



مجلة الشروق للملوج التجارية
ISSN: 1687/8523
Online : 2682-356X
2007/12870
sjcs@sha.edu.eg
موقع المجلة : <https://sjcs.sha.edu.eg/index.php>



أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

د/ ريم محمد محمود عبد المنعم
أستاذ المحاسبة المساعد

المعهد العالي للعلوم الإدارية - بلبيس الشرقية
reemeyad2007@gmail.com

د/ أمير عاطف نصحي عياد
مدرس المحاسبة

كلية التجارة - جامعة عين شمس
amiratef@bus.asu.edu.eg

د/ أحمد محمد سعد مصطفى
مدرس المحاسبة

المعهد العالي للعلوم الإدارية - بلبيس الشرقية
mrahmedsaad07@gmail.com

كلمات مفتاحية :

تقنيات الذكاء الاصطناعي - خوارزميات تعلم الآلة - التنبؤ بالأرباح المستقبلية -
ثقة المستثمرين.

التوثيق المقترح وفقا لنظام APA :

عبد المنعم، ريم محمد محمود، عياد، أمير عاطف نصحي، مصطفى، أحمد محمد
سعد، (٢٠٢٥)، أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة
كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية،
مجلة الشروق للعلوم التجارية، العدد السابع عشر، المعهد العالي للحاسبات
وتكنولوجيا المعلومات، أكاديمية الشروق.

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

د/ ريم محمد محمود عبد المنعم
أستاذ المحاسبة المساعد
المعهد العالي للعلوم الإدارية - بلبس الشرقية
reemeyad2007@gmail.com

د/ أمير عاطف نصحي عياد
مدرس المحاسبة
كلية التجارة - جامعة عين شمس
amiratef@bus.asu.edu.eg

د/ أحمد محمد سعد مصطفى
مدرس المحاسبة
المعهد العالي للعلوم الإدارية - بلبس الشرقية
mrahmedsaad07@gmail.com

ملخص الدراسة:

هدفت هذه الدراسة إلى قياس أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين. واعتمدت الدراسة على خوارزميات تعلم الآلة التالية في التنبؤ: مربع كاي للكشف التلقائي عن التفاعل (CHAID)، شجرة التصنيف والانحدار (C&R Tree) وهما إحدى الخوارزميات الفرعية لخوارزمية شجرة القرارات (DT)، الأقرب جار (KNN)، آلة دعم المتجهات (SVM)، آلة متجهات الدعم الخطية (LS)، الشبكات العصبية (NN)، الغابات العشوائية (RF). وأجريت الدراسة على عينة من الشركات غير المالية المساهمة المدرجة بالبورصة حجمها ٥٠ شركة تنتمي لقطاعات اقتصادية مختلفة وتدرج تحت مؤشر EGX100، وذلك خلال الفترة من عام ٢٠١٩م حتى عام ٢٠٢٤م. واستخدمت الدراسة العديد من الأساليب الإحصائية التي تصلح للتعامل مع متغيرات الدراسة، وذلك لاختبار فرض الدراسة. وقد توصلت نتائج الدراسة إلى وجود أثر إيجابي ذو دلالة إحصائية للتنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين. كما أظهرت النتائج أن خوارزمية الغابات العشوائية (RF) هي الأكثر فعالية ودقة في التنبؤ بالأرباح المستقبلية من بين الخوارزميات الأخرى المستخدمة، وتساهم في تعزيز ثقة المستثمرين.

الكلمات المفتاحية: تقنيات الذكاء الاصطناعي - خوارزميات تعلم الآلة - التنبؤ بالأرباح المستقبلية - ثقة المستثمرين.

The Effect of Predicting Future Earnings Using Machine Learning Algorithms as an Artificial Intelligence Technique on Enhancing Investor Confidence: An Applied Study

Abstract:

The aim of this study was to measure the impact of predicting future earnings using machine learning algorithms as one of the artificial intelligence techniques on enhancing investor confidence. The study employed the following machine learning algorithms for forecasting: Chi-squared Automatic Interaction Detector (CHAID), Classification and Regression Tree (C&R Tree) both of which are sub-algorithms of the Decision Tree technique K-Nearest Neighbors (KNN), Support Vector Machine (SVM), Linear Support Vector Machine (LS), Neural Networks (NN), and Random Forests (RF). The study was conducted on a sample of 50 non-financial listed companies included in the EGX100 index, representing various economic sectors, during the period from 2019 to 2024. Various statistical methods suitable for handling the study variables were used to test the research hypothesis. The results of the study showed a statistically significant positive impact of predicting future earnings using machine learning algorithms as an artificial intelligence technique on enhancing investor confidence. The findings also revealed that the Random Forest (RF) algorithm was the most effective and accurate in predicting future earnings among the other algorithms used and contributed to enhancing investor confidence.

Keywords: Artificial Intelligence Techniques - Machine Learning Algorithms - Prediction future earnings - Investor Confidence.

١- مقدمة الدراسة:

في ظل التقدم التكنولوجي السريع الذي يشهده العالم في مختلف المجالات، أصبح الذكاء الاصطناعي أحد أهم العوامل التي تسهم في تطوير العديد من الصناعات والقطاعات. ففي القطاع المالي تحديداً، لعبت تقنيات الذكاء الاصطناعي دوراً مهماً في تحسين دقة العمليات المالية من خلال تحليل كميات ضخمة من البيانات واستخراج الأنماط "أي تحليل كميات كبيرة من البيانات بهدف اكتشاف العلاقات المتكررة والغير ظاهرة" التي يصعب على الإنسان التعرف عليها (Huang et al., 2022).

وتُعتبر تقنيات الذكاء الاصطناعي من أهم التطورات التكنولوجية في مختلف المجالات بشكل عام وفي مجال المحاسبة بشكل خاص، حيث يُعرف الذكاء الاصطناعي بأنه مجموعة من الخصائص والسلوكيات المتقدمة التي تتميز بها برامج الحاسوب، مما يمكنه من محاكاة القدرات العقلية للبشر، ومن أبرز مميزاته قدرته على التعلم والاستنتاج، فضلاً عن اتخاذ قرارات سريعة بشأن الأحداث غير المتوقعة التي لم يتم برمجتها مسبقاً، حيث تهدف هذه التقنيات إلى مساعدة الشركات في تحقيق أهداف محددة بكفاءة وفعالية (عبدالقادر، ٢٠١٩). ومن بين هذه التقنيات المتطورة، تعتبر خوارزميات تعلم الآلة من الأدوات الأساسية التي تعتمد عليها تقنيات الذكاء الاصطناعي في التنبؤات المالية. وتشمل هذه الخوارزميات العديد من الأساليب المتقدمة مثل الشبكات العصبية الاصطناعية، المنطق الضبابي، آلات دعم المتجهات، الغابات العشوائية، وشجرة القرارات، إلى جانب العديد من الخوارزميات الأخرى. حيث تعتمد هذه التقنيات على تحليل كميات ضخمة من البيانات التاريخية للشركات والأسواق المالية (Aly et al., 2023; Amos and Rimona, 2019).

وقد أشارت دراسات (Papadimitriou and Demirel et al., 2021; Khan, 2024; Gogas, 2021) إلى أن خوارزميات تعلم الآلة تتميز بقدرتها على معالجة كميات هائلة ومعقدة من البيانات التي يصعب على البشر تحليلها يدوياً. حيث يمكن لهذه الخوارزميات أن تستخلص أنماطاً وعلاقات خفية داخل تلك البيانات "أي أن الخوارزميات قادرة على تحليل البيانات واكتشاف العلاقات أو الأنماط التي قد تكون غير واضحة أو مخفية في البيانات، فهذه الأنماط تكون غير ظاهرة بالعين

المجردة، ولا يستطيع الإنسان اكتشافها بسهولة بدون استخدام تقنيات متقدمة"، مما يساهم بشكل كبير في تحسين دقة التنبؤات المتعلقة بالأداء المالي للشركات والأسواق. وبفضل هذه القدرات التحليلية المتقدمة، يمكن أن توفر خوارزميات تعلم الآلة تقديرات أكثر دقة وموثوقية للربح والنمو المستقبلي، مما تساعد المستثمرين على اتخاذ قرارات استثمارية مدروسة ومعتمدة على بيانات حقيقية وموضوعية. كما أن هذه التنبؤات يمكن أن تساعد في تخفيض المخاطر المحتملة وتحسين استراتيجيات الاستثمار. وقد أوضحت دراسة (Schmitz and Leoni, 2019) إلى أن المقومات الأساسية التي يجب توافرها في منشآت الأعمال لتمكينها من تطبيق تقنيات الذكاء الاصطناعي هي وجود بنية تحتية مناسبة تشمل الأجهزة والبرمجيات والموارد اللازمة لدعم هذه التقنيات. كما يجب أن تكون هناك إدارة متخصصة في التحليل المستمر للبيانات، بحيث تتمكن من توفير معلومات دقيقة وملائمة تدعم التنبؤ بالتغيرات المستقبلية في بيئة الأعمال. هذا التحليل المنتظم يساعد المنشأة على الاستجابة بفعالية للتغيرات والظروف الجديدة، مما يساهم في اتخاذ قرارات استراتيجية تساهم في تحقيق أهدافها.

ويُعد التنبؤ بالأرباح المستقبلية من العوامل الأساسية التي تؤثر بشكل كبير في اتخاذ قرارات المستثمرين. فكلما كانت التوقعات حول أرباح الشركات في المستقبل أكثر دقة، كلما تمكن المستثمرون من اتخاذ قرارات استثمارية مدروسة بشكل أفضل، مما يعزز من فرصهم في تحقيق أرباح أعلى وتحقيق نتائج إيجابية. ويعتمد التنبؤ بالأرباح المستقبلية بشكل رئيسي على تحليل البيانات المالية للشركات، مثل الإيرادات والأرباح السابقة، بالإضافة إلى دراسة الاتجاهات السائدة في السوق، مثل التغيرات الاقتصادية وتطورات القطاع (Dallu, 2018). كما تلعب خوارزميات تعلم الآلة دوراً حيوياً في تحسين دقة التنبؤات، حيث تساهم هذه الخوارزميات في تحليل كميات ضخمة من البيانات واكتشاف العلاقات أو الأنماط المخفية التي قد لا تكون واضحة من خلال التحليل التقليدي. باستخدام هذه الخوارزميات، تصبح التوقعات أكثر دقة وأقل عرضة للأخطاء، مما يساعد المستثمرين في اتخاذ قرارات قائمة على أساس علمي مدروس (Altarazi and Santos, 2024).

٢- مشكلة الدراسة:

في العصر الحديث، أصبحت التنبؤات المالية جزءاً أساسياً من القرارات المالية والاستثمارية التي تولى اهتماماً كبيراً لدى المستثمرون في الأسواق المالية. وبما أن أسواق المال تشهد تقلبات مستمرة، فقد أصبحت الحاجة إلى تنبؤات مالية دقيقة للأرباح المستقبلية أكثر إلحاحاً. حيث تُعد خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي أحد الأدوات الحديثة التي تعتمد على معالجة البيانات الضخمة لاستخلاص الأنماط والتوقعات الدقيقة. وقد أشارت دراسة (عويس، ٢٠٢٤) إلى أن الشركات تعتمد بشكل كبير على التنبؤ بالأرباح لاتخاذ قرارات حاسمة بشأن الاستثمارات المستقبلية، إدارة الموارد، وتحديد استراتيجيات التسويق. وتقليدياً، كانت هذه التوقعات تعتمد على النماذج الإحصائية التقليدية والتحليل التاريخي للأداء المالي. ومع ذلك، فإن الذكاء الاصطناعي وتقنياته الحديثة، بما في ذلك تعلم الآلة وتحليل البيانات الكبيرة، توفر تحسينات كبيرة في دقة هذه التوقعات. فمن خلال تحليل أنماط البيانات المالية بالإضافة إلى المعلومات الخارجية مثل التغيرات في السوق، الاقتصاد، وسلوك المستهلكين، يمكن للذكاء الاصطناعي تحديد الاتجاهات المستقبلية والتنبؤ بالأرباح بشكل أكثر دقة وفعالية.

في هذا السياق، أظهرت الدراسات المتعلقة بخوارزميات تعلم الآلة تأثيراً متبايناً على التنبؤات المالية. ولذلك، من الضروري فهم العوامل التي تؤثر في التنبؤ بالأرباح المستقبلية من خلال دور هذه الخوارزميات وتقييم تلك العوامل على تعزيز ثقة المستثمرين. حيث تأتي هذه الحاجة نتيجة لأهمية الدور الذي يمكن أن تلعبه هذه الخوارزميات في تحسين دقة التنبؤات المالية وبيان انعكاسها على تعزيز ثقة المستثمرين، مما يستدعي دراسة هذه العوامل بشكل أكثر تفصيلاً لتحديد كيفية تعزيز قدرتها في توفير تقديرات موثوقة للأرباح المستقبلية.

ومع ذلك، يظل التساؤل قائماً حول أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين، والتي تعتبر أحد العوامل الأساسية التي تحدد استقرار الأسواق المالية ونموها، خاصة فيما يتعلق بتأثير التنبؤات المستقبلية الدقيقة التي يعتمد عليها المستثمرون في قراراتهم المالية

والاستثمارية مثل تقارير الأرباح، والتنبؤات والتوقعات المالية، والتحليلات الاقتصادية.

في ضوء ما سبق تتمثل مشكلة الدراسة في التساؤل الرئيس التالي:

"ما هو أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين؟"

وللإجابة عن التساؤل الرئيس، تطرح الدراسة التساولين الفرعيين التاليين:

- ما هو أثر التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين؟
- ما هو أثر التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين؟

٣- الأدبيات المحاسبية السابقة واشتقاق فروض الدراسة:

يتناول الباحثين في هذا الجزء من الدراسة تحديد وتحليل أهم الجهود البحثية السابقة المتعلقة بمتغيرات الدراسة الرئيسية والمتمثلة في التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي، وتعزيز ثقة المستثمرين. ويسعى الباحثين إلى عرض الدراسات السابقة التي تناولت التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي، والدراسات السابقة التي تناولت أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين، وذلك بغرض التعرف على ما توصلت إليه الدراسات السابقة من نتائج، ومعرفة ما يمكن أن تساهم به الدراسة الحالية لاستكمال جهود تلك الدراسات.

١/٣ الأدبيات المحاسبية التي تناولت التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي:

١/١/٣ هدفت دراسة (Hunt et al., 2019) إلى تقييم فعالية تقنيات تعلم الآلة في تحسين التنبؤ بمتغيرات الأرباح ومدى تأثيرها على العوائد، واستخدمت الدراسة ثلاثة نماذج وهما: الانحدار اللوجستي التدريجي -Stepwise Logistic Regression"

، الإلاستيك نت - Elastic Net، والغابات العشوائية - Random Forest"، وذلك على عينة تمثلت في ١١٦٩٠٤ ملاحظة شركة -سنة من خلال استخدام بيانات الشركات خلال السنوات المالية من عام ١٩٧٣م حتي عام ١٩٧٧م، والتنبؤ بعام ١٩٧٨م، وهكذا حتى الوصول إلى آخر بيانات مالية متاحة من عام ٢٠١١م حتي عام ٢٠١٥م للتنبؤ بعام ٢٠١٦م، وقامت الدراسة بعمل مقارنة بين الثلاث نماذج لتوقع اتجاه التغير في الأرباح السنوية القادمة من خلال زيادة الأرباح أو عدم زيادتها، ووجدت الدراسة أن نموذج "الغابات العشوائية" يتفوق على النماذج التقليدية وهم: الانحدار اللوجيستي التدريجي والإلاستيك نت، وذلك في دقة التنبؤ والعوائد غير العادية. وأظهرت نتائج الدراسة أن تعلم الآلة يساعد في تحليل بيانات مالية معقدة وتحقيق نتائج أفضل في التنبؤ بتغيرات الأرباح. وأظهرت نتائج الدراسة أيضاً أن نموذج الغابات العشوائية، يمكن أن تكون أداة فعالة في تحليل الأسواق المالية وتحقيق أرباح.

٢/١/٣ هدفت دراسة (Amos and Rimona, 2019) إلى قياس أثر تقنيات التعلم الآلي في التنبؤ بحركة الأرباح المستقبلية عن طريق تطبيق تقنية الآلات الداعمة للمتجهات (SVM) على بيانات "XBRL" وإنشاء نموذج للتنبؤ بحركة الأرباح المستقبلية، وبيانات "XBRL" هي لغة معيارية مفتوحة تستخدم لتبادل المعلومات المالية بين الشركات والمستثمرين والهيئات التنظيمية، واستخدمت الدراسة تقنية الآلات الداعمة للمتجهات (SVM) على بيانات لغة تقارير الأعمال "XBRL" التي تفرضها لجنة الأوراق المالية والبورصات، واختبرت الدراسة بيانات التغير في الأرباح بين الربع الثاني من عام ٢٠١٧م والربع الثالث من عام ٢٠١٧م على عينة من الشركات بلغت ٤١٠٩ شركة، وتوصلت نتائج الدراسة إلى أن التنبؤ بحركة أرباح الشركات المستقبلية وصلت إلى نسبة ٨٤,٢٠% باستخدام نموذج تقنية الآلات الداعمة للمتجهات (SVM) وهي نسبة مرتفعة مقارنة بالنماذج التقليدية، كما أشارت النتائج إلى أن نموذج تقنية الآلات الداعمة للمتجهات (SVM) يتمتع بقيمة تحليلية ويمكن استخدامه كأداة في التحليل المالي، وسيكون لها تأثير كبير على قرارات الاستثمار.

٣/١/٣ هدفت دراسة (Chen et al., 2022) إلى التنبؤ باتجاه تغيرات الأرباح المستقبلية من خلال تطبيق تقنية تعلم الآلة على مجموعة من المعلومات المالية التفصيلية، واستخدمت الدراسة تقنيتي الغابات العشوائية والانحدار اللوجستي، على عينة من البيانات المالية التفصيلية لقياس اتجاه تغيرات الأرباح للعام المقبل خلال الفترة من ٢٠١٥م حتي ٢٠١٦م مقارنة بالسنتين المتتاليتين خلال الفترة من ٢٠١٧م حتي ٢٠١٨م، وتوصلت نتائج الدراسة إلى أن تطبيق تقنية الغابات العشوائية على المعلومات المالية التفصيلية أظهرت تفوقاً مقارنة بالنموذج التقليدي "الانحدار اللوجستي بنسبة تتراوح من ٦٧,٥٢٪ إلى ٦٨,٦٦٪"، كما أشارت النتائج إلى أهمية التعلم الآلي والبيانات المالية التفصيلية في التنبؤ باتجاه تغير الأرباح، مما يضيف قيمة للتحليل المالي ويساعد في اتخاذ قرارات الاستثمار.

٤/١/٣ هدفت دراسة (Martins, 2022) إلى التنبؤ بالأرباح باستخدام نماذج تعلم الآلة ومقارنتها بتوقعات المحللين الماليين، وذلك من خلال الإجابة على عدد من التساؤلات: التساؤل الأول: هل يمكن أن تتفوق نماذج التعلم الآلي على دقة المحلل المالي في التنبؤ بالأرباح. التساؤل الثاني: هل يمكن لنماذج التعلم الآلي تأكيد توقعات المحللين الماليين، ولقد استخدمت الدراسة نماذج تعلم الآلة ومقارنتها بتوقعات المحللين الماليين على عينة من الشركات المتداولة في ناسداك (NASDAQ)، وبورصة نيويورك (NYSE)، وبورصة أمكس (AMEX)، مع استبعاد الأسواق الأخرى، على مدار ٢٠ عاماً، من نهاية الربع الثالث لعام ٢٠٠٠م حتى نهاية عام ٢٠٢٠م، وتوصلت الدراسة إلى عدة نتائج من خلال الإجابة على التساؤل الأول وهو أن تنبؤات المحللين أكثر دقة من نماذج التعلم الآلي، وأرجعت الدراسة ذلك إلى قيام المحللين بإجراء تحليلات وأبحاث مكثفة في كل تنبؤ جنباً إلى جنب مع استخدام المعلومات غير العامة "وهي المعلومات التي ليست متاحة للجمهور ولا يمكن الوصول إليها من خلال وسائل الإعلام العامة". وتمثلت نتائج الإجابة على التساؤل الثاني في أن التنبؤ بالأرباح باستخدام نماذج التعلم الآلي يعد تأكيد جيد لتوقعات المحللين الماليين، وأنه يمكن لنماذج التعلم الآلي تحديد المواقف التي تكون فيها دقة المحلل المالي أعلى وأقل، والتي يمكن استخدامها بشكل غير مباشر لتحديد المواقف المتعلقة بأخطاء المحللين الماليين.

٥/١/٣ هدفت دراسة (Ateya, 2024) إلى تقديم أدلة تجريبية بشأن تأثير خوارزميات التعلم الآلي على المقدرة التنبؤية للمعلومات المحاسبية، من خلال التحقيق مما إذا كانت المقدرة التنبؤية لخوارزميات التعلم الآلي مقارنة بنماذج التنبؤ التقليدية التي تعتمد على المعلومات المحاسبية، أكثر دقة في التنبؤ بأسعار الأسهم. كما هدفت الدراسة أيضاً إلى التحقق مما إذا كانت القدرة التنبؤية لخوارزميات التعلم الآلي تتجاوز نماذج التنبؤ التقليدية في نماذج التنبؤ بشأن التنبؤ بالاحتفاظ بالنقدية. بالإضافة إلى ذلك، هدفت الدراسة إلى التحقق مما إذا كان دمج خوارزميات التعلم الآلي والمعلومات المحاسبية في نماذج التنبؤ يؤدي إلى تحسين القدرة التنبؤية للمعلومات المحاسبية، واستخدمت الدراسة مداخل متعددة مثل مدخل دراسة الحالة مقارنة بمدخل دراسة الحدث، وتوصلت نتائج التحليل المقارن إلى أن المقدرة التنبؤية للمعلومات المحاسبية أكثر دقة من المقدرة التنبؤية لخوارزميات التعلم الآلي عند التنبؤ بأسعار الأسهم. ويدل ذلك على أن استخدام خوارزميات التعلم الآلي لا تؤدي بالضرورة إلى تنبؤات مالية أكثر دقة، وأن خوارزميات التعلم الآلي ليست بديلاً عن المعلومات المحاسبية كمدخلات في نماذج التنبؤات المالية. وباستخدام المدخل التطبيقي، تم تحليل ٥٦٤ شركة خلال الفترة من ٢٠١٩م إلى ٢٠٢٢م للتنبؤ بالاحتفاظ بالنقدية. واستخدمت الدراسة عدة خوارزميات مثل أشجار القرار، وناقلات الدعم، و K-Nearest، ومقارنتها مع النماذج التقليدية "الانحدار الخطي المتعدد" القائم على معلومات المحاسبة كنماذج للتنبؤ، وأظهرت النتائج انخفاض دقة تنبؤات الانحدار الخطي المتعدد، بينما أثبتت النتائج أن أشجار القرار كخوارزميات معقدة تحقق معدلات دقة أعلى، ولذلك، فإن استخدام خوارزميات متقدمة من التعلم الآلي قد تؤدي إلى تنبؤات أكثر دقة بالاحتفاظ بالنقدية. كما أظهرت النتائج أن المعلومات المحاسبية تؤثر تأثيراً كبيراً على دقة الخوارزميات المتعلقة بالاحتفاظ بالنقدية.

٦/١/٣ هدفت دراسة (Ham, 2024) إلى مقارنة أساليب التعلم الآلي المختلفة بتوقعات المحللين الماليين في التنبؤ بالأرباح، بهدف تقديم رؤية أكثر دقة تخفض من أخطاء التنبؤ المستقبلية، وتحديد أي الأسلوبين يتوافق بشكل أفضل مع توقعات المستثمرين، وركزت الدراسة على اختيار أنسب معايير التعلم الآلي، من خلال تقييم تأثير خيارات المواصفات، وهي القرارات والمعايير المستخدمة عند بناء نماذج التعلم الآلي للتنبؤ بالأرباح. وأجرت الدراسة مقارنة شاملة بين ٣٠٢٤ نموذجاً مشتقاً

من تسع مجموعات مختلفة من خيارات المواصفات، باستخدام ست خوارزميات للتعلم الآلي. وأظهرت النتائج أن عدداً قليلاً فقط من هذه الخيارات له تأثير كبير على دقة التنبؤ. كما أظهرت الدراسة أن أساليب التعلم الآلي تتفوق على توقعات المحللين الماليين في أغلب الحالات، ولكن الفارق يكون طفيفاً في التوقعات قصيرة المدى وفارق كبير للشركات ذات القيمة السوقية، مما يجعل توقعات المحللين خياراً قابلاً للاستخدام. ومع ذلك، أثبتت التوقعات المستندة إلى التعلم الآلي فعاليتها في تحسين دقة التنبؤات طويلة الأجل، خاصةً للشركات ذات القيمة السوقية الصغيرة، بالإضافة إلى تقديم بديل أقوى لتوقعات السوق قصيرة الأجل.

٧/١/٣ هدفت دراسة (عويس، ٢٠٢٤) إلى تقييم دور الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية بالتطبيق على الشركات المقيدة بالبورصة المصرية، واعتمدت الدراسة على تقييم الدراسات السابقة والبيانات المستخلصة من القوائم والتقارير المالية للشركات المقيدة في سوق الأوراق المالية، وتم الاعتماد على عينة من الشركات المقيدة بالبورصة المصرية بلغ عددها (٢٠) شركة خلال الفترة من عام ٢٠١٩م وحتى عام ٢٠٢٣م، واعتمدت الدراسة على تحليلين أحدهما أساسي والآخر إضافي من خلال اختبار أثر تقنيات الذكاء الاصطناعي على التنبؤ بالأرباح المستقبلية للشركات، وتم استخدام العديد من الأساليب الإحصائية التي تصلح للتعامل مع متغيرات البحث كالوسط الحسابي والانحراف المعياري والانحدار البسيط واختبار Mann-Whitney وذلك لاختبار فروض البحث، وتم استخدام خوارزميات الذكاء الاصطناعي في التنبؤ (شجرة القرارات Decision tree – الغابات العشوائية Random Forest – اله المتجهات الداعمة Support Vector Machine – بايز Native Bayes – الجار الأقرب K-Nearest Neighbor بالتطبيق على قطاعات مختلفة (العقارات – بتروكيماويات – الاتصالات)، وقد توصلت الدراسة إلى وجود علاقة ذات دلالة إحصائية بين تقنيات الذكاء الاصطناعي والتنبؤ بالأرباح المستقبلية لشركات الأعمال، وأظهرت النتائج أيضاً أن استخدام خوارزميات الغابات العشوائية هي الخوارزمية الأكثر فاعلية من بين النماذج المستخدمة، بينما تعاني باقي الخوارزميات من ضعف في الأداء.

٢/٣ الأدبيات المحاسبية التي تناولت أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين:

١/٢/٣ هدفت دراسة (Gupta et al., 2021) إلى التحقق فيما إذا كانت تقنيات تعلم الآلة (ML)، باستخدام مجموعة واسعة من المتغيرات المالية والاقتصادية الكلية، تساعد في التنبؤ بالتقلبات المحققة لمؤشر S&P 500 وتحقق قيمة اقتصادية، وقامت الدراسة باستخدام خوارزميات الغابات العشوائية كإحدى تقنيات تعلم الآلة على بيانات سوق الأسهم في الولايات المتحدة خلال الفترة من ٢٠٠١م إلى ٢٠٢٠م، وتوصلت نتائج الدراسة إلى أن استخدام تقنية تعلم الآلة باستخدام خوارزميات الغابات العشوائية ساعدت المستثمرين على التنبؤ بتقلبات سوق الأسهم باستخدام مجموعة واسعة من المتغيرات الاقتصادية الكلية والمالية، مما ازدادت ثقة المستثمرين في الاعتماد على تلك التقنية لتحسين استراتيجيات الاستثمار وتصميم السياسات الاقتصادية لمواجهة تقلبات السوق.

٢/٢/٣ هدفت دراسة (Raja, 2021) إلى معرفة تأثير مشاعر الخوف للمستثمرين على التنبؤ بالعوائد في الأسواق المتقدمة والناشئة باستخدام خوارزميات التعلم الآلي، وقامت الدراسة بتقسيم بيانات الدراسة إلى فئتين رئيسيتين: الأسواق المتقدمة والأسواق الناشئة، وركزت الدراسة على ستة دول من كل فئة بناءً على مؤشرات MSCI للأسواق الناشئة والمتقدمة، وذلك خلال الفترة من ٢٠٢٠/١/١م حتى ٢٠٢٠/١٢/٣١م، واستخدمت الدراسة نظاماً من المعادلات لاختبار تأثير مشاعر الخوف على عوائد الأسواق المتقدمة والناشئة باستخدام GARCH للتحقق من استمرارية تقلبات الأسواق المعنية، علاوة على استخدام خوارزميات التعلم الآلي لتخصيص رأس المال العقلاني لتحسين العوائد، وتوصلت نتائج الدراسة إلى أن الأسواق المتقدمة والناشئة تتأثر بمشاعر الخوف فيما يتعلق بالعوائد، وتتفوق الأسواق الناشئة على الأسواق المتقدمة في تحقيق أقصى العوائد، كما تؤكد النتائج أن التعلم الآلي يساعد في التنبؤ بالعوائد حتى في ظل المشاعر المرتفعة في السوق. كما أشارت نتائج الدراسة إلى أن خوارزميات التعلم الآلي تتخذ قرارات عقلانية في ظل مشاعر الخوف العالية، حيث تعيد تخصيص استثماراتها لتحسين العوائد.

٣/٢/٣ هدفت دراسة (Yalamati, 2023) إلى قياس تأثير الذكاء الاصطناعي على أداء المستثمرين الأفراد لتحقيق العوائد الرأسمالية في سوق الأسهم، واعتمدت الدراسة على منهجية متعددة الأساليب، حيث تجمع بين التحليل الكمي لبيانات التداول والاستكشاف النوعي لتجارب المستثمرين. وتهدف إلى الكشف عن أنماط استخدام الذكاء الاصطناعي، ودراسة العلاقة بين القرارات المدفوعة بالذكاء الاصطناعي وأداء الاستثمار، وتحليل الجوانب النفسية والسلوكية للمستثمرين الأفراد عند تفاعلهم مع أدوات الذكاء الاصطناعي، واعتمدت الدراسة على تصميم بحثي متعدد الأساليب يجمع بين النهجين الكمي والنوعي، كما استخدمت الدراسة تقنية العينة العشوائية الطبقية لضمان التمثيل العادل لمختلف العوامل الديموغرافية، بما في ذلك العمر، الجنس، خبرة الاستثمار، واستخدام الذكاء الاصطناعي، وذلك خلال الفترة من عام ٢٠١٠م حتى ٢٠٢١م، وتوصلت نتائج الدراسة إلى أن تقنيات الذكاء الاصطناعي تؤثر على أداء المستثمرين الأفراد، وتساهم في تحقيق العوائد الرأسمالية، بالإضافة إلى تأثير اعتماد الذكاء الاصطناعي في سوق الأسهم.

٤/٢/٣ هدفت دراسة (Zhou, 2023) إلى تحليل سلوك المستثمرين الأفراد باستخدام تطبيقات تعلم الآلة، وأشارت الدراسة إلى أن سلوك المستثمرين يتأثر بعدة عوامل مثل الخصائص الشخصية، ظروف السوق، قدرات اكتساب المعلومات، التحيزات النفسية، الأنماط السلوكية، وقواعد اتخاذ القرار الشائعة، واعتمدت الدراسة على بناء نماذج سلوك المستثمرين الأفراد على النظريات الإحصائية والاقتصادية من خلال حجم التداول لعمليات الشراء والبيع لأسهم الشركات المدرجة في بورصة الولايات المتحدة، وذلك باستخدام تطبيقات تعلم الآلة خلال الفترة ٢٠٢٣/١/١م حتى ٢٠٢٣/٢/١٥م، وتوصلت نتائج الدراسة إلى أن تطبيقات تعلم الآلة يمكنها أن تتنبأ بسلوك المستثمرين الأفراد، بناءً على بيانات التداول التاريخية للمستثمرين، كما يمكن لتطبيقات تعلم الآلة إنشاء نماذج تنبؤية للتنبؤ بسلوك المستثمرين الأفراد في المستقبل، حيث يمكن لمثل هذه التنبؤات أن توفر دعماً قوياً لقرارات المستثمرين الخاصة ومراجعة فعالة للمنظمين في السوق.

٥/٢/٣ هدفت دراسة (محمد، ٢٠٢٣) إلى بيان دور تقنية آلة متجة الدعم (SVM) كإحدى تقنيات الذكاء الاصطناعي (AI) في تحسين جودة التقارير المالية، وذلك من

خلال زيادة درجة التنبؤ بالتدفقات النقدية من الأنشطة التشغيلية، واعتمدت الدراسة في تحقيق الهدف البحثي على تناول الدراسات السابقة ذات الصلة بمتغيرات الدراسة، بالإضافة إلى إجراء دراسة تطبيقية على عينة من الشركات المقيدة بالبورصة المصرية، وكان عددها ٧٠ شركة ممثلة من ١٢ قطاع اقتصادي، وتم استخدام برنامج (MATLAB R2022b) لتطبيق تقنية آلة متجة الدعم (SVM) وذلك للتنبؤ بالتدفقات النقدية من الأنشطة التشغيلية، وأسفرت نتائج الدراسة التطبيقية عن ارتفاع متوسط الدقة التنبؤية لتقنية (SVM)، حيث بلغ متوسط الدقة التنبؤية بالتدفقات النقدية ما بين (٩٤,١٥%) كحد أدنى وذلك عند (SVM Quadratic)، وبين (٩٤,١٥%) كحد أقصى عند (SVM Gaussian)، حيث أنه كلما ارتفعت درجة الدقة التنبؤية كلما زادت قوة نموذج التنبؤ، مما يدل على وجود علاقة معنوية بين تطبيق تقنية (SVM) وبين دقة التنبؤ بالتدفقات النقدية، مما يساهم في تحسين جودة التقارير المالية.

٦/٢/٣ هدفت دراسة (Gokoglan and Sevim, 2024) إلى دراسة تأثير تقنية الذكاء الاصطناعي على قرارات المستثمرين الفردية، وقام الباحثان بتوزيع استبيان على عدد ١٨٠٠ مستثمر مكون من ٢٢ عبارة وفقاً لنطاق الدراسة خلال عام ٢٠١٦م، وأشارت الدراسة إلى أنه بعد مراجعة الإجابات، تم تضمين ١٦١٦ استبياناً تم الإجابة عليها بشكل صحيح ودقيق في نطاق التحليل، كما قامت الدراسة بحساب معامل ألفا (Cronbach's Alpha)، وبلغت قيمته ٩١%، مما يشير إلى مستوى عالٍ من الموثوقية، وقامت الدراسة باستخدام جداول التكرار (Frequency Tables)، واختبار (t-test)، وتحليل التباين الأحادي (ANOVA)، وتوصلت الدراسة إلى عدة نتائج، أولاً: تقنيات الذكاء الاصطناعي لها تأثير إيجابي في تحليل بيانات السوق، ثانياً: تقنيات الذكاء الاصطناعي تمكن المستثمر الذي يرغب في الاستثمار من تنفيذ أوامر بيع وشراء في سوق التداول، ثالثاً: تقنيات الذكاء الاصطناعي توجه المستثمر بالقيام على الاستثمار في شركات أكثر ربحية.

٧/٢/٣ هدفت دراسة (Cai and Chen, 2024) إلى فحص أداء تقنيات تعلم الآلة بناءً على معنويات المستثمرين عبر الإنترنت للتنبؤ بمخاطر سوق الأسهم، وعمل مقارنة مع الطرق التقليدية ذات الخطوتين (تحليل معنويات المستثمرين /

النمذجة والتنبؤ)، واستخدمت الدراسة أسلوب التدرج الشديد (XGBoost) والغابة العشوائية (Random Forest) كأحدى تقنيات تعلم الآلة على بيانات تخضع لظروف وأحداث سوق محددة خلال الفترة من عام ٢٠٠٤م إلى عام ٢٠٢١م، وأشارت النتائج التجريبية للدراسة إلى أن تقنيات تعلم الآلة يمكن أن تساعد في تحسين معنويات المستثمرين عبر الإنترنت في سوق المال، علاوة على قدرتها على التنبؤ بمخاطر سوق الأسهم بناءً على معنويات المستثمرين عبر الإنترنت.

٨/٢/٣ هدفت دراسة (Masood, 2024) إلى فحص تأثير خوارزميات تعلم الآلة على تحسين المحفظة الاستثمارية للمستثمر وإدارة المخاطر، واستخدمت الدراسة بيانات من ٩٠ شركة بريطانية في بورصة لندن مدرجة في مؤشر FTSE100 حيث تمتلك تقييم ESG (البيئة والمجتمع والحوكمة) خلال الفترة من ٢٠١١/١٢/٣١م حتى ٢٠٢٣/٨/٣٠م، وقامت باختبار عدة نماذج تعلم آلي، وتوصلت الدراسة إلى أنه لا تزال تطبيقات تعلم الآلة محدودة في القطاع المالي، رغم قدراتها المثبتة. ومع تزايد البيانات الضخمة، وصعود الاستثمار المستدام، وتوفر قدرات حوسبية غير مسبقة، يصبح الاعتماد على الأساليب التقليدية غير عملي، كما توصلت نتائج الدراسة إلى أنه يتطلب مزيد من الأبحاث لاستكشاف التحديات المحتملة، وتطوير تطبيقات أكثر دقة لهذه الخوارزميات في البيئات المالية.

التعلق على الأدبيات المحاسبية السابقة، واشتقاق فروض الدراسة:

أظهرت الأدبيات المحاسبية السابقة المتعلقة بالتنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي، أن استخدام خوارزميات تعلم الآلة، باعتبارها إحدى تقنيات الذكاء الاصطناعي، توفر دقة وفعالية أكبر في التنبؤ بالأرباح المستقبلية مقارنة بالأساليب التقليدية. ومع ذلك، جاءت بعض النتائج متباينة، حيث أظهرت دراسة (Martins, 2022) أن توقعات المحللين الماليين تفوقت على نماذج تعلم الآلة من حيث الدقة، معتبرة أن هذه النماذج يمكن أن تكون أداة داعمة وليست بديلاً كاملاً. كما توصلت دراسة (Ateya, 2024) إلى أن خوارزميات تعلم الآلة لا تضمن تحسين دقة التنبؤات المالية بشكل قاطع، مشيرة إلى أهمية المعلومات المحاسبية كمدخل أساسي في النماذج التنبؤية.

وفيما يتعلق ببيئة التطبيق، يتضح أن معظم الدراسات التي تناولت هذا الموضوع قد أجريت في أسواق أجنبية، في حين أن الدراسات العربية لا تزال محدودة، خاصة في البيئة المصرية، وبحسب ما توصل إليه الباحثين، فإن دراسة (عويس، ٢٠٢٤) تُعد من المحاولات القليلة التي ناقشت هذا المجال في مصر، حيث ركزت على تقييم دور الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية للشركات المدرجة في البورصة المصرية، مع تطبيقها على عينة من الشركات المدرجة في البورصة المصرية داخل قطاعات العقارات، البتروكيماويات، والاتصالات. ومع ذلك، لم تشمل الدراسة جميع خوارزميات تعلم الآلة، بل اقتصر على بعضها.

أما الدراسة الحالية، فتتميز بتركيزها على أثر التنبؤ بالأرباح المستقبلية باستخدام مختلف خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين، مع إجراء مقارنة شاملة بين هذه الخوارزميات لتحديد الأكثر دقة في التنبؤ. كما تعتمد الدراسة على عينة من الشركات المدرجة في مؤشر EGX 100 خلال الفترة من ٢٠١٩م إلى ٢٠٢٤م، مما يمنحها نطاقاً زمنياً أوسع، ويجعلها أكثر شمولاً مقارنة بالدراسات السابقة. وتبرز أهمية هذه الدراسة في حداثتها، إلى جانب اختلاف بيئة التطبيق والإطار الزمني عن الأبحاث السابقة، مما يعزز من قيمتها العلمية، ويفتح آفاقاً جديدة لاستخدام خوارزميات تعلم الآلة في التنبؤ بالأرباح المستقبلية للشركات المدرجة في البورصة المصرية.

وفي السياق ذاته، ومن خلال استعراض وتحليل الأدبيات المحاسبية السابقة التي تناولت أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين، يمكن استخلاص مجموعة من النتائج المهمة. فقد أشارت غالبية الدراسات إلى أن تطبيق خوارزميات تعلم الآلة في التنبؤ بالأرباح المستقبلية يسهم بشكل إيجابي في تعزيز ثقة المستثمرين. حيث توصلت غالبية الدراسات إلى أن خوارزميات تعلم الآلة تساعد المستثمرين على التنبؤ بتقلبات ومخاطر سوق الأسهم والتنبؤ بعوائد الأسهم والأرباح المستقبلية، وهذا بدوره يعزز من ثقة المستثمرين في الاعتماد على تلك الخوارزميات لتحسين استراتيجيات الاستثمار وتصميم السياسات الاقتصادية لمواجهة تقلبات السوق، كما يمكن لخوارزميات تعلم الآلة إنشاء نماذج تنبؤية للتنبؤ بالفعال بسلوك المستثمرين الأفراد في المستقبل.

وتجدر الإشارة إلى أن العديد من الدراسات تناولت خوارزميات تعلم الآلة باعتبارها إحدى تقنيات الذكاء الاصطناعي، مؤكدةً دورها المحوري في تحسين التنبؤات المالية وتطوير الأنظمة الذكية. ومع ذلك، ما يميز الدراسة الحالية عن الدراسات السابقة هو دمجها بين ثلاثة متغيرات رئيسية، وهي: خوارزميات تعلم الآلة، التنبؤ بالأرباح المستقبلية، وتعزيز ثقة المستثمرين. ووفقاً لمعرفتنا، تُعد هذه الدراسة من بين أوائل الدراسات التي تتناول هذا الترابط في البيئة المصرية، مما يضيف عليها أهمية خاصة.

ومع ذلك، يلاحظ أن هذه الدراسات أجريت في بيئات أجنبية، ولم تتناول - في حدود علم الباحثين - هذا الموضوع في البيئة العربية بشكل عام، والبيئة المصرية بشكل خاص. وبناءً على ذلك، يرى الباحثين أن هناك فجوة بحثية تستدعي المزيد من الدراسات في السوق المصري، وهو ما تسعى الدراسة الحالية إلى معالجته. حيث تهدف إلى سد جزء من هذا النقص من خلال اختبار أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين في البورصة المصرية.

وفي ضوء ما سبق، يتضح أن هناك نقصاً واضحاً في الأبحاث الأجنبية والعربية التي تناولت أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين، وهو ما يعزز من أهمية وخصوصية الدراسة الحالية، حيث تساهم في سد هذه الفجوة وإثراء المعرفة في هذا المجال الحيوي.

وإزاء ما سبق يمكن اشتقاق فرض الدراسة الرئيس على النحو التالي:

"يوجد أثر إيجابي ذو دلالة احصائية للتنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين".

وينبثق من هذا الفرض الفرضين الفرعيين التاليين:

- يوجد أثر إيجابي ذو دلالة احصائية للتنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.
- يوجد أثر إيجابي ذو دلالة احصائية للتنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.

٤- أهداف الدراسة:

استناداً إلى المشكلة البحثية التي تعالجها الدراسة يمكن تحديد الهدف الرئيسي للدراسة في قياس أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي وبيان انعكاسها على تعزيز ثقة المستثمرين، ويتحقق الهدف الرئيسي للبحث من خلال تحقيق مجموعة من الأهداف الفرعية التالية:

- التحقق من أثر التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.
- التحقق من أثر التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.

٥- أهمية الدراسة:

في ضوء مشكلة الدراسة تتمثل أهمية الدراسة من الناحية العلمية، والناحية العملية فيما يلي:

١/٥ : الناحية العلمية:

- تزايد التغيرات التي طرأت على أساليب التنبؤ بالأرباح المستقبلية للشركات والتي ارتبطت في الآونة الأخيرة بتطبيق خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي، والتي تعد خطوة نحو تطوير نظريات اقتصادية جديدة تدعم الابتكار في مجال التنبؤات المالية.
- توفير قاعدة معرفية حول كيفية التنبؤ بالأرباح المستقبلية للشركات باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي، وبالتالي تخفيض المخاطر وتحسين عوائد الاستثمارات، مما يؤدي إلى تعزيز ثقة المستثمرين في الأسواق المالية.

٢/٥ : الناحية العملية:

- تحسين دقة التنبؤ بالأرباح المستقبلية من خلال تحليل كميات ضخمة من البيانات واستخلاص الأنماط والعلاقات الخفية التي يصعب اكتشافها باستخدام

- الأساليب التقليدية، بما يسهم في: إدخال تقنيات حديثة عند دراسة الأسواق المالية، تعزيز ثقة المستثمرين، وتخفيض المخاطر المرتبطة بالاستثمار.
- توفير دليل تطبيقي حول أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.

٦- خطة الدراسة:

انطلاقاً من أهمية الدراسة وتحقيقاً لأهدافها والإجابة على تساؤلاتها البحثية، فقد تم استكمال الدراسة على النحو التالي:

- الإطار النظري للدراسة.
- الدراسة التطبيقية.
- الخلاصة والنتائج ومجالات البحث المستقبلية.
- مراجع الدراسة.

٧- الإطار النظري للدراسة:

١/٧: دور خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية:

ذكر تقرير صادر عن معهد المحاسبين القانونيين في إنجلترا وويلز أن الذكاء الاصطناعي سيؤدي إلى تحول جذري في مهنة المحاسبة والمراجعة، مما يستدعي من المحاسبين التأهب لهذه التغيرات المستقبلية. وأوضح التقرير أن المهنة تحتاج إلى التكيف مع التطورات التكنولوجية، حيث ستلعب الأنظمة الذكية دوراً متزايداً في عمليات التحليل واتخاذ القرارات المالية، مما يتطلب استغلال إمكانياتها بفعالية. كما أشار التقرير إلى أن المحاسبين استفادوا من التكنولوجيا على مدار السنوات لتعزيز جودة أعمالهم، إلا أن الذكاء الاصطناعي يمثل مرحلة جديدة بقدراته المتقدمة وسرعته في معالجة البيانات، مما قد يقلل من الاعتماد على الجهود البشرية في بعض العمليات التقليدية، ويدفع بالمحاسبين إلى التركيز على المهام الاستراتيجية التي تتطلب فهماً أعمق للسياق المالي والتخطيط المستقبلي (ICAEW, 2023).

ومع ذلك، أشار تقرير معهد المحاسبين القانونيين في إنجلترا وويلز إلى أنه من غير المتوقع أن يحل الذكاء الاصطناعي محل المحاسبين بشكل كامل، حيث أن الأنظمة الذكية رغم قدرتها على معالجة وتحليل البيانات بدقة وسرعة، لا تمتلك القدرة على محاكاة الفهم البشري والسياق المهني في اتخاذ القرارات المحاسبية المعقدة، مما يحد من إمكانياتها في هذا المجال (زباله، ٢٠٢٣).

ومع التطور السريع في الاقتصاد والتكنولوجيا، أصبح الذكاء الاصطناعي عنصراً محورياً في مهنة المحاسبة، حيث ساهم بشكل كبير في تحسين كفاءة العمليات المالية. كما شهدت السنوات الأخيرة اهتماماً عالمياً متزايداً بتطبيقات الذكاء الاصطناعي في المحاسبة، نظراً لقدرتها على تعزيز دقة البيانات وتحسين سرعة وكفاءة المعالجة المالية (Li and Li, 2018). وقد امتد تأثير هذه التقنيات ليشمل مختلف جوانب المحاسبة، ابتداءً من تبسيط العمليات المحاسبية الروتينية وصولاً إلى تطوير أنظمة تحليل مالي متقدمة، مثل إدخال البيانات وإعداد التقارير، بهدف ابتكار أنظمة تحليل مالي متطورة تعزز دقة وكفاءة عملية اتخاذ القرار (أميرهم، ٢٠٢٢).

ويمكن تعريف خوارزميات تعلم الآلة على أنها أحد فروع الذكاء الاصطناعي التي تتيح للحواسيب تنفيذ مهام ذات طابع ذكي من خلال التعلم من البيانات، بدلاً من الاعتماد على قواعد مبرمجة مسبقاً (Ding, et al., 2020). وتعتمد هذه التقنيات على تحليل البيانات التاريخية واستخدامها كمدخلات للتنبؤ بنتائج غير مبرمجة مسبقاً بدقة، مما يتيح لها استخراج أنماط خفية ومعرفة مفيدة، كما تساهم في تحويل البيانات الخام، التي قد تكون ضخمة أو غير منظمة أو غير مكتملة، إلى بيانات منتظمة وقابلة للفهم، مما يعزز من قيمتها في دعم القرارات وتحليل المعلومات (Chen, X., et al., 2022).

وأشارت الأدبيات المحاسبية (Huang et al., 2022; Chen et al., 2022) إلى أن خوارزميات تعلم الآلة تُعد من أبرز تقنيات الذكاء الاصطناعي، حيث تم تقديم مفهوم تعلم الآلة لأول مرة بواسطة العالم Arthur Samuel في عام ١٩٥٢م، ومنذ ذلك الحين شهد هذا المجال تطورات كبيرة ساهمت في تعزيز تطبيقاته في مختلف المجالات والقطاعات بما في ذلك

الأعمال التجارية، فهي برامج حاسوبية قادرة على التعلم تلقائياً من البيانات التاريخية واكتشاف الأنماط والاتجاهات دون الحاجة إلى برمجة محددة من قبل البشر، حيث تزود التطبيقات البرمجية بقدرة التعلم الذاتي دون الحاجة إلى برمجتها بشكل محدد لأداء مهمة معينة، حيث تساهم هذه الخوارزميات في التنبؤ بالنتائج بدقة من خلال تحليل بيانات التجارب السابقة واستخدامها لاستشراف البيانات المستقبلية. وبعبارة أخرى، تتميز هذه الأنظمة بقدرتها على التعلم تلقائياً أو تحت إشراف بشري محدود، حيث تعتمد على خوارزميات متقدمة لاستخلاص المعلومات من البيانات المتاحة ومعالجتها، وتطبيق الأساليب الإحصائية لتقدير النتائج بشكل تلقائي ضمن نطاق دقيق ومقبول (موسى وبلال، ٢٠١٩).

وأكدت دراستي (Aly et al., 2023; Kamble and Shah, 2018) على أن تعلم الآلة يعتمد على تحليل البيانات باستخدام تقنيات متقدمة لاكتشاف الأنماط المخفية، ثم توظيف هذه الأنماط للتنبؤ بالأحداث المستقبلية بدقة. وتستخدم في هذا المجال مجموعة من الخوارزميات الفعالة، من أبرزها: خوارزميات دعم المتجهات (Support Vector Machines)، والشبكات العصبية (Neural Networks)، وشجرة القرارات (Decision Tree)، والغابة العشوائية (Random Forest)، حيث تتميز هذه الخوارزميات بقدرتها على تحليل البيانات الضخمة بعمق واكتشاف الأنماط المعقدة التي قد لا تستطيع الطرق التقليدية التعرف عليها.

ويؤكد الباحثين، استناداً إلى الدراسات المشار إليها، أن هذه الخوارزميات تمثل أحد مجالات الذكاء الاصطناعي المهمة، خاصة في التنبؤات المالية. فهي تعتمد على تقنيات إحصائية لفهم هيكلية البيانات، مما يمكن الأنظمة من التعلم والتدريب المستمر لإنشاء نماذج قادرة على تحسين أدائها بمرور الوقت. كما تساهم هذه النماذج في اكتشاف الأنماط داخل البيانات المستهدفة، مما يعزز دقة القرارات ويدعم التنبؤ بالمستقبل بفاعلية.

ومع التقديم المستمر في مجال الأعمال الإلكترونية، شهدت العديد من الشركات توسعاً ملحوظاً في اعتماد أنظمة الذكاء الاصطناعي، بما في ذلك خوارزميات تعلم الآلة. وقد اعتمدت الشركات الكبرى في مجال المحاسبة، مثل شركات KPMG ، IBM ، Watso، على خوارزميات تعلم الآلة لتحليل كميات

ضخمة من البيانات المنظمة وغير المنظمة المتعلقة بالمعلومات المالية للشركات، حيث تستخدم تلك الشركات هذه الخوارزميات لتمكين النظام من التعلم وتحسين أدائها بشكل تدريجي في مجالات محددة ليعتمد على تحليل البيانات لاكتشاف الأنماط الضمنية، ثم يتم تطبيق هذه الأنماط لإجراء التنبؤات حول المستقبل (Hunt et al., 2019).

وفي السياق ذاته تُصنف تقنيات تعلم الآلة إلى أربعة أنواع رئيسية، من بينها النوع الأول وهو "التعلم الخاضع للإشراف (Supervised Learning)" ويعد هذا النوع إحدى أساليب التعلم التي تقوم على تزويد الآلة بمجموعة من البيانات المصنفة، مما يمنحها الخبرة اللازمة لاستخلاص الأنماط وتطبيقها على البيانات في مرحلة التنبؤ، ويُستخدم هذا النوع على نطاق واسع في العلوم الاجتماعية، وله تطبيقات متعددة في مجال المحاسبة، لا سيما في كشف الغش، وإجراء التنبؤات المالية، وتحليل المخاطر الائتمانية (Hoang and Wiegatz, 2022). وفي هذا النوع من التعلم يتم تدريب الخوارزميات على بيانات تحتوي على مخرجات معروفة (أو تسميات) وهي:

- الشبكات العصبية العميقة (Deep Neural Networks): هي نوع من خوارزميات تعلم الآلة المستوحاة من بنية العقل البشري، حيث تتكون من عدة طبقات من العقد (Nodes) أو الخلايا العصبية المتصلة ببعضها، وتُستخدم هذه الشبكات في تحليل البيانات الضخمة والتعرف على الأنماط المخفية، مما يجعلها أداة قوية في التنبؤ بالأرباح المستقبلية (Martins, 2022).
- الغابات العشوائية (Random Forest): هي أحد خوارزميات تعلم الآلة تُستخدم بشكل واسع في التنبؤ وتحليل البيانات. وهي عبارة عن خوارزمية تجمع بين عدة شجرات قرار (Decision Trees) لتكوين نموذج قوي قادر على التنبؤ بدقة أعلى (Chen and Zhang, 2020).
- آلة دعم المتجهات (Support Vector Machines): هي أحد خوارزميات تعلم الآلة المستخدمة في التصنيف والانحدار، وتعتمد على

إيجاد أفضل فاصل (Decision Boundary) بين الفئات المختلفة في البيانات (Khoa and Huynh, 2021).

أما النوع الثاني من تصنيفات تقنيات تعلم الآلة يتمثل في "التعلم غير الخاضع للإشراف (Unsupervised Learning)"، ويعد هذا النوع من التعلم هو أحدي الأساليب التي يتم فيها تزويد الآلة بمجموعة من البيانات غير المصنفة، حيث تحاول الآلة اكتشاف الأنماط المخفية بشكل مستقل وإنشاء مجموعات. وتعد الخوارزميات المستخدمة في التعلم غير الخاضع للإشراف هي التي تتيح للآلة التعلم بشكل ذاتي، ويُستخدم هذا النوع من التعلم عادةً عندما تتضمن المشكلة كمية ضخمة من البيانات غير المصنفة (متولي، ٢٠٢٢). ويتميز هذا النوع بتعدد تطبيقاته، لا سيما في المجال المحاسبي، حيث يُوظف في اكتشاف الغش والاحتيال المالي (حسن، ٢٠٢٥). وفي هذا النوع من التعلم يتم استخدام الخوارزميات التالية:

- تحليل المكونات الرئيسية (PCA): هي تقنية تقليل الأبعاد (Dimensionality Reduction) وتُستخدم لاستخراج الميزات الأكثر أهمية في البيانات مع الاحتفاظ بأكبر قدر من المعلومات، وتحسين دقة النماذج المالية (Eachempati et al., 2021).
- خوارزميات التجميع مثل K-Means: هي تقنية تحول البيانات المالية إلى مجموعة جديدة من المتغيرات غير المترابطة (المكونات الرئيسية)، والتي تمثل أكبر قدر من التباين، وتحليل اتجاهات السوق وتقسيم الشركات وفقاً لأنماط الأداء (Martins, 2022).

بينما النوع الثالث في "التعلم المعزز (Reinforcement Learning)": وهو أحد فروع تعلم الآلة، حيث يتعلم النموذج من خلال التفاعل مع البيئة واتخاذ قرارات بناءً على التجربة والخطأ للحصول على أقصى مكافأة (Reward)، ويُستخدم في سيناريوهات تتطلب اتخاذ قرارات ديناميكية، مثل التداول المالي، التنبؤ بالأرباح، وإدارة المخاطر (Dixon et al., 2020).

وأخيراً يتمثل النوع الرابع في "التعلم شبه الخاضع للإشراف (Semi - Supervised Learning)": هو أسلوب في تعلم الآلة يجمع بين التعلم الخاضع للإشراف (Supervised Learning)، الذي يعتمد على بيانات

مصنفة مسبقاً، والتعلم غير الخاضع للإشراف (Unsupervised Learning)، الذي يعتمد على بيانات غير مصنفة لاكتشاف الأنماط والعلاقات. في هذا النهج، يتم تدريب النموذج باستخدام كمية صغيرة من البيانات المصنفة (Labeled Data) وكميات كبيرة من البيانات غير المصنفة (Unlabeled Data)، مما يساعد على تحسين دقة التنبؤات مع تقليل الحاجة إلى بيانات مصنفة مكلفة أو صعبة التجميع (Gordon, 2021).

وفي السياق ذاته أشارت دراسة (Hunt et al., 2019) أن خوارزميات تعلم الآلة تشمل على مجموعة متنوعة من الأساليب، منها: شجرة القرارات (DT)، الغابات العشوائية (RF)، الشبكات العصبية الاصطناعية (ANN)، أشجار الانحدار المعزز (BRT)، آلية التدرج المعزز (GBM)، الشبكة العصبية متعددة الطبقات، الشبكة العصبية للذاكرة طويلة المدى (LSTM)، وآلية نقل الدعم (SVM). وفيما يلي شرح لتلك الخوارزميات.

- شجرة القرارات (DT): تعتمد على تقسيم البيانات إلى فروع بناءً على متغيرات مستقلة. ورغم فعاليتها في التصنيف والتنبؤ، إلا أنها تعاني من التباين العالي، مما قد يؤدي إلى الإفراط في استيعاب بيانات التدريب، ويتفرع من تلك الخوارزمية كل من: خوارزمية مربع كاي للكشف التلقائي عن التفاعل (CHAID)، وخوارزمية شجرة التصنيف والانحدار (C&R Tree) (Hunt et al., 2019).
- الغابات العشوائية (RF): تتغلب على عيوب شجرة القرارات من خلال دمج عدة أشجار قرار، مما يقلل التباين ويحسن الدقة. وتتميز بالمرونة وسهولة التعامل مع البيانات الكبيرة والمفقودة (Ding, et al., 2020).
- أشجار الانحدار المعزز (BRT): تعتمد على دمج نتائج عدة نماذج وتحسن دقة التنبؤ دون الحاجة لافتراضات خطية. كما توفر إطاراً طبيعياً لتقييم أهمية المتغيرات المختلفة في التنبؤ (Rossi, 2018).
- آلية التدرج المعزز (GBM): تعمل على تحسين النماذج الضعيفة عبر تصحيح الأخطاء تدريجياً، ولكن الإفراط في إضافة الأشجار لا يحسن الأداء بعد نقطة معينة (Ding, et al., 2020).

- الشبكة العصبية الاصطناعية (ANN): يحاكي العقل البشري عبر طبقات متعددة من الخلايا العصبية، مما يجعلها قادرة على تحليل الأنماط المعقدة في البيانات غير المنظمة، وتستخدم بكثرة في التنبؤات المالية (Martins, 2022).
- الشبكة العصبية للذاكرة طويلة المدى (LSTM): مُصممة للتعامل مع البيانات المتسلسلة، مما يجعلها مناسبة لتحليل السلاسل الزمنية (Eachempati et al., 2021).
- آلية نقل الدعم (SVM): تتميز بقدرتها على تصنيف البيانات المعقدة باستخدام مفهوم الفواصل الفائقة، مما يجعلها فعالة في التنبؤ بالسلاسل الزمنية والتعرف على الأنماط (Chen et al., 2022).
- الشبكة البايزية (BN): تستخدم النماذج الرسومية الاحتمالية لتمثيل العلاقات السببية بين المتغيرات، مما يجعلها أداة قوية في إدارة المخاطر والتنبؤ بالاحتمالات المستقبلية (Chan et al., 2023).

ويمكن للباحثين تلخيص تقنيات تعلم الآلة بناءً على ما سبق عرضه، وذلك من خلال الجدول رقم (١) والذي يوضح مقارنة بين خوارزميات تعلم الآلة من حيث التعريف والهدف الأساسي وأمثلة على الخوارزميات وعلاقتها بالتنبؤ بالأرباح.

جدول رقم (١)

مقارنة بين خوارزميات تعلم الآلة

النوع	التعريف	الهدف الأساسي	أمثلة على الخوارزميات	علاقتها بالتنبؤ بالأرباح
التعلم الخاضع للإشراف Supervised Learning	يعتمد على بيانات مدخلة مع تسميات (Labels) لمعرفة العلاقة بين المتغيرات	التنبؤ أو التصنيف بناءً على بيانات مصنفة مسبقاً	- الانحدار الخطي - الشبكات العصبية العميقة - الغابات العشوائية - دعم المتجهات	توقع الأرباح بناءً على البيانات التاريخية المصنفة (مثل المبيعات السابقة والتقارير المالية)

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

التعلم غير الخاضع للإشراف Unsupervised Learning	يعتمد على بيانات غير مصنفة لاكتشاف الأنماط والعلاقات	استخراج الأنماط والتجمعات دون الحاجة إلى تسميات مسبقة	- خوارزميات التجميع مثل (K-Means) - تحليل المكونات الرئيسية (PCA)	تحليل الاتجاهات المالية، واكتشاف الأنماط المخفية في السوق، وتصنيف الشركات وفقاً لأنماط الأداء
التعلم شبه الخاضع للإشراف Semi-Supervised Learning	مزيج من التعلم الخاضع وغير الخاضع للإشراف، يستخدم كمية قليلة من البيانات المصنفة وكبيرة من البيانات غير المصنفة	تحسين دقة النماذج عندما تكون البيانات المصنفة محدودة	- خوارزميات التعلم العميق شبه الخاضعة للإشراف - خوارزميات التجميع مع الإشراف الجزئي	التنبؤ بالأرباح في الأسواق الناشئة حيث تكون البيانات المصنفة غير كافية
التعلم المعزز Reinforcement Learning	يعتمد على آلية "المكافأة والعقاب" لتدريب النموذج على اتخاذ القرارات بناءً على التجربة	اتخاذ قرارات ديناميكية وتحسين الأداء بناءً على التفاعل مع البيئة	- خوارزميات Q-Learning - الشبكات العصبية المعززة (DQN)	تحسين استراتيجيات التداول المالي، وإدارة المخاطر المالية، والتكيف مع التغيرات في السوق

المصدر : من إعداد الباحثين

من خلال استعراض الجدول السابق، يتضح أنه يقدم مقارنة شاملة بين أنواع خوارزميات تعلم الآلة، موضحاً تعريف كل نوع، هدفه الأساسي، أمثلة على

الخوارزميات المستخدمة، ودورها في التنبؤ بالأرباح. ويتميز الجدول بوضوحه وتنظيمه، مما يسهل استيعاب الفروقات بين التعلم الخاضع للإشراف، التعلم غير الخاضع للإشراف، التعلم شبه الخاضع للإشراف، والتعلم المعزز. كما يبرز كيف يمكن لكل نوع أن يساهم في تحسين دقة التوقعات المالية، سواء من خلال تحليل البيانات التاريخية، اكتشاف الأنماط، أو اتخاذ قرارات ديناميكية.

إزاء ما سبق يري الباحثين أن خوارزميات تعلم الآلة علم يسعي إلى توفير القدرة على التعلم وبناء النماذج، والذي يعتمد على مجموعة متنوعة من الخوارزميات لتساهم في تطوير الأنظمة الذكية القادرة على التعامل مع البيانات وتحليلها واتخاذ القرارات بشكل شبه مستقل. وتشمل هذه الخوارزميات على مجموعة من الأساليب والعمليات التي تعتمد على الرياضيات والإحصاء لتمكين الحواسيب من "التعلم" من البيانات وتجميع الأنماط من البيانات واتخاذ القرارات بناءً على هذه الأنماط. إذ يمكن استخدام هذه الخوارزميات لتحليل البيانات المالية ومعالجة كميات ضخمة من البيانات واستخراج العلاقات والأنماط التي تؤثر على التنبؤات المالية والمستثمرين وتحديد الفرص الاستثمارية، وبالتالي اتخاذ قرارات مالية رشيدة ترفع من كفاءة الأسواق المالية.

٢/٧: أثر استخدام خوارزميات تعلم الآلة في التنبؤ بالأرباح المستقبلية وانعكاسه على تعزيز ثقة المستثمرين.

أصبحت المعلومات المستقبلية عنصراً أساسياً في التقارير المالية للشركات المدرجة في سوق الأوراق المالية، وذلك نظراً لدورها في تقديم رؤى حول خطط الشركات وتوجهاتها المستقبلية، بما في ذلك أنشطة الاستثمار المتوقعة وإيراداتها المحتملة. وذلك على عكس المعلومات التاريخية، التي تُعد المكون الرئيسي للتقارير المالية التقليدية المقدمة لأصحاب المصالح. إلا أن هذه المعلومات وحدها لا تكفي لتقييم الأداء المستقبلي للشركة. لذلك، تحظى المعلومات المستقبلية بأهمية خاصة لدى المستثمرين، نظراً لدورها في تحسين عملية اتخاذ القرار الاستثماري وزيادة جاذبية الشركات للاستثمار. كما تؤثر هذه المعلومات بشكل مباشر على سوق الأوراق المالية، من خلال تأثيرها على بعض متغيرات سوق الأوراق المالية مثل: حجم التداول وحركة أسعار الأسهم (Papaj and Strojek, 2019).

ويمكن تصنيف المعلومات المستقبلية إلى مجموعة من البيانات القابلة للتحقق، والتي تشمل عدة جوانب رئيسية تساعد المستثمرين والإدارة في اتخاذ القرارات المالية والاستراتيجية. حيث تتضمن هذه المعلومات بيانات السهم التي تتيح للمستثمرين تقييم جدوى الاحتفاظ به أو بيعه، ومدى تحقيق الربحية والتوقعات حول التدفقات النقدية المستقبلية، وتعتبر التقديرات المتعلقة بالربحية المستقبلية من العناصر الأساسية في تقييم النشاط الاقتصادي للشركة، نظراً لأهميتها للمستثمرين وملاءمتها لاحتياجاتهم، مما يجعل هذه التوقعات ضرورية للمستثمرين في تقدير الأرباح المستقبلية (سعد الدين، ٢٠١٤).

ويُعد التنبؤ بالأرباح المحاسبية أحد العوامل الجوهرية في تقييم الأداء المالي للشركات، حيث يساهم بشكل رئيسي في رسم صورة واضحة حول مستقبلها المالي ومدى استقرارها وقدرتها على تحقيق النمو المستدام. وتعتمد الشركات على هذه التوقعات ليس فقط في إعداد خططها التشغيلية والاستراتيجية، بل أيضاً في تعزيز مستوى الشفافية والمصداقية في التقارير المالية، وهو ما يؤدي إلى زيادة ثقة المستثمرين وأصحاب المصلحة. فكلما كانت التنبؤات أكثر دقة وموثوقة، زادت قدرة المستثمرين على اتخاذ قرارات مالية واستثمارية سليمة، مما يقلل من حالة عدم اليقين التي قد تؤثر على الأسواق المالية ويعزز من أداءها المستدام (المر، ٢٠٢٢ ، الساعدي والغزي، ٢٠١٧).

ويُعرف التنبؤ بالأرباح بأنه عملية تقدير العائد المالي المتوقع من العمليات التشغيلية للشركة خلال فترة مستقبلية محددة، باستخدام البيانات المالية المتاحة والمعلومات الاقتصادية والصناعية ذات الصلة، وذلك بهدف توفير فهم واضح لتطور أداء الشركة وتحديد العوامل المؤثرة على أرباحها، مما يساعد في تعزيز دقة القرارات التشغيلية والاستثمارية (Chang et al., 2024). ويعتمد المستثمرون، سواء الأفراد أو المؤسسات المالية، على التنبؤ بالأرباح المحاسبية لتقييم المخاطر والعوائد المحتملة لاستثماراتهم، حيث تؤثر هذه التقديرات بشكل مباشر على قراراتهم المتعلقة بشراء أو بيع الأسهم، وتحديد مدى جاذبية الشركة كوجهة استثمارية. ولذلك، فإن دقة هذه التوقعات تساهم في تحسين كفاءة السوق المالية، إذ تساعد على تسعير الأسهم والأصول بشكل أكثر إنصافاً وفقاً للتوقعات المستقبلية

للأرباح. كما أن الشركات التي تتمكن من تقديم تقديرات دقيقة وموثوقة لأرباحها المستقبلية تكتسب ميزة تنافسية، حيث تصبح أكثر جاذبية للمستثمرين الذين يبحثون عن استثمارات مستقرة وعوائد متوقعة بقدر كبير من الدقة (خالد و بريمة، ٢٠٢٢).

فالتنبؤ بالأرباح يلعب دوراً رئيسياً في قرارات الإدارة الداخلية للشركات، حيث يساعد في توجيه استراتيجيات النمو، وتحديد السياسات المالية، وتخصيص الموارد بفعالية. وعند الاعتماد على أساليب تحليل متقدمة، مثل خوارزميات تعلم الآلة والذكاء الاصطناعي، يصبح بالإمكان تحقيق مستويات غير مسبوقة من الدقة في التنبؤات المالية، مما يمنح الشركات ميزة استباقية في مواجهة التحديات المالية وتحديد الفرص الاستثمارية المستقبلية. ومع استمرار التطورات في تقنيات تحليل البيانات، أصبح من الممكن ليس فقط التنبؤ بالأرباح بدقة أكبر، ولكن أيضاً فهم العوامل المؤثرة عليها بعمق أكبر، مما يعزز ثقة المستثمرين ويخلق بيئة مالية أكثر استقراراً ونمواً، تدعم الاستثمارات طويلة الأجل وتساهم في تحقيق استدامة الأسواق المالية (حجازي، ٢٠٢٣). وتعد ربحية السهم مؤشراً مهماً على أداء الشركة ونشاطها، كما أنها تمثل مقياساً أساسياً للتنبؤ بالأرباح المستقبلية. فهي تساعد الإدارة في تحليل المخاطر واتخاذ قرارات استثمارية فعالة، مما يساهم في تقييم الأداء المالي للشركة. كما تحظى بأهمية كبيرة لدى المستثمرين، حيث تُستخدم في توقع التدفقات النقدية المستقبلية. إضافةً إلى ذلك، تدخل ربحية السهم في حساب العديد من النسب المالية المستخدمة في تقييم الأسهم، مما يمكّن المحللين الماليين من تحديد مدى توافق القيمة السوقية لأسهم الشركة مع قيمتها الحقيقية (Chordia et al., 2017).

وفي ظل الطبيعة الديناميكية والمتغيرة للأسواق المالية، يمثل التنبؤ بالأرباح المستقبلية عاملاً حاسماً في صياغة استراتيجيات الاستثمار وتوجيه قرارات المستثمرين. وقد اعتمدت التقديرات المالية على النماذج الإحصائية التقليدية، إلا أن التطور التكنولوجي أتاح استخدام خوارزميات تعلم الآلة، التي أثبتت قدرتها على تحسين دقة التنبؤات المالية وزيادة موثوقيته. هذا التطور في تحليل البيانات لا يساهم فقط في تقديم رؤى أعمق حول الأداء المالي المستقبلي، بل يعزز أيضاً من ثقة المستثمرين في قراراتهم الاستثمارية (Olubusola et al., 2023).

وتسهم استخدام هذه التقنيات في تعزيز ثقة المستثمرين بعدة طرق. أولاً، توفر هذه النماذج دقة أعلى في التنبؤ، مما يقلل من حالة عدم اليقين التي قد تؤثر على قرارات المستثمرين (Khan and Upadhyaya, 2020). ثانياً، يعتمد تعلم الآلة على تحليل بيانات موضوعية بعيداً عن التحيز البشري، مما يجعل التوقعات أكثر شفافية ومصداقية (Alanazi, 2025). ثالثاً، يساهم التنبؤ الدقيق بالأرباح في تحسين استراتيجيات إدارة المخاطر، حيث يصبح لدى المستثمرين رؤية واضحة حول الأداء المالي المتوقع للشركات، مما يقلل من احتمالات الخسائر. كما أن وجود توقعات موثوقة يقلل من التقلبات غير المبررة في الأسواق، مما يعزز استقرارها ويزيد من ثقة المستثمرين على المدى الطويل (Li et al., 2024).

وقد أشارت الأدبيات المحاسبية (Kara, 2023; Bustos et al., 2020; Olubusola et al., 2024; Altarazi and Santos, 2024) إلى أن التنبؤ بالأرباح المستقبلية يُعد أحد الركائز الأساسية في الفكر المحاسبي، حيث يلعب دوراً حيوياً في تقييم الأداء المالي للشركات وصياغة القرارات الاستثمارية والإدارية. ويعتمد هذا التنبؤ بشكل متزايد على خوارزميات تعلم الآلة، نظراً لقدرتها الفائقة على تحليل البيانات المالية بدقة وعمق أكبر من الأساليب التقليدية. فمن خلال دراسة وتحليل البيانات المالية التاريخية، تستطيع هذه الخوارزميات اكتشاف أنماط وعلاقات غير مرئية ليست متوفرة بوسائل التحليل التقليدية، مما يتيح للشركات تحسين دقة توقعاتها حول الاتجاهات المستقبلية للأرباح. وتعتمد خوارزميات تعلم الآلة على معالجة كميات ضخمة من البيانات، مما يعزز موثوقية التنبؤات ويجعلها أكثر دقة في دعم عمليات اتخاذ القرار.

كما أوضحت تلك الدراسات أن التنبؤ بالأرباح المستقبلية لا تقتصر أهميته على تحسين عملية التخطيط المالي والإداري داخل الشركات، بل تمتد أيضاً إلى تقييم الأوراق المالية واتخاذ القرارات الاستثمارية. فالمستثمرون يعتمدون بشكل أساسي على التنبؤ بالأرباح لتقييم مدى ربحية الشركات في المستقبل، مما يؤثر بشكل مباشر على قرارات شراء أو بيع الأسهم. كما تُستخدم الأرباح المحاسبية المستقبلية في نماذج التقييم المالي المختلفة، مثل نموذج القيمة الحالية للتدفقات النقدية المتوقعة، ونموذج الدخل المتبقي، ونموذج تسعير الأصول الرأسمالية، حيث تلعب الأرباح

دوراً محورياً في تحديد قدرة الشركة على تحقيق تدفقات نقدية مستدامة وضمن قدرتها على توزيع الأرباح على المساهمين. بالإضافة إلى ذلك، فإن دقة التنبؤ بالأرباح تعزز ثقة المستثمرين، مما يساهم في استقرار الأسواق المالية ويؤدي إلى تحسين بيئة الاستثمار بشكل عام.

وهذا ما اتفقت عليه دراسة (Huang and You, 2022) في أن خوارزميات تعلم الآلة تُسهم بشكل كبير في تعزيز ثقة المستثمرين من خلال تقديم تنبؤات دقيقة وموثوقة بشأن الأرباح المستقبلية، مما يساعدهم في اتخاذ قرارات استثمارية مدروسة. وأكدت عليه دراسة (Eachempati et al., 2021) على ضرورة استخدام خوارزميات تعلم الآلة في تحليل تصورات المستثمرين والتنبؤ بها، حيث تُعد هذه التقنيات أداة قوية لاستخلاص رؤى دقيقة حول سلوك المستثمرين واتجاهاتهم المستقبلية في الأسواق المالية، كما تعمل خوارزميات تعلم الآلة على تصنيف وتحليل هذه التصورات من خلال نماذج مدربة مسبقاً، أو عبر تطبيقها في سياقات متعددة، مما يتيح لها القدرة على توليد أنماط تصنيف جديدة تسهم في تحسين دقة التنبؤات المالية.

وفي هذا السياق، أصبح بإمكان الشركات الاستفادة من خوارزميات تعلم الآلة ليس فقط في تحليل البيانات المالية، بل أيضاً في اختيار النماذج الأكثر توافقاً مع احتياجاتها العملية وأهدافها الاستراتيجية. فمن خلال التقييم المستمر لأداء هذه الخوارزميات، تستطيع الشركات تحديد الأدوات التحليلية الأكثر كفاءة ودقة، مما يسهم في تعزيز جودة التنبؤ بالأرباح المستقبلية وتحسين عملية اتخاذ القرارات المالية والاستثمارية. كما أن التطور المستمر في خوارزميات تعلم الآلة يوفر للشركات فرصة لتحسين استراتيجياتها بناءً على بيانات وتحليلات دقيقة، مما يضمن تحقيق ميزة تنافسية مستدامة في بيئة الأعمال الديناميكية (Kureljusic and Metz, 2023).

ويوضح جدول رقم (٢) أبرز خوارزميات تعلم الآلة المستخدمة في التنبؤ بالأرباح المحاسبية وانعكاسها على تعزيز ثقة المستثمرين.

جدول رقم (٢)

أبرز خوارزميات تعلم الآلة المستخدمة في التنبؤ بالأرباح المحاسبية وانعكاسها على تعزيز ثقة المستثمرين

الخوارزمية	تأثيرها على التنبؤ بالأرباح المحاسبية	انعكاسها على تعزيز ثقة المستثمرين
الغابات العشوائية Random Forest	أوضحت دراسة (متولي، ٢٠٢٢) أن استخدام معلومات التقارير المالية في نماذج تعلم الآلة، مثل خوارزمية الغابات العشوائية، يُحسِّن دقة التنبؤ بالأداء المالي للشركات المقيدة في البورصة المصرية.	أشارت دراسة (Cai and Chen, 2024) إلى أن تحسين دقة التنبؤات المالية باستخدام هذه الخوارزمية يعزز ثقة المستثمرين في المعلومات المقدمة، مما يدعم قراراتهم الاستثمارية.
الشبكات العصبية Neural Networks	أشارت دراسة (عويس، ٢٠٢٤) إلى أن الشبكات العصبية تساهم في التنبؤ بربحية السهم، مما يؤثر إيجابياً على الإفصاح عن المعلومات المالية المستقبلية.	أوضحت دراسة (Altarazi and Santos, 2024) أن تقديم تنبؤات دقيقة حول ربحية السهم باستخدام هذه التقنيات يمكن أن يزيد من ثقة المستثمرين في الإفصاحات المالية.
شجرة القرارات Decision Tree	أوضحت دراسة (Amos and Rimona, 2019) أن شجرة القرارات تُظهر فعالية في التنبؤ بعوائد الأسهم وربحية السهم، وأن استخدامها يؤثر على الإفصاح عن المعلومات المستقبلية.	أشارت دراسة (Aly et al., 2023) إلى أن زيادة دقة التنبؤات المالية باستخدام شجرة القرارات يمكن أن تعزز ثقة المستثمرين في المعلومات المالية المستقبلية.
آلية دعم المتجهات Support Vector Machine	أشارت دراسة (المر، ٢٠٢٤) إلى أن استخدام هذه الآلية في التنبؤ بعوائد الأسهم وربحية السهم يؤثر على الإفصاح عن المعلومات المستقبلية.	أوضحت دراسة (Chan et al., 2023) أن تحسين دقة التنبؤات باستخدام هذه الآلية يمكن أن يؤدي إلى تعزيز ثقة المستثمرين في الإفصاحات المالية.
الشبكية البايزية Bayesian Network	أشارت دراسة (عويس، ٢٠٢٤) إلى أن الشبكة البايزية تُستخدم في التنبؤ بربحية السهم، وقد وتوصلت الدراسة إلى أن استخدامها يؤثر على الإفصاح عن المعلومات المستقبلية.	أوضحت دراسة (Eachempati et al., 2021) أن استخدام الشبكة البايزية في تحسين دقة التنبؤات المالية يمكن أن يزيد من ثقة المستثمرين في المعلومات المستقبلية المقدمة.

أشارت دراسة (المر، ٢٠٢٤) أن خوارزمية الأقرب جار تحسّن من دقة التوقعات المالية، مما تساعد في تقديم توقعات موثوقة تعزز من مصداقية المعلومات المالية للشركات، وهو ما يؤدي إلى زيادة ثقة المستثمرين في اتخاذ قراراتهم الاستثمارية.	أشارت دراسة (عويس، ٢٠٢٤) أن هذه الخوارزمية تُستخدم في تحليل البيانات المالية لاكتشاف الأنماط التاريخية وتوقع الأرباح المستقبلية، خاصة عند التعامل مع بيانات غير خطية، وتعمل هذه الطريقة من خلال مقارنة القيم الجديدة مع أقرب القيم المشابهة في البيانات التاريخية، مما يساعد في تقديم تقديرات أكثر واقعية للأرباح المتوقعة.	الأقرب جار K-Nearest Neighbors
---	--	---

ويُظهر الجدول رقم (٢) مدى أهمية خوارزميات تعلم الآلة في التنبؤ بالأرباح المحاسبية وانعكاسها على تعزيز ثقة المستثمرين. حيث تسهم هذه الخوارزميات، مثل الغابات العشوائية والشبكات العصبية وشجرة القرارات وآلية دعم المتجهات والشبكة البايزية والأقرب جار، في تحسين دقة التنبؤات المالية بشكل عام والتنبؤ بالأرباح المستقبلية بشكل خاص، مما يُمكن الشركات من تقديم تقديرات أكثر واقعية، ويعزز ذلك من ثقة المستثمرين من خلال توفير بيانات دقيقة وموثوقة تساعد في اتخاذ قرارات استثمارية مدروسة.

ومن هذا المنطلق، يرى الباحثين أن تبني خوارزميات تعلم الآلة في التنبؤ بالأرباح يمثل تحولاً جوهرياً في مجال التحليل المالي، حيث توفر هذه التقنيات أدوات تحليلية متطورة قادرة على معالجة كميات ضخمة من البيانات المالية بدقة وسرعة تتجاوز الأساليب التقليدية. ويسهم هذا التوجه في تحسين جودة التنبؤات المالية، مما يعزز من قدرة الشركات على التخطيط الاستراتيجي واتخاذ قرارات استثمارية أكثر دقة وفعالية. بالإضافة إلى ذلك، فإن دقة التنبؤ بالأرباح باستخدام هذه الخوارزميات تساهم في رفع مستوى الشفافية والمصداقية في الأسواق المالية، مما يؤدي إلى زيادة ثقة المستثمرين ودعم استقرار السوق. فعندما يتمكن المستثمرون من الوصول إلى توقعات مالية دقيقة وموثوقة، يصبح بإمكانهم اتخاذ قرارات استثمارية أكثر دقة، مما يحفز النشاط الاستثماري ويعزز من كفاءة تخصيص الموارد المالية.

وفي النهاية، يمكن القول إن استخدام خوارزميات تعلم الآلة في التنبؤ بالأرباح المستقبلية يمثل نقلة نوعية في تحليل الأسواق المالية واتخاذ القرارات الاستثمارية، حيث يساهم في تحسين دقة التوقعات، وزيادة الشفافية، وتعزيز الاستقرار المالي. ومع استمرار تطور هذه التقنيات، من المتوقع أن يتزايد تأثيرها في أسواق المال، مما يدعم قدرة المستثمرين على اتخاذ قرارات أكثر ذكاءً ويساعد في مواكبة المستجدات الاقتصادية بمرونة وسرعة، الأمر الذي يفتح المجال لمزيد من الفرص الاستثمارية على المستوى العالمي.

٨- الدراسة التطبيقية:

تناول الباحثين في الجانب النظري من الدراسة دور خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية، وأثر استخدام خوارزميات تعلم الآلة في التنبؤ بالأرباح المستقبلية وانعكاسه على تعزيز ثقة المستثمرين، وذلك من خلال إستقراء وتحليل لأهم الإصدارات والأدبيات المحاسبية السابقة في تلك مجال، ومن خلال الدراسة التطبيقية سوف يقوم الباحثين بإختبار الفروض التي تم إشتقاقها من الأدبيات المحاسبية السابقة، وذلك لتحديد مدى قبول صحة هذه الفروض من عدمها، وتحقيق الأهداف البحثية التي تسعى إليها هذه الدراسة، حتى يتمكن الباحثين من إستخلاص نتائج الدراسة، والتي على ضوئها يمكن إبداء التوصيات، وإقتراح مجالات للبحوث المستقبلية ذات الصلة بمتغيرات الدراسة.

ترتيباً على ذلك سيتم تناول النقاط التالية، على النحو التالي:

١/٨ : مجتمع وعينة الدراسة

٢/٨ : مصادر جمع البيانات

٣/٨ : صياغة نماذج الدراسة

٤/٨ : متغيرات الدراسة والتعريفات الإجرائية

٥/٨ : التحليل القياسي واختبار فرض الدراسة

١/٨ : مجتمع وعينة الدراسة:

١/١/٨ : مجتمع الدراسة:

يتمثل مجتمع الدراسة في الشركات المساهمة المدرجة بالبورصة المصرية والتي تدرج ضمن مؤشر EGX100، وذلك خلال الفترة من عام ٢٠١٩م حتى عام ٢٠٢٤م.

٢/١/٨ : عينة الدراسة:

تتمثل عينة الدراسة في عدد ٥٠ شركة مساهمة مدرجة بالبورصة المصرية، وتدرج ضمن مؤشر EGX100، وذلك خلال الفترة من عام ٢٠١٩م حتى عام ٢٠٢٤م، والتي تنتمي إلى قطاعات وأنشطة مختلفة داخل بيئة الأعمال المصرية. وقد قام الباحثين باختيار العينة بناءً على المعايير الآتية:

١. أن تكون شركات العينة قد وفقت أوضاع قيد أسهمها داخل البورصة المصرية، أي إنها متوافقة مع جميع شروط وإستمرار القيد داخل السوق، بالإضافة إلى أنها قد إستوفت جميع المستندات المطلوبة منها للعرض على لجنة القيد وتكون قد أجازتها اللجنة.

٢. إنتهاء السنة المالية لجميع الشركات محل الدراسة التطبيقية في تاريخ موحد لتبدأ في ١/١ وتنتهي في ١٢/٣١ كل عام، وذلك لإستيفاء البيانات المطلوبة بالنماذج الإحصائية.

٣. تم إختيار العينة من بين الشركات المدرجة ضمن مؤشر البورصة المصرية EGX100 وهي الشركات الأنشطة وفقاً لرأس المال السوقي المرجح، وذلك لأن هذا المؤشر يوفر تمثيلاً جيداً لمختلف القطاعات، حيث إنه لا يركز على صناعة بعينها، علاوة على أنه يشمل على الأسهم العادية فقط أما الأسهم الممتازة والسندات فلا يتضمنها، وتتضمن عينة الدراسة على عدد ٥٠ شركة، نظراً لعدم توافر البيانات اللازمة عن بعض الشركات المدرجة في هذا المؤشر.

٤. أن تكون مدة بقاء شركات العينة المدرجة ضمن مؤشر EGX100 متواجدة خلال فترة الدراسة والمتمثلة في ست سنوات، حيث يتم مراجعة

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

مؤشر EGX100 أربع مرات سنوياً وذلك بواسطة الإدارة المختصة بالبورصة المصرية، وتقوم بمراجعة شاملة في بداية شهر فبراير وأغسطس من كل عام والتي تشمل إضافة وإستبعاد الشركات من المؤشر.

٥. تم إستبعاد الشركات المدرجة ضمن مؤشر EGX100 التي تنتمي إلى القطاعات المالية وهي: البنوك، وشركات التأمين، وشركات الخدمات المالية المصرفية، وذلك نظراً لاختلاف متطلبات وخصائص هذه القطاعات. ويوضح الجدول رقم (٣) التصنيف القطاعي لشركات عينة الدراسة.

جدول رقم (٣)
التصنيف القطاعي لشركات عينة الدراسة

م	القطاع	عدد الشركات	النسبة
١	اعلام	١	٢%
٢	الاتصالات	٥	١٠%
٣	المرافق	١	٢%
٤	المنتجات المنزلية والشخصية	١	٢%
٥	الموارد الأساسية	٦	١٢%
٦	النقل والشحن	٣	٦%
٧	أغذية	٩	١٨%
٨	تشبيد وبناء	٣	٦%
٩	خدمات وسيارات	٢	٤%
١٠	رعاية صحية وأدوية	٣	٦%
١١	سياحة ترفية	١	٢%
١٢	طاقة وخدمات مساندة	١	٢%
١٣	عقارات	١٤	٢٨%
الإجمالي		٥٠	١٠٠%

٢/٨ : مصادر جمع البيانات:

اعتمد الباحثين في جمع البيانات على القوائم والتقارير المالية، والتقارير الأخرى المنشورة بالمواقع الإلكترونية الخاصة بكل شركة، وكذلك المواقع الإلكترونية التالية:

- البورصة المصرية <http://www.egx.com.eg>
- الهيئة العامة للرقابة المالية <https://fra.gov.eg>
- معلومات مباشر <http://www.mubasher.info/countries/sa>
- شركة إنفستنج <https://www.investing.com>

٣/٨ : صياغة نماذج الدراسة:

١/٣/٨ : التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة:

يعتمد الباحثين بشأن التنبؤ بربحية السهم على نموذج الانحدار الخطي المتعدد Multiple Linear Regression Model، وذلك قياساً على دراسة (محمود ، ٢٠١٣) ، حيث تعتبر ربحية السهم المتنبأ بها (المتغير التابع) ، وكلاً من ربحية السهم التاريخية، التدفقات النقدية من الأنشطة التشغيلية (المتغيرات المستقلة)، حجم الشركة، ربحية الشركة، ونوع القطاع (المتغيرات الضابطة)، وبذلك يمكن صياغة نموذج التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة على النحو التالي:

$$P(EPS_{it+1}) = \beta_0 + \beta_1 EPS_{it} + \beta_2 CHO_{it} + \beta_3 SIZE_{it} + \beta_4 PROF_{it} + \beta_5 ST_{it} + e_{it} \dots\dots\dots (1)$$

حيث أن :

$P(EPS_{it+1})$	: التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة في الشركة (i) في الفترة (t+1).
EPS_{it}	: ربحية السهم التاريخية في الشركة (i) في الفترة (t).
CHO_{it}	: التدفقات النقدية التشغيلية من الأنشطة التشغيلية في الشركة (i) في الفترة (t).
$SIZE_{it}$	: حجم الشركة (i) في الفترة (t).
$PROF_{it}$	: ربحية الشركة (i) في الفترة (t).
ST_{it}	: نوع القطاع في الشركة (i) في الفترة (t).

β_0	: ثابت الانحدار.
β_1	: معامل الانحدار للمتغير ربحية السهم التاريخية.
β_2	: معامل الانحدار لمتغير التدفقات النقدية من الأنشطة التشغيلية.
β_3	: معامل الانحدار لمتغير حجم الشركة.
β_4	: معامل الانحدار لمتغير ربحية الشركة.
β_5	: معامل الانحدار لمتغير نوع القطاع.
e_{it}	: المتبقي احصائياً من تقدير النموذج (الخطأ العشوائي).

٢/٣/٨ : التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة:

يعتمد الباحثين بشأن التنبؤ بالتدفقات النقدية التشغيلية على نموذج الانحدار الخطي المتعدد Multiple Linear Regression Model، وذلك قياساً على دراسة (اسماعيل، ٢٠١٧)، حيث تعتبر التدفقات النقدية التشغيلية المتنبأ بها (المتغير التابع)، وكلاً من التدفقات النقدية التشغيلية التاريخية، صافي الربح (المتغيرات المستقلة)، حجم الشركة، ونوع القطاع (المتغيرات الضابطة)، وبذلك يمكن صياغة نموذج التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة على النحو التالي:

$$P(CFO_{it+1}) = \beta_0 + \beta_1 CFO_{it} + \beta_2 NPROF_{it} + \beta_3 SIZE_{it} + \beta_4 ST_{it} + e_{it} \dots\dots\dots (2)$$

حيث أن :

$P(CFO_{it+1})$	: التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة في الشركة (i) في الفترة (t+1).
CFO_{it}	: التدفقات النقدية التشغيلية التاريخية في الشركة (i) في الفترة (t).
$NPROF_{it}$	: صافي ربح الشركة (i) في الفترة (t).
$SIZE_{it}$	: حجم الشركة (i) في الفترة (t).
ST_{it}	: نوع القطاع في الشركة (i) في الفترة (t).
β_0	: ثابت الانحدار.
β_1	: معامل الانحدار لمتغير التدفقات النقدية التشغيلية التاريخية.
β_2	: معامل الانحدار لمتغير صافي الربح.
β_3	: معامل الانحدار لمتغير حجم الشركة.
β_4	: معامل الانحدار لمتغير نوع القطاع.
e_{it}	: المتبقي احصائياً من تقدير النموذج (الخطأ العشوائي).

٣/٣/٨ : أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين:

يعتمد الباحثين بشأن اختبار فرض الدراسة على نموذج الانحدار الخطي المتعدد Multiple Linear Regression Model، والذي يبنى على أن تعزيز ثقة المستثمر تعد دالة في كل من التنبؤ بالأرباح المستقبلية المتمثلة في (ربحية السهم، التدفقات النقدية التشغيلية) وذلك باستخدام خوارزميات تعلم الآلة، والمتغيرات الضابطة المتمثلة في (حجم الشركة، الرافعة المالية، ربحية الشركة)، وذلك من خلال العلاقة الدالية التالية: تعزيز ثقة المستثمرين والمتمثلة في (حجم التداول) = دالة (التنبؤ بربحية السهم والتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة + المتغيرات الضابطة)، وبذلك يمكن صياغة نموذج الدراسة على النحو التالي:

$$IC_{it} = \beta_0 + \beta_1 P(EPS_{it+1}) + \beta_2 P(CFO_{it+1}) + \beta_3 SIZE_{it} + \beta_4 LEV_{it} + \beta_5 PROF_{it} + e_{it} \quad (3)$$

حيث أن :

IC _{it}	: تعزيز ثقة المستثمر في الشركة (i) في الفترة (t).
P(EPS _{it+1})	: التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة في الشركة (i) في الفترة (t+1).
P(CFO _{it+1})	: التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة في الشركة (i) في الفترة (t+1).
SIZE _{it}	: حجم الشركة (i) في الفترة (t).
LEV _{it}	: الرافعة المالية للشركة (i) في الفترة (t).
PROF _{it}	: ربحية الشركة (i) في الفترة (t).
β ₀	: ثابت الانحدار.
β ₁	: معامل الانحدار لمتغير التنبؤ بربحية السهم باستخدام خوارزميات تعلم الآلة.
β ₂	: معامل الانحدار لمتغير التنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة.
β ₃ - β ₅	: معاملات الانحدار للمتغيرات الضابطة.
e _{it}	: المتبقي احصائياً من تقدير النموذج (الخطأ العشوائي).

وقد أشارت العديد من الدراسات المحاسبية (المر ٢٠٢٢ ، عويس، ٢٠٢٤ ،
(Ateya, 2024, 2024 ;Aly et al., 2023; Amos and Rimona, 2019
إلى أن أبرز خوارزميات تعلم الآلة المستخدمة في التنبؤ بالأرباح المستقبلية
تشمل:

- خوارزمية شجرة القرار (Decision Tree) ويتفرع من تلك الخوارزمية:
مربع كاي للكشف التلقائي عن التفاعل (Chi-squared Automatic
Interaction Detector)، وشجرة التصنيف والانحدار (Classification
(and Regression Tree).
- خوارزمية الأقرب جار (K-Nearest Neighbors).
- خوارزمية آلة دعم المتجهات (Support Vector Machine)، ويتفرع من
تلك الخوارزمية: آلة متجهات الدعم الخطية (Linear Support).
- خوارزمية الشبكات العصبية (Neural Networks).
- خوارزمية الغابات العشوائية (Random Forests).

ويعتمد الباحثين في إجراء التحليل الإحصائي على هذه الخوارزميات،
باعتبارها الأكثر شيوعاً واستخداماً في مجال التنبؤات المالية بشكل عام والتنبؤ
بالأرباح المستقبلية بشكل خاص، ثم يتم إجراء مقارنة منهجية بينها بهدف تحديد أي
منها يُعد الأكثر كفاءة ودقة في التنبؤ بالأرباح المستقبلية.

٤/٨ : متغيرات الدراسة والتعريفات الإجرائية:

يوضح الجدول رقم (٣) وصفاً لمتغيرات الدراسة والتعريف الإجرائي لها،
حيث يتم قياس المتغير المستقل من خلال التنبؤ بالأرباح المستقبلية باستخدام
خوارزميات تعلم الآلة، والمتغير التابع من خلال تعزيز ثقة المستثمرين، والمتغيرات
الضابطة من خلال حجم الشركة والرافعة المالية وربحية الشركة، على النحو التالي:

جدول رقم (٣)
التعريف الإجرائي لمتغيرات الدراسة

التعريف الإجرائي للمتغيرات	المتغيرات	
	اسم المتغير	رمز المتغير
المتغير المستقل : التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة		
يتم قياس التنبؤ بالأرباح المستقبلية من خلال ربحية السهم أو نصيب السهم الواحد من الأرباح، ويتم حسابه من خلال المعادلة الآتية: صافي الربح بعد الفوائد والضرائب ÷ المتوسط المرجح لعدد الأسهم العادية. (الساعدي والغزي، ٢٠١٧، جمال بودرمين، ٢٠١٧; Chordia et al. , 2017)	ربحية السهم	EPS _{it+1}
يتم قياس التنبؤ بالأرباح المستقبلية من خلال التدفقات النقدية التشغيلية، ويتم حسابها من خلال المعادلة التالية: صافي التدفقات النقدية من الأنشطة التشغيلية للشركة في نهاية السنة ÷ إجمالي أصول الشركة في نهاية السنة (الساعدي والغزي، ٢٠١٧; Chordia et al. , 2017).	التدفقات النقدية التشغيلية	CFO _{it+1}
المتغير التابع : تعزيز ثقة المستثمرين		
يتم قياس تعزيز ثقة المستثمر من خلال حجم التداول، ويتم حسابه من خلال كمية الأسهم المتداولة (بيع-شراء) في فترة زمنية معينة ويعتمد هذا المؤشر أهميته من عدة محاور: المحور الأول- قدرته على قياس تعزيز ثقة المستثمرين لارتباط حجم التداول بعلاقة طردية مع ارتفاع اهتمام المستثمرين بالتعامل مع الشركة، المحور الثاني- يساهم حجم التداول في التنبؤ بالأرباح المستقبلية من خلال مقارنته مع الشركات الأخرى، المحور الثالث- حجم التداول المرتفع مؤشر على استقرار الأسهم واهتمام المستثمرين بها (عويس، ٢٠٢٤، محمد، ٢٠٢٤، الناصر، ٢٠٢١; Papaj and Strojek, 2019).	تعزيز ثقة المستثمرين	IC _{it}

المتغيرات الضابطة:		
حجم الشركة	SIZE _{it}	وتقاس باللوغاريتم الطبيعي لإجمالي أصول الشركة (i) في نهاية السنة (t). (عيفي، ٢٠١٧، عبدالمقصود، ٢٠٢٢).
المديونية (الرافعة المالية)	LEV _{it}	وتقاس بنسبة إجمالي الالتزامات إلى إجمالي أصول الشركة (i) في نهاية السنة (t). (عيفي، ٢٠١٧، عبدالمقصود، ٢٠٢٢).
ربحية الشركة	PROF _{it}	يتم قياسها من خلال معدل العائد على الأصول للشركة (i) خلال السنة (t) ، والذي يتم حسابه من خلال المعادلة التالية : صافي الربح بعد الضرائب ÷ متوسط إجمالي الأصول خلال السنة (محمد، ٢٠٢٤).

ويتم استخدام المتغيرات الضابطة لأغراض التحكم وضبط تأثير بعض المتغيرات الحاكمة الأخرى على تلك العلاقات التأثيرية. حيث قام الباحثين بتضمين النموذج التطبيقي المقترح بالدراسة الحالية، ببعض من تلك المتغيرات، علماً بأنها لا تدخل ضمن نطاق الدراسة الحالية، وهو ما اصطلح على تسميتها في البحوث والدراسات بالمتغيرات الرقابية أو الضابطة.

٥/٨: التحليل القياسي واختبار فرض الدراسة:

أعتمد الباحثين في هذه الدراسة على التحليل القياسي لنهج ثنائي المراحل، حيث أنه يدمج بين أدوات الذكاء الاصطناعي والنماذج الاقتصادية القياسية، وذلك بهدف دراسة العلاقة بين التنبؤ بالأرباح المستقبلية وثقة المستثمرين، وذلك من خلال اتباع المرحلتين التاليتين:

المرحلة الأولى: التنبؤ بالأرباح المستقبلية باستخدام أبرز خوارزميات من تعلم الآلة، تتمثل في:

- خوارزمية شجرة القرارات (Decision Tree) ويتفرع من تلك الخوارزمية التي تستخدم في التحليل الإحصائي للبيانات: مربع كاي للكشف التلقائي عن التفاعل (Chi-squared Automatic Interaction Detector)، وشجرة التصنيف والانحدار (Classification and Regression Tree).
- خوارزمية الأقرب جار (K-Nearest Neighbors).
- خوارزمية آلة دعم المتجهات (Support Vector Machine)، ويتفرع من تلك الخوارزمية: آلة متجهات الدعم الخطية (Linear Support).
- خوارزمية الشبكات العصبية (Neural Networks).
- خوارزمية الغابات العشوائية (Random Forests).

وذلك بهدف التنبؤ بمؤشرين ماليين رئيسيين يعكسان الأرباح المستقبلية للشركات، وهما ربحية السهم (EPS) و التدفقات النقدية التشغيلية (CFO) من خلال استخدام هذه الخوارزميات، سيتم تحليل البيانات من عدة زوايا مختلفة، مما يسهم في تقديم تنبؤات دقيقة حول الأرباح المستقبلية. كما سيتم تقييم جودة التنبؤات باستخدام مجموعة من مؤشرات الدقة المتنوعة، والتي من أبرزها:

- معامل الارتباط الخطي (Linear Correlation): هو مقياس لمدى قوة العلاقة الخطية بين القيم المتنبأ بها والقيم الفعلية. وكلما اقتربت القيمة من +١ أو -١، كلما كانت العلاقة أقوى. وإذا كانت القيمة قريبة من صفر، فهذا يعني أنه لا يوجد ارتباط خطي بين المتغيرين.
- الانحراف المعياري (Std. Dev.): هو مقياس لتشتت التنبؤات حول القيمة المتوسطة. الانحراف المعياري المنخفض يعني أن التنبؤات قريبة من القيمة المتوسطة الفعلية، بينما الانحراف المعياري العالي يشير إلى تباين كبير في النتائج.
- متوسط الخطأ المطلق (MAE): وهو يقيس المتوسط البسيط للأخطاء بين القيم الفعلية والتنبؤات. كلما كان هذا الرقم أقل، كلما كانت التنبؤات أكثر دقة.

- متوسط الخطأ المطلق النسبي (MAPE): يعبر عن متوسط النسبة المئوية للخطأ بين القيم الفعلية والتنبؤات. يعتبر مقياساً مهماً لقياس دقة التنبؤات خاصة عند المقارنة بين مجموعة من النماذج.

المرحلة الثانية: يتم فيها استخدام القيم المتنبأ بها من المرحلة الأولى كمدخلات تفسيرية ضمن نماذج قياسية تعتمد على بيانات طويلة متوازنة (Balanced Panel Data)، وبالتحديد نموذج التأثيرات الثابتة، وذلك لقياس أثر هذه التنبؤات على ثقة المستثمرين. وقد شمل التحليل اختبار الفرضيات المتعلقة بمدى دلالة وتأثير التنبؤات المستخرجة عبر الخوارزميات المختلفة، مع تضمين متغيرات ضابطة مثل حجم الشركة، والربحية، والرافعة المالية لضمان دقة التقدير.

١/٥/٨: التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة:

في هذه المرحلة، يتم تحليل نتائج التنبؤ بربحية السهم (EPS)، والتدفقات النقدية التشغيلية (CFO) باستخدام الخوارزميات السبعة، ثم يتم تقييم أدائها وفقاً للمعايير المختلفة التي تم اختيارها. فهذه المعايير تعتبر أساسية لتقييم مدى دقة التنبؤات التي تم الحصول عليها من خلال الخوارزميات. وبعد تقييم هذه المعايير، سيتم ترتيب الخوارزميات من الأفضل إلى الأقل أداء بناءً على قيم هذه المعايير. هذه الطريقة توفر تحليلاً شاملاً لأداء الخوارزميات وتساعد في اختيار النموذج الأكثر دقة وأداءً.

١/١/٥/٨: التنبؤ بربحية السهم (EPS):

يوضح الجدول رقم (٤) نتائج التنبؤ بربحية السهم، مع ترتيب الخوارزميات المستخدمة من الأعلى دقة تنبؤية إلى الأقل دقة تنبؤية.

جدول (٤)
نتائج التنبؤ بربحية السهم

Table 4. Goodness-of-fit statistics for forecasting methods used to forecast EPS Testing (n = 69)

Algorithms used	No. of Predictors Used	Linear Correlation	Standard Deviation	Mean Absolute Error	Relative Error
Random Forests (RF)	10	0.743	1.212	0.750	0.518
Chi-squared Automatic Interaction Detector (CHAID)	7	0.739	1.211	0.837	0.529
Support Vector Machine (SVM)	16	0.711	1.235	0.782	0.542
Neural Network (NN)	15	0.619	1.378	0.997	0.673
Classification and Regression Tree (C&R Tree)	7	0.519	1.479	0.912	0.734
Linear Support Vector Machine (LSVM)	14	0.464	2.048	0.977	0.789
K-Nearest Neighbors Algorithm (KNN)	16	0.352	1.706	0.870	0.980

ويتضح من الجدول رقم (٤) أن خوارزمية الغابات العشوائية Random Forests (RF) قد أظهرت تفوقاً واضحاً مقارنةً بباقي الخوارزميات، حيث حققت أعلى قيمة لمعامل الارتباط الخطي بلغت ٧٤,٣%، مما يشير إلى علاقة قوية ومباشرة بين القيم المتوقعة والقيم الفعلية لـ EPS. كما كان للتقديرات المتنبأ بها أقل انحراف معياري ١,٢١٢، كما سجلت أقل قيمة لمتوسط الخطأ المطلق MAE عند ٠,٧٥٠، وكذلك أقل قيمة لمتوسط الخطأ المطلق النسبي MAPE بنسبة ٥١,٨٠%، مما يدل على دقة نموذجية في التنبؤ. تليها خوارزمية مربع كاي للكشف التلقائي عن التفاعل CHAID التي أظهرت نتائج مقارنة.

في المقابل، سجلت خوارزمية الجار الأقرب KNN أقل أداء من حيث جميع المؤشرات، إذ بلغ معامل الارتباط لديها ٥١,٤% فقط، مع MAE مرتفع عند ١,٠٧٤، وصلت إلى ٩٨%، مما يعكس ضعف هذه الخوارزمية في التقاط الأنماط المالية المرتبطة بـ EPS في العينة المستخدمة. وأن كان يقترب منها في السوء خوارزمية آلة متجهات الدعم الخطية LSVM.

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

وبناءً على القدرة التنبؤية العالية التي أظهرتها خوارزمية الغابات العشوائية (RF)، سيتم التركيز على استعراض الأشكال البيانية للقيم المتنبأ بها من هذه الخوارزمية باعتباره أفضل قيم متنبأ بها لربحية السهم.




Figure 1. Predictor Importance & Scatter plot for EPS prediction




Figure 2. Actual and expected value path for EPS in Testing group (n = 69)

ومن القطاع (A) في الشكل رقم (١) يتضح أن خوارزمية الغابات العشوائية (RF) قد اعتمدت على عشرة متغيرات مفسرة، كان أكثرها أهمية أو مساهمة في التنبؤ بربحية السهم، وهو القطاع السابع (قطاع التشييد والبناء)، يليها بفارق كبير حجم الشركة، ثم ربحية السهم في السنة السابقة، وربحية الشركة، وإجمالي التدفقات النقدية من الأنشطة التشغيلية، وأخيراً قطاعات النقل والشحن، والموارد الأساسية، والاتصالات، والعقارات، والأغذية على الترتيب. بينما يوضح القطاع B شكل انتشاري للعلاقة بين القيم الفعلية لربحية السهم والقيمة المتنبأ بها، ومنها يمكن ملاحظة بوضوح وجود اتساق كبير بين القيم الفعلية والمتنبأ بها في علاقة خطية. وهذا يعني أن خوارزمية RT قد نجحت في محاكاة العلاقة بين المتغيرات بطريقة صحيحة، والنتائج المتنبأ بها قريبة جداً من الواقع. هذا يشير إلى أداء عالي الجودة للنموذج، وأنه يمكن الاعتماد عليه في التنبؤات المستقبلية.

أما الشكل رقم (٢) فهو يعرض مقارنة بين القيم الفعلية لربحية السهم باللون الأزرق مقابل القيم المتنبأ بها باللون البرتقالي. ومن الوهلة الأولى، يمكن ملاحظة التطابق الكبير بين القيم المتوقعة والقيم الفعلية بحيث لا يمكننا أن نرى اللون الأزرق المعبر عن القيم الفعلية بسهولة بسبب تطابق اللون البرتقالي عليه المعبر عن القيم المتنبأ بها، وبالتالي فالخطان (الأزرق والبرتقالي) يتبعان نمطاً متشابهاً بشكل عام، مما يشير إلى أن القيم المتنبأ بها تعكس القيم الفعلية بشكل ممتاز. وهذا يشير لأن النموذج التنبؤي (خوارزمية الغابات العشوائية) قد قامت بتقديم تنبؤات دقيقة للغاية




Figure 3. Gain chart for EPS prediction

ويوضح شكل رقم (٣) مخطط الأرباح الموضح أعلاه أداء النموذج التنبؤي المطبق على كل من بيانات التدريب والاختبار لخوارزمية الغابات العشوائية، فيُمثل المحور الأفقي النسبة التراكمية من الحالات، مرتبة ترتيباً تنازلياً حسب احتمالية التنبؤ بحدوث الفئة المستهدفة، في حين يُظهر المحور الرأسي الأرباح تراكمية معبراً عنه كنسبة مئوية. وهنا يمثل المنحنى الأحمر (\$R-EPS) أداء النموذج الفعلي، بينما يمثل الخط القطري الأداء العشوائي الأساسي (أي في حال عدم وجود نموذج). ويُظهر المخطط ارتفاعاً حاداً في الأرباح، لاسيما خلال أول ١٠% إلى ٢٠% من البيانات، مما يشير إلى أن النموذج فعال للغاية في تحديد الحالات التي تتحقق فيها الحالة المستهدفة ($EPS > 6.205$).

ويصل منحنى الأرباح إلى أكثر من ٩٥% من المكسب قبل بلوغ ١٠٠% من إجمالي الحالات، مما يؤكد على القوة التمييزية العالية للنموذج. كما أن التقارب بين منحنيات التدريب والاختبار يُظهر قدرة النموذج على التعميم الجيد دون وجود مؤشرات على الإفراط في التوافق (Overfitting). وتشير هذه النتائج إلى أن النموذج قادر على ترتيب الحالات حسب الأهمية بشكل دقيق، مما يعزز من فعالية عمليات التحليل التنبؤي ودعم اتخاذ القرار.

٢/١/٥/٨: التنبؤ بالتدفقات النقدية التشغيلية (CFO):

يوضح الجدول رقم (٥) نتائج التنبؤ بالتدفقات النقدية التشغيلية، مع ترتيب الخوارزميات المستخدمة من الأعلى دقة تنبؤية إلى الأقل دقة تنبؤية.^١

^١ لم تتمكن خوارزمية شجرة التصنيف والانحدار (C&R Tree) من التنبؤ بالتدفقات النقدية التشغيلية، والذي قد يُعزى إلى طبيعة البيانات مثل العلاقات غير الخطية أو المعقدة بين المتغيرات، أو البيانات غير المستقرة، أو التقلبات الشديدة في البيانات.

جدول رقم (٥)
نتائج التنبؤ بالتدفقات النقدية التشغيلية

Table 5. Goodness-of-fit statistics for forecasting methods used to forecast CFO Testing (n = 69)

Algorithms used	No. of Predictors Used	Linear Correlation	Standard Deviation	Mean Absolute Error	Relative Error
Random Forests (RF)	10	0.893	3.057	0.745	0.892
Chi-squared Automatic Interaction Detector (CHAID)	4	0.616	3.580	0.805	0.902
Neural Network (NN)	14	0.225	3.752	0.829	0.994
Support Vector Machine (SVM)	15	0.122	3.788	0.878	1.019
Linear Support Vector Machine (LSVM)	15	0.049	4.374	1.157	1.027
K-Nearest Neighbors Algorithm (KNN)	15	-0.007	3.841	0.874	1.045

ويتضح من الجدول رقم (٥) أن خوارزمية الغابات العشوائية Random Forests (RF) قد أظهرت مرة أخرى تفوقاً واضحاً مقارنةً بباقي الخوارزميات عند التنبؤ بالتدفقات النقدية التشغيلية، حيث حققت أعلى ارتباط خطي بلغ ٨٩,٣%، وهو ارتباط قوي جداً إحصائياً. كما حققت أقل MAE (٠,٧٤٥)، MAPE (٨٩,٢٠%)، مما يدل على قدرة الخوارزمية على التنبؤ بالقيم النقدية المستقبلية بدقة ملحوظة. وبمثل ربحية السهم، تلي هذه الخوارزمية في القدرة التنبؤية هي خوارزمية مربع كاي للكشف التلقائي عن التفاعل CHAID، بفارق كبير نسبياً عن RF، حيث بلغ معامل الارتباط لها ٦١,٦٠%. أما باقي الخوارزميات فكان لها قدرة تنبؤية متواضعة جداً، مثل خوارزمية الشبكات العصبية NN بمعامل ارتباط ٢٢,٥٠%، وخوارزمية آلة متجهات الدعم SVM بمعامل ١٢,٢٠%.

وسجلت خوارزمية آلة متجهات الدعم الخطية LSVM، وخوارزمية الجار الأقرب KNN، للتنبؤ بربحية السهم أقل أداء من حيث جميع المؤشرات، حيث انخفض معامل الارتباط لهما بشدة، مع ارتفاع متوسط الخطأ والنسبة الخاصة به، مما يدل على ضعف القدرة التنبؤية لهما.

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

وبالمثل، بناءً على القدرة التنبؤية العالية التي أظهرتها خوارزمية الغابات العشوائية (Rf)، سيتم التركيز على استعراض الأشكال البيانية للقيم المتنبأ بها من هذه الخوارزمية باعتباره أفضل قيم متنبأ بها للتدفقات النقدية التشغيلية.




Figure 4. Predictor Importance & Scatter plot for EPS prediction




Figure 5. Actual and expected value path for CFO in Testing group (n = 69)

ومن القطاع A في الشكل رقم (٤) يتضح أن خوارزمية RF قد اعتمدت على عشر متغيرات مفسرة للتنبؤ بـ CFO، كان أكثرها أهمية أو مساهمة في التنبؤ هو حجم الشركة، يليه بفارق ضخم التدفقات النقدية التشغيلية في السنة السابقة، ثم القطاع النقل والشحن، وربحية الشركة، ثم قطاعات الموارد الأساسية، والاتصالات، والعقارات، والأغذية، والتشييد والبناء، وأخيراً الرعاية الصحية والأدوية على الترتيب. أما النتائج في القطاع B تؤكد أن خوارزمية الغابات العشوائية (RF) هي أداة قوية وموثوقة للتنبؤ بـ CFO، وأنها تقدم دقة عالية في محاكاة العلاقة بين المتغيرات. هذه النتائج تجعلها خياراً مثالياً للاعتماد عليها في التنبؤات المستقبلية، خصوصاً عندما تتطلب القرارات المالية تحليلاً دقيقاً وعالي الجودة.

ويؤكد ذلك الشكل رقم (٥) والذي يعكس دقة عالية في أداء خوارزمية الغابات العشوائية في التنبؤ بالقيم المستقبلية. بما أن القيم المتنبأ بها تطابق القيم الفعلية تقريباً، فهذا يشير إلى أداء متميز للنموذج وقدرته على تقديم تنبؤات موثوقة. هذا يعزز الثقة في استخدام الخوارزمية في التنبؤات المستقبلية.




Figure 6. Gain chart for CFO prediction

كما يُظهر مخطط الأرباح أعلاه زيادة حادة في الأرباح، وبالتحديد في أول ٥% من البيانات، مما يشير إلى فعالية النموذج في تحديد الحالات التي تتحقق فيها الفئة المستهدفة ($CFO > 12.745$). كما يوضح المخطط أن منحنى المكسب يصل إلى ١٠٠% من المكسب قبل الوصول إلى ١٠٠% من الحالات، مما يبرز القوة التمييزية العالية للنموذج. تشير هذه النتائج إلى أن النموذج قادر على ترتيب الحالات وفقاً لأهميتها بدقة، مما يعزز من فعالية التحليل التنبؤي ودعم اتخاذ القرار.

وبناءً على ما سبق تشير هذه النتائج إلى أن خوارزمية الغابات العشوائية (RF) وخوارزمية شجرة التصنيف والإنحدار الانحدارية (C&R Tree) وخوارزميات مربع كاي للكشف التلقائي عن التفاعل (CHAID) تتفوق على الخوارزميات الأخرى في التنبؤ بالمتغيرات المدروسة، وهو ما قد يُعزز قدرتها العالية على التعامل مع العلاقات غير الخطية والبيانات ذات التوزيع غير الطبيعي. كما يمكن ملاحظة أن النماذج القائمة على خوارزميات الجار الأقرب والانحدار الخطي تميل إلى الأداء الأضعف، في هذا السياق، ربما بسبب حساسيتها للضوضاء والبيانات المتطرفة، وهي خصائص شائعة في البيانات المالية.

٢/٥/٨: تقدير أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين:

في هذا الجزء من الدراسة، سنعرض نتائج المرحلة الثانية (أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على تعزيز ثقة المستثمرين) والخاصة باستخدام القيم المتنبأ بها من المرحلة الأولى (التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة) كمدخلات تفسيرية لقياس أثرها على ثقة المستثمرين. وبالتالي يهدف هذا التحليل إلى فهم كيف يمكن لخوارزميات تعلم الآلة مثل الغابات العشوائية (RF) والشبكات العصبية (NN) وأدوات أخرى أن تسهم في تحسين دقة التنبؤات للأرباح المستقبلية، وبالتالي تأثيرها على تعزيز ثقة المستثمرين. حيث تؤثر التوقعات الدقيقة للأرباح المستقبلية على رغبة المستثمرين في اتخاذ قرارات استثمارية مدروسة، ومن خلال استخدام خوارزميات تعلم الآلة، يمكننا تقدير العلاقة بين دقة التنبؤات للأرباح المستقبلية وتأثير ذلك على تعزيز ثقة المستثمرين، مما

يسهم في تعزيز فهمنا لكيفية تأثير التكنولوجيا الحديثة في تحسين الشفافية وتقليل المخاطر في الأسواق المالية.

وقبل التقدير يوضح الجدول رقم (٦) عرض للإحصاءات الوصفية لمتغيرات النموذج التي سيتم استخدامها في تحليل تأثير التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة على ثقة المستثمرين. وتشمل الإحصاءات الوصفية المتوسط الحسابي، الذي يعكس القيمة المركزية للبيانات، والانحراف المعياري، الذي يقيس تشتت البيانات حول المتوسط. بالإضافة إلى ذلك، سيتم عرض الحد الأدنى والحد الأقصى للقيم، مما يوفر فكرة عن نطاق البيانات، والوسيط الذي يمثل القيمة التي تقسم البيانات إلى نصفين متساويين. وتهدف هذه الإحصاءات إلى تقديم نظرة شاملة ومبسطة للبيانات، مما يساعد في فهم توزيع المتغيرات وتحديد الأنماط الأساسية.

جدول رقم (٦)

الإحصاءات الوصفية لمتغيرات الدراسة

Table 6. Descriptive summary statistics, 2020-2024 (n = 50)

	Obs.	Mean	Median	Std. Dev.	Min	Max
▪ Dependent variable:						
Investor Confidence (in million)	250	118.0	33.64	316.0	0.184	3640
Ln Investor Confidence	250	17.28	17.33	1.683	12.11	22.02
▪ Independent Variables:						
Actual EPS	250	1.008	0.340	2.292	-8.230	20.64
1. Predicted EPS using Rf	250	1.066	0.459	1.843	-2.701	11.95
2. Predicted EPS using CHAID	249	1.104	0.526	1.674	-3.127	4.854
3. Predicted EPS using SVM	250	0.694	0.405	0.955	-2.544	4.610
4. Predicted EPS using NN	250	0.969	0.425	1.340	-0.534	4.289
5. Predicted EPS using C&R Tree	250	0.908	0.325	1.386	0.325	5.283
6. Predicted EPS using LSVM	250	1.099	0.622	1.821	-4.093	12.11
7. Predicted EPS using KNN	250	1.001	0.413	1.481	-0.630	6.408
Actual CFO	250	0.321	0.032	2.196	-1.010	26.50
1. Predicted CFO using Rf	250	0.224	0.036	0.635	-0.261	4.858
2. Predicted CFO using CHAID	248	0.176	0.015	0.369	0.015	1.562
3. Predicted CFO using NN	250	0.340	0.315	0.103	-0.039	0.816
4. Predicted CFO using SVM	250	0.071	0.062	0.186	-0.601	1.657

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

5. Predicted CFO using LSVM	250	0.213	0.054	1.483	-1.497	19.13
6. Predicted CFO using KNN	250	0.095	0.042	0.345	-0.151	3.716
▪ Control Variables:						
Firm Size	250	21.79	21.75	1.508	17.02	27.60
Leverage	250	0.687	0.528	1.126	0.003	9.970
PROF	250	0.132	0.056	0.459	-1.015	5.209

ويتضح من الجدول (٦) أن حجم التداول على شركات العينة يتراوح ما بين (١٨٤,٠ - ٣٦٤٠ مليون) بمتوسط عام مرتفع نسبياً يعادل ١١٨ مليون، ولكن مع تشتت كبير (الانحراف المعياري: ٣١٦)، مما يشير إلى تباين قوي في سلوك المستثمرين. كما نلاحظ أن التنبؤات باستخدام RT، CHAID أعطت قيماً أقرب للمتوسط الفعلي مقارنة بخوارزميات مثل SVM أو KNN، ما يعكس جودة توقعاتها. كما يتضح وجود تباين كبير بين الحد الأدنى والأقصى لعينة الشركات بالنسبة لكافة متغيرات الدراسة. هذا التباين قد يبدو طبيعياً نتيجة للاختلافات في هياكل الشركات وخصائصها وخبراتها وظروفها الداخلية والخارجية التي تواجهها والقطاعات التي تنتمي إليها. وأخيراً، بالنسبة للمتغيرات الضابطة، فيتضح أن عينة الدراسة ثرية بسيطرتها على العديد من الخصائص والاختلافات بين الشركات والتي تظهر من المتغيرات الضابطة.

ولتقدير نموذج الدراسة سيتم الاعتماد على نموذج الآثار الثابتة (FEM) (Fixed Effects Model) بناءً على نتائج اختبار (Hausman)، والذي أثبت أن نموذج الآثار الثابتة أفضل لبيانات وعينة الدراسة من نموذج الآثار العشوائية. حيث تأخذ هذه الطريقة في اعتبارها مشكلة الاختلافات أو التأثيرات الفردية لكل شركة عند التحليل، ويتم ذلك عن طريق إضافة متغيرات وهمية لكل شركة. وهنا يعرض الجدول رقم (٧) نتائج التقدير من خلال سبعة أعمدة، يضم كل عمود انحدار مستقل بذاته مرتبط بطريقة من طرق التنبؤ. فعلى سبيل المثال، تم استخدام متغير EPS، CFO المتنبأ بهم بخوارزمية الغابات العشوائية (RF) في الانحدار الأول (Reg(1)، وتم استخدام نفس المتغيرين ولكن المتنبأ بهما باستخدام خوارزمية مربع كاي للكشف التلقائي عن التفاعل (CHAID) في الانحدار الثاني (Reg(2)، وهكذا حتي نصل للانحدار السابع والأخير والذي يضم متغير EPS المتنبأ به بخوارزمية شجرة التصنيف والانحدار (C&R F).

جدول رقم (٧)
نتائج تقدير نموذج الدراسة

Table 7. Predicting future profits using Machine Learning Algorithms and investor confidence: Econometrics results

Dependent variables: Investor Confidence (ln Trading Volume)

Method: 1-way fixed effects model (with white diagonal robust standard error)

	Reg (1)	Reg (2)	Reg (3)	Reg (4)	Reg (5)	Reg (6)	Reg (7)
	Predicted using Rf	Predicted using CHAID	Predicted using SVM	Predicted using NN	Predicted using LSVM	Predicted using KNN	Predicted using C&RF
Predicted EPS	0.0878 [2.991]***	0.0313 [1.326]	0.0949 [1.906]*	0.0604 [1.611]	0.0536 [1.759]*	0.0147 [0.365]	-0.0099 [-0.507]
Predicted CFO	-0.4135 [-2.486]**	-0.2716 [-1.072]	-0.1516 [-0.284]	0.5026 [1.931]*	-0.0135 [-0.346]	0.1108 [0.635]*	
Predicted CFO square	0.1141 [3.414]***						
Firm Size	0.2122 [5.435]***	0.2154 [5.243]***	0.2021 [4.168]***	0.1911 [3.835]***	0.2057 [4.499]***	0.2012 [4.839]***	0.2315 [6.027]***
Leverage	0.1039 [4.558]***	0.1069 [3.826]***	0.1015 [3.496]***	0.0762 [2.436]**	0.1037 [3.631]***	0.0958 [4.537]***	0.1076 [5.399]***
Firm Profitability	0.1022 [1.968]*	0.0993 [1.768]*	0.0836 [0.682]	0.0243 [0.356]	-0.0345 [-0.319]	0.0882 [1.670]*	0.1156 [2.203]**
Constant	12.521 [14.67]***	12.511 [13.83]***	12.742 [12.12]***	12.832 [11.97]***	12.678 [12.67]***	12.795 [14.03]***	12.795 [12.16]***
Key Regression statistics							
R-squared	95.04%	94.9%	95.4%	95.5%	95.4%	95.2%	95.3%
Adjusted R-squared	93.6%	93.5%	94.1%	94.2%	94.1%	93.9%	94.02%
DW stats.	1.9408	1.9801	1.9479	1.9674	1.9466	1.9296	1.9186
Fisher test (F-stats.)	67.521***	66.455***	74.409***	76.119***	74.599***	72.026***	74.842***
Practical significance (Effect Size): Cohen's d							
Predicted EPS	0.4306 (Intermediate)	0.1904 (No Effect)	0.1356 (No Effect)	0.2314 (Small Effect)	0.2526 (Small Effect)	0.0525 (No Effect)	-0.0726 (No Effect)
Predicted CFO	0.4915 (Intermediate)	-0.1539 (No Effect)	-0.0204 (No Effect)	0.2773 (Small Effect)	-0.0497 (No Effect)	0.0911 (No Effect)	

Note: - ***, **, * indicate significance at 1%, 5% and 10% respectively. - t-Statistic in parentheses.

يتضح من نتائج الجدول رقم (٧) العديد من النتائج المثيرة للاهتمام، والتي يمكن سردها فيما يلي:

من خلال الانحدار الأول Reg(1) يتضح وجود تأثير إيجابي للقيم المتنبأ بها لربحية السهم باستخدام خوارزمية الغابات العشوائية (Rf) على ثقة المستثمرين عند مستوى دلالة ١ %، كما أوضحت نتائج هذا الانحدار أيضاً وجود علاقة غير خطية

بين القيم المتنبأ بها للتدفقات النقدية التشغيلية باستخدام خوارزمية (Rf) على ثقة المستثمرين، كما أن هذه العلاقة تأخذ شكل حرف U، بمعنى أن التدفقات النقدية المنخفضة ستؤثر سلباً على ثقة المستثمرين، ولكن هذا التأثير يتحول إلى إيجابي عند صافي التدفقات النقدية المرتفعة والتي تعزز من ثقة المستثمرين. وبالتالي يُدعم الانحدار الأول أن التنبؤ بالأرباح المستقبلية باستخدام خوارزمية الغابات العشوائية (Rf) سيعزز من ثقة المستثمرين.

وفي المقابل، لم يكن للقيم المتنبأ بها لربحية السهم، والتدفقات النقدية التشغيلية باستخدام باقي خوارزميات تعلم الآلة المستخدمة على ثقة المستثمرين (في أفضل الأحوال كان هناك تأثير إيجابي ضعيف جداً عند مستوى دلالة ١٠% لأحد المتغيرين المتنبأ بهما على ثقة المستثمرين، بينما لم يكن هناك تأثير للمتغير الآخر). وبالتالي تدعم تلك الانحدارات أن التنبؤ بالأرباح المستقبلية باستخدام أي خوارزمية أخرى بخلاف الغابات العشوائية (RF) لا تؤثر على ثقة المستثمرين.

وقد يرجع ذلك لتفوق خوارزمية الغابات العشوائية في التنبؤ بربحية السهم المستقبلية (EPS) والتدفقات النقدية التشغيلية المتوقعة (CFO) مقارنة بالخوارزميات الأخرى. هذا يشير لأن دقة التنبؤ بالأرباح المستقبلية والتدفقات النقدية التشغيلية المتوقعة باستخدام خوارزمية الغابات العشوائية تُعد مؤشرات مهمة وموثوقة للمستثمرين عند اتخاذ قراراتهم الاستثمارية. فتقة المستثمرين تتأثر عادةً بالشفافية والدقة في التنبؤات المتعلقة بالأرباح المستقبلية للشركات. وبالتالي، عندما تكون التنبؤات دقيقة، تزيد الثقة في السوق، مما يدفع المستثمرين إلى اتخاذ قرارات استثمارية قائمة على هذه المعلومات الدقيقة.

فعندما يتمكن النموذج التنبؤي من تقديم نتائج دقيقة وقابلة للتطبيق في تحديد ربحية السهم والتدفقات النقدية التشغيلية، يعكس ذلك صورة مصداقية وقوة للأدوات التحليلية المستخدمة. مما يؤدي إلى تأثير إيجابي على ثقة المستثمرين في التنبؤات المالية المتعلقة بالشركات. وهذا يعني أن دقة التنبؤ باستخدام الغابات العشوائية لا تقتصر فقط على معرفة ربحية السهم والتدفقات النقدية التشغيلية المتوقعة، بل تمتد لتؤثر بشكل مباشر في قرارات المستثمرين، الذين يصبحون أكثر ثقة في استراتيجياتهم الاستثمارية بناءً على هذه التنبؤات.

أما الخوارزميات الأخرى التي لم تظهر نفس التأثير قد تكون أقل دقة أو قدرة على التكيف مع الأنماط المعقدة في البيانات، مما قد يؤدي إلى نتائج أقل موثوقية. على سبيل المثال، خوارزميات مثل (SVM) أو (KNN) قد تكون أكثر عرضة للانحراف أو حساسة لوجود بعض القيم الشاذة في البيانات، مما يضعف قدرتها على التنبؤ بدقة في السياقات المالية المعقدة. ومن جهة أخرى، الغابات العشوائية التي تعتمد على تجميع النماذج الفرعية، تعزز من قدرتها على التعامل مع المتغيرات غير الخطية والتفاعلات المعقدة، مما يؤدي إلى دقة أكبر في التنبؤ، وبالتالي إلى تحقيق ثقة أكبر من المستثمرين.

وبالنسبة للمتغيرات الضابطة فنجد تأثير إيجابي لحجم الشركة والرافعة المالية على ثقة المستثمرين في كافة الانحدارات، مما يؤكد قوة ومتانة نتائج هذين المتغيرين. أما بالنسبة لربحية الشركة فكانت نتائجها غير قوية، حيث كان لها تأثير إيجابي على ثقة المستثمرين في أربع انحدارات بينما لم يكن لها أي تأثير في ثلاث انحدارات أخرى. ومن الإحصاءات العامة، يتضح من قيمة معامل التحديد المعدل (R^2 Adjusted) أن المتغيرات المستقلة تُفسر ما بين ٩٣,٥٠% - ٩٤,٢٠% من تباين ثقة المستثمرين، أما باقي النسبة فترجع إلى الخطأ العشوائي نتيجة لوجود متغيرات أخرى لم يتم السيطرة عليها داخل النموذج. كما أن قيمة إحصائية دربن واتسون لتعادل ٢ تقريباً مما يشير لعدم تعرض النموذج لمشكلة الازدواج الخطي من الدرجة الأولى، كما يشير اختبار فيشر (Fisher) إلى رفض الفرض العدم وقبول الفرض البديل بوجود دلالة إحصائية لانحدارات الدراسة ككل عند مستوى دلالة ١%.

ونظراً لأن الأهمية الإحصائية هي أقل الأشياء إثارة للاهتمام حول النتائج، فالدلالة الإحصائية p ليست كافية لأنها تُخبرنا فقط بوجود علاقة أقوى بين متغيرين (رفض الفرضية الصفرية)، أي تُخبر القارئ ببساطة أنه من غير المحتمل أن تكون العلاقة الموجودة بين المتغيرات ناتجة عن الصدفة البحتة. وبالتالي سيتم الاعتماد على حجم الأثر والذي يوفر مقياساً كمياً لحجم الارتباط بين المتغيرات. وبالتالي يوفر تقييماً لقوة النتائج التي لا توفرها الاختبارات ذات الدلالة الإحصائية وحدها، أي

بمعنى آخر يوضح حجم الدلالة العملية للعلاقة في الواقع الفعلي. وعلنه فحجم الأثر يجلب لنا معلومات إضافية للقرار الاستنتاجي لقبول أو رفض فرضية العدم.^٢

ويتم حساب حجم الأثر هنا من الارتباطات الجزئية بين القيم المتنبأ بها لربحية السهم والتدفقات النقدية التشغيلية وبين ثقة المستثمرين. والتي تقيس علاقة الارتباط بين المتغير التابع والمستقل مع السيطرة على باقي المتغيرات الأخرى بالنموذج (بافتراض أنها تؤثر أيضاً على المتغير التابع). ويتضح من إحصائية Cohen (1988) أسفل الجدول (٤) أن القيم المتنبأ بها لربحية السهم والتدفقات النقدية التشغيلية باستخدام خوارزمية الغابات العشوائية (RF) في الانحدار الأول، كان لها حجم أثر متوسط على ثقة المستثمرين. بينما كان للقيم المتنبأ بها باستخدام خوارزمية الشبكات العصبية (NN) في الانحدار الرابع حجم أثر صغير. وفي المقابل، لم يكن للقيم المتنبأ بها لـ EPS، CFO باستخدام باقي الخوارزميات أي حجم أثر على ثقة المستثمرين.

وهذا يتضمن وجود أهمية متوسطة في الواقع العملي للتنبؤ بالأرباح المستقبلية باستخدام خوارزمية الغابات العشوائية (Rf) في تعزيز ثقة المستثمرين، وهذا يعطي دعم قوي لتطوير النظرية، وبناء سياسات لتعزيز ثقة المستثمرين من خلال التنبؤ بالأرباح المستقبلية من خلال خوارزمية الغابات العشوائية (RF).

وبناءً على ما سبق، تشير تلك النتائج إلى أن استخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية قد يحدث فرقاً ملحوظاً في تعزيز ثقة المستثمرين، خصوصاً عند استخدام خوارزمية الغابات العشوائية Random Forests. والتي تُعد الأكثر فعالية ودقة وموثوقية في التنبؤ بالأرباح المستقبلية، وأن هذه التنبؤات الدقيقة تساهم في تعزيز ثقة المستثمرين.

إزاء مما سبق يتضح أن تلك النتائج تدعم الفرض الفرعي الأول في الدراسة الحالية بوجود أثر إيجابي ذو دلالة إحصائية للتنبؤ بربحية السهم باستخدام

^٢ هناك مناقشة واسعة تحت اسم (NHTS) Null Hypothesis Significance Testing. لذلك أوصت الجمعية الأمريكية لعلم النفس (APA) في الفصل 1.01 تصميم وإعداد التقارير البحثية؛ أن تشمل جميع التقارير الإحصائية المنشورة حجم الأثر أيضاً (قسم دليل الإصدار الخامس APA (2002).

خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين . لذا، يمكن قبوله. كما تدعم تلك النتائج الفرض الفرعي الثاني في الدراسة الحالية بوجود أثر إيجابي ذو دلالة احصائية للتنبؤ بالتدفقات النقدية التشغيلية باستخدام خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين. لذا، يمكن قبوله. وبالتالي تدعم نتائج الدراسة فرض الدراسة الرئيس بوجود أثر إيجابي ذو دلالة احصائية للتنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كأحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين. لذا، يمكن قبوله.

٩- الخلاصة والنتائج والتوصيات ومجالات البحث المستقبلية:

١/٩: الخلاصة والنتائج:

تعد مصر هي الدولة الرائدة في منطقة الشرق الأوسط في مجال الذكاء الاصطناعي، حيث احتلت المركز الخامس عشر على مستوى العالم من حيث خدمات الاتصالات وأنظمة الذكاء الاصطناعي وذلك وفقاً لمؤشر جلوبال سيرفيسيز لوكيشن (Location Index (Global Services لعام ٢٠٢١ الخاص بمؤسسة (Kearney) كما يعتبر قطاع الاتصالات وتكنولوجيا المعلومات في مصر أحد الوجهات الرائدة في العالم في تقنيات الذكاء الاصطناعي.

وتعتبر خوارزميات تعلم الآلة فرعاً من الذكاء الاصطناعي، فهي برامج حسابية قادرة على التعلم من البيانات التاريخية بشكل تلقائي، واكتشاف الأنماط والاتجاهات دون الحاجة إلى برمجة محددة من قبل الإنسان. كما أن هذه العملية تتضمن تحليل البيانات باستخدام تقنيات مختلفة لاستخلاص الأنماط الضمنية، ثم تطبيق هذه الأنماط لتوليد تنبؤات حول المستقبل، وتتمثل أبرز خوارزميات تعلم الآلة: خوارزمية مربع كاي للكشف التلقائي عن التفاعل (Chi-squared Automatic Interaction Detector)، خوارزمية شجرة التصنيف والانحدار (Classification and Regression Tree) وهما فرع من فروع خوارزمية شجرة القرارات (Decision tree)، خوارزمية الأقرب جار (K-Nearest Neighbors)، خوارزمية آلة دعم المتجهات (Support Vector Machine)، خوارزمية آلة دعم الخطية (Linear Support)،

خوارزمية الشبكات العصبية (Neural Networks)، وخوارزمية الغابات العشوائية (Random Forests).

واستهدفت الدراسة قياس أثر التنبؤ بالأرباح المستقبلية (التنبؤ بربحية السهم، التنبؤ بالتدفقات النقدية التشغيلية) باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين، وأجريت الدراسة على عينة من الشركات غير المالية المساهمة المصرية التي تدرج تحت مؤشر EGX100 قوامها ٥٠ شركة تنتمي لقطاعات اقتصادية مختلفة، وذلك خلال الفترة الممتدة من عام ٢٠١٩م حتى عام ٢٠٢٤م.

وبناء على ما تم عرضه في الإطار النظري للدراسة، وما استنتجه الباحثين من التحليل الإحصائي للدراسة، يمكن عرض أهم النتائج على النحو التالي:

- أن خوارزمية الغابات العشوائية (RF) وخوارزمية شجرة التصنيف والانحدار (C&R Tree) وخوارزميات مربع كاي للكشف التلقائي عن التفاعل (CHAID) تتفوق على الخوارزميات الأخرى في التنبؤ بالمتغيرات المدروسة، وهو ما قد يُعزز قدرتها العالية على التعامل مع العلاقات غير الخطية والبيانات ذات التوزيع غير الطبيعي. كما يمكن ملاحظة أن النماذج القائمة على خوارزميات الجار الأقرب والانحدار الخطي تميل إلى الأداء الأضعف.
- أن استخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي في التنبؤ بالأرباح المستقبلية قد يُحدث فرقاً ملحوظاً في تعزيز ثقة المستثمرين، خصوصاً عند استخدام خوارزمية الغابات العشوائية (Random Forests). والتي تُعد الأكثر دقة وموثوقية في التنبؤ بالأرباح المستقبلية، وأن هذه التنبؤات الدقيقة تساهم في تعزيز ثقة المستثمرين.
- وجود أثر إيجابي ذو دلالة إحصائية للتنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين.

٢/٩: التوصيات:

- في ضوء ما توصلت إليه الدراسة من نتائج، يمكن تقديم التوصيات التالية:
- تشجيع استخدام تقنيات الذكاء الاصطناعي، وبالأخص خوارزميات تعلم الآلة، في تحليل البيانات المحاسبية والمالية، لما لها من قدرة عالية على التنبؤ بدقة وتحسين جودة القرارات الاستثمارية.
 - تعزيز البنية التحتية الرقمية وتحسين جودة البيانات في الشركات المصرية، بما يسمح بتطبيق فعال لخوارزميات تعلم الآلة، ويسهم في زيادة موثوقية المخرجات التحليلية.
 - توسيع نطاق استخدام خوارزمية الغابات العشوائية (Random Forests) في التنبؤ بالمؤشرات المالية المستقبلية، نظراً لما أثبتته الدراسة من تفوقها من حيث الدقة والموثوقية مقارنة بالخوارزميات الأخرى.
 - توفير برامج تدريبية للعاملين في مجالات المحاسبة والمالية لرفع كفاءتهم في التعامل مع أدوات الذكاء الاصطناعي، بما يسهم في دمج هذه التقنيات الحديثة ضمن ممارسات العمل المحاسبي والمالي اليومية.
 - تشجيع الهيئات الرقابية والبورصات على تبني سياسات تنظيمية تدعم استخدام الذكاء الاصطناعي، خاصة في مجالات الإفصاح المالي والتنبؤ بالأداء، وذلك لضمان زيادة الشفافية وتعزيز ثقة المستثمرين.
 - التكامل بين خبراء المحاسبة وتحليل البيانات داخل المؤسسات، من خلال فرق عمل مشتركة تدمج الخبرة المالية مع المهارات التقنية، لتعزيز الاستفادة من أدوات الذكاء الاصطناعي في دعم عملية اتخاذ القرار.

٣/٩: مجالات البحث المستقبلية:

- في ضوء ما توصلت إليه الدراسة من نتائج، يقترح الباحثين العديد من المجالات التي يمكن أن تشكل أساساً لبحوث ودراسات مستقبلية، لعل من أهمها:
- تحليل مدى تأثير شفافية خوارزميات تعلم الآلة على ثقة المستثمرين في التنبؤات المحاسبية.

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

- استخدام خوارزميات تعلم الآلة في التنبؤ بتقلبات الأرباح المستقبلية ودورها في الحد من سلوكيات المخاطرة لدى المستثمرين.
- قياس فعالية النماذج التنبؤية المبنية على الذكاء الاصطناعي في بيئات عدم التأكد ودورها في تعزيز ثقة المستثمرين.
- مقارنة بين تأثير التنبؤ بالأرباح باستخدام خوارزميات تعلم الآلة والتنبؤ التقليدي على تقييم الشركات من قبل المستثمرين.
- قياس أثر توقيت إعلان التنبؤات المدعومة بتقنيات تعلم الآلة على استجابة السوق وثقة المستثمرين.
- قياس فاعلية نماذج تعلم الآلة في التنبؤ بتراجع الأرباح (Profit Decline) ومدى تأثير ذلك على سلوك المستثمر في بيع أو الاحتفاظ بالأسهم.
- قياس أثر إدخال عناصر المخاطر غير المالية (مثل السمعة، الأزمات، التغير المناخي) ضمن نماذج التنبؤ بالأرباح باستخدام خوارزميات تعلم الآلة.
- قياس فعالية النماذج التنبؤية المبنية على الذكاء الاصطناعي في بيئات عدم التأكد ودورها في تعزيز ثقة المستثمرين.

١٠- مراجع الدراسة:

١/١٠: المراجع باللغة العربية:

- اسماعيل، عصام عبد المنعم. (٢٠١٧). مقدرة التدفقات النقدية التشغيلية والربح المحاسبي في التنبؤ بالتدفقات النقدية التشغيلية المستقبلية : دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية، **مجلة كلية التجارة للبحوث العلمية**، جامعة الاسكندرية، كلية التجارة، ٥٤ (١) : ٣١-١.
- القاضي، كريم محمد حافظ. (٢٠٢٣). أثر تطبيق تقنيات نظم الذكاء الاصطناعي على شفافية التقارير المالية في ضوء الإصدارات المهنية المعاصرة : دراسة تطبيقية، **المجلة العلمية للدراسات والبحوث المالية والتجارية**، جامعة دمياط، كلية التجارة، ٤ (٢) : ١٠٠٧-١٠٤٦.
- الساعدي، علاء عبدالحسين صالح و الغزي، سعود سعد. (٢٠١٧). التنبؤ بالأرباح المستقبلية باستخدام الأرقام التاريخية للأرباح والتدفقات النقدية، **مجلة دراسات إدارية**، جامعة البصرة، كلية الإدارة والاقتصاد، ٩ (١٨) : ٢٩٣-٣٤٤.
- المر، نرمين علي محمد. (٢٠٢٢). قياس تأثير دقة تنبؤات المحللين بالأرباح على قرارات المستثمرين في ضوء المعايير المرتبطة، **المجلة العلمية للدراسات المحاسبية**، جامعة قناة السويس، كلية التجارة، ٤ (١) : ٤٤٧-٥١٤.
- الناصر، زهرة. (٢٠٢٢). أثر تطوير لوائح وسياسات حوكمة الشركات على ثقة المستثمرين في الشركات المدرجة في سوق الأسهم السعودي (تداول)، **الدراسات والأبحاث - هيئة السوق السعودي**، جامعة دار العلوم، ١-٤٩.
- أميرهم، جيهان عادل. (٢٠٢٢). أثر استخدام تطبيقات الذكاء الاصطناعي على مستقبل مهنة المحاسبة والمراجعة (دراسة ميدانية)، **مجلة البحوث المالية والتجارية**، جامعة بور سعيد، كلية التجارة، ٢٣ (٢) : ٢٤٤-٢٩٤.
- جمال، قدام و بودرمين، سارة. (٢٠١٧). أثر حوكمة الشركات على ربحية السهم دراسة قياسية على عينة من المؤسسات الفرنسية المدرجة في مؤشر CAC40، **مجلة الأصيل للبحوث الاقتصادية والإدارية**، جامعة جيجل، الجزائر، ٨ (٢) : ٢٠٤-٢٢٣.
- حجازي، حكيم محمد أيمن. (٢٠٢٣). القدرة التنبؤية لنماذج التنبؤ بالأرباح : دراسة اختبارية، **مجلة البحوث التجارية**، جامعة الزقازيق، كلية التجارة، ٤٥ (١) : ١١٠-١٤٤.
- حسن، محمود السيد محمود علي. (٢٠٢٥). دور أليات الذكاء الاصطناعي عند التنبؤ بالأرباح، **مجلة البحوث المالية والتجارية**، جامعة بور سعيد، كلية التجارة، ٢٦ (١) : ٦٧١-٦٩١.
- خالد، حسن عوض حسن و بريمة، علي بونس. (٢٠٢٢). القيمة التنبؤية للمعلومات المحاسبية ودورها في ترشيد القرارات الاستثمارية – دراسة ميدانية على بنك فيصل الإسلامي السوداني، **المجلة العربية للعلوم الإنسانية والاجتماعية**، مركز سنبل للأبحاث والدراسات، عمان – الأردن، ١١ (١) : ٣٧-١.
- زباله، رواء صبرى. (٢٠٢٣). تأثير الذكاء الاصطناعي في جودة التدقيق وانعكاسه على قرارات المستثمرين، **رسالة ماجستير**، جامعة كربلاء، كلية الادارة والاقتصاد، قسم المحاسبة، العراق، ٢٣ (٢) : ١٥٦-١.

أثر التنبؤ بالأرباح المستقبلية باستخدام خوارزميات تعلم الآلة كإحدى تقنيات الذكاء الاصطناعي على تعزيز ثقة المستثمرين - دراسة تطبيقية

سعد الدين، إيمان محمد. (٢٠١٤). إطار مقترح للمعلومات المالية المستقبلية واختباره من منظور المستثمرين في سوق الأوراق المالية : دراسة ميدانية، **مجلة التجارة والتمويل**، كلية التجارة، جامعة طنطا، ٣٤ (١) : ٢٢٧-٣٢٤.

عبدالقادر، مها محي الدين. (٢٠١٩). أثر التكامل بين نظم الخبرة والشبكات العصبية على تحسين كفاءة وفعالية المراجعة الخارجية - دراسة ميدانية، **رسالة ماجستير غير منشورة**، جامعة المنصورة، كلية التجارة، ٣.

عبدالمقصود، نيفين صبحي عبدالمجيد. (٢٠٢٢). دور خصائص مجلس الإدارة والرافعة المالية وسياسة توزيع الأرباح على قيمة الشركة باستخدام إعادة بيان القوائم المالية كمتغير وسيط، **مجلة المحاسبة والمراجعة لاتحاد الجامعات العربية**، كلية التجارة، جامعة بني سويف، ١١ (٢) : ١-٤٩.

عفيفي، هلال عبدالفتاح. (٢٠١٧). خصائص القوائم المالية المعدلة في الشركات المساهمة المصرية : دراسة اختبارية، **مجلة البحوث التجارية**، كلية التجارة، جامعة الزقازيق، ٣٩ (٢) : ٢٣٠-٢٩٧.

عويس، شادي أحمد ذكي. (٢٠٢٤). تقنيات الذكاء الاصطناعي ودورها في التنبؤ بالأرباح المستقبلية بالتطبيق على الشركات المقيدة بالبورصة المصرية، **المجلة العلمية للدراسات التجارية والبيئية**، جامعة قناة السويس، كلية التجارة، ١٥ (٤) : ٢٦٨-٣٢١.

متولي، سعاد السيد محمد. (٢٠٢٢). استخدام معلومات التقارير المالية في نماذج تعلم الآلة للتنبؤ بالأداء المالي للشركات المقيدة في البورصة المصرية - دراسة اختبارية، **مجلة البحوث المالية والتجارية**، جامعة بورسعيد، كلية التجارة، ٢٣ (٤) : ٤٦٥-٥٢١.

محمد، أحمد صلاح سيد. (٢٠٢٣). دور تقنية آلة متجه الدعم "SVM" كإحدى تقنيات الذكاء الاصطناعي في تحسين جودة التقارير المالية : دراسة تطبيقية، **مجلة الفكر المحاسبي**، جامعة عين شمس، كلية التجارة، ٢٧ (١) : ١٤٩-١٧٧.

محمد، حسناء عطية حامد. (٢٠٢٤). الدور المعدل المحللين الماليين للعلاقة بين إعادة إصدار القوائم المالية وثقة المستثمرين : دراسة تطبيقية على الشركات المدرجة بالسوق المالي السعودي، **المجلة العلمية للبحوث التجارية**، جامعة المنوفية، كلية التجارة، ٥٤ (٣) : ٢٤٧-٣٠٠.

محمود، حسن توفيق. (٢٠١٣). التنبؤ بربحية السهم العادي (EPS) من خلال الأرباح والتدفقات النقدية للشركات الصناعية، **مجلة الاقتصاد والتنمية البشرية**، ٨ : ٧-٢٤.

موسى، عبدالله و بلال، أحمد حبيب. (٢٠١٩). الذكاء الاصطناعي ثورة في تقنيات العصر، **المجموعة العربية للتدريب والنشر**، الطبعة الأولى، القاهرة، ١-٣٣٠.

٢/١٠: المراجع باللغة الإنجليزية:

- Alanazi, B. (2025). A Comparative Study of Traditional Statistical Methods and Machine Learning Techniques for Improved Predictive Models. **International Journal of Analysis and Applications**, 23(18): 1-18.
- Altarazi, F. and Santos, D. (2024). Profit Prediction Using Machine Learning and Regression Models: A Comparative Study, **IEOM Society International, And USA**, 4(6): 1-13.
- Aly, G., Elguoshy, R. and Metwaly, Z. (2023). Machine Learning Algorithms and Auditor's Assessments of the Risks Material Misstatement: Evidence from the Restatement of Listed London Companies, **Information Sciences Letters an international jornal**, 14(4): 1285-1298.
- Amos, B. and Rimona P. (2019). Earning Movement Prediction Using Machine Learning-Support Vector Machines (SVM), **Journal of Management Information and Decision Sciences**, 22(2): 36-53.
- Ateya, S. (2024). The Impact of Machine Learning Algorithms on Improving the Predictive Ability of Accounting Information as Business Partners: An Empirical Evidence from Egyptian listed firms, **Journal of Accounting Research**, 11(3): 97-146.
- Bustos, O. and Pomares, A. (2020). Stock Market Movement Forecast: A Systematic Review, **Expert Systems with Applications**, 156: 113-464.
- Cai, Z. and Chen, P. (2024). Online Investor Sentiment via Machine Learning, **journal of Mathematics MDPI**, 12(20): 1-14.
- Chan, S., Chu, M., and So, K. (2023). A moving-window bayesian network model for assessing systemic risk in financial markets, **PloS one**, 18(1): 1-24.
- Chang, H., Ishida, S., and Kochiyama, T. (2024). Management Forecasting Ability and Predictive Ability of Dividend Changes for Future Earnings, **Journal of Accounting, Auditing & Finance**, 39(1): 304-331.
- Chen, M. and Zhang, Z. (2020). A Hybrid Model for Financial Fraud Detection Using Random Forest and Neural Networks, **Journal of Financial Crime**, 27(1): 68-85.
- Chen, X., Cho, Y., Dou, Y. and Lev, B. (2022). Predicting Future Earnings Changes Using Machine Learning and Detailed Financial Data, **Journal of Accounting Research**, 60(2): 467-515.

- Chordia, T., Goyal, A., and Shanken, J. A. (2017). Cross-sectional asset pricing with individual stocks: betas versus characteristics, Available at SSRN: <https://ssrn.com/abstract=2549578>, pp. 1-61.
- Dallu, A. M. (2018), Artificial intelligence and the future of internal audit, **Journal of kasneb newslne**, 2: 1-5.
- Demirel, U., Cam, H. and Unlu, R. (2021). Predicting Stock Prices Using Machine Learning Methods and Deep Learning Algorithms: The Sample of the Istanbul Stock Exchange, **Journal of Science - Gazi University**, 34(1): 63-82.
- Ding, K., Lev, B., Peng, X., Sun, T., and Vasarhelyi, A. (2020). Machine learning improves accounting estimates: Evidence from insurance payments, **Review of Accounting Studies**, 25(3): 1134-1198.
- Dixon, F., Halperin, I. and Bilokon, P. (2020). Machine Learning in Finance from theory to practice, **Springer International Publishing**, 1-565.
- Eachempati, P., Srivastava, P. R., Kumar, A., Tan, K. H. and Gupta, S. (2021). Validating the impact of accounting disclosures on stock market: A deep neural network approach, **Technological Forecasting and Social Change**, 170: 1-47.
- Fieberg, C., Metko, D., Poddig, T. and Loy, T. (2023). Machine learning techniques for cross-sectional equity returns' prediction, **OR Spectrum**, 45(1): 289-323.
- Gogas, P. and Papadimitriou, T. (2021). Machine Learning in Economics and Finance, **Computational Economics**, 57: 1-4.
- Gokoglan, K. and Sevim, H. (2024). The impact of artificial intelligence recommendations on individual investor decisions, **Journal of Business, Economics and Finance**, 13(1): 1-12.
- Gordon, L. (2021). The Role of Data Analytics and Machine Learning in Resurrecting Inductive-Based Accounting Research, **Transactions on Engineering and Computing Sciences**, 2(9): 1-18.
- Gupta, R., Nel, J. and Pierdzioch, C. (2021). Investor Confidence and Forecastability of US Stock Market Realized Volatility: Evidence from Machine Learning, **Journal of Behavioral Finance**, 24(1): 111-122.
- Ham, H. (2024). Topics in Financial Forecasting Through Machine Learning, **A Dissertation Submitted to the Graduate Faculty of the University of Georgia in Partial Fulfillment of the Requirements for the Degree- Doctor of Philosophy**, Athens, Georgia, 7-41

- Hoang, D. and Wiegratz, K. (2022). Machine learning Methods in Finance: Recent Applications and Prospects, **European Financial Management**, Wiley Online Library, 1-45.
- Huang, A. and You, H. (2022). Artificial Intelligence in Financial Decision Making, **Handbook of Financial Decision Making**, Forthcoming, 1-32.
- Huang, F., No, G., Vasarhelyi, A. and Yan, Z. (2022). Audit data analytics, machine learning, and full population testing, **Journal of Finance and Data Science**, 8: 138-144.
- Hunt, J., Myers, J. and Myers, L. (2019). Improving Earnings Predictions with Machine Learning, **journal of Computer Science, Business, Economics**, 1-41.
- ICAEW. (2023). Artificial intelligence and the future of accounting, **Institute of Chartered Accountants in England and Wales**, available at: <https://www.icaew.com/technical/technology/artificial-intelligence/artificial-intelligence-the-future-of-accountancy>.
- Kamble, R. and Shah, D. (2018). Application of artificial intelligence in human life, **International Journal of Research-Granthaalayah**, 6(6): 178-188.
- Kara, A. (2023). A Machine Learning Approach to Financial Forecasting: A Case Study, **the Eurasia Proceedings of Educational & Social Sciences**, 32: 8-12.
- Khan, A. (2024). Machine Learning for Financial Forecasting, **International Journal of Advanced Engineering Technologies and Innovations**, 1(2): 31-58.
- Khan, H. and Upadhayaya, S. (2020). Does business confidence matter for investment?, **Journal of Empirical Economics**, 59: 1633-1665.
- Khoa, T. and Huynh, T. (2021). Is it possible to earn abnormal return in an inefficient market? An approach based on machine learning in stock trading, **Computational Intelligence and Neuroscience**, 1-14.
- Kureljusic, M. and Metz, J. (2023). The applicability of machine learning algorithms in accounts receivables management, **Journal of Applied Accounting Research**, 24(4): 769-786.
- Li, C., Stack, K., Sun, L. and Xu, J. (2024). Enterprise Risk Management and Management Earnings Forecasts, **Forthcoming at Management Science**, 1-57.
- Li, Z. and Li Zh. (2018). The Impact of Artificial Intelligence on Accounting, **advances in Social Science**, Education and Humanities Research, 181: 813-816.

- Martins, A. (2022). Earnings Prediction using Machine Learning Methods and Analyst Comparison, **CATOLICA LISBON, Business & Economics**, 1-59.
- Masood, F. (2024). Assessing the Impact of Machine Learning Algorithms on Portfolio Optimisation in the Era of Sustainable Investing, **International Journal of Emerging Multidisciplinaries: Computer Science and Artificial Intelligence**, 3(1): 1-9.
- Monahan, S. (2018). Financial Statement Analysis and Earnings Forecasting, **Foundations and Trends in Accounting**, 12(2): 105-215.
- Olubusola, O., Mhlongo, N., Daraojimba, D., Olusola, A., Nifise, A. and Falaiye, T. (2024). Machine learning in financial forecasting: A U.S. review: Exploring the advancements, challenges, and implications of AI-driven predictions in financial markets, **World Journal of Advanced Research and Reviews**, 21(02): 1969-1984.
- Papaj, E. and Strojek, M. (2019). Forward-looking information disclosure as a risk factor in accounting—the case of Poland, Multiple Perspectives in Risk and Risk Management, **Springer Proceedings in Business and Economics**, 125-141.
- Raja, H. (2021). Returns Optimization and Returns Prediction in Presence of Fear Sentiments Using Machine Learning Algorithms, **A thesis submitted in partial fulfillment for the degree of Master of Science**, Faculty of Management & Social Sciences Department of Management Sciences, Capital University of science and technology, 1-91.
- Rossi, G. (2018). Predicting stock market returns with machine learning **Van Munching HallSmith**, School of Business, Georgetown University, 1-44.
- Schmitz, J. and Leoni, G. (2019). Accounting and auditing at the time of blockchain technology: a research agenda, **Australian Accounting Review**, 29(2): 331-342.
- Sun, T. (2019). Applying deep learning to audit procedures: An illustrative framework, **Accounting Horizons**, 33(3): 89-901.
- Yalamati, S. (2023). Artificial Intelligence influence in individual investors performance for capital gains in the stock market, **international scientific journal for research**, 5(5): 1-24.
- Zhou, X. (2023). Theoretical Discussion on Individual Investor Behavior from a Quantitative Finance Perspective: Possibilities for Machine Learning Applications, **Open Journal of Business and Management**, 11(8): 2802-2810.