية الشركة، ويظهر نموذج البحث تبعا لذلك في الشكل رقم (2) كما يلي:



شكل 2: نموذج البحث

توصيف وقياس متغيرات الدراسة

أ- المتغير التابع (حكم مراقب الحسابات بشأن استمرارية الشركات):

تم قياس المتغير من خلال تطابق كل من نتائج نموذج ألتمان Z-Score للحكم على الحالة المالية للشركة وحكم مراقب الحسابات بشأن الاستمرارية قياساً على الدراسات السابقة (مثل: على، 2020؛ مشابط، 2020؛ حسين، 2021) تقاس بمتغير ثنائي يأخذ القيمة (1) عند دقة الرأي بشأن الاستمرارية، ويأخذ القيمة (صفر) غير ذلك، حيث يتطلب القياس الخطوات التالية:

(1) يتم تحديد الحالة المالية لمشاهدات العينة، إما إستقرار مالي أو تعثر مالي، وذلك من خلال الاعتماد على نموذج ألتمان كنموذج للتنبؤ بالتعثر المالي، ويتكون النموذج من مجموعة من الأوزان النسبية لمجموعة من المؤشرات، يختلف كل وزن نسبي عن الآخر باختلاف الأهمية النسبية للمؤشر ، ويتمثل النموذج في المعادلة الآتية (Altman, 1968)

$$Z = 1.2X_1 + 1.4X_2 + 3.3 X_3 + 0.6 X_4 + 0.999 X_5 \dots\dots(1)$$

حيث ان

X_1 = رأس المال العامل / إجمالي الأصول

X_2 = الأرباح المحتجزة / إجمالي الأصول

X_3 = صافى الربح التشغيلي قبل الفوائد والضرائب / إجمالي الأصول

X_4 = القيمة السوقية لحقوق الملكية / إجمالي الديون

X_5 = صافى المبيعات / إجمالي الأصول

وقد قسم ألتمان نتيجة المعادلة السابقة إلى ثلاثة أقسام:

أ. المنطقة الحمراء (تعثر مالي): إذا كانت نتيجة النموذج Z أقل من 1.81.

ب. المنطقة الرمادية (غير محدد مالياً): إذا كانت نتيجة النموذج Z من 1.81 إلى 2.99 ولتحديد الوضع المالي لقيم هذه المنطقة قام كل من دراسة (Indrawaty & Wardayati (2016) ودراسة (على، 2020) بتقسيم قيمة المشاهدة التي تقع بتلك المنطقة إلى مجموعتين هما: إذا كانت نتيجة النموذج Z من 1.81 إلى أقل من 2.7، تصنف المشاهدة على أنها محتملة التعثر المالي، وتضم إلى المنطقة الحمراء. وإذا كانت نتيجة النموذج Z من 2.7 إلى 2.99، تصنف المشاهدة على أن لديها مؤشر غير جوهري للتعثر المالي (تضم المنطقة الخضراء).

ج. المنطقة الخضراء (استقرار مالي): إذا كانت نتيجة النموذج Z أكبر من 2.99.

(2) يتم تحديد حكم مراقب الحسابات بشأن الاستمرارية، من خلال تحليل المحتوى لتقرير لتقرير مراقب الحسابات، سواء كان حكماً غير معدلاً بشأن الاستمرارية وفق معيار المراجعة الدولي رقم (700)، أو حكماً معدلاً بشأن الاستمرارية وفق معيار المراجعة الدولي رقم (705)، (706) (على، 2020).

(3) قياس دقة الرأي بشأن الاستمرارية وهو متغير ثنائي يأخذ القيمة (1) في حالة إصدار مراقب الحسابات تقرير بحكم غير معدل والحالة المالية للمشاهدة استقرار مالي و/أو لديها مؤشر غير

جوهري للتعثر المالي، وإصدار تقرير بحكم معدل والحالة المالية للمشاهدة تعثر مالي و/أو احتمال تعثر مالي. ويأخذ القيمة (صفر) عند عدم دقة الحكم بشأن الاستمرارية، وذلك في حالتي: إصدار تقرير بحكم غير معدل والحالة المالية للمشاهدة تعثر مالي و/أو احتمال تعثر مالي، وإصدار تقرير بحكم معدل والحالة المالية استقرار مالي و/أو لديها مؤشر غير جوهري للتعثر المالي (على، 2020؛ حسين، 2021) وبالتطبيق على عينة البحث يمكن تقسيم المشاهدات عبر سنوات الدراسة كما هو موضح في الجدول رقم (1) الآتي:

جدول 1: مشاهدات حكم مراقب الحسابات بشأن استمرارية/عدم استمرارية الشركة على مدار سنوات الدراسة

الاجمالي	حكم مراقب الحسابات بعدم استمرارية الشركة	حكم مراقب الحسابات باستمرارية الشركة	السنة
121	78	43	2018
119	78	41	2019
116	72	44	2020
115	42	73	2021
471	270	201	الاجمالي

ب- المتغيرات المستقلة

قام الباحث باجراء مسح العديد من الدراسات السابقة ومنها (Jan, 2021; Yang & Nazareth, 2022; Zdošek et al., 2022) التي قامت باختبار حكم مراقب الحسابات بشأن الاستمرارية والمتغيرات الأخرى لاشتقاق النموذج المبدئي وقد توصل الباحث الى (24) متغير مالي وغير مالي يمكن الحصول عليه من التقارير والقوائم المالية ومصادر المعلومات الأخرى ويمكن توضيحهم في الجدول رقم (2) التالي:

جدول 2: النموذج المبدئي للمتغيرات المستقلة

رمز المتغير	المتغير	القياس	رمز المتغير	المتغير	القياس
X1	نسبة صافي الربح على حقوق الملكية	نسبة الجارية	X13	الأصول الجارية/ الالتزامات الجارية	نسبة الجارية
X2	هامش الربح الاجمالي	نسبة اجمالي الربح على صافي المبيعات	X14	مقاييس جودة التقرير المالي	القيمة السوقية/ القيمة النظرية لحقوق الملكية
X3	نسبة صافي الربح قبل الضرائب على صافي الأصول الجارية		X15	حكم مراقب الحسابات بشأن ضعف هيكل الرقابة	متغير تثنائي (صفر) في حالة عدم وجود ضعف في هيكل الرقابة بتقرير مراقب الحسابات، (واحد) غير ذلك
X4	نسبة الدخل التشغيلي	الدخل التشغيلي / صافي المبيعات	X16	يتم مراجعة الشركات بواسطة مكاتب المراجعة كبيرة الحجم	1 للشركات يتم مراجعتها بواسطة مكاتب المراجعة كبيرة الحجم، صفر غير ذلك
X5	المائد على الأصول	اجمالي الأصول / صافي المبيعات	X17	عمر الشركة	(لوغاريتم عدد سنوات عمر الشركة)
X6	نسبة الالتزامات الجارية الى اجمالي الالتزامات	الالتزامات الجارية/ اجمالي الالتزامات	X18	حجم الشركة	(لوغاريتم اجمالي الأصول)
X7	اجمالي الالتزامات الى حقوق الملكية	اجمالي الالتزامات/ حقوق الملكية	X19	وجود خسائر السنة الحالية	ثنائي 1 في حالة وجود خسارة في السنة الحالية، صفر غير ذلك
X8	نسبة الدين	نسبة اجمالي الالتزامات الى اجمالي الأصول	X20	محل دوران الحسابات العملاء	صافي المبيعات / متوسط حسابات العملاء
X9	نسبة الاستحقاقات الى اجمالي الأصول	الاستحقاقات/ اجمالي الأصول	X21	محل دوران اجمالي الأصول	صافي المبيعات/ اجمالي الأصول
X10	نسبة حسابات جاري العملاء الى الأصول الجارية	حسابات جاري العملاء/ الأصول الجارية	X22	محل دوران الالتزامات الجارية	الالتزامات الجارية/ صافي المبيعات
X11	نسبة التنفقات النقدية الى اجمالي الالتزامات	التنفقات النقدية/ اجمالي الالتزامات	X23	العائد على المبيعات	صافي الدخل على المبيعات
X12	نسبة النقدية	النقدية ومافي حكمها/ الالتزامات الجارية	X24	صافي المائد على حقوق الملكية	صافي الدخل / متوسط حقوق الملكية

المصدر: (Jan, 2021; Yang & Nazareth, 2022; Zdolšek et al., 2022)

وسوف يتم اختبار فروض البحث من خلال عدد من الخطوات كما هو موضح في الشكل رقم (3) حيث يتم البداية بالنموذج المبدئي المكون من 24 متغير مالي وغير مالي وتقسيم عينة البحث الى 66% لتدريب النموذج و44% لاختبار النموذج وذلك من خلال المراحل الاتية:

المرحلة الأولى: اختيار افضل المتغيرات بخوارزمية البحث التطوري EA الخاص بنموذج المبدئي

في هذه المرحلة تم اشتقاق النموذج المبدئي المكون من 24 متغير مالي وغير مالي تم استخدامهم في الدراسات السابقة والموضحة بالجدول رقم (2) والتي لها تاثير على حكم مراقب الحسابات بشأن الاستمرارية

$$Aopinion_{i,t} = B_0 + B_1X_{1i,t} + B_2X_{2i,t} \dots \dots \dots + B_{24}X_{24i,t} + \alpha_{i,t} \cdot (2)$$

حيث يتضمن النموذج المتغير التابع حكم مراقب الحسابات بشأن استمرارية الشركة Aopinion وباقي المتغيرات المستقلة المالية وغير المالية (X1 إلى X24) الموضحة مسبقا.

ومن ثم تم تطبيق خوارزمية البحث التطوري للحصول على اهم المتغيرات المؤثرة في حكم مراقب الحسابات بشأن الاستمرارية وقد توصلت الخوارزمية إلى النموذج النهائي المكون من (13) متغير بدلا من (24) متغير كالاتي ويمكن الرجوع الى الملحق رقم (1) لبيان نتائج الخوارزمية :

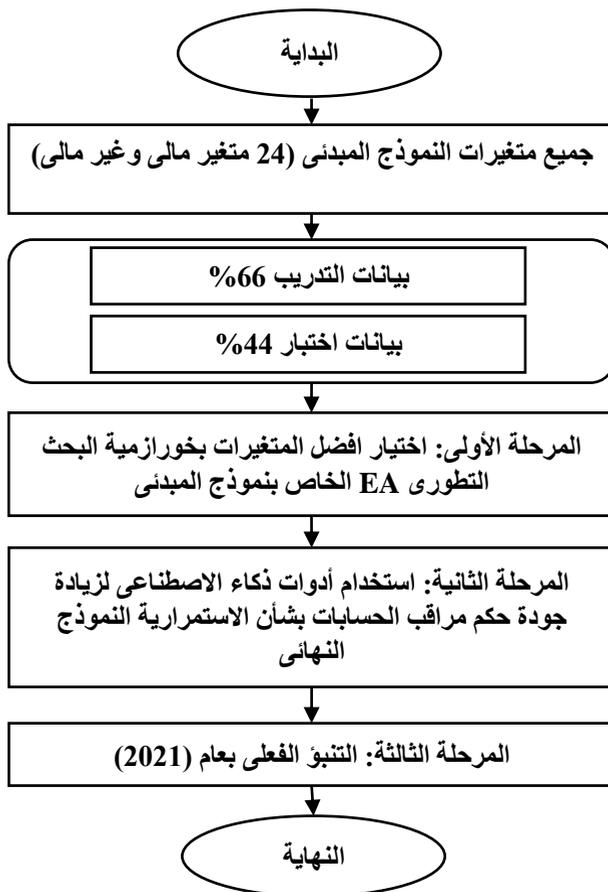
$$Aopinion_{i,t} = B_0 + B_2X_{2i,t} + B_6X_{6i,t} + B_7X_{7i,t} + B_8X_{8i,t} + B_{10}X_{10i,t} + B_{15}X_{15i,t} + B_{16}X_{16i,t} + B_{17}X_{17i,t} + B_{18}X_{18i,t} + B_{19}X_{19i,t} + B_{20}X_{20i,t} + B_{21}X_{21i,t} + B_{23}X_{23i,t} + \alpha_{i,t}.....(3)$$

المرحلة الثانية: استخدام أدوات ذكاء الاصطناعي لزيادة جودة حكم مراقب الحسابات بشأن الاستمرارية النموذج النهائي

لاختبار فرض البحث وبيان أثر اعتماد مراقب الحسابات على نموذج هجين من أدوات الذكاء الاصطناعي على تحسين جودة حكمه بشأن الاستمرارية ودقتها في التنبؤ، تم اجراء اختبار T للفرق الجوهرى بين الانحدار اللوجستي كأسلوب تقليدي للتحليل وأدوات الذكاء الاصطناعي المختلفة للنموذجين الأولى والنهائى لمقاييس التقييم المختلفة.

المرحلة الثالثة: التنبؤ الفعلى بعام (2021)

لإختبار لمصادقية أدوات الذكاء الاصطناعي فى عملية التنبؤ ، وذلك عن طريق إدخال البيانات المالية للشركات فى عام 2021 والحصول على نتائج تنبؤ بحكم مراقب الحسابات بشأن استمرارية الشركة ومقارنتها بالقيم الفعلية



شكل 3: مراحل البحث

4-4-6 أساليب تقييم النماذج

سوف يتم الاعتماد على العديد من المقاييس لقياس أداء كلا من الإنحدار اللوجستي وأدوات الذكاء الاصطناعي للنموذج، وتتضمن هذه المقاييس قيمة جذر الخطأ التربيعي (RMSE) ومعامل Kappa ونسبة الحالات الصحيحة والخاطئة في مرحلة تدريب الخوارزمية طبقاً لدراسات (Forsati, Moayedikia, Jensen, Shamsfard, & Meybodi, 2014; M. a Geiger & Rama, 2006; Yeh et al., 2014)

- معدل الدقة والخطأ من النوع الأول والثاني

أوضح كلا من (Barboza et al., 2017; Goo et al., 2016; Lehmann & Norman, 2006) ان من اكثر الأساليب استخداماً في نماذج التصنيف حيث يقيس معدل الدقة من خلال قياس معدل الدقة وكلا من الخطأ من النوع الأول والنوع ويمكن توضيح الحالات كما يلي:

○ **True Positive (TP)** هي عدد الحالات الإيجابية الصحيحة التي تعنى ان بعض الحالات الإيجابية "positive Class" يعنى ان حكم مراقب الحسابات بعدم استمرار الشركة وقد تم التنبؤ بحكم مراقب الحسابات بعدم استمرارها.

○ **False Negative (FN)** هي عدد الحالات السليمة الخاطئة والتي تعنى ان بعض الحالات الإيجابية تم التنبؤ بها بصورة سلبية وخاطئة أي حكم مراقب الحسابات بعدم استمرار الشركة وقد تم التنبؤ باستمرار الشركة.

○ **True Negative (TN)** هي عدد الحالات السلبية الصحيحة، أي حكم مراقب الحسابات باستمرار الشركة وقد تم التنبؤ بها باستمرار الشركة.

○ **False Positive (FP)** هي عدد الحالات الإيجابية الخاطئة أي حكم مراقب الحسابات استمرار الشركة وقد تم التنبؤ بها عدم استمرار الشركة

وبالتالي فان مقياس معدل الخطأ الأول والثاني من المقاييس الهامة التي توضح التفرقة بين الحالات المفلسة وغير المفلسة يمكن توضيح طريقة القياس كما يلي:

$$\text{معدل الخطأ من النوع الأول} = \frac{FP}{TN+FP}$$

$$\text{معدل الخطأ من النوع الثاني} = \frac{FN}{TP+FN}$$

$$\text{معدل الدقة} = \frac{TP+TN}{TP+FP+FN+TN}$$

ويعنى خطأ النوع الأول ان معدل التنبؤ الخاطيء للنموذج الذي قام بتصنيف الشركات بصورة خاطئة التي لديها حكم مراقب حسابات باستمرار الشركة والتنبؤ بعدم استمرارها، في حين الخطأ من النوع الثاني هو معدل التنبؤ الخاطيء للنموذج حيث قام بتصنيف الشركات التي لديها حكم مراقب حسابات عدم الاستمرار بالتنبؤ باستمرارها، وبالتالي فان النموذج الذي لديه معدل خطأ من النوع الثاني اقل هو الأفضل (Lehmann & Norman, 2006; Xu & Kalelkar, 2020; Yeh et al., 2014)

- معامل Kappa الإحصائي

يقيس معامل kappa نجاح استخدام المتغيرات المستقلة في تفسير المتغير التابع للنموذج المستخدم في تصنيف الحالات التي يتم اختبارها في النموذج وقد تم استخدامه في العديد من الدراسات منها (Forsati et al., 2014; Park, Hamm, & Kim, 2019)

- قيمة الجذر التربيعي RMSE

يُعرف قيمة جذر الخطأ التربيعي بأنه الجذر التربيعي لمتوسط الفرق بين الحالات المتوقعة والحقيقية للبيانات وكلما إنخفض قيمة الخطأ كلما كان النموذج أفضل وذات مصداقية مرتفعة حيث إنخفاض القيمة يدل على كفاءة النموذج في التنبؤ (Etheridge, Sriram, & Hsu, 2000; Koskivaara, 2003).

- اختبار Paired Sample T-Test

بعد تحديد المتغيرات الهامة المستخدمة في حكم مراقب الحسابات بشأن الاستمرارية باستخدام خوارزمية Evolutionary Research والتي تشكل النموذج النهائي لمراقب الحسابات تم إجراء اختبار T-Test لاختبار الفروق الجوهرية لمقاييس التقييم المختلفة للخوارزميات المختلفة بين النموذج الأولي والنهائي لحكم مراقب الحسابات بين كما هو الحال في دراسة (Denna, Hansen, Meservy, & Wood, 1992; Karuppu, 2009; Yeh et al., 2014)

6-4-5 أدوات وإجراءات الدراسة

بشأن أدوات الدراسة، فقد تم الاستناد إلى البيانات الفعلية والثانوية الواردة بالقوائم المالية والإيضاحات المتممة لشركات العينة، والبيانات المتاحة على الموقع الإلكتروني مباشر معلومات (<https://www.mubasher.info/>) والتقارير المالية للشركات المقيدة بالبورصة المصرية. أما بشأن إجراءات الدراسة، فقد قام الباحث بتجهيز البيانات المطلوبة، وحساب قيم المتغيرات على اختلاف أنواعها وأخيراً استخدام النسب والنماذج الملائمة لحساب بعض متغيرات الدراسة.

6-4-6 أدوات التحليل الإحصائي

تم الاعتماد على الإحصاءات الوصفية لتحديد الخصائص الرئيسية لمتغيرات الدراسة. ولاختبار فرض البحث تم الاعتماد على نماذج الانحدار اللوجستي وأدوات الذكاء الاصطناعي المختلفة، والتي تم تشغيلها ببرنامج weka 3.8 الخاص باستخدام أدوات الذكاء الاصطناعي وإجراء الاختبارات المختلفة، وقد تم الاعتماد على برنامج spss الإحصائي للحصول على نتائج الإحصاءات الوصفية وسوف يعتمد الباحث على خوارزمية البحث التطويري EA لاختيار أفضل المتغيرات التي تمثل النموذج النهائي للبحث،

بينما خوارزمية الشبكات العصبية الاصطناعية، خوارزمية الجار الأقرب والغابات العشوائية كأدوات ذكاء اصطناعي لزيادة دقة التنبؤ بحكم مراقب الحسابات بشأن الاستمرارية.

6-4-7 نتائج الدراسة التطبيقية كما يلي

يمكن عرض نتائج الدراسة التطبيقية كما يلي:

- نتائج الإحصاءات الوصفية

بدءاً بنتائج الإحصاءات الوصفية ومعاملات الارتباط المبدئية ذات الصلة بالمتغيرات الأساسية للبحث في الجدول رقم (3)، المستقلة (المكونة من 24 متغير مالي وغير مالي) والتابع (جودة حكم مراقب الحسابات بشأن الاستمرارية) اتضح ان قيمة الوسط الحسابي (0.64) لحكم مراقب الحسابات بشأن الاستمرارية Aopinion بما يتماشى مع الانحراف المعياري المنخفض (0.481)، وبملاحظة القيمة الصغرى والعظمى لقيم المتغيرات بالجدول المكونة من 24 متغير مالي وغير مالي نجد عدم وجود قيم شاذة وأن جميعها في المعدلات الطبيعية.

جدول 3: الإحصاء الوصفي لمتغيرات البحث

Variable	Obs	Mean	Std. Dev.	Min	Max
Aopinion	356	.64	.481	0	1
x1	356	.157	.415	-3.01	3.322
x2	356	3.819	5.036	-9.872	17.96
x3	356	.227	.576	-1.347	5.323
x4	356	.763	2.259	-5.715	10.032
x5	356	.056	.218	-1.59	1.427
x6	356	.757	.283	0	1
x7	356	1.042	1.418	-2.468	9.413
x8	356	.544	.753	.001	7.429
x9	356	.035	.144	-.297	1.066
x10	356	.26	.292	0	1.918
x11	356	.089	.837	-8.855	4.924
x12	356	.578	1.141	-.295	7.766
x13	356	2.069	1.814	.009	9.216
x14	356	1.915	1.947	-5.872	8.904
x15	356	.228	.42	0	1
x16	356	.669	.471	0	1
x17	356	1.461	.273	.903	2.049
x18	356	9.142	.699	7.394	10.737
x19	356	.154	.362	0	1
x20	356	1.179	2.248	-7.372	9.898
x21	356	.056	.218	-1.59	1.427
x22	356	.475	1.499	-8.3	9.425
x23	356	.189	.732	-6.798	3.15
x24	356	.112	.43	-3.322	2.901

- نتائج اختبار فرض البحث

أ- مقياس معدل الخطأ من النوع الأول والثاني ومعدل الدقة

يجد الباحث من الجدول رقم (4) التالي، تحسن انخفاض لجميع الخوارزميات في النموذج النهائي المكون من (14) متغير مقارنة بالنموذج الأساسي المكون من (24) متغير، حيث انخفض معدل الخطأ من النوع الأول لجميع الخوارزميات بفارق حوالى (1% إلى 3%) بالاعتماد على (13) متغير فقط بدلا من (24) متغير وهو ما يؤكد كفاءة النموذج النهائي فضلا عن وجود فرق معنوي بين نسبة الخطأ من النوع الأول للانحدار وباقي الخوارزميات الأخرى المستخدمة، وكانت أقل نسبة لخوارزمية الغابات العشوائية للخطأ من النوع الأول يليها الشبكات العصبية الاصطناعية والجار الأقرب وهو ما يؤكد كفاءة أدوات الذكاء الاصطناعي المختلفة في التنبؤ بحكم مراقب الحسابات بشأن الاستمرارية مقارنة بالانحدار اللوجستي التقليدي.

جدول 4: نتائج اختبار نموذج T للفرق المعنوي بين الخوارزميات المختلفة لمعدل الخطأ من

النوع الأول للنموذج الأولي والنهائي

النموذج	الانحدار اللوجستي	خوارزمية الغابات العشوائية	خوارزمية الشبكات العصبية الاصطناعية	خوارزمية الجار الأقرب
النموذج الأولي (24) متغير)	33%	12%	18%	20%
النموذج النهائي (13) متغير)	30%	10%	16%	19%

*يدل على وجود فرق جوهري بين الانحدار اللوجستي وباقي الخوارزميات المستخدمة المصدر: الملحق رقم (2)

يجد الباحث من الجدول رقم (5) التالي، تحسن انخفاض لجميع الخوارزميات في النموذج النهائي المكون من (13) متغير مقارنة بالنموذج الأساسي المكون من (24) متغير، حيث انخفض معدل الخطأ من النوع الثاني لجميع الخوارزميات بفارق حوالى (1% إلى 4%) فيما عدا الانحدار اللوجستي ظل ثابتا ما يؤكد فضلا عن وجود فرق معنوي بين نسبة الخطأ من النوع الأول للانحدار وباقي الخوارزميات الأخرى المستخدمة، وكانت أقل نسبة لخوارزمية الغابات العشوائية للخطأ من النوع الثاني يليها خوارزمية الجار الأقرب والشبكات العصبية الاصطناعية وبالتالي النموذج الأقل خطأ من النوع الثاني هو الاكفأ هو ما يؤكد كفاءة أدوات الذكاء الاصطناعي المختلفة خاصة خوارزمية الغابات العشوائية في التنبؤ بحكم مراقب الحسابات بشأن الاستمرارية مقارنة بالانحدار اللوجستي التقليدي.

جدول 5: نتائج اختبار نموذج T للفرق المعنوي بين الخوارزميات المختلفة لمعدل الخطأ

من النوع الثاني للنموذج الأولي والنهائي

النموذج	الانحدار اللوجستي	خوارزمية الغابات العشوائية	خوارزمية الشبكات العصبية الاصطناعية	خوارزمية الجار الأقرب
النموذج الأولي (24 متغير)	*%12	*%4	*%11	*%9
النموذج النهائي (13 متغير)	*%12	*%3	*%10	*%5

*يدل على وجود فرق جوهري بين الانحدار اللوجستي وباقي الخوارزميات المستخدمة

المصدر: الملحق رقم (2)

يلاحظ الباحث من الجدول رقم (6) التالي، ان خوارزمية الغابات العشوائية حققت اعلى نسبة دقة تنبؤ للنموذج بنسبة (93.40%) للنموذج النهائي مقارنة بالنموذج الأولي (92.08%) يليها خوارزمية الجار الأقرب بنسبة دقة تنبؤ (88%) مقارنة بنسبة (86.06%) للنموذج الأولي، ثم خوارزمية الشبكات العصبية الاصطناعية التي حققت دقة نسبة تنبؤ (86.80%) مقارنة بنسبة (85.71%) للنموذج الأولي وفي النهاية نموذج الانحدار اللوجستي الذي حقق دقة تنبؤ (78.68%) مقارنة بنسبة (77.83%) للنموذج الأولي، وارتفاع النسبة بين النموذج الأولي والنموذج النهائي يدل على كفاءة خوارزمية البحث التطوري EA في اختيار المتغيرات وبناء النموذج النهائي للتنبؤ بحكم مراقب الحسابات بشأن الاستمرارية فضلا عن تفوق الخوارزميات المختلفة للذكاء الاصطناعي مقارنة بالانحدار اللوجستي.

جدول 6: مقارنة معدل الدقة للخوارزميات المختلفة لمعدل الخطأ من النوع الاول للنموذج الأولي

والنهائي

النموذج	الانحدار اللوجستي	خوارزمية الغابات العشوائية	خوارزمية الشبكات العصبية الاصطناعية	خوارزمية الجار الأقرب
النموذج الأولي (24 متغير)	%77.83	%92.08	%85.71	%86.06
النموذج النهائي (13 متغير)	%78.68	%93.40	%86.80	%88

*يدل على وجود فرق جوهري بين الانحدار اللوجستي وباقي الخوارزميات المستخدمة

المصدر: الملحق رقم (2)

ب- مقياس معامل Kappa الاحصائي

يجد الباحث من الجدول رقم (7) التالي، ارتفاع معامل kappa لكافة الخوارزميات المختلفة المستخدمة في النموذج النهائي مقارنة بالنموذج الأساسي بفارق معنوي يتراوح (1%-3%) بين الانحدار اللوجستي وكافة الخوارزميات الأخرى المستخدمة للنموذجين، مما يؤكد على كفاءة النموذج النهائي باستخدام خوارزمية البحث التطوري ES من ناحية ومن ناحية أخرى تفوق الخوارزميات المختلفة الأخرى بصورة معنوية مقارنة بالانحدار اللوجستي، وقد حققت خوارزمية الغابات العشوائية أعلى معدل بنسبة 86% يليها خوارزمية الجار الأقرب بمعدل نسبة (78%) ثم الشبكات العصبية الاصطناعية بنسبة (74%) وكان الأقل نسبة هو الانحدار اللوجستي بنسبة (59%) وذلك للنموذج النهائي المستخدم في الدراسة.

جدول 7: نتائج اختبار نموذج T للفرق المعنوي بين الخوارزميات المختلفة معامل الاحصائي

Kappa للنموذج الأولي والنهائي

النموذج	الانحدار اللوجستي	خوارزمية الغابات العشوائية	خوارزمية الشبكات العصبية الاصطناعية	خوارزمية الجار الأقرب
النموذج الأولي (24 متغير)	0.56	*0.85	*0.71	*0.76
النموذج النهائي (13 متغير)	0.59	*0.86	*0.74	*0.78

*يدل على وجود فرق جوهري بين الانحدار اللوجستي وباقي الخوارزميات المستخدمة

المصدر: الملحق رقم (2)

ج- مقياس معامل الخطأ RMSE

يجد الباحث من الجدول رقم (8) التالي، انخفاض معدل جذر الخطأ التربيعي لكافة الخوارزميات المختلفة المستخدمة في النموذج النهائي المكون من (13) متغير مقارنة بالنموذج الأساسي المكون من (24) بمعدل يتراوح من (1%-3%) مما يؤكد على كفاءة النموذج النهائي باستخدام خوارزمية evolutionary search ونجد ان خوارزمية الغابات العشوائية كانت اقل معدل خطأ تربيعي يصل إلى 23% ثم خوارزمية الشبكات العصبية الاصطناعية ويليها خوارزمية الجار الأقرب وأخيرا الانحدار اللوجستي، مع وجود فروق معنوية بين معدلات الانحدار اللوجستي وباقي الخوارزميات المستخدمة.

جدول 8: نتائج اختبار نموذج T للفرق المعنوي بين الخوارزميات المختلفة RMSE للنموذج

الأولى والنهائي

النموذج	الانحدار اللوجستي	خوارزمية الغابات العشوائية	خوارزمية الشبكات العصبية الاصطناعية	خوارزمية الجار الأقرب
النموذج الأولي (24 متغير)	0.38	*0.24	*0.31	*0.35
النموذج النهائي (13 متغير)	0.36	*0.23	*0.29	*0.32

*يدل على وجود فرق جوهري بين الانحدار اللوجستي وباقي الخوارزميات المستخدمة

المصدر: الملحق رقم (2)

وبناء على ماسبق، يجد الباحث تفوق النموذج النهائي المشتق من خوارزمية البحث التطوري EA في زيادة معدلات الدقة وانخفاض معدلات خطأ التنبؤ من النوع الأول والثاني، فضلا عن زيادة معامل Kappa وانخفاض معدل الخطأ التربيعي RMSE وعليه يمكن قبول فرض البحث الفرعي الأول القائل يؤثر اعتماد مراقب الحسابات على خوارزمية البحث التطوري إلى زيادة في معنوية جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية متمثلا في الانحدار اللوجستي وباختبار T يجد الباحث تفوق أدوات الذكاء الاصطناعي على الانحدار اللوجستي وتأتي في المقدمة خوارزمية الغابات العشوائية، ثم خوارزمية الجار الأقرب يليها خوارزمية الشبكات العصبية الاصطناعية، وعليه يتم قبول فرض الفرعي الثاني القائل يؤثر اعتماد مراقب الحسابات على أدوات الذكاء الاصطناعي (الغابات العشوائية، تقنية الدعم الألى، الشبكات العصبية الاصطناعية، الجار الأقرب) إلى زيادة في معنوية جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية، وعليه يمكن قبول فرض البحث القائل يؤثر اعتماد مراقب الحسابات على النموذج الهجين من أدوات الذكاء الاصطناعي إلى زيادة معنوية في جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية وهذا مايتفق مع ماتوصلت إليه العديد من الدراسات السابقة منها (Yeh et al., 2016; Goo et al., 2016; Chi & Shen, 2022; 2014)

د- نتائج إختبار تنبؤ أدوات الذكاء الإصطناعي والإنحدار اللوجستي لملاحظات عام 2021

بحكم مراقب الحسابات بشأن استمرارية الشركات.

بناء على ما سبق من التحليل الإحصائي والفرق الجوهري بين أدوات الإختبار فقد قام الباحث بإجراء إختبار لمصادقية أدوات الذكاء الإصطناعي في عملية التنبؤ، وذلك عن طريق إدخال البيانات المالية للشركات في عام 2021 وعددها (115) ملاحظة للتنبؤ بحكم مراقب الحسابات بشأن استمرارية الشركة

لعام 2021 والحصول على النتائج ، ثم يقوم البرنامج بإظهار نتائج التنبؤ كما هو موضح في الملحق رقم (3)، ويتم توضيح القيم الصحيحة والخاطئة والإجمالية للحالات المتنبأ بها كما في الجدول رقم (9) التالي

جدول 9: نتائج التنبؤ الفعلي للحالات الصحيحة والخطأ لعام 2021 لنماذج أدوات الذكاء

الإصطناعي والانحدار اللوجستي

نسبة المشاهدات	الانحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية
نسبة مشاهدات التنبؤ الصحيحة	81%	83%	82%	91%
نسبة مشاهدات التنبؤ الخاطئة	19%	17%	18%	9%
اجمالي المشاهدات	%100	%100	%100	%100

المصدر: الملحق رقم (3)

يظهر من خلال الجدول السابق قيم مدى القدرة التنبؤية بحكم مراقب الحسابات بشأن استمرارية الشركة من خلال أدوات الذكاء الاصطناعي المختلفة والانحدار اللوجستي، وبالنظر للحالات التي قامت بها أدوات الذكاء الاصطناعي بالتنبؤ بها ومقارنتها بالنتائج الفعلية بناء على المقياس المستخدم في التحليل الأساسي لحكم مراقب الحسابات بشأن الاستمرارية، نجد أنه من خلال خوارزمية الجار الأقرب قامت بالتنبؤ بشكل صحيح بنسبة (82%) من اجمالي الشركات، في حين قامت (18%) من اجمالي الشركات تنبؤ خاطئ لحكم مراقب الحسابات بشأن استمرارية الشركة. ومن خلال خوارزمية الغابات العشوائية قامت بالتنبؤ بشكل صحيح بنسبة (91%) من اجمالي الشركات، في حين قامت بالتنبؤ الخاطيء بنسبة (9%) من اجمالي الشركات. ومن خلال الشبكات العصبية الاصطناعية قامت بالتنبؤ بشكل صحيح بنسبة (83%) من اجمالي الشركات، في حين التنبؤ الخاطيء بنسبة (17%). أما ما يخص نموذج الإنحدار اللوجستي نجد أنها قامت بالتنبؤ بشكل صحيح بنسبة (81%) من اجمالي الشركات ، في حين (19%) من اجمالي الشركات تنبؤ خاطيء، وبالتالي يتضح من خلال هذا التحليل أن نماذج أدوات الذكاء الاصطناعي المختلفة يحقق دقة تنبؤية عالية ومرتفعة مقارنة بنموذج الإنحدار اللوجستي، وتتفوق عليهم خوارزمية الغابات العشوائية يليها الشبكات العصبية الاصطناعية ثم الجار الأقرب وفي النهاية الانحدار اللوجستي وبالتالي يتم قبول الفرض البحث القائل بأنه يؤثر اعتماد مراقب الحسابات على النموذج الهجين من أدوات الذكاء الاصطناعي إلى زيادة معنوية في جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية وتتفق هذه النتيجة مع بعض الدراسات السابقة (Chi & Shen, 2022; Goo et al., 2016; Yeh et al., 2014)

7- الخلاصة ومجالات البحث المقترحة

استهدف البحث دراسة واختبار تأثير اعتماد مراقب الحسابات على النموذج الهجين من أدوات الذكاء الاصطناعي إلى زيادة معنوية في جوده حكمه بشأن استمرارية الشركات المقيدة بالبورصة المصرية مقارنة بإعتماده على الأساليب التقليدية.

خلص الباحث، إلى الأثر المعنوي لاستخدام خوارزمية البحث التطويري EA في تصميم نموذج جديد مكون من (13 متغير) لزيادة جودة حكم مراقب الحسابات بشأن استمرارية الشركات، فضلا عن تفوق أدوات الذكاء الاصطناعي المختلفة في زيادة جودة حكم مراقب الحسابات بشأن استمرارية الشركات المصرية مقارنة بالانحدار اللوجستي وذلك على كافة مقاييس التقييم المختلفة التي تضمنت معدل الدقة، ومعامل Kappa و معدل الخطا التربيعي RMSE. كما أشارت النتائج، تفوق خوارزمية الغابات العشوائية في التنبؤ بحكم مراقب الحسابات بشأن الاستمرارية يليها خوارزمية الجار الأقرب ثم الشبكات العصبية الاصطناعية، في حين الانحدار اللوجستي حقق أقل نسبة في التنبؤ. كما أوضحت نتائج التنبؤ الفعلي بعام (2021) وتوصل الباحث إلى نفس النتائج التي تم توصل إليها في التحليل الأساسي. الأمر الذي يؤيد توجه الباحث في اختياره تصميم نموذج هجين لتصميم نموذج جديد لحكم مراقب الحسابات بشأن الاستمرارية وزيادة التنبؤ باستخدام الأدوات المختلفة للذكاء الاصطناعي.

وإستنادا على ماسبق، يوصى الباحث بضرورة زيادة الوعي بأدوات الذكاء الاصطناعي والتدريب على استخدامها في مجالات المحاسبية المختلفة، فضلا عن، الإستعانة بذوى الخبرة التكنولوجيا مع مراقبي الحسابات في مصر لتطوير نماذج لدعم القرار ممايزيد من جودة عملية المراجعة، وأخيرا، عقد دورات تدريبية من قبل الهيئات المهنية لتدريب وزيادة خبرة مراقبي الحسابات في استخدام أدوات الذكاء الاصطناعي في عملية المراجعة.

وختاما فإننا نعتقد بأهمية إتجاه البحث المحاسبي في مصر مستقبلا في المجالات التالية:

أثر التعلم العميق للتنبؤ باستمرارية الشركات بالاعتماد على البيانات المالية وغير المالية، أثر إجراء تحليل السلاسل الزمنية باستخدام أدوات الذكاء الاصطناعي لتوضيح العلاقة بين اكتشاف الغش والحالة المالية للشركات، فضلا عن أثر استخدام أدوات الذكاء الاصطناعي في إجراء التحديد التلقائي للمحادثات في المقابلات مع المديرين لاختبار واكتشاف الغش من خلال اكتشاف السلوك المشكوك فيه أو التأخير في الرد على الاسئلة اثناء المقابلات. بالإضافة إلى اختبار أثر استخدام الذكاء الاصطناعي في اكتشاف تعابير الوجه في المقابلات الشخصية لعميل المراجعة من المديرين، اثر استخدام الشبكات العصبية الاصطناعية العميقة في تقييم عملية المخاطر، من خلال تدريب النموذج على المؤشرات المرتبطة

بالمخاطر الحتمية من أجل تقييم مخاطر التحريفات الجوهرية في القوائم المالية، وأخيراً، دراسة واختبار أثر الاعتماد على أدوات التنقيب عن البيانات في فحص البيانات من مصادر مختلفة مثل وسائل التواصل الاجتماعي مثل الفيس بوك وتويتر والتعليقات على وسائل التواصل الاجتماعي فضلاً عن إصدارات الصحف والأخبار لتدريب النموذج من أجل تقييم المخاطر الحتمية لعملية المراجعة.

المراجع

أولاً: المراجع باللغة العربية

أبو الخير، أسامه أحمد محمد. (2019). دور استخدام أساليب التنقيب في البيانات لتحسين تقديرات مراقب الحسابات في مدى وجود أخطاء جوهرية بالقوائم المالية : دراسة ميدانية في بيئة الأعمال المصرية. مجلة الدراسات التجارية المعاصرة، 5(7)، 305-347. doi: 10.21608/ csj. 2019.90668

حسن، حنان عبد المنعم مصطفى. (2021). أثر تطبيق الحوسبة السحابية على مدى تقرير المراجع عن استمرارية المنشأة في النشاط. مجلة الإسكندرية للبحوث المحاسبية، 5(3)، 393-456. Doi: 10.21608/aljalexu.2021.206892

حسين يونس محمد، عبدالله. (2021). أثر أتعاب المراجعة والثقة الإدارية المفرطة على دقة رأى مراقب الحسابات بشأن الاستمرارية دليل من الشركات المقيدة بالبورصة المصرية. الفكر المحاسبى، 1(25)، 476-547. doi: 10.21608/atasu.2021.160035

خلف، أبوبكر عبدالله. (2017). دور الذكاء الاصطناعي في تحسين جودة المراجعة الداخلية. المجلة العلمية للبحوث والدراسات التجارية . حلوان، 31(3)، 621-641.

عبد الرحيم، رضا محمود محمد. (2020). أثر التعديلات في شكل ومحتوى تقرير مراقب الحسابات وفقاً لمعيار المراجعة الدولي رقم (570) المعدل لسنة 2015 بشأن الإستمرارية على قراري الإستثمار ومنح الإئتمان: دراسة تجريبية. مجلة الاسكندرية للبحوث المحاسبية، 4(2)، 1-94. doi: 10.21608/aljalexu.2020.105947

على، نهى محمد زكى محمد. (2020). أثر درجة التخصص الصناعي لمراقب الحسابات وطول فترة إرتباطه بعمله على جودة حكمه المهني بشأن الإستمرارية - دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية. مجلة الاسكندرية للبحوث المحاسبية . 4(2)، 361-447. doi: 10.21608/aljalexu.2020.106384

محمد، أحمد سليم. (2018). تفسير العلاقة بين هيكل الملكية وخصائص مجلس الإدارة ولجنة المراجعة بشفافية واستمرارية الأرباح: دراسة تطبيقية على الشركات المشتركة. الفكر المحاسبي، 22(3)، 806-841.

مشابط، نعمة حرب. (2020). أثر جودة المراجعة الخارجية على سلامة رأى مراقب الحسابات بشأن الإستمرارية - دراسة تطبيقية على الشركات الصناعية المسجلة بالبورصة المصرية. مجلة الاسكندرية للبحوث المحاسبية، 4(2)، 230-289. doi: 10.21608/ aljalexu. 2020. 105957

معايير المراجعة المصرية، (2008)، المعيار رقم (570) الإستمرارية متاح على: 16
https://www.efsa.gov.eg/content/efsa-arlefsa2-merg-audit

ثانياً: المراجع باللغة الأجنبية

Abdulameer, M., Mansoor, M. M., Alchuban, M., Rashed, A., Al-Showaikh, F., & Hamdan, A. (2022). The Impact of Artificial Intelligence (AI) on the Development of Accounting and Auditing Profession. In *Studies in Computational Intelligence* (Vol. 1019). https://doi.org/10.1007/978-3-030-93921-2_12

Abiyev, R. H. (2014). Credit Rating Using Type-2 Fuzzy Neural Networks. *Mathematical Problems in Engineering, 2014*, 1-8. <https://doi.org/10.1155/2014/460916>

Agostini, M. (2018). The Role of Going Concern Evaluation in Both Prediction and Explanation of Corporate Financial Distress: Concluding Remarks and Future Trends. *Corporate Financial Distress*, 119-126. https://doi.org/10.1007/978-3-319-78500-4_5

Ahmed, M., Mahmood, A. N., & Islam, M. R. (2016). A survey of anomaly detection techniques in financial domain. *Future Generation Computer Systems*, 55, 278-288. <https://doi.org/10.1016/j.future.2015.01.001>

- Alareeni, B., & Hamdan, A. (2022). The Impact of Artificial Intelligence on Accounting and Auditing in Light of the COVID-19 Pandemic. *Accounting, Finance, Sustainability, Governance and Fraud*, 3–7. [https://doi.org /10.1007/978-981-19-1036-4_1](https://doi.org/10.1007/978-981-19-1036-4_1)
- Albashrawi, M., & Lowell, M. (2016). Detecting Financial Fraud Using Data Mining Techniques : a. *Journal of Data Science*, Vol. 14, pp. 553–570. Retrieved from http://www.jds-online.com/file_download/558/10-Detecting+Financial+Fraud+Using+Data+Mining+Techniques-JDS_V3.pdf
- Albawwat, I. E., Al-Hajaia, M. E., & Al Frijat, Y. S. (2021). The Relationship Between Internal Auditors' Personality Traits, Internal Audit Effectiveness, and Financial Reporting Quality: Empirical Evidence from Jordan. *Journal of Asian Finance, Economics and Business*, 8(4), 797–808. [https://doi.org /10.13106/jafeb.2021.vol8.no4.0797](https://doi.org/10.13106/jafeb.2021.vol8.no4.0797)
- Altman, E. I. (1968). The Prediction of Corporate Bankruptcy: A Discriminant Analysis. *The Journal of Finance*, 23(1), 193–194. [https://doi.org /10.1111/j.1540-6261.1968.tb00843.x/pdf](https://doi.org/10.1111/j.1540-6261.1968.tb00843.x/pdf)
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics: Conference Series*, 1142(1), 012012. <https://doi.org/10.1088/1742-6596/1142/1/012012>
- Awad, S. S. (2022). Using Data Mining Tools To Prediction of Going Concern on Auditor Opinion–Empirical Study in Iraqi Commercial. *Academy of Accounting and Financial Studies Journal*, (February), 0–13. Retrieved from https://www.researchgate.net/profile/Ilham-Mohammed-Wathik2/publication/358802230_Using-Data-mining-tools-to-Prediction-of-going-Concern-on-Auditor-Opinion-Empirical-study-In-Iraqi-Commercial-1528-263526-3-1010/links/62162e89b15a6a210163bdbb/Using-Data-
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405–417. <https://doi.org/10.1016/j.eswa.2017.04.006>

- Biswas, S. K., Sinha, N., Purakayastha, B., & Marbaniang, L. (2014). Hybrid expert system using case based reasoning and neural network for classification. *Biologically Inspired Cognitive Architectures*, 9, 57–70. <https://doi.org/10.1016/j.bica.2014.06.004>
- Carson, E., Fargher, N. L., Geiger, M. A., Lennox, C. S., Raghunandan, K., & Willekens, M. (2013). Audit reporting for going-concern uncertainty: A research synthesis. *Auditing*, 32(SUPPL.1), 353–384. <https://doi.org/10.2308/ajpt-50324>
- Chen, S. (2019). An effective going concern prediction model for the sustainability of enterprises and capital market development. *Applied Economics*, 51(31), 3376–3388. <https://doi.org/10.1080/00036846.2019.1578855>
- Chi, D. J., & Chu, C. C. (2021). Artificial intelligence in corporate sustainability: Using lstm and gru for going concern prediction. *Sustainability (Switzerland)*, 13(21). <https://doi.org/10.3390/su132111631>
- Chi, D. J., & Shen, Z. De. (2022). Using Hybrid Artificial Intelligence and Machine Learning Technologies for Sustainability in Going-Concern Prediction. *Sustainability (Switzerland)*, 14(3). <https://doi.org/10.3390/su14031810>
- Chu, M. K., & Yong, K. O. (2021). Big Data Analytics for Business Intelligence in Accounting and Audit. *Open Journal of Social Sciences*, 09(09), 42–52. <https://doi.org/10.4236/jss.2021.99004>
- Chye Koh, H., & Kee Low, C. (2004). Going concern prediction using data mining techniques. *Managerial Auditing Journal*, 19(3), 462–476. <https://doi.org/10.1108/02686900410524436>
- Denna, E. L., Hansen, J. V, Meservy, R. D., & Wood, L. E. (1992). Case-Based Reasoning and Risk Assessment in Audit Judgment. *International Journal of Intelligent Systems in Accounting Finance & Management*, 1(3), 163–171. Retrieved from <http://search.ebscohost.com/login.aspx?direct=true&db=bth&AN=18475595&site=ehost-live>

- Derks, K., de Swart, J., van Batenburg, P., Wagenmakers, E. J., & Wetzels, R. (2021). Priors in a Bayesian audit: How integration of existing information into the prior distribution can improve audit transparency and efficiency. *International Journal of Auditing*, 25(3), 621–636. <https://doi.org/10.1111/ijau.12240>
- Dhall, D., Kaur, R., & Juneja, M. (2020). Machine learning: A review of the algorithms and its applications. *Lecture Notes in Electrical Engineering*, 597, 47–63. https://doi.org/10.1007/978-3-030-29407-6_5/TABLES/2
- Ding, R. (2022). Enterprise Intelligent Audit Model by Using Deep Learning Approach. *Computational Economics*, 59(4), 1335–1354. <https://doi.org/10.1007/s10614-021-10192-9>
- Dutta, I., Dutta, S., & Raahemi, B. (2017). Detecting financial restatements using data mining techniques. *Expert Systems with Applications*, 90, 374–393. <https://doi.org/10.1016/j.eswa.2017.08.030>
- Elyan, E., & Gaber, M. M. (2017). A genetic algorithm approach to optimising random forests applied to class engineered data. *Information Sciences*, 384, 220–234. <https://doi.org/10.1016/j.ins.2016.08.007>
- Etheridge, H. L., Sriram, R. S., & Hsu, H. Y. K. (2000). A comparison of selected artificial neural networks that help auditors evaluate client financial viability. *Decision Sciences*, 31(2), 531–550. <https://doi.org/10.1111/j.1540-5915.2000.tb01633.x>
- Fabris, F., Magalhães, J. P. de, & Freitas, A. A. (2017). A review of supervised machine learning applied to ageing research. *Biogerontology*, 18(2), 171–188. <https://doi.org/10.1007/S10522-017-9683-Y/TABLES/1>
- Fedorova, E., Gilenko, E., & Dovzhenko, S. (2013). Bankruptcy prediction for Russian companies: Application of combined classifiers. *Expert Systems with Applications*, 40(18), 7285–7293. <https://doi.org/10.1016/j.eswa.2013.07.032>

- Fernández, M. Á., Sánchez Serrano, J. R., Alaminos Aguilera, D., & Casado, G. (2018). Predicting going concern opinion for hotel industry using classifiers combination. *International Journal of Scientific Management and Tourism*, ISSN-e 2386-8570, ISSN 2444-0299, Vol. 4, N^o. 1, 2018, Págs. 91-106, 4(1), 91-106. Retrieved from <http://agora.edu.es/servlet/articulo?codigo=6358784&info=resumen&idioma=ENG>
- Fieberg, C., Hesse, M., Loy, T., & Metko, D. (2022). *Machine Learning in Accounting Research*. 105-124. https://doi.org/10.1007/978-3-031-04063-4_6
- Forsati, R., Moayedikia, A., Jensen, R., Shamsfard, M., & Meybodi, M. R. (2014). Enriched ant colony optimization and its application in feature selection. *Neurocomputing*, 142, 354-371. <https://doi.org/10.1016/j.neucom.2014.03.053>
- Fukas, P., Rebstadt, J., Remark, F., & Thomas, O. (2021). Developing an Artificial Intelligence Maturity Model for Auditing. *29th European Conference on Information Systems Research Papers*, (June), 133. Retrieved from <http://rtsairesearch.googlecode.com/svn/trunk/Papers and Researches / General Games/Developing an Artificial Intelligence Engine.pdf>
- Geiger, M. A., Gold, A., & Wallage, P. (2021). Auditor going concern reporting: A review of global research and future research opportunities. *Auditor Going Concern Reporting: A Review of Global Research and Future Research Opportunities*, 1-168. <https://doi.org/10.4324/9781003127093>
- Geiger, M. a, & Rama, D. V. (2006). Reporting Accuracy. *Accounting Horizons*, 20(1), 1-17. Retrieved from <http://www.sciencedirect.com /science/article/pii/S0278425406000342%5Cnhttp://www.aaajournals.org/doi/abs/10.2308/acch.2006.20.1.1>
- Gepp, A., Linnenluecke, M. K., O'Neill, T. J., & Smith, T. (2018). Big data techniques in auditing research and practice: Current trends and future opportunities. *Journal of Accounting Literature*, 40(1), 102-115. <https://doi.org/10.1016/j.acclit.2017.05.003>

- Goo, Y. J. J., Chi, D. J., & Shen, Z. De. (2016). Improving the prediction of going concern of Taiwanese listed companies using a hybrid of LASSO with data mining techniques. *SpringerPlus*, 5(1). <https://doi.org/10.1186/s40064-016-2186-5>
- Hahn, P. (2019). Artificial intelligence and machine learning. In *Handchirurgie Mikrochirurgie Plastische Chirurgie* (Vol. 51). <https://doi.org/10.1055/a-0826-4789>
- Hajek, P., Olej, V., & Myskova, R. (2014). Forecasting corporate financial performance using sentiment in annual reports for stakeholders' decision-making. *Technological and Economic Development of Economy*, 20(4), 721–738. <https://doi.org/10.3846/20294913.2014.979456>
- Heye, A. M. (2021). The Future of Auditing: An Analysis of AI Implementation in the Big Four Accounting Firms. *Journal of Accounting & Organizational Change*, 3(2), 120–520. Retrieved from <https://scholars.unh.edu/honors/563>
- Indrawaty, & Wardayati, S. M. (2016). Implementing Islamic Corporate Governance (ICG) and Islamic Social Reporting (ISR) in Islamic Financial Institution (IFI). *Procedia - Social and Behavioral Sciences*, 219, 338–343. <https://doi.org/10.1016/j.sbspro.2016.04.042>
- Issa, H., Sun, T., & Vasarhelyi, M. A. (2016). Research ideas for artificial intelligence in auditing: The formalization of audit and workforce supplementation. *Journal of Emerging Technologies in Accounting*, 13(2), 1–20. <https://doi.org/10.2308/jeta-10511>
- Jacky, Y., & Sulaiman, N. A. (2022). The use of data analytics in external auditing: a content analysis approach. *Asian Review of Accounting*, 30(1), 31–58. <https://doi.org/10.1108/ARA-11-2020-0177/FULL/HTML>
- Jan, C. L. (2021). Using deep learning algorithms for CPAs' going concern prediction. *Information (Switzerland)*, 12(2), 1–22. <https://doi.org/10.3390/info12020073>

- Joseph, J., & Gaba, V. (2020). Organizational structure, information processing, and decision-making: A retrospective and road map for research. *Academy of Management Annals*, 14(1), 267–302. <https://doi.org/10.5465/annals.2017.0103>
- Karuppu, N. (2009). Evidence on Auditors Use of Business Continuity Models as an Analytical Procedure. *Accounting & Taxation*, 1(1), 63–74. Retrieved from <https://ideas.repec.org/a/ibf/acttax/v1y2009i1p63-74.html>
- Kellogg, K. C., Valentine, M. A., & Christin, A. (2020). Algorithms at work: The new contested terrain of control. *Academy of Management Annals*, 14(1), 366–410. <https://doi.org/10.5465/annals.2018.0174>
- Kirkos, E., Spathis, C., Nanopoulos, A., & Manolopoulos, Y. (2007). Identifying Qualified Auditors' Opinions: A Data Mining Approach. *Journal of Emerging Technologies in Accounting*, 4, 183–197.
- Koh, H. C., & Low, C. K. (2004). Going concern prediction using data mining techniques. *Managerial Auditing Journal*, 19(3), 462–476. <https://doi.org/10.1108/02686900410524436>
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of Emerging Technologies in Accounting*, 14(1), 115–122. <https://doi.org/10.2308/jeta-51730>
- Koskivaara, E. (2003). *Artificial Neural Networks in Auditing: State of the Art Data Mining and Knowledge Management Laboratory*. Retrieved from <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=d69456180f8d55ec7a3d4374d762813e165bf64c>
- Lehmann, C. M., & Norman, C. S. (2006). The Effects of Experience on Complex Problem Representation and Judgment In Auditing: An Experimental Investigation. *Behavioral Research in Accounting*, 18(1), 65–83. <https://doi.org/10.2308/BRJA.2006.18.1.65>

- Lehner, O. M., Ittonen, K., Silvola, H., Ström, E., & Wührleitner, A. (2022). Artificial intelligence based decision-making in accounting and auditing: ethical challenges and normative thinking. *Accounting, Auditing and Accountability Journal*, 35(9), 109–135. <https://doi.org/10.1108/AAAJ-09-2020-4934>
- Leitner-Hanetseder, S., Lehner, O. M., Eisl, C., & Forstenlechner, C. (2021). A profession in transition: actors, tasks and roles in AI-based accounting. *Journal of Applied Accounting Research*, 22(3), 539–556. <https://doi.org/10.1108/JAAR-10-2020-0201>
- Lindebaum, D., Vesa, M., & Den Hond, F. (2020). Insights from “the machine stops” to better understand rational assumptions in algorithmic decision making and its implications for organizations. *Academy of Management Review*, 45(1), 247–263. <https://doi.org/10.5465/amr.2018.0181>
- Loughran, T., & McDonald, B. (2016). Textual Analysis in Accounting and Finance: A Survey. *Journal of Accounting Research*, 54(4), 1187–1230. <https://doi.org/10.1111/1475-679X.12123>
- Mahapatra, U., Nayak, S. M., & Rout, M. (2020). A Systematic Approach to Enhance the Forecasting of Bankruptcy Data. *Advances in Intelligent Systems and Computing*, 1119, 641–650. https://doi.org/10.1007/978-981-15-2414-1_64/FIGURES/9
- Mai, F., Tian, S., Lee, C., & Ma, L. (2019). Deep learning models for bankruptcy prediction using textual disclosures. *European Journal of Operational Research*, 274(2), 743–758. <https://doi.org/10.1016/j.ejor.2018.10.024>
- Mateos-García, D., García-Gutiérrez, J., & Riquelme-Santos, J. C. (2016). An evolutionary voting for k-nearest neighbours. *Expert Systems with Applications*, 43, 9–14. <https://doi.org/10.1016/j.eswa.2015.08.017>
- Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. (2020). The Ethical Implications of Using Artificial Intelligence in Auditing. *Journal of Business Ethics*, 167(2), 209–234. <https://doi.org/10.1007/s10551-019-04407-1>

- Nasir, M., Simsek, S., Cornelsen, E., Ragothaman, S., & Dag, A. (2021). Developing a decision support system to detect material weaknesses in internal control. *Decision Support Systems*, 151. <https://doi.org/10.1016/j.dss.2021.113631>
- Nnenna, V., & Amaka, M. (2020). Automation of Accounting Processes: Impact of Artificial Intelligence. *International Journal of Research and Innovation in Social Science*, IV(VIII), 2454–6186. Retrieved from www.rsisinternational.org
- Park, S., Hamm, S. Y., & Kim, J. (2019). Performance evaluation of the GIS-based data-mining techniques decision tree, random forest, and rotation forest for landslide susceptibility modeling. *Sustainability (Switzerland)*, 11(20). <https://doi.org/10.3390/su11205659>
- Pradhan, R., Pathak, K., & Singh, V. (2011). Application of Neural Network in Prediction of Financial Viability. *International Journal of Soft Computing and Engineering (IJSCE)*, 1(2), 41–45. Retrieved from <http://www.doaj.org/doaj?func=fulltext&aId=847548>
- Raisch, S., & Krakowski, S. (2021). Artificial intelligence and management: The automation–augmentation paradox. *Academy of Management Review*, 46(1), 192–210. <https://doi.org/10.5465/AMR.2018.0072>
- Rohmah, K. L., Arisudhana, A., & Nurhantoro, T. S. (2022). The Future of Accounting With Artificial Intelligence: Opportunity And Challenge. *International Conference on Science and Technology Innovation (ICoSTEC)*, 1(1), 87–91. <https://doi.org/10.35842/ICOSTEC.V1I1.5>
- Rudra Kumar, M., & Kumar Gunjan, V. (2020). Review of Machine Learning models for Credit Scoring Analysis. *Ingeniería Solidaria*, 16(1). <https://doi.org/10.16925/2357-6014.2020.01.11>
- Saif, S. M., Sarikhani, M., & Ebrahimi, F. (2012). Finding Rules for Audit Opinions Prediction Through Data Mining Methods. *SSRN Electronic Journal*, 1(2), 28–36. <https://doi.org/10.2139/ssrn.2185919>

- Salehi, M., & Fard, F. Z. (2013). Data Mining Approach to Prediction of Going Concern using Classification and Regression Tree (CART). *Global Journal of Management and Business Research Accounting and Auditing*, 13(3), 25–29. Retrieved from <http://profdoc.um.ac.ir/paper-abstract-1034174.html>
- Sartori, F., Mazzucchelli, A., & Gregorio, A. Di. (2016). Bankruptcy forecasting using case-based reasoning: The CRePERIE approach. *Expert Systems with Applications*, 64, 400–411. <https://doi.org/10.1016/j.eswa.2016.07.033>
- Sexton, R. S., & Gupta, J. N. D. (2000). Comparative evaluation of genetic algorithm and backpropagation for training neural networks. *Information Sciences*, 129(1–4), 45–59. [https://doi.org/10.1016/S0020-0255\(00\)00068-2](https://doi.org/10.1016/S0020-0255(00)00068-2)
- Sherwood, M. G., Nagy, A. L., & Zimmerman, A. B. (2020). Non-cpas and office audit quality. *Accounting Horizons*, 34(3), 169–191. <https://doi.org/10.2308/horizons-18-072>
- Shirata, C. Y., & Sakagami, M. (2008). An Analysis of the “Going Concern Assumption”: Text Mining from Japanese Financial Reports. *Journal of Emerging Technologies in Accounting*, 5(1), 1–16. <https://doi.org/10.2308/jeta.2008.5.1.1>
- Sun, J., & Li, H. (2008). Data mining method for listed companies’ financial distress prediction. *Knowledge-Based Systems*, 21(1), 1–5. <https://doi.org/10.1016/j.knosys.2006.11.003>
- Tang, X., Li, S., Tan, M., & Shi, W. (2020). Incorporating textual and management factors into financial distress prediction: A comparative study of machine learning methods. *Journal of Forecasting*, 39(5), 769–787. <https://doi.org/10.1002/for.2661>
- Tsai, C. F., & Chiou, Y. J. (2009). Earnings management prediction: A pilot study of combining neural networks and decision trees. *Expert Systems with Applications*, 36(3 PART 2), 7183–7191. <https://doi.org/10.1016/j.eswa.2008.09.025>

- Tsao, G. (2021). *What are the Factors that Influence the Adoption of Data Analytics and Artificial Intelligence in Auditing?* 1–78.
- Vasquez, G. (2021). the Influence of Financial Relationships on Auditor Going Concern Decisions. *Journal of Theoretical Accounting Research*, 17(1), 141–175.
- Verhoeven, L., Mantelaers, E., & Zoet, M. (2022). *Automating the going concern assessment*.
- Xu, Q., & Kalelkar, R. (2020). Consequences of Going–Concern Opinion Inaccuracy at the Audit Office Level. *AUDITING: A Journal of Practice & Theory*, 39(3), 185–208. <https://doi.org/10.2308/AJPT-18-050>
- Yang, T., & Nazareth, D. (2022). Genetic Algorithm–based Feature Selection for Auditing Decisions. *AMCIS 2022 Proceedings*.
- Yeh, C. C., Chi, D. J., & Lin, Y. R. (2014). Going–concern prediction using hybrid random forests and rough set approach. *Information Sciences*, 254, 98–110. <https://doi.org/10.1016/j.ins.2013.07.011>
- Yıldırım, M., Okay, F. Y., & Özdemir, S. (2021). Big data analytics for default prediction using graph theory. *Expert Systems with Applications*, 176, 114840. <https://doi.org/10.1016/J.ESWA.2021.114840>
- Zdolšek, D., Jagrič, T., & Kolar, I. (2022). Auditor’s going–concern opinion prediction: the case of Slovenia. *Economic Research–Ekonomski Istraživanja*, 35(1), 106–121. <https://doi.org/10.1080/1331677X.2021.1888766>
- Zhang, C. (Abigail), Cho, S., & Vasarhelyi, M. (2022). Explainable Artificial Intelligence (XAI) in auditing. *International Journal of Accounting Information Systems*, 46, 100572. [https://doi.org/10.1016/j. accinf. 2022. 100572](https://doi.org/10.1016/j.accinf.2022.100572)

الملاحق

الملحق رقم (1) خوارزمية اختيار المتغيرات البحث التطويري EA واشتقاق النموذج النهائي:

=== Attribute Selection on all input data ===

Search Method:

Evolutionary Search.

Start set: no attributes

Population size: 20

Number of generations: 20

Initialization: random initialization

Selection: tournament selection

Crossover: single-point crossover

Mutation: bit-flip mutation

Replacement: generational replacement with elitism

Report frequency: 20

Seed: 1

Log file: C:\Program Files\Weka-3-8-4

Initial population

fitness -> subset

0.8803 -> 4 5 7 10 14 23 24

0.8493 -> 24

0.9384 -> 2 4 8 10 11 13 14 15 18 22 24

0.9439 -> 1 3 5 6 7 8 10 11 13 14 15 16 18 21

0.8684 -> 2 6 9 12

0.82 -> 9

0.938 -> 1 2 4 5 9 10 12 15 16 22 24

0.8633 -> 9 13 16 23

0.862 -> 7

0.9023 -> 5 9 11 13 14 17 20 21 23

0.8777 -> 1 2 4 11 18 21

0.8289 -> 12

0.9146 -> 1 2 3 4 6 8 9 17 18 19 20 21 23
0.9478 -> 1 2 4 6 7 10 15 16 17 20 21 22
0.8289 -> 12
0.8879 -> 1 2 4 5 8 12 13 14 16 18 20 21 23 24
0.9087 -> 7 8 9 17 22
0.8637 -> 3 9 11 18 21 22
0.8998 -> 3 4 6 7 8 9 10 11 13 14 16 17 21 24
0.9223 -> 3 8 9 12 14 17 18 19 20 21

Generation: 20

fitness -> subset

0.9648 -> 2 6 7 8 10 15 16 17 18 19 20 21 23
0.9626 -> 2 3 5 6 8 10 12 15 16 17 18 19 20 23
0.9571 -> 5 6 8 13 15 16 17 18 19 23 24
0.9541 -> 2 3 6 7 8 9 10 11 13 15 16 17 18 19 23
0.9618 -> 2 3 6 7 8 10 13 15 16 17 18 19 20 23
0.9478 -> 2 3 5 6 7 8 11 15 18 19 20 23 24
0.9473 -> 2 7 8 10 12 13 15 16 24
0.9546 -> 2 3 6 8 10 11 13 14 15 17 18 19 20 22 23
0.9533 -> 2 3 4 5 15 16 17 18 19 20 23
0.8828 -> 1 3 6 7 8 10 12 16 20 21
0.9575 -> 2 3 6 7 8 9 10 12 15 17 18 20 21 23
0.9597 -> 2 3 6 7 8 9 10 15 17 18 20 21
0.9597 -> 2 3 6 7 8 10 15 16 17 18 20 23
0.9597 -> 2 3 5 6 10 12 15 16 17 18 19 20 22
0.9512 -> 2 3 5 6 10 13 15 16 17 19 23
0.9554 -> 2 3 7 8 10 12 13 15 16 17 18 20 21 22
0.955 -> 3 6 7 8 10 12 15 16 17 21
0.9541 -> 2 6 7 8 10 11 15 17 20 21
0.8951 -> 1 3 6 7 8 10 17 20 21 24
0.9554 -> 1 2 5 6 7 8 10 15 16 17 18 19 20 21 22 23

=== Statistics of the Evolutionary Search ===

Last updated iteration: 20

Current mean fitness: 0.9494

Current max fitness: 0.9648

Current max fitness with individual: 2 6 7 8 10 15 16 17 18 19 20 21 23

Current min fitness: 0.8828

Current min fitness with individual: 1 3 6 7 8 10 12 16 20 21

Max fitness found: 0.9648

Max fitness found in iteration: 17

Max fitness found with individual: 2 6 7 8 10 15 16 17 18 19 20 21 23

Min fitness found: 0.82

Min fitness found in iteration: 0

Min fitness found with individual: 9

Attribute Subset Evaluator (supervised, Class (nominal): 25 Aopinion):

Wrapper Subset Evaluator

Learning scheme: weka.classifiers.trees.RandomForest

Scheme options: -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1

Subset evaluation: classification accuracy

Number of folds for accuracy estimation: 5

Selected attributes: 2,6,7,8,10,15,16,17,18,19,20,21,23 : 13

x2

x6

x7

x8

x10

x15

x16

x17

x18

x19

x20

x21

x23

الملحق رقم (2) اختبار T للفرق المعنوي بين النموذج النهائي والأولى لنتائج المقاييس المختلفة

أولاً: عدد الحالات الإيجابية True positive rate

Tester: weka.experiment.PairedTTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: True_positive_rate

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/30/22, 1:53 PM

Dataset (1) funcnio | (2) tree (3) func (4) lazy

'weka goin conc training' (10) 0.88 | 0.96 v 0.90 0.95 v

'weka goin conc without 1 (10) 0.88 | 0.96 v 0.89 0.91

(v/ /*) | (2/0/0) (0/2/0) (1/1/0)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

(4) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

ثانيا: عدد الحالات الإيجابية الخاطئة False Positive rate

Tester: weka.experiment.PairedTTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: False_positive_rate

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/30/22, 1:53 PM

Dataset (1) funcio | (2) tree (3) func (4) lazy

'weka goin conc without 1 (10) 0.33 | 0.12 * 0.18 * 0.20 *

'weka goin conc training' (10) 0.30 | 0.10 * 0.16 * 0.19 *

(v/ /*) | (0/0/2) (0/0/2) (0/0/2)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

(4) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

ثالثا: عدد الحالات السليمة الخاطئة False Negative Rate

Tester: weka.experiment.PairedTTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: False_negative_rate

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/30/22, 1:54 PM

dataset (1) functio | (2) tree (3) func (4) lazy

 'weka goin conc without 1 (10) 0.12 | 0.04 * 0.11* 0.09*

'weka goin conc training' (10) 0.12 | 0.03 * 0.10* 0.05 *

 (v/ /*) | (0/0/2) (0/2/0) (0/1/1)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

(4) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

رابعاً: عدد الحالات السلبية الصحيحة true Negative Rate

Tester: weka.experiment.PairedTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: True_negative_rate

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/30/22, 1:53 PM

Dataset (1) functio | (2) tree (3) func (4) lazy

'weka goin conc training' (10) 0.70 | 0.90 v 0.84 v 0.81 v
'weka goin conc without 1 (10) 0.67 | 0.88 v 0.82 v 0.85 v

(v/ /*) | (2/0/0) (2/0/0) (2/0/0)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

(4) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

خامسا: معامل Kappa الإحصائي

Tester: weka.experiment.PairedTTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: Kappa_statistic

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/28/22, 6:50 PM

Dataset (1) funcio | (2) tree (3) func (4) lazy

'weka goin conc without 1 (10) 0.56 | 0.85 v 0.71 v 0.76 v
'weka goin conc training' (10) 0.59 | 0.86 v 0.74 v 0.78 v

(v/ /*) | (2/0/0) (2/0/0) (2/0/0)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

(4) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

سادسا: معامل الخطأ **Root_mean_squared_error**

Tester: weka.experiment.PairedTTTester -G 3,4,5 -D 1 -R 2 -S 0.05 -result-matrix "weka.experiment.ResultMatrixPlainText -mean-prec 2 -stddev-prec 2 -col-name-width 0 -row-name-width 25 -mean-width 2 -stddev-width 2 -sig-width 1 -count-width 5 -print-col-names -print-row-names -enum-col-names"

Analysing: Root_mean_squared_error

Datasets: 2

Resultsets: 4

Confidence: 0.05 (two tailed)

Sorted by: -

Date: 12/28/22, 8:38 PM

Dataset (1) funcio | (2) tree (3) lazy (4) func

'weka goin conc without 1 (10) 0.38 | 0.24 * 0.31 * 0.35 *

'weka goin conc training' (10) 0.36 | 0.23 * 0.29 * 0.32 *

(v/ /*) | (0/0/2) (0/0/2) (0/0/2)

Key:

(1) functions.Logistic '-C -R 1.0E-8 -M 200 -do-not-check-capabilities -num-decimal-places 4 -batch-size 200' 3932117032546553727

(2) trees.RandomForest '-P 100 -store-out-of-bag-predictions -print -attribute-importance -I 100 -num-slots 1 -K 10 -M 1.0 -V 0.001 -S 1 -B' 1116839470751428698

(3) lazy.KStar '-B 50 -M a -num-decimal-places 5 -batch-size 350' 332458330800479083

(4) functions.MultilayerPerceptron '-L 0.2 -M 0.1 -N 600 -V 0 -S 0 -E 20 -H \"a, 5, 5\" -5990607817048210779

الملحق رقم (3) نتائج التنبؤ بعام (2021) لحكم مراقب الحسابات بشأن استمرارية الشركات باستخدام الانحدار اللوجستي وأدوات الذكاء الاصطناعي

المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية	المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية
1	استمرار	صحيح	صحيح	صحيح	صحيح	59	استمرار	صحيح	صحيح	صحيح	صحيح
2	استمرار	صحيح	صحيح	صحيح	صحيح	60	تعثر	صحيح	صحيح	صحيح	صحيح
3	تعثر	صحيح	صحيح	صحيح	صحيح	61	استمرار	صحيح	صحيح	صحيح	صحيح
4	استمرار	صحيح	صحيح	صحيح	صحيح	62	استمرار	صحيح	صحيح	صحيح	صحيح
5	استمرار	صحيح	صحيح	صحيح	صحيح	63	تعثر	صحيح	صحيح	صحيح	صحيح
6	تعثر	صحيح	صحيح	صحيح	صحيح	64	استمرار	صحيح	صحيح	صحيح	صحيح
7	استمرار	صحيح	صحيح	صحيح	صحيح	65	تعثر	صحيح	صحيح	صحيح	صحيح
8	تعثر	صحيح	صحيح	صحيح	صحيح	66	تعثر	صحيح	صحيح	صحيح	صحيح
9	تعثر	صحيح	صحيح	صحيح	صحيح	67	استمرار	صحيح	صحيح	صحيح	صحيح
10	تعثر	صحيح	صحيح	صحيح	صحيح	68	تعثر	صحيح	صحيح	صحيح	صحيح
11	استمرار	صحيح	صحيح	صحيح	صحيح	69	تعثر	صحيح	صحيح	صحيح	صحيح
12	استمرار	صحيح	صحيح	صحيح	صحيح	70	استمرار	صحيح	صحيح	صحيح	صحيح
13	استمرار	صحيح	صحيح	صحيح	صحيح	71	استمرار	صحيح	صحيح	صحيح	صحيح
14	استمرار	صحيح	صحيح	صحيح	صحيح	72	استمرار	صحيح	صحيح	صحيح	صحيح
15	استمرار	صحيح	صحيح	صحيح	صحيح	73	استمرار	صحيح	صحيح	صحيح	صحيح
16	استمرار	صحيح	صحيح	صحيح	صحيح	74	استمرار	صحيح	صحيح	صحيح	صحيح
17	استمرار	صحيح	صحيح	صحيح	صحيح	75	استمرار	صحيح	صحيح	صحيح	صحيح
18	استمرار	صحيح	صحيح	صحيح	صحيح	76	استمرار	صحيح	صحيح	صحيح	صحيح
19	استمرار	صحيح	صحيح	صحيح	صحيح	77	استمرار	صحيح	صحيح	صحيح	صحيح
20	تعثر	صحيح	صحيح	صحيح	صحيح	78	استمرار	صحيح	صحيح	صحيح	صحيح
21	استمرار	صحيح	صحيح	صحيح	صحيح	79	تعثر	صحيح	صحيح	صحيح	صحيح

المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية	المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية
22	استمرار	صحيح	صحيح	صحيح	صحيح	80	استمرار	صحيح	صحيح	صحيح	صحيح
23	تعثر	صحيح	صحيح	صحيح	صحيح	81	استمرار	صحيح	صحيح	صحيح	صحيح
24	استمرار	صحيح	صحيح	صحيح	صحيح	82	تعثر	صحيح	صحيح	صحيح	صحيح
25	استمرار	صحيح	صحيح	صحيح	صحيح	83	استمرار	صحيح	صحيح	صحيح	صحيح
26	تعثر	صحيح	صحيح	صحيح	صحيح	84	استمرار	صحيح	صحيح	صحيح	صحيح
27	استمرار	صحيح	صحيح	صحيح	صحيح	85	تعثر	صحيح	صحيح	صحيح	صحيح
28	تعثر	صحيح	صحيح	صحيح	صحيح	86	استمرار	صحيح	صحيح	صحيح	صحيح
29	استمرار	صحيح	صحيح	صحيح	صحيح	87	تعثر	صحيح	صحيح	صحيح	صحيح
30	استمرار	صحيح	صحيح	صحيح	صحيح	88	استمرار	صحيح	صحيح	صحيح	صحيح
المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية	المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحدار اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية
31	استمرار	صحيح	صحيح	صحيح	صحيح	89	استمرار	صحيح	صحيح	صحيح	صحيح
32	استمرار	صحيح	صحيح	صحيح	صحيح	90	استمرار	صحيح	صحيح	صحيح	صحيح
33	استمرار	صحيح	صحيح	صحيح	صحيح	91	استمرار	صحيح	صحيح	صحيح	صحيح
34	تعثر	صحيح	صحيح	صحيح	صحيح	92	استمرار	صحيح	صحيح	صحيح	صحيح
35	استمرار	صحيح	صحيح	صحيح	صحيح	93	تعثر	صحيح	صحيح	صحيح	صحيح
36	تعثر	صحيح	صحيح	صحيح	صحيح	94	استمرار	صحيح	صحيح	صحيح	صحيح
37	تعثر	صحيح	صحيح	صحيح	صحيح	95	تعثر	صحيح	صحيح	صحيح	صحيح
38	تعثر	صحيح	صحيح	صحيح	صحيح	96	تعثر	صحيح	صحيح	صحيح	صحيح

المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحاد اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية	المشاهدة رقم	حكم مراقب الحسابات الفعلي لعام 2019	الاتحاد اللوجستي	الشبكات العصبية الاصطناعية	الجار الأقرب	خوارزمية الغابات العشوائية
39	استمرار	صحيح	صحيح	صحيح	صحيح	97	تعثر	صحيح	صحيح	صحيح	صحيح
40	استمرار	خاطئ	خاطئ	صحيح	صحيح	98	استمرار	صحيح	صحيح	صحيح	صحيح
41	تعثر	خاطئ	خاطئ	صحيح	صحيح	99	استمرار	صحيح	صحيح	صحيح	صحيح
42	استمرار	صحيح	خاطئ	صحيح	صحيح	100	تعثر	خاطئ	خاطئ	خاطئ	صحيح
43	تعثر	خاطئ	صحيح	خاطئ	خاطئ	101	استمرار	خاطئ	خاطئ	خاطئ	خاطئ
44	استمرار	صحيح	صحيح	صحيح	صحيح	102	تعثر	صحيح	صحيح	صحيح	خاطئ
45	تعثر	خاطئ	صحيح	صحيح	صحيح	103	استمرار	صحيح	صحيح	صحيح	صحيح
46	استمرار	صحيح	صحيح	صحيح	صحيح	104	تعثر	صحيح	صحيح	صحيح	صحيح
47	استمرار	خاطئ	صحيح	صحيح	صحيح	105	استمرار	صحيح	صحيح	صحيح	صحيح
48	استمرار	صحيح	صحيح	صحيح	صحيح	106	استمرار	صحيح	صحيح	صحيح	صحيح
49	استمرار	صحيح	صحيح	صحيح	صحيح	107	استمرار	صحيح	صحيح	صحيح	صحيح
50	استمرار	صحيح	صحيح	خاطئ	صحيح	108	استمرار	صحيح	صحيح	صحيح	صحيح
51	تعثر	خاطئ	صحيح	خاطئ	صحيح	109	استمرار	صحيح	صحيح	صحيح	صحيح
52	تعثر	خاطئ	خاطئ	خاطئ	خاطئ	110	تعثر	خاطئ	خاطئ	خاطئ	صحيح
53	استمرار	صحيح	صحيح	صحيح	صحيح	111	استمرار	صحيح	صحيح	صحيح	صحيح
54	تعثر	خاطئ	صحيح	صحيح	صحيح	112	تعثر	خاطئ	صحيح	صحيح	صحيح
55	تعثر	صحيح	صحيح	صحيح	صحيح	113	استمرار	صحيح	صحيح	صحيح	صحيح
56	استمرار	صحيح	صحيح	صحيح	صحيح	114	تعثر	صحيح	صحيح	صحيح	صحيح
57	تعثر	خاطئ	خاطئ	خاطئ	خاطئ	115	تعثر	خاطئ	خاطئ	خاطئ	صحيح
58	استمرار	صحيح	صحيح	صحيح	صحيح			صحيح	صحيح	صحيح	صحيح

□