

التنبؤ بالتقديرات المحاسبية باستخدام تقنيات تعلم الآلة وأثره على مستوى تمهيد الدخل: بالتطبيق على البيئة المصرية

د/ احمد عيد محمد ابو المعاطي

مدرس المحاسبة بمعهد الدلتا

العالي لنظم المعلومات الإدارية والمحاسبية

الملخص:

استهدف البحث عرض التقديرات المحاسبية في ضوء المعايير ذات صلة، وممارسات تمهيد الدخل من منظور محاسبي، لمعرفة أثر استخدام خوارزميات تعلم الآلة في التنبؤ بالتقديرات المحاسبية علي ممارسات تمهيد الدخل، واعتمد البحث علي المنهجية المطبقة علي كافة الشركات المقيدة في سوق الأوراق المالية المصري، وخاصةً بالتركيز علي الشركات الصناعية في الفترة من ٢٠١٩ إلى ٢٠٢٢ أي أن المدة المتاحة للسلسلة الزمنية مدتها ٤ سنوات، وبلغت عينة الدراسة ١٢٥ مشاهدة.

وتمثلت أهم النتائج التي توصلت إليها الدراسة في وجود فروق جوهرية ذات دلالة إحصائية بين تمهيد الدخل عن طريق التقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية المتنبأ بها باستخدام الأساليب التقليدية، وجود فروق جوهرية ومعنوية بين الأساليب التقليدية المتمثلة في أسلوب Probit وبين خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية، بالإضافة إلي وجود فروق جوهرية ذات دلالة إحصائية بين تمهيد الدخل عن طريق التقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية الفعلية لعينة الدراسة.

الكلمات الدالة: تعلم الآلة، الغابة العشوائية، الشبكات العصبية، ممارسات تمهيد الدخل.

Abstract:

The research aimed to present accounting estimates in light of relevant standards and income smoothing practices from an accounting perspective, to determine the impact of using machine learning algorithms in predicting accounting estimates on income smoothing practices. The research relied on the applied methodology on all companies registered in the Egyptian stock market, especially by focusing On industrial companies in the period from 2019 to 2022, meaning that the period available for the time series is 4 years, and the study sample amounted to 125 observations.

The most important findings of the study were that there were significant differences with statistical significance between smoothing income through accounting estimates using machine learning algorithms and accounting estimates predicted using traditional methods. There were also significant and significant differences between traditional methods represented by the Probit method and machine learning algorithms for predicting estimates. Accounting, in addition to the presence of significant, statistically significant differences between income smoothing through accounting estimates using machine learning algorithms and the actual accounting estimates for the study sample.

Keywords: Machine learning, Random Forest, Neural Networks, Income Smoothing Practices

أولاً: الإطار العام للبحث

١/١ مشكلة البحث:

لقد أدت ظروف عدم التأكد المحيطة بالتقديرات المحاسبية، والبعد الشخصي المتلازم في الأحكام المتعلقة بإعدادها ومراجعتها، وتقلب الأسواق المالية، وسهولة تعرضها للتحيزات الإدارية والأخطاء، والتي يترتب عليها توفير معلومات غير موثوق بها في القوائم المالية ومن ثم ينتج عنها تضليل مستخدمي هذه المعلومات، ونتيجة لزيادة درجة التعقيد وعدم التأكد في معلومات التقديرات المحاسبية وخاصة في ظل تطور المعايير المحاسبية واستخدامها لمحاسبة القيمة العادلة وتعدد السياسات المحاسبية المتاحة في معالجة البنود الواردة بالقوائم المالية.

ونظراً لامتتع المديرون بمرونة كبيرة في تحديد التقديرات المحاسبية، وتوقيت وحجم التغيير في التقدير المحاسبي، ونتيجة لاستغلال المعالجات والممارسات البديلة كوسيلة لإظهار التقارير المالية وتحويلها مما يجب أن تكون عليه التقارير إلى ما ترغب أن تظهره الإدارة في هذه التقارير للغير، مما يعنى استخدام الإدارة للتقديرات المحاسبية كأداة غير مباشرة للتلاعب حيث تعكس تقارير الأرباح رغبات الإدارة بدلاً من الأداء المالي الأساسي للشركة (Chung, et al., 2022).

وقد تقوم الإدارة بممارسات تمهيد الدخل عن طريق تغيير بعض السياسات المحاسبية المستخدمة في إعداد قوائمها المالية بشكل متعمد من خلال التلاعب بتوقيت وحجم الأنشطة التجارية وتقليل النفقات التقديرية، فقد تلجأ إدارة الشركة لتخفيض أرباحها خلال السنوات الجيدة وتخزينها لإضافتها لأرباح السنوات ذات الركون الاقتصادي أو التضخم، وذلك بهدف تحقيق الاستقرار في الدخل مما يدل على استقرار الوضع الاقتصادي للشركة ويحفز المستثمرون على زيادة استثماراتهم في الشركة (Egbunike, et al, 2023).

ومن ثم يستنتج الباحث أن هناك حاجة حتمية لاستعمال تقنيات جديدة لتحسن التنبؤ بالتقديرات المحاسبية وتقليل درجة عدم التأكد والتحيز التي تختص بها التقديرات المحاسبية مما يساعد على زيادة موثوقية التقديرات المحاسبية، ومن ثم يقلل من ممارسات تمهيد الدخل، وذلك لأن الأساليب التقليدية أصبحت غير قادرة على مواجهة درجة التعقيد بالقوائم المالية والتحيزات الإدارية والتضخم.

ويرى الباحث أن خوارزميات تعلم الآلة من أفضل التقنيات التي يمكن من خلالها زيادة مستوى دقة التقديرات المحاسبية، حيث تعد أحد فروع الذكاء الاصطناعي التي تقوم بعملية تحليل البيانات باستخدام الخوارزميات لإيجاد الأنماط الضمنية ومن ثم

تطبق الأنماط الموجودة لعمل تنبؤات حول المستقبل (Hunt, et al. 2022)، كما تحول خوارزميات تعلم الآلة البيانات الخام التي يمكن أن تكون كبيرة جداً أو غير مفهومة أو حتى ذات معرفة غير كاملة إلي بيانات منتظمة ومفهومة ومن ثم معلومات مفيدة (Chen, et al., 2022).

وبالتالي فإن الدراسة الحالية تهدف الى تتبع أثر استخدام خوارزميات تعلم الآلة في التنبؤ بالتقديرات المحاسبية، نظراً للحاجة الماسة لدقة التقديرات المحاسبية ودورها في تحسين جودة المعلومات المالية والنظرة المستقبلية للوضع المالي والأداء التشغيلي للشركة وهذا بدوره يحد من ممارسات تمهيد الدخل ويساعد المستثمرين في اتخاذ قرارات استثمارية رشيدة، وهو مالم يختبر إجرائيا في البيئة المصرية، رغم أهميته في الفترة الحالية.

**ومن ثم يمكن للدراسة الحالية صياغة مشكلتها في التساؤل التالي؟
هل هناك أثر لاستخدام خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية للحد من ممارسات تمهيد الدخل؟**

٢/١ أهمية البحث:

في ضوء مشكلة البحث تتمثل أهميته العلمية في تقديم طرق جديدة لزيادة جودة التنبؤ بالتقديرات المحاسبية من خلال استخدام خوارزميات تعلم الآلة للحد من ممارسات تمهيد الدخل وذلك لندرة الدراسات المحاسبية التي تناولت العلاقة بينهما في البيئة المصرية.

بينما تستمد أهمية البحث العملية من إمكانية استخدام خوارزميات تعلم الآلة في زيادة جودة التنبؤ بالتقديرات المحاسبية التي تعكس الظروف الاقتصادية الحالية والتوقعات المستقبلية وهذا بدوره يقدم المعلومات المفيدة لاتخاذ القرارات الاقتصادية، وذلك نظراً لتقليل خوارزميات تعلم الآلة لدرجة عدم التأكد والتحيز التي تختص بها التقديرات المحاسبية مما يحد من ممارسات تمهيد الدخل ويزيد من ثقة مستخدمي التقارير المالية، وبالتالي فإن دراسة تلك العلاقة في البيئة المصرية قد يقدم أدلة إضافية بشأنها في الأسواق الناشئة والأقل تطوراً، وهو ما يعد دافعاً قوياً لاجراء هذه الدراسة في بيئة الأعمال المصرية.

٣/١ أهداف البحث:

يتمثل الهدف الرئيسي لهذا البحث في معرفة أثر استخدام خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية علي ممارسات تمهيد الدخل، ويمكن تحقيق هذا الهدف من خلال دراسة التقديرات المحاسبية من منظور محاسبي، واختيار الخوارزمية الأفضل للتنبؤ بالتقديرات المحاسبية وأثر ذلك علي ممارسات تمهيد الدخل، وذلك للحصول على دليل من الواقع العملي من الشركات المقيدة في البورصة المصرية.

٤/١ مجال البحث:

يقتصر البحث علي دراسة أثر استخدام خوارزميات تعلم الآلة في التنبؤ بالتقديرات المحاسبية علي ممارسات تمهيد الدخل، ويتمثل مجتمع الدراسة في كافة الشركات المقيدة في سوق الأوراق المالية المصري وخاصةً بالتركيز على الشركات الصناعية، ولذلك قام الباحث باستبعاد البنوك وشركات التأمين والمؤسسات المالية لما لها من طبيعة خاصة، ونظراً لأن القرار الوزاري الصادر بشأن تطبيق معايير المحاسبة المصرية المعدلة صادر سنة ٢٠١٩ برقم ٦٩، فإنه يمكن للباحث تحديد الفترة الزمنية للدراسة الحالية في الفترة من ٢٠١٩ إلى ٢٠٢٢ أي أن المدة المتاحة للسلسلة الزمنية مدتها ٤ سنوات، وبلغت العينة النهائية الصالحة للتحليل ١٢٥ مشاهدة.

٥/١ الدراسات السابقة وتحديد الفجوة البحثية:

استهدفت دراسة (Albrecht., et al, 2023) اختبار تأثير التغيرات الجوهرية في التقديرات المحاسبية (MCEs) على فائدة الأرباح في ضوء معيار ASC 250 الصادر عن مجلس المحاسبة المالية FASB وتوصلت الدراسة إلي أن التغيرات الجوهرية في التقديرات المحاسبية في المتوسط تزيد من فائدة الأرباح التي يتم قياسها من خلال القدرة التنبؤية للأرباح للتدفقات النقدية المستقبلية واستجابة المستثمرين لأخبار الأرباح، على الرغم من أن النتائج الدراسة أشارت إلى أن بعض الشركات تحدد توقيت تنفيذها لتغيرات الجوهرية في التقديرات المحاسبية لتحقيق أهداف الأرباح المرغوبة، كما أوضحت الدراسة أن إفصاحات ASC 250 تجتذب مراجعة المستثمرين والجهات التنظيمية، مما يشير إلى أن التغيرات الجوهرية في التقديرات المحاسبية هي أداة مكلفة لإدارة الأرباح.

كما تناولت دراسة (Boone, et al, 2023) اختبار العلاقة بين كثافة التقدير المحاسبي (AEI) المتأصلة في التقارير المالية للشركة وميل الشركة لتلبية توقعات أرباح المحللين أو التغلب عليها وما إذا كانت هذه العلاقة مخففة من خلال خبرة تقدير المراجع على مستوى مكتب المدينة أو المستوى الوطني، وتوصلت أهم نتائج الدراسة إلي وجود علاقة إيجابية بين كثافة التقدير المحاسبي والميل إلى تلبية توقعات المحللين، كما وجدت الدراسة القليل من الأدلة التي تشير إلى أن العلاقة تضعف بسبب خبرة تقدير المراجعين.

في حين قدمت دراسة (Kureljusic, & Karger, 2023) نظرة عامة شاملة للنتائج الحالية حول كيفية استخدام الذكاء الاصطناعي وخوارزميات تعلم الآلة في

أغراض تحسين التنبؤ في المحاسبة المالية، واستخدمت الدراسة Scopus و Web of Science كقواعد بيانات علمية وبلغت حجم العينة ٤٧ دراسة، وتوصلت الدراسة إلي أنه يمكن للشركات تقييم خوارزميات الذكاء الاصطناعي وتعلم الآلة الأكثر ملائمة لاحتياجاتهم العملية بالإضافة إلي نجاحها في تحسين التنبؤ.

بينما ركزت دراسة (Hammami & Hendijani Zadeh, 2022) على استخدام خوارزميات تعلم الآلة في التنبؤ بممارسات إدارة الأرباح، وقامت الدراسة بتقسيم ممارسات إدارة الأرباح إلي إدارة الأرباح علي أساس الاستحقاق وإدارة الأرباح الحقيقية، واستخدمت الدراسة قاعدة بيانات COMPUSTAT خلال الفترة ٢٠١٤-٢٠١٨، وتوصلت الدراسة إلي أن خوارزمية الغابة العشوائية تتفوق في التنبؤ بممارسات إدارة الأرباح.

بينما فحصت دراسة (Chung et al, 2022) ما إذا كانت الشركات تحدد توقيت قراراتها لإجراء تغييرات في التقديرات المحاسبية (CAEs) مع مراعاة معايير أرباحها، وباستخدام بيانات CAE عبر جميع الحسابات من عام ٢٠٠٦ إلى ٢٠١٨، وتتمثل أهم نتائج الدراسة في أن ٢٨.١% من CAEs التي تزيد الدخل يتم تنفيذها في أوقات تكون فيها أرباح ما قبل CAE أقل من معيار الأرباح المتوقعة، لكن إدراج CAE يسمح بشكل فعال للشركة بالوفاء بالمعيار وذلك بهدف الحصول على "الاعتسال المالي الكبير" ووضع الشركة في موضع تحقيق أرباح مستقبلية إيجابية.

وركزت دراسة (Almaqtari et al, 2021) الضوء على إمكانيات تحسين إدارة الأرباح لتقييد ممارسات إدارة الأرباح والاحتيايل المالي، وقامت الدراسة بعمل مراجعة للأدبيات المتاحة حول إدارة الأرباح واكتشاف الاحتيايل بهدف معرفة منهجية الأساليب والتقنيات المستخدمة في الأبحاث السابقة لتحديد إدارة الأرباح واكتشاف الاحتيايل، وأشارت نتائج الدراسة إلي أن الأبحاث السابقة في تحسين إدارة الأرباح تتباين بين عدة تقنيات ولم توفر أي من هذه التقنيات تحسناً مثالياً لإدارة الأرباح، كما أوضحت النتائج أن محددات إدارة الأرباح معقدة بناءً على نوع وحجم كيانات الأعمال مما يزيد من تعقيد إمكانيات التحسين، وأوصت الدراسة باستخدام خوارزميات تعلم الآلة في التنبؤ بممارسات إدارة الأرباح للحد منها وتقييدها.

وقامت دراسة (Ding et al, 2020) بمعرفة أثر دور خوارزميات تعلم الآلة في تحسين التنبؤ بالتقديرات المحاسبية وذلك بدليل من مطالبات وخسائر شركات التأمين الأمريكية خلال الفترة من ١٩٩٦ إلى ٢٠١٧، وتوصلت الدراسة إلي أن خوارزميات تعلم الآلة يمكن أن تحسن التنبؤ بالتقديرات المحاسبية بكفاءة عالية ومن ثم تعزز فائدة المعلومات المالية للمستثمرين.

بينما تناولت دراسة (Amel-Zadeh et al, 2020) دور خوارزميات تعلم الآلة في تحليل القوائم المالية من خلال قدرتها على التنبؤ بعلامة وحجم عوائد الأسهم غير العادية حول إعلانات الأرباح بناءً على بيانات التقارير المالية وذلك خلال الفترة ١٩٩١-٢٠١٨، وأوضحت نتائج الدراسة أن خوارزميات الغابة العشوائية والشبكات العصبية المتكررة تتفوق في الأداء على الشبكات العصبية العميقة والنماذج الخطية مثل OLS وLasso، كما أشارت الدراسة إلى أنه في حالة استخدام تنبؤات الخوارزميات في استراتيجية الاستثمار يتضح أن خوارزمية الغابة العشوائية تهيمن على جميع الخوارزميات الأخرى وأن الطرق غير الخطية تؤدي أداءً أفضل نسبياً للتنبؤ بردود فعل السوق المتطرفة.

كما بحثت دراسة (Bertomeu, 2020) في أثر أهمية خوارزميات تعلم الآلة في أبحاث المحاسبة التجريبية خاصةً أثر خوارزميات تعلم الآلة علي تحسين التقديرات المحاسبية، وتوصلت نتائج الدراسة إلي أن خوارزميات تعلم الآلة تحسن التقديرات المحاسبية عن تقديرات الإدارة وهذا بدوره يحسن من جودة المعلومات المحاسبية، كما أوضحت الدراسة أن خوارزميات تعلم الآلة تعطي مسارات لمعرفة الأسباب التي تتسبب في وضع الإدارة لتقديرات خاطئة.

تحليل الدراسات السابقة وتحديد الفجوة البحثية:

في ضوء الدراسات السابقة، توصل الباحث الى ما يلي:

- فيما يتعلق بالدراسات التي تناولت التقديرات المحاسبية أظهرت دراسة (Albrecht., et al.,2023) علي مدي أهمية التقديرات المحاسبية لمستخدمي التقارير المالية وذلك لأن التغيرات الجوهرية في التقديرات المحاسبية في المتوسط تزيد من فائدة الأرباح التي يتم قياسها من خلال القدرة التنبؤية للأرباح للتدفقات النقدية المستقبلية واستجابة المستثمرين لأخبار الأرباح، وأن التغيرات الجوهرية في التقديرات المحاسبية هي أداة مكلفة لإدارة الأرباح، وأكدت علي ذلك دراسة (Chung, et al., 2022) بإدراج التغيرات في التقديرات المحاسبية يسمح بشكل فعال للشركة بالوفاء بالمعيار وذلك بهدف الحصول على "الاغتسال المالي الكبير" ووضع الشركة في موضع تحقيق أرباح مستقبلية إيجابية.
- أما فيما يتعلق بالدراسات التي تناولت العلاقة بين خوارزميات تعلم الآلة والتقديرات المحاسبية، توصلت كل من (Bertomeu, 2020; Ding,et al,2020) الى أن خوارزميات تعلم الآلة تحسن التنبؤ بالتقديرات المحاسبية بكفاءة عالية وتعطي مسارات لمعرفة الأسباب التي تتسبب في وضع الإدارة لتقديرات خاطئة، هذا بالإضافة إلي كفاءتها في التنبؤ باستراتيجية الاستثمار وهذا بدوره يحسن من جودة المعلومات المحاسبية ومن ثم تعزز فائدة المعلومات المالية للمستثمرين.

- كما أوصت دراسة (Almaqtari, et al, 2021) باستخدام خوارزميات تعلم الآلة في التنبؤ بممارسات إدارة الأرباح للحد منها وتقييدها، واتفقت معها دراسة (Hammami, & Hendijani Zadeh, 2022) علي أن خوارزمية الغابة العشوائية تتفوق في التنبؤ بممارسات إدارة الأرباح.
- معظم الدراسات في البيئة المصرية تناولت الأساليب التقليدية في دراسة العلاقة بين التقديرات المحاسبية وتمهيد الدخل.

وبالتالي يرى الباحث أن الدراسة الحالية تسهم في تغطية تلك الفجوة من خلال التركيز على الدور التنبؤى لخوارزميات تعلم الآلة في تفسير العلاقة بين التقديرات المحاسبية ومستوى تمهيد الدخل.

٦/١ خطة البحث:

- لتحقيق أهداف البحث، سوف يقوم الباحث بتقسيم البحث كما يلي:
١. الإطار العام للبحث.
 ٢. الخلفية النظرية واشتقاق الفروض.
 ٣. الدراسة التطبيقية
 ٤. نتائج البحث وتوصياته وأهم مجالات البحث المترحة
 ٥. المراجع.

ثانياً: الخلفية النظرية واشتقاق الفروض

يتناول الباحث في هذا القسم مفهوم وأهم بنود التقديرات المحاسبية ، وكذلك ممارسات تمهيد الدخل، كما يتعرض لاستخدام خوارزميات تعلم الآلة في التنبؤ بالتقديرات المحاسبية وأثرها على ممارسات تمهيد الدخل، ومن ثم يتم تقسيم هذا القسم كما يلي:

١/٢ التقديرات المحاسبية في ضوء المعايير ذات الصلة:

تمثل التقديرات المحاسبية تحديد أرقام تقريبية ومقدرة والتي تحتاج الى مراجعة عند توافر معلومات إضافية. فمثلاً الإعتراف بالأرباح أو الخسائر الناتجة عن تحقق الإلتزامات الطارئة والتي لم يتم تقديرها بشكل موثوق، تعتبر فروقات ناتجة عن التقديرات المحاسبية ولا يمثل ذلك تصحيح أخطاء. وتتطلب عملية إعداد القوائم المالية الإستخدام المتكرر للتقديرات للعديد من البنود مثل: الأعمار الإنتاجية للأصول القابلة للاهتلاك، أو نمط الاهتلاك المتوقع للمنافع الاقتصادية المستقبلية في تلك الأصول، تقادم المخزون، الديون المشكوك في تحصيلها، التزامات الضمانات، تكاليف التقاعد، القيمة العادلة للأصول والالتزامات المالية التي ليس لها سوق نشط(أبو نصار & حميدات، ٢٠١٣).

يوجد عدد من العناصر في التقارير المالية لا يمكن قياسها بشكل موثوق ولكن يمكن تقديرها فقط، الأمر الذي يتطلب تقديرات تعتمد علي أحدث المعلومات المتاحة (Pavic, et al., 2016)، واتفق مع ذلك معيار المحاسبة المصري رقم (٥) حين ذكر احتمالية صعوبة قياس العديد من بنود القوائم المالية بدقة ولكن يمكن تقديرها فقط نظراً لظروف عدم التأكد التي تتسم بها أنشطة الأعمال، كما أوضح هذا المعيار أيضاً أن استخدام التقديرات يعد جزءاً أساسياً في إعداد القوائم المالية ولا يؤدي إلى التقليل من مصداقيتها.

وعرفت دراسة (Nangih, & Anichebe, 2021) التقديرات المحاسبية بالمبالغ التقريبية للمعاملات التجارية التي لا يوجد لها أساس دقيق للقياس والتي يتم إجراؤها في التقارير المالية بناءً على الأدلة التاريخية وحكم المُعدِّين أو الإدارة، ومن ثم تستند التقديرات إلى عوامل ذاتية وموضوعية، ويتم استخدام التقديرات في المحاسبة القائمة على الاستحقاق لجعل التقارير المالية تظهر بصورة حقيقية وعادلة، فعادةً ما يتم استخدامها في البيانات المالية التاريخية لقياس آثار المعاملات أو الأحداث التجارية السابقة، أو الوضع الحالي للأصل أو الالتزام، ولذلك هي عرضة للتحييز الإداري.

واتفق في ذلك مجلس معايير المراجعة الدولية (IAASB) حين عرف التقديرات المحاسبية في ٢٠٠٨ على أنها مبلغ نقدي تقريبي في حالة عدم وجود وسيلة قياس دقيقة (Oyewo, et al., 2020)، كما تناولها المعهد الكندي للمحاسبين القانونيين (CICA) علي أنها عبارة عن قيم مالية مدرجة لبعض عناصر القوائم المالية اعتماداً علي الأحداث الماضية والحالية لتلك البنود، وأكد مجلس (PCAOB) علي أنها تعبر عن القيم والحسابات التي يتم إعدادها في ظل ظروف عم التأكد قد ينتج عنها أخطاء في عملية التقدير، واتفق معه مجلس (IASB) علي أن التقديرات المحاسبية بمثابة تقديرات محتملة تتم في ظل ظروف حالية ومستقبلية غير مؤكدة (أحمد، ٢٠٢٣).

حيث أكد مجلس (IASB) علي اعتماد التقارير المالية علي التقديرات والأحكام إلي حد كبير، فقد تمثل التقديرات والأحكام الإدارية جزء كبير من التقارير المالية ومن الممكن أن تحسن هذه التقديرات من جودة المعلومات المالية عن طريق توفير المديرين لمعلومات مستقبلية لأصحاب المصلحة، ولكن في بعض الأحيان يتم تقليل جودة المعلومات المالية من قبل مُعديها أو الإدارة من خلال استغلالها للتقديرات المحاسبية والتلاعب بالتقارير المالية، كما أكد مجلس (PCAOB) في معيار المراجعة رقم (٢٥٠١) عام ٢٠١٨ علي أن التقديرات المحاسبية معرضة لتحييز الإدارة بشكل كبير (Shaw & Whitworth, 2022).

ووفقاً للمعايير الدولية لإعداد التقارير المالية (IFRS) تعبر التقديرات المحاسبية عن أحكام تستند إلى أحدث المعلومات الموثوقة المتاحة، ونظراً لكونها جزءاً مهماً من التقارير المالية يجب ألا تقلل من موثوقية ومصداقية المعلومات المالية للشركات، كما

يجب على الشركة أن تفصح عن التقديرات المحاسبية الهامة وكذلك طبيعة ومقدار التغيير في التقدير المحاسبي الذي له تأثير على الفترة الحالية أو الذي من المتوقع أن يكون له تأثير على الفترات المستقبلية (Pavic, et al., 2016)، واتفق مع هذا الرأي مجلس التقارير المالية النيجيري (FRCN) وأكد علي أن الإفصاح عن المعلومات المتعلقة بالتقديرات المحاسبية يجب أن يكون واضحاً وموثوقاً وعادلاً لضمان التمثيل الصادق للمعلومات الواردة في التقارير المالية بنيجيريا (Nangih & Anichebe, 2021).

لذا تمثل المعايير المحاسبية مصدراً هاماً للتقديرات المحاسبية ومن ضمنها المعيار المحاسبي الدولي (IAS 8) الذي يصف السياسات المحاسبية والتغييرات في التقديرات المحاسبية وأخطاء التغيير في التقدير المحاسبي على أنه تعديل لمبلغ القيمة الدفترية للأصل أو الالتزام ، أو مقدار الإهلاك الدوري للأصل، الذي ينتج عن تقييم الوضع الحالي والمزايا المستقبلية المتوقعة والالتزامات المرتبطة بالأصول والالتزامات، أي أن التغيير في التقديرات المحاسبية ينتج عن المعلومات والتطورات الجديدة، ومن ثم لا تعد هذه التغييرات تصحيحاً للأخطاء، ولكن يعتبر التغيير في أساس القياس المطبق تغييراً في السياسة المحاسبية وليس تغيير في التقدير المحاسبي، ويتفق معيار (SFSFSA) (154 الصادر عن مجلس معايير المحاسبة المالية في ذلك مع معيار المحاسبة الدولي (IAS 8) (Pavic, et al., 2016; Albrecht, et al., 2023).

وأكد المعيار في الفقرة (١٢٥) على إفصاح الشركات عن المعلومات المتعلقة بالافتراضات التي تضعها حول المستقبل، وكما ذكر في معيار (IAS 8) بالفقرة (٣٩) ينبغي توضيح طبيعة هذه المعلومات إلي جانب الإفصاح عن طبيعة ومقدار التغييرات في التقديرات المحاسبية والسياسات المتبعة بها (Sacer, et al., 2016)، وتتمثل أهم هذه السياسات في طرق تقدير مخصص الديون المشكوك فيها، طرق تقدير الإهلاك للشهرة، طرق تقدير الإهلاك للأصول الثابتة (Nangih, & Anichebe, 2021).

وأكدت دراسة (Chung, et al., 2022) علي أن التقديرات المحاسبية الدقيقة تعزز أهمية المعلومات المالية كما توفر للمديرين وسيلة للتواصل الداخلي ومعلومات مستقبلية للمستثمرين والمشاركين الآخرين في السوق، واتفقت معها دراسة (Albrecht, et al 2023) علي أن الإفصاح عن التقديرات المحاسبية يتيح كثيراً من المعلومات التي يسهل استخدامها من قبل مستخدمي القوائم المالية ، ويسهل من عملية تقييم الأداء المالي للشركات ، كما أنه يحسن من شفافية التقارير المالية، كما يساهم الإفصاح عن التغييرات في التقديرات المحاسبية في تقييد ممارسة إدارة الأرباح.

وأكد علي ذلك دراسة (Putri, & Suputra, 2019) بتناولها لتأثير الإفصاح عن التقرير المالي والقدرة الإدارية على إدارة الأرباح في إندونيسيا من ٢٠١٢ إلى ٢٠١٦ عينة من ٣٧٥ شركة ، ولقد اعتمدت الدراسة علي ٣٣ بند من بنود الإفصاح الطوعي،

وأوضحت الدراسة أن الإفصاح عن التقرير المالي له تأثير على إدارة الأرباح ، ولكن ليس له تأثير كبير على القدرة الإدارية، بينما أوضحت دراسة (Cain, et al., 2020) أن صعوبة إجراء تقديرات دقيقة قد تعرض جودة المعلومات المالية للخطر، بالإضافة إلى احتمالية تلاعب المديرين بقيمتها عن عمد، وذلك لاعتمادها على تقييمات ذاتية للأحداث المستقبلية مما يتيح للمديرين المرونة الكافية في تحديد التقديرات المحاسبية.

٢/٢ ممارسات تمهيد الدخل من منظور محاسبي

تعتبر ممارسات تمهيد الدخل عن محاولة المديرين لتحقيق دوافعهم التعاقدية، توصيل معلومات خاصة مفيدة إلى أسواق رأس المال، تحسين المعلومات المتعلقة بالأرباح، وخفض تكلفة رأس المال، وهذا يعني أن ممارسة تمهيد الدخل بمثابة جهد من قبل الشركات لنقل معلومات قيمة إلى المستثمرين بما يتوافق مع نظرية الإشارة، حيث يتبع المديرين ممارسة تمهيد الدخل كإجراء وقائي لتقليل المخاطر المتصورة من قبل المستثمرين والمقرضين على حد سواء، وبالتالي خفض تكلفة رأس المال (Tee,) 2020.

ونكرت دراسة (Egbunike, et al, 2023) عدة تعريفات لممارسة تمهيد الدخل وهي أنها محاولة إدارية لممارسة السلطة التقديرية لإعداد التقارير بهدف تخفيف التقلبات المتعمدة في أرباح شركاتهم، ويقصد بها أيضاً مدى اختلاف صافي الدخل المدرج في قائمة الدخل عن الأرباح الحقيقية، أي أن تلك الممارسات عبارة عن منهج خاص يؤثر على شفافية الواقع الاقتصادي الأساسي وقرارات أصحاب المصلحة في تخصيص الموارد النادرة، وهذا يعني أنها أحد أشكال التلاعب بالأرباح، لذا تتأثر جودة الأرباح بالاستخدام الإداري لممارسات تمهيد الدخل الحقيقي أو المحاسبي في محاولة لخداع المستثمرين.

ويري الباحث أن ممارسة تمهيد الدخل تدل على قيام الإدارة بتقليل مستوي الأرباح الحالية عمداً كمحاولة منها لتقليل الانحرافات غير الطبيعية للأرباح من خلال استخدامها لبعض الممارسات التي تسمح بها مرونة المعايير لتخفيض الأرباح في الفترات التي تحقق فيها الشركة أرباح عالية وإضافتها للفترات التي تنخفض فيها الأرباح عن الحد المسموح به، فهو أمر استراتيجي ولا ينتهك أي مبادئ محاسبية.

ومن خلال تلك المفاهيم يمكن تصنيف ممارسات تمهيد الدخل إلى نوعين وهما التمهيد الطبيعي والتمهيد المتعمد، ويحدث التمهيد الطبيعي نتيجة للعمليات الطبيعية في توليد الدخل للشركة بدون أي تأثير متعمد من قبل الإدارة، بينما ينشأ التمهيد المتعمد نتيجة للقرارات التي تتخذها الإدارة وينقسم هذا النوع إلى نوعين وهما التمهيد الحقيقي والتمهيد المحاسبي، ويقصد بالتمهيد الحقيقي التمهيد الاقتصادي فهو يوضح الإجراءات

الإدارية التي تحاول السيطرة على الأحداث الاقتصادية التي تؤثر بشكل مباشر على أرباح الشركة في المستقبل (Fauzi, 2019).

ومن ضمن هذه الإجراءات اتخاذ قرارات متعلقة بأنشطة الإنتاج والاستثمار أي تعديل حجم الأنشطة التجارية بهدف تحقيق الوصول للدخل المستهدف، ومن أمثلة ذلك زيادة المبيعات من خلال تقديم تخفيضات في الأسعار أو من خلال شروط ائتمانية أكثر تساهلاً، الإفراط في الإنتاج للإفصاح عن انخفاض تكلفة البضائع؛ وتقليل النفقات التقديرية كنفقات البحث والتطوير أو النفقات الإعلانية، ويمكن أيضاً تصنيف أساليب التلاعب بناءً على نوع النشاط: التلاعب في أنشطة التشغيل أو الاستثمار أو التمويل (Yahya, 2019) (Egbunike, et al. 2023 ; Toumeh, &).

بينما يختلف التمهيد المحاسبي عن التمهيد الحقيقي فهو لا يعتمد على المعاملات المالية الحقيقية، ولكنه يُمكن الإدارة من التأثير على الأرقام المحاسبية المفصح عنها في القوائم المالية للشركة، فمن خلاله تقوم الإدارة باستغلال مرونة المعايير المحاسبية واختيار السياسة المناسبة لهدفها ثم تقوم الإدارة بتعديل التقديرات المحاسبية وتغيير الطرق المحاسبية وفقاً للمعايير المحاسبية المتعارف عليها، وهذا يعني أن الإدارة تقوم بممارسة تمهيد الدخل المحاسبي من خلال إعادة تصنيف بنود قائمة الدخل كوسيلة لتقييم ما إذا كانت الشركات تستخدم التقديرات والإفصاحات المحاسبية وكيفية استخدامها من أجل الوفاء بالتقارير المالية أو الأهداف التعويضية دون التأثير على الوضع الاقتصادي (Chung, et al., 2022).

ويكمن دافع الإدارة من اتباع ممارسات تمهيد الدخل في تحقيق العديد من المنافع منها زيادة ثقة المستثمرين وحثهم على زيادة الاستثمار أو لرفع قيمة أسهم الشركة أو لتقليل الضرائب (Chung, et al., 2022)، لذا يتبع المديرين دوافعهم التعاقدية في ممارسة تمهيد الدخل من خلال سلوكهم الانتهازي لتخفيض تكلفة التعاقد بين الشركة والأطراف الأخرى إلي أدنى حد ممكن ولتجنب القيود المفروضة المتواجدة بالتعاقد، وهذا يعني أن المديرين الذين يعتمد مكافآتهم على صافي الدخل يستغلوا مرونة السياسات المحاسبية لكي تزيد الأرباح ويقل تقلباتها، وذلك لضمان الحصول على مكافآتهم في الفترة الحالية.

ففي حالة كان الربح الفعلي أقل من الحد الأدنى للأرباح بدرجة كبيرة سوف يدفع الإدارة لتخفيض الربح إلي مستوي أقل من الفعلي أو تحويله لخسائر حتي تضمن الحصول على مكافآتها في الفترات المستقبلية وهذا ما يسمى بسياسة الاغتسال المالي الكبير للقوائم المالية Big Bath ، وقد يكون دافع الإدارة من تخفيض الربح تقليل المدفوعات الضريبية التي تتحملها الشركة وذلك من خلال استغلال الإدارة للسياسات المحاسبية التي تجعل أرباحها مستقرة ومن ثم يقل حجم الضريبة التي تتحملها الشركة (Lestari & Aeni, 2019; Toumeh, & Yahya, 2019).

كما ينشأ لدي الإدارة دوافع إدارة الأرباح المتعلقة بسوق الأوراق المالية لتحقيق منفعة رفع قيمة أسهم الشركة من خلال اتباعها لممارسات تمهيد الدخل، وذلك عن طريق قيامها بتطبيق مهاراتها المهنية في الاستفادة من مرونة الطبيعة التوجيهية لبعض المعايير لإدارة المعلومات المحاسبية للشركة بهدف تحسين صافي الدخل مما يؤثر على أسعار الأسهم بصورة إيجابية، وترتبط تلك الدوافع المتعلقة بسوق الأوراق المالية أيضاً بزيادة ثقة المستثمرين من خلال قيام الإدارة بزيادة أرباح الشركة لتتفق مع تنبؤات المحللين الماليين أو تنبؤات الإدارة في الفترات السابقة، ومن ثم يزيد المستثمرين من استثماراتهم في هذه الشركة لاستقرار أرباحها (2022) (Salawu,).

وأوضحت دراسة (Fauzi, 2019) أن حدوث ممارسات تمهيد الدخل تعتمد على عدة اعتبارات لإدارة الشركة، من بينها: (١) يفترض المديرون أن تدفق الأرباح المستقر يمكن أن يدعم توزيعات الأرباح بمستوى أعلى من تدفق الأرباح الذي يحتوي على المزيد من المتغيرات؛ و (٢) تقليل الارتباط بين توقعات عوائد الشركات وعوائد محافظ السوق.

ولقد ناقشت دراسة (Salawu, 2022) وجهتين نظر تتمثل الأولى في أن ممارسة تمهيد الدخل يمكن اعتبارها أداة إدارية مواتية، والثانية في أنها غير جذابة ولم تعد عصرية، حيث يتم تحفيز المديرين لممارسات تمهيد الدخل نظراً لأن المستثمرين يقدرّون الشركات التي تفصح عن أرباح مستقرة عالية تُمكنهم من سهولة التنبؤ بالأرباح المستقبلية لهذه الشركة، كما يعتقد المشاركون في سوق رأس المال خاصةً المستثمرون والمحللون أن تمهيد الدخل يدل على أن أرباح الشركات المفصح عنها ستستمر في المستقبل، ومن ثم تعتبر تلك الشركات أقل خطورة من الشركات ذات الأرباح المتقلبة، ولكن توصلت الدراسة إلي أن ممارسات تمهيد الدخل مرتبطة بالتلاعب والإفصاح الاحتيالي الذي يفتقر للشفافية.

كما يؤخذ على ممارسات تمهيد الدخل إفسادها للتوقيت والتأكد ومن ثم تؤدي إلى عدم كفاءة الاستثمار، نظراً لاحتواء ممارسات تمهيد الدخل على التمهيد بين الفترات الزمنية للأرباح المفصح عنها، وذلك بهدف تسوية التقلبات في الأرباح المفصح عنها بين الفترات، من خلال استخدام المديرين لممارسة تمهيد الدخل الحقيقي لصعوبة اكتشافه النسبية، لأنه يرتبط بقرارات التشغيل وعادةً لا ينتهك القواعد أو اللوائح (Abozaid, et al., 2020).

وأوضحت دراسة (Ch, 2020) أن ممارسة تمهيد الدخل تؤثر على صورة الشركة وأدائها، ولكن لا يقاوم المديرين هذه الممارسة لأن الجمهور متحمس لبيع الأسهم بهدف الحصول على فوائد اقتصادية عندما تكون الأرباح أقل تقلباً لأن المستثمرين يبدون أكثر انجذاباً للاستثمار أكثر عندما يكون لدى الشركات دخل آمن ومستقر، ودافعت دراسة (Lestari & Aeni, 2019) عن عدم مقاومة المديرين لممارسة تمهيد الدخل بغرض

تجنب الضرائب، وذلك نظراً لميول الشركات إلى دفع ضرائب أقل عندما يكون الدخل مستقراً.

فيما تناولت دراسة (Firmansyah, & Irwanto, 2020) أن ممارسات تمهيد الدخل لها تأثير سلبي علي عدم التأكد من المعلومات وبالتالي تؤثر بصورة سلبية علي تقلبات أسعار الأسهم، ولذلك تمارس الإدارة ممارسات تمهيد الدخل بهدف تقليل تقلبات أسعار الأسهم، وأكدت دراسة (Ojomadele, & Adejuwon, 2020) علي أن ممارسات تمهيد الدخل تساعد في بعض الفضاءات المالية المفصح عنها في نيجيريا خاصة حالات مبالغة شركة Cadbury Nigeria Plc في تقدير الأرباح وتزوير أرقام حسابات Afribank مما أدى إلى فضائح مالية.

٣/٢ أثر استخدام خوارزميات تعلم الآلة في التنبؤ بالتقديرات المحاسبية علي ممارسات تمهيد الدخل

في ظل اقتصاد سريع الخطى فإن أي تأخير في الإفصاح عن النتائج المالية يمكن أن يكون ضاراً للشركة، ولذلك يجب على الشركات أن تسعى دائماً لتحقيق الكفاءة والتحسينات في تقاريرها. وقد تم تحقيق ذلك من خلال التقدم في برامج المحاسبة لالتقاط هذه الأحداث الاقتصادية ولاتخاذ القرارات التقديرية وتسجيل أحداث معينة في القوائم المالية في الوقت الحقيقي (Petkov, 2020).

ولذلك تبحث الشركات بشكل متزايد عن طرق جديدة لخلق القيمة للمعلومات، ومن ضمن هذه الطرق خوارزميات تعلم الآلة والتي تعد مجالاً فرعياً للذكاء الاصطناعي يهدف إلى تنفيذ أنظمة ذكية من خلال التعلم من البيانات بدلاً من استخدام القواعد المحددة مسبقاً (Ranta et al., 2023)، حيث يتم تطبيق خوارزميات تعلم الآلة لتحديد الأنماط في مجموعات البيانات، ويمكن بعد ذلك استخدام هذه الأنماط لمهام التصنيف أو الانحدار بالمقارنة مع الأساليب التقليدية، وتتميز خوارزميات تعلم الآلة بأن قواعد القرار لا تحتاج إلى برمجة بشكل صريح.

ولكنها تقوم بتحديد الارتباطات بين بيانات المدخلات والمخرجات بناءً علي مجموعة البيانات المحددة، وتشتمل التطبيقات الحالية والمحتملة لخوارزميات تعلم الآلة علي المهام التي تم حلها حتى الآن من خلال العديد من القواعد والمشكلات المعقدة التي لا يمكن للطرق التقليدية حلها بشكل كافٍ، والمهام التي تتطلب درجة عالية من القدرة على التكيف، وأخيراً استخراج المعرفة من مجموعات البيانات الكبيرة (Kureljusic, & Metz, 2023).

فمن مميزات استخدام خوارزميات تعلم الآلة لتحليل القوائم المالية أنه يمكن تدريب هذه الخوارزميات لاختيار المتغيرات المحاسبية الواعدة لمهمة التنبؤ التي يحددها الباحث وتعلم العلاقات (غير الخطية) بين المتغيرات من التدريب على البيانات ذات مبالغ كبيرة، كما توفر خوارزميات تعلم الآلة تقنيات اختيار متغيرة وتقليل الأبعاد عن طريق تقليل التباين الزائد بين المتغيرات، وتحتوي تلك الخوارزميات على طرق لتجنب مشاكل الملائمة الزائدة، أي أن خوارزميات تعلم الآلة مناسبة تماماً لمهام التنبؤ التي تتضمن مدخلات عالية الأبعاد بأشكال وظيفية غير معروفة، وهذا جعلها تتفوق على النماذج الخطية التقليدية في مجال التنبؤ (Amel-Zadeh, et al., 2020).

حيث يتعلق الأمر بأساليب التعلم لخوارزميات تعلم الآلة عادةً ما يتم التمييز بين مهام تعلم الآلة الخاضعة للإشراف وغير الخاضعة للإشراف، حيث يتم تطبيق خوارزميات تعلم الآلة الخاضعة للإشراف على المشكلات المتعلقة بقاعدة البيانات المناسبة، مما يسمح بتحديد الأنماط بناءً على العينات السابقة، ويجب أن تكون الأنماط المحددة صالحة بمرور الوقت وقابلة للتطبيق على مجموعات البيانات المماثلة لضمان تعلم العلاقات الصحيحة ودقة التنبؤات المستقبلية (Chollet, 2021).

بينما يتم تطبيق خوارزميات تعلم الآلة غير الخاضعة للإشراف على المشكلات الجديدة التي لا يمكن حلها عن طريق تحديد العلاقات بين المدخلات والمخرجات في مجموعة البيانات، حيث تقوم هذه الخوارزميات بتحليل الارتباطات بين عينات بيانات الإدخال دون أي متغيرات مستهدفة لتحديد مجموعات الميزات التي قد يكون لها تأثير على المخرجات غير المعروفة، لذا تعد خوارزميات تعلم الآلة الخاضعة للإشراف طريقة تعليمية مناسبة لمشكلة التنبؤ (Kureljusic, & Metz, 2023).

ومع تزايد الاهتمام في البيئة المحاسبية بدمج خوارزميات تعلم الآلة كمجموعة من أدوات إعداد التقارير للتنبؤ بجودة التقارير وتحليلها وتحسينها، ونظراً لتعلم خوارزميات تعلم الآلة الأنماط المخفية للبيانات بطريقة تحكمها مجموعة محددة من المعلمات المفرطة، كما يعتمد تحديد المجموعة المثلى للمعلمات المفرطة التي تنتج نموذجاً مع التنبؤ الأكثر دقة على التجربة والخطأ (Ding, et al., 2020)، وتأكيد كلاً من مجلس المحاسبين المهنيين القانونيون في كندا (CPA Canada) والمعهد الأمريكي للمحاسبين القانونيين (AICPA) على قدرة خوارزميات تعلم الآلة في التقاط ممارسات تلاعب الإدارة بالقوائم المالية، كما أوضحت دراسة أجرتها شركة برايس ووترهاوس كوبرز (PwC, 2017) أن الهيئات التنظيمية والسلطات الضريبية ستستفيد أيضاً من استخدام خوارزميات تعلم الآلة في العثور على التناقضات في العائدات المفصح عنها (Hammami, & Hendijani Zadeh, 2022).

حيث يمكن لتحليلات خوارزميات تعلم الآلة تحسين عملية صنع القرار للإدارة من خلال فهم البيانات الضخمة لأنواع مختلفة من المشاكل التحليلية وهي: (1)

التحليلات الوصفية التي تشرح ما يحدث في الوقت الحاضر؛ (٢) التحليلات الإرشادية التي تخطط لما يجب القيام به في المستقبل؛ و (٣) التحليلات التنبؤية التي تحلل احتمالات المستقبل، وعلى الرغم من أن كل هذه الأنواع من التحليلات مهمة لمختلف الشركات، إلا أن التحليلات التنبؤية ذات أهمية قصوى في الأسواق المالية لأنها ترتبط مباشرة بوحدة من النظريات الأكثر شعبية وإثارة للجدل في مجال التمويل، وهي فرضية السوق الفعالة (EMH) التي قدمها (Fama, 1970) (Akyildirim, et al., 2023).

ووفقاً لتأكيد بعض الدراسات (Barth, Binz, 2022; Bertomeu, 2021) و2023؛ علي جودة خوارزميات تعلم الآلة في التنبؤ بالأخطاء والتحريفات، وفي قياس محتوى المعلومات، وتحليل القوائم المالية، حيث تسمح خوارزميات تعلم الآلة للشركات بتقديم قوائم مالية أكثر دقة وفي الوقت المناسب، ويرجع ذلك إلى طبيعة الذكاء الاصطناعي وقدرته على تحليل البيانات وتفسيرها على نطاق أسرع بكثير من البشر (Chen, et al., 2022).

حيث أكدت دراسة (Petkov, 2020) علي أن تمكين الذكاء الاصطناعي وخوارزميات تعلم الآلة من الدخول في وظيفة المحاسبة يمكن أن يقلل الأخطاء التي يرتكبها البشر إلى الحد الأدنى، وذلك لأن الأشخاص عرضة لارتكاب الأخطاء في تطبيق أي قواعد وأنظمة ويلاحظ هذا في كثير من الأحيان في وظيفة المحاسبة، ومن المتوقع إذا تم تفويض بعض المهام إلى الذكاء الاصطناعي وخوارزميات تعلم الآلة أو استبدالها وتطبيق المعايير المناسبة أو مجموعة من الإرشادات حول كيفية تنفيذ خوارزميات تعلم الآلة للتقديرات المحاسبية يجب أن تكون ذو دقة وموثوقية.

كما يمكن لخوارزميات تعلم الآلة استيعاب مساحة أكبر بكثير وذلك للاستفادة من معلومات أكثر دقة بالقوائم المالية، كما تعتمد خوارزميات تعلم الآلة علي شبكة واسعة في بحثها عن المواصفات التي تسمح بالارتباطات المعقدة بين المتنبئات عالية الأبعاد وتوقعات المتغيرات، لذا تعتبر هذه الخوارزميات متخصصة في مهام التنبؤ بدلاً من شرح المهام، أي أنها توفر أداء تنبؤي عالي خارج العينة باستخدام "التصنيف" كاستخدام عدد من أشجار القرار في الغابات العشوائية للتخفيف من فرط التجهيز (Chen, et al., 2022)، لذا يمكن استغلال قدرتها في توفير تقديرات محاسبية مستقلة بدون تحيز عند استخدامها كأداة تنبؤية.

كما أكدت دراسة (Chattopadhyay, et al., 2022) علي أن خوارزميات تعلم الآلة تساعد في توليد توقعات دقيقة وغير متحيزة للأرباح المستقبلية، وما إذا كانت هذه التنبؤات يمكن أن تؤدي إلى تقديرات أفضل للتكلفة الضمنية لرأس المال، فإذا قامت العديد من الشركات بتطبيق خوارزميات تعلم الآلة باستخدام معايير مدربة محددة مسبقاً، سوف يؤدي ذلك إلي وجود تحسن لإمكانية المقارنة بين الشركات لأغراض

إعداد التقارير المالية، ومن ثم ستصبح وظيفة المحاسبة في تلك المرحلة بمثابة اختبار للذكاء الاصطناعي بشكل أساسي لضمان الامتثال للقواعد وعدم التلاعب من قبل إدارة الشركة (Petkov, 2020)، وهذا من شأنه أن يساعد إلى حد ما في تقليل بعض الفرص المتاحة للوظيفة البشرية لارتكاب أعمال احتيالية معينة، مما يقلل من ممارسات تمهيد الدخل.

وذلك نظراً لاختلاف منهج خوارزميات تعلم الآلة في اكتشاف ممارسات إدارة الأرباح علي أساس الاستحقاق بالإضافة إلي اكتشافها لتحيز الإدارة عن الأساليب الإحصائية التقليدية، وذلك لأن استخراج هذه الخوارزميات للبيانات على عكس المنهج التقليدي، فخوارزمية الغابة العشوائية (FS) تقوم باختيار الميزات لتقليل الأبعاد المتجه في مجموعات البيانات عالية الأبعاد، أي أن تلك الخوارزمية تزيل الميزات المزجة والمتكررة لنموذج التعلم في مجموعات البيانات الكبيرة التي تتضمن العديد من الميزات (المتغيرات)، كما تحاول تلك الخوارزمية أيضاً في المشكلات عالية الأبعاد كإدارة الأرباح تحديد مجموعة فرعية من الميزات التي تساعد في الوصول إلى دقة التنبؤ المثلى لاكتشاف ممارسات إدارة الأرباح، لذا يتضح أن خوارزمية الغابة العشوائية تهدف إلي تعزيز دقة التنبؤ والقوة التفسيرية للتصنيف مما يقلل من تكلفة الحساب والتعقيد أيضاً لتحقيق الحل الأمثل (Hammami, & Hendijani Zadeh, 2022).

بالإضافة إلي مساعدة خوارزميات تعلم الآلة في التحسين من تقدير رصيد الحساب بشكل مباشر ومن ثم الإفصاح عن الآليات التي يمكن من خلالها قيام خوارزميات تعلم الآلة بالتخفيف من الأخطاء المتعمدة وغير المقصودة خاصةً حول تقديرات وإدراك احتياطات الخسائر كتقديرات المطالبات المستقبلية المتعلقة بالسياسات الحالية، وتعتبر تقديرات الخسائر المستمدة من خوارزميات تعلم الآلة مع بعض استثناءات قليلة أعلى من تقديرات الخسارة الإدارية الفعلية التي تستند إليها التقارير المالية، ومن ثم يمكن الاستفادة من إمكانية خوارزميات تعلم الآلة في تقييم موثوقية التقديرات الأساسية للتقارير المالية ومن ثم تحسين جودة وفائدة المعلومات المالية، بالإضافة إلي قدرة خوارزميات تعلم الآلة على تحسين قدرة المراجعين بشكل كبير على تقييم التقديرات المحاسبية، وبالتالي تعزيز الفائدة المالية لمعلومات المستثمرين (Ding, et al., 2020).

واتفق مع هذا الرأي دراسة (Petkov, 2020) حين أكدت علي أهمية وتفوق استخدام الخدمات المالية جنباً إلى جنب مع خوارزميات تعلم الآلة لإنشاء مصنفات تعلم جماعية مقارنةً بالأساليب التقليدية، فهذا بدوره ساعد علي التغلب على مشكلات مالية مختلفة مثل التنبؤ بإفلاس الشركات والتنبؤ بمدى صحة التقديرات المحاسبية، حيث تقوم خوارزمية الغابة العشوائية بإضافة أو إزالة ميزات من مجموعات فرعية مختلفة

من الميزات، وبعد ذلك يتم تقييم المجموعة الفرعية التي تم إنشاؤها بواسطة نموذج التصنيف، ويتم اختيار أفضل مجموعة فرعية بأعلى دقة، وهذا بدوره يجعل التصنيف سريعاً مما يساعد على زيادة موثوقية التقديرات المحاسبية، ومن ثم يقلل تحد من ممارسات تمهيد الدخل.

وأكدت دراسة (Hunt, et al . 2022) على أنه عند استخدام خوارزمية الغابة العشوائية في التنبؤ بمدي زيادة الأرباح المستقبلية تقوم الخوارزمية باكتشاف متى تكون زيادة الأرباح أكثر ترجيحاً للشركات بالإضافة إلى القيم الكبيرة لإجمالي الأصول مقارنة بالشركات ذات القيم الصغيرة لإجمالي الأصول، وبعد ذلك تشكل عقدة ذات جانبيين مهمين الأولي هي تحديد إجمالي الأصول كمتغير مفيد، والثانية هي تحديد القيمة المثلى لتقسيم الملاحظات في مجموعات الأصول الإجمالية الكبيرة والصغيرة، وتكرر هذه العملية بحيث أنها تستمر في إنشاء المزيد من العقد حتي تتوصل من خلالها إلى إيجاد أفضل حل في كل عقدة وهذه هي الطريقة التي تقوم بها العقد لفصل البيانات المتميزة، ويتضح من ذلك أن الغابة العشوائية تقسم الملاحظات إلى احتمالات عالية ومنخفضة لزيادة الأرباح المستقبلية بناءً على القيم التي يمكن ملاحظتها من القوائم المالية، وهذا بدوره يحد من قيام الإدارة باختزال الأرباح في حالة زيادتها لفترات أخرى ومن ثم تحد من ممارستها لتمهيد الدخل (Hunt, et al . 2022).

فقد لا تحتاج خوارزميات تعلم الآلة إلى تحسين التنبؤ ولكن يمكن أن تعطي مسارات لمعرفة الثغرات التي تؤدي إلى سوء التقديرات المحاسبية، حيث تقوم خوارزميات تعلم الآلة بتحليل شامل لجميع البيانات المتواجدة على عكس تقدير الإدارة الذي يتجاهل البعض من المعلومات العامة المستخدمة في الخوارزمية، فالمتغيرات التي لا تستخدمها الإدارة من الممكن أن تجعل التقديرات المحاسبية تحتفظ بأهميتها أو تصبح أكثر أهمية نسبياً، في حين أن المتغيرات التي تدرسها الإدارة يجب أن تفقد معظم أهميتها بعد دمج تقديرات الإدارة، وذلك لأنه من غير الممكن أن تكون جميع المعلومات جزءاً من وضع الإدارة للتقديرات المحاسبية لأن الإجراءات من الناحية المؤسسية لا تجري تعديلات على هذه المتغيرات، لذا تحسن خوارزميات تعلم الآلة من جودة التقديرات المحاسبية فقد ينتج عن سوء التقدير أنماطاً يمكن لتلك الخوارزميات اكتشافها بالإضافة إلى إدراكها لعدم التأكد (Bertomeu, 2020)، وهذا بدوره يؤدي إلى تحسين جودة التقديرات المحاسبية ومن ثم تقليل ممارسات تمهيد الدخل.

وفقاً لدراسة (Commerford, et al., 2022) تعتبر التقديرات المحاسبية المعقدة ذاتية بطبيعتها لأنها تطلعية، ويمكن للمديرين دمج مجموعة متنوعة من المدخلات والافتراضات التي يصعب التحقق منها، ويمكن أن تختلف طبيعة مدخلات التقدير، حيث تبدو بعض المدخلات أكثر موضوعية من غيرها، حيث تبدو المدخلات المستندة إلى مصادر البيانات الخارجية أكثر موضوعية من المدخلات المستندة إلى توقعات

الإدارة وافتراضاتها، في حين أن التقديرات المحاسبية الناتجة عن خوارزميات تعلم الآلة تكون أفضل من التقديرات الإدارية لأنها قد تستخدم بيانات الأرشفة في تدريبها بشكل أكثر اتساقاً ومنهجية من المديرين، ومن ناحية أخرى قد يُدرج المديرون في تقديراتهم معلومات مستقبلية كمعلومات عن التضخم المتوقع أو حالة الاقتصاد والتي من الواضح أن خوارزميات تعلم الآلة تتجاهلها، ويتضح من ذلك تفوق خوارزميات تعلم الآلة على البشر في التنبؤ بالتقديرات المحاسبية (Ding, et al., 2020).

بالإعتماد على ما تم عرضه آنفاً، فإن استخدام خوارزميات تعلم الآلة يمكن أن تساهم بدرجة كبيرة في تحسين التنبؤ بالتقديرات المحاسبية والحد من ممارسات تمهيد الدخل في البيئة المصرية، وتناولت معايير المحاسبة المصرية الصادرة بالقرار رقم ٦٩ لسنة ٢٠١٩ التقديرات المحاسبية في أكثر من معيار ويمكن إيجاز أهمها ودور تعلم الآلة في تحسينها:

- تساعد خوارزميات تعلم الآلة على تقدير قيمة المخزون آخر المدة بدقة عالية نظراً لقدرتها على استخراج المعرفة من البيانات الضخمة وبأقل تكلفة ممكنة، كما يساعد تقدير تلك الخوارزميات للمخزون على الحد من تلاعب الإدارة بقيمتها من خلال استغلالها لمرونة معيار المحاسبة المصري رقم (٢) بعنوان "المخزون" ، والذي حدد إمكانية اختيار الإدارة بين عدة طرق مما يتيح للإدارة بدائل ويمكنها تقدير القيمة التي سيتم تخصيصها لتقدير قيمة المخزون باستخدام أي من الطرق المحددة في المعيار، ويعاب على ذلك أن التأثيرات الناتجة عن اختيار الإدارة لم تكن متماثلة نظراً لاعتمادها على الطريقة المعتمدة وخاصةً عندما يكون هناك تلاعب متعمد، وهذا ما ستقضي عليه خوارزميات تعلم الآلة.
- كما جاء المعيار رقم (٢٣) بعنوان "الأصول غير الملموسة" وأشار في الفقرتي (٢٢، ٢٣) الى أن الشركة يجب أن تقدر احتمالية تدفق المنافع الاقتصادية المستقبلية مستخدمة في ذلك افتراضات معقولة ، ومن ثم فإن مبالغ الشهرة المدرجة في التقارير المالية يمكن أن تؤثر على قيمة أصول الشركة، وبالتالي يجب تقديرها بعناية وبشكل صحيح لتجنب التحريفات، حيث يمكن أن يضعف ذلك من التمثيل الصادق للمعلومات المالية (Nangih, & Anichebe, 2021) ، وهنا يأتي دور خوارزميات تعلم الآلة نظراً لقدرتها على إجراء بتحليل شامل لجميع البيانات المتواجدة على عكس تقدير الإدارة الذي قد لا يهتم ببعض المعلومات المستخدمة في تلك الخوارزميات.
- أما طرق تقدير مخصص الديون المشكوك فيها وأرصدة المدينين التي يتمثل أهمها في طريقة الخصم المباشر من خلال الاعتماد على خصم مبلغ الدين في حالة عدم تحصيله واعتباره ديون معدومة دون تكوين أي مخصصات، أما الطريقة الأخرى تتمثل في تكوين مخصص كنسبة من رصيد المدينين، وتعتمد هذه الطرق على

المناخ الاقتصادي العام والوضع المالي لعملاء لذا ينبغي الاستعانة بخوارزميات تعلم الآلة نظراً لقدرتها علي التنبؤ بمدي استقرار المناخ الاقتصادي بالإضافة إلي قدرتها علي التنبؤ بالوضع المالي المستقبلي (Stein, 2019; Downes, et al., 2019).

- وبالنسبة لطرق تقدير الإهلاك فقد تناولت معايير المحاسبة المصرية والدولية العديد من طرق الإهلاك التي يمكن اتباعها، ولكن كل طريقة قد ينتج عنها نتائج مختلفة عن الأخرى، مما يؤثر على الدلالة القيمية للأصل الثابت، ومن ثم على قيمة الأصول الثابتة بقائمة المركز المالي (Nangih, & Anichebe, 2021)، ويتمحور دور خوارزميات تعلم الآلة هنا في الثبات علي الطريقة التي يتم التقدير بيها لهذا الإهلاك بالإضافة إلي قدرتها علي توقع العمر الإنتاجي المقدر للآلة وماهي الطريقة المناسبة لتقدير إهلاكها.

لذا فإن الدراسة الحالية تصيغ فروضها على النحو التالي:

H1 : لا توجد فروق جوهرية ذات دلالة إحصائية بين مستوى تمهيد الدخل عن طريق التنبؤ بالتقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية المتنبأ بها باستخدام الأساليب التقليدية.

H2 : لا توجد فروق جوهرية ذات دلالة إحصائية بين مستوى تمهيد الدخل عن طريق التنبؤ بالتقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية الفعلية لعينة الدراسة.

ثالثاً: الدراسة التطبيقية

تهدف الدراسة الحالية إلى دراسة دور استخدام خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية وأثره على مستوى تمهيد الدخل للشركات المقيدة في سوق الأوراق المالية المصري. ولكي يتمكن الباحث من تحقيق هذا الهدف فإنه سيقوم بإجراء التحليل الإحصائي أولاً باستخدام خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية لعينة الدراسة المختارة من الشركات المدرجة في السوق المصري. وفي هذا الشأن، سيعتمد الباحث على أكثر الخوارزميات التي استقر عليها الفكر المحاسبي في مجال تعلم الآلة وهي: خوارزمية الأقرب جار (K-Nearest Neighbour)، والشبكات العصبية (Neural Network)، وخوارزمية الغابات العشوائية (Random Forest)، وخوارزمية تعلم الآلة الاشرافي (Support Vector Machine).

وتأسيساً على ذلك، يمكن للباحث عرض الجانب التطبيقي للدراسة من خلال استعراض مجتمع وعينة الدراسة، وتعريف معلمات ومتغيرات القرار في ضوء خوارزميات تعلم الآلة، ثم تشغيل تلك الخوارزميات على عينة الدراسة، وأخيراً مقارنة

النتائج بين الأساليب التقليدية للتنبؤ وخوارزميات تعلم الآلة بغرض اختبار الفروق الجوهرية، وذلك على النحو التالي:

١/٣ مجتمع وعينة الدراسة

يتمثل مجتمع الدراسة في كافة الشركات المقيدة في سوق الأوراق المالية المصري، ولا سيما بالتركيز على الشركات الصناعية وذلك لأنها أكثر الأنشطة التي تستطيع التلاعب بالمعايير المحاسبية بما يمكنها من إجراء العديد من التقديرات المحاسبية بما يتناسب مع طبيعة النشاط الصناعي. وفي هذا الشأن قام الباحث باستبعاد البنوك وشركات التأمين والمؤسسات المالية لما لها من طبيعة خاصة، وبالتالي قام الباحث بحصر القطاعات الصناعية المتمثلة في خدمات ومنتجات صناعية وسيارات، والعقارات، والتشييد ومواد البناء والأغذية والمشروبات.

ونظراً لأن القرار الوزاري الصادر بشأن تطبيق معايير المحاسبة المصرية صادر سنة ٢٠١٩ برقم ٦٩، فإنه يمكن للباحث تحديد الفترة الزمنية للدراسة الحالية في الفترة من ٢٠١٩ إلى ٢٠٢٢ أي أن المدة المتاحة للسلسلة الزمنية مدتها ٤ سنوات.

وعلى هذا النحو، فقد سجلت الشركات الصناعية المصرية الموجودة بالقطاعات سالفة التحديد خلال فترة الدراسة عدد ١٦٨ مشاهدة (٤٢ شركة × ٤ سنوات)، وبحذف القيم الشاذة والمتطرفة البالغة ٣١ مشاهدة وكذلك بحذف القيم المفقودة البالغة ١٢ مشاهدة تبين أن العينة النهائية الصالحة للتحليل تبلغ ١٢٥ مشاهدة.

٢/٣ تحديد متغيرات الدراسة ومتنبآت تعلم الآلة:

تختلف طبيعة الدراسة الحالية عن العديد من الدراسات المحاسبية، وذلك لأن المتغير المستقل بالدراسة الحالية هو متغير التقديرات المحاسبية باستخدام تعلم الآلة وتطبيقاته على الشركات الصناعية محل الدراسة، أما المتغير التابع فهو تمهيد الدخل، ومن ثم يمكن للباحث عرض هذا الجزء من الدراسة على النحو التالي:

١/٢/٣ المقياس التقليدي للتقديرات المحاسبية (كمتغير مستقل):

في إطار التطبيق المحاسبي السليم لمعايير المحاسبة المصرية والمنبثقة من معايير التقرير المالي الدولية، يتضح أن أهم مواطن وجود التقديرات المحاسبية تتمثل في: تقييم القيمة العادلة، واضمحلال قيمة الأصول، والتقديرات الأخرى المتعلقة بالأصول الضريبية المؤجلة وإجمالي الالتزامات والمخصصات والاحتياطات (Lau, et al., 2021).

وفي هذا الشأن يمكن للباحث تحديد القياس التقليدي للتقديرات المحاسبية من خلال حجم التقديرات المحاسبية أو المبلغ المتعلق بهم جميعاً من القوائم المالية الموجودة للشركات الصناعية محل الدراسة.

٢/٢/٣: متنبآت تعلم الآلة لقياس التقديرات المحاسبية (كمتغير مستقل):

في إطار تحقيق هدف الدراسة الحالي ستصبح متغيرات ومعلومات الدراسة هي كافة المتغيرات التي يمكن استخدامها لتغذية خوارزميات تعلم الآلة للتنبؤ بحجم التقديرات المحاسبية على المستويات الثلاثة المختلفة السابق ذكره بمقياس التقديرات المحاسبية التقليدي. وبناء على ذلك تصبح (X1, X2, X..... Xn) هي المعبرة عن متغيرات ومعلومات التنبؤ بالتقديرات المحاسبية ويمكن تعريف كل منها على النحو التالي:

جدول رقم (١): متنبآت تعلم الآلة بالتقديرات المحاسبية

| المتغير | التفسير |
|---------|--|
| X1 | صافي الدخل قبل البنود غير العادية مقسوماً على إجمالي الأصول |
| X2 | الأصول المتداولة مقسومة على إجمالي الالتزامات |
| X3 | الرافعة المالية |
| X4 | مؤشر الخسارة، وهو متغير وهمي يأخذ القيمة ١ في حالة الخسارة والقيمة صفر فيما عدا ذلك |
| X5 | إجمالي أرصدة المخزون والعملاء مقسومة على إجمالي الأصول |
| X6 | متغير وهمي يأخذ القيمة ١ عند اعتراف الشركة بوجود بنود خاصة (special Item) والقيمة صفر فيما عدا ذلك |
| X7 | تكلفة رأس المال |
| X8 | الجذر التربيعي لعدد قطاعات الأعمال بالشركة |
| X9 | متغير وهمي يأخذ القيمة ١ إذا تم وجدت عمليات تشغيلية أجنبية والقيمة صفر فيما عدا ذلك |
| X10 | مؤشر التدفق النقدي من التشغيل |
| X11 | إجمالي الاستحقاقات للشركة خلال الفترة المالية |
| X12 | متغير وهمي يأخذ القيمة ١ إذا تم تواجد دخل غير معدل والقيمة صفر فيما عدا ذلك |
| X13 | الانحراف المعياري للدخل السنوي قبل البنود غير العادية |
| X14 | التغير في إيرادات المنشأة خلال الفترة المالية |
| X15 | مستوى العسر المالي مقيساً بمؤشر Z-Score |

٣/٢/٣ قياس مستوى تمهيد الدخل (كمتغير تابع)

يعبر تمهيد الدخل عن قدرة الشركة على السيطرة على التقلبات المختلفة في دخل الشركة خلال الفترات المالية المختلفة. وفي هذا الشأن، يمكن للباحث الاعتماد على

بواقفي نموذج (Lang et al. 2012) كمقياس متعارف عليه لتحديد مستوى الدخل المحاسبي، وذلك وفقاً للنموذج التالي:

$$SMTH = \beta_0 + \beta_1 \text{ Size} + \beta_2 \text{ Lev} + \beta_3 \text{ BM} + \beta_4 \text{ STD_Sale} + \beta_5 \text{ Loss} + \beta_6 \text{ Opcycle} + \beta_7 \text{ SG} + \beta_8 \text{ Oplev} + \beta_9 \text{ AVECFO} + \varepsilon$$

حيث أن:

- SMTH = الانحراف المعياري للدخل خلال ٣ سنوات؛
- Size = لوغاريتم القيمة الدفترية للشركة مقياساً بحجم الأصول؛
- Lev = الرافعة المالية وتساوي إجمالي الأصول على إجمالي الالتزامات؛
- BM = معدل القيمة الدفترية إلى إجمالي القيمة السوقية للشركة؛
- STD_Sale = الانحراف المعياري للمبيعات لمدة من ٣ إلى ٥ سنوات؛
- Loss = مؤشر الخسارة، متغير وهمي يأخذ القيمة ١ في حالة الخسارة والقيمة صفر فيما عدا ذلك؛
- Opcycle = طول الدورة التشغيلية للشركة ويساوي لوغاريتم الطبيعي لعدد أيام دوران حسابات العملاء؛
- SG = معدل نمو المبيعات للسنة الحالية عما يسبقها؛
- Oplev = كثافة رأس المال، وتقاس بصافي الممتلكات والمعدات والآلات مقسومة على إجمالي الأصول؛
- AVECFO = متوسط التدفقات النقدية من العمليات التشغيلية مقسومة على إجمالي الأصول.

٣/٣ اختبارات المتانة لأدوات القياس المختلفة

يهدف الباحث من خلال هذه الخطوة إلى اختبار الصلاحية البنائية لمقاييس الدراسة تحديداً حيث أنهما يعتمدان على المقاييس المركبة متعددة الأبعاد. وفي هذا الشأن يمكن للباحث الاعتماد على كلٍ من:

- تحديد المعاملات المعيارية لتقييم صلاحية مكونات المقياس.
- استخدام متوسط التباين المستخرج لمعاملات التحميل.
- حساب معامل الثبات المركب للمقياس ككل.

وتحقيقاً لذلك قد أوضحت نتائج التحليل الإحصائي عن المعاملات المعيارية للمكونات الفرعية لمقياس متنبات تعلم الآلة ومعامل الثبات المركب للمقياس ككل وفقاً للجدول رقم (٢) التالي:

جدول رقم (٢): نتائج صلاحية مقاييس المتغيرات المستقلة

| الصدق التقاربي | | معاملات التحميل | | المتغير |
|------------------|----------------------|-----------------|-------|---|
| الثبات المركب CR | التباين المستخلص AVE | معامل التحميل | البعد | |
| ٠.٧٢١ | ٠.٧٣٨ | ٠.٧٣٠ | X1 | متنبآت تعلم الآلة للتقديرات المحاسبية |
| | | ٠.٧٢٤ | X2 | |
| | | ٠.٧٥٠ | X3 | |
| | | ٠.٧٦٠ | X4 | |
| | | ٠.٦٨٧ | X5 | |
| | | ٠.٧٧٢ | X6 | |
| | | ٠.٧٤٣ | X7 | |
| | | ٠.٧١٧ | X8 | |
| | | ٠.٧٦٠ | X9 | |
| | | ٠.٧٦٣ | X10 | |
| | | ٠.٦٨٥ | X11 | |
| | | ٠.٦٩١ | X12 | |
| | | ٠.٧٢٣ | X13 | |
| | | ٠.٧١٤ | X14 | |
| | | ٠.٦٩٦ | X15 | |

ويتضح لدى الباحث من النتائج المعروضة بالجدول السابق مجموعة الملاحظات التي يمكن توضيحها فيما يلي:

١. جميع المعاملات المعيارية مقبولة فوفقاً لدراسة (Hair, et al., 2010) يتضح أن قيم المعاملات المعيارية المقبولة لا بد وأن تكون مساوية أو أكبر من ٠.٥، ومن ثم لن يتم حذف أي مكون من مكونات المقاييس الفرعية للمتغيرات المستقلة.
٢. تبين أن قيم الصدق التقاربي المعبر عنه بمتوسط التباين المستخلص (AVE) والثبات المركب (CR) ذات قيم كبيرة، حيث كانت قيم الثبات المركب أكبر من ٠.٥، ومن ثم قبول الصدق التقاربي للنموذج وذلك لارتفاع متوسط التباين عن ٠.٥ حيث أن قيم AVE المقبولة لا بد وأن تكون مساوية أو أكبر من ٠.٥، وهو ما يشير إلى أن المكونات الفرعية للمتغيرات المستقلة تفسر أكثر من ٥٠% من المتغير نفسه.

٤/٣ الإحصاء الوصفي لمتنبآت الدراسة ومتغيراتها

تعبر الإحصاءات الوصفية عن الشكل التوزيعي للعينة والتي يمكن على أساسه الحكم على طبيعة العينة وامكانية مقارنة نتائج العينة بالدراسات الأخرى ذات الصلة، وقد أوضحت نتائج التحليل الإحصائي عن الجدول رقم (٣) التالي:

جدول رقم (٣): نتائج الإحصاء الوصفي لمتنبات الدراسة ومتغيراتها

| Max. | Min. | Std. Dev. | Mean | البعد | المتغير |
|-------|-------|-----------|-------|-------|---------------------------------------|
| ٠.٣٦ | ٠.١٢- | ٠.١١ | ٠.٢١ | X1 | متنبات تعلم الآلة للتقديرات المحاسبية |
| ٠.٨١ | ٠.٤٤ | ٠.٠٥ | ٠.٥٣ | X2 | |
| ٠.٤١ | ٠.١٥ | ٠.٠٥ | ٠.٢٣ | X3 | |
| ١.٠٠ | ٠.٠٠ | ٠.١٣ | ٠.٠٨ | X4 | |
| ٠.٣٩ | ٠.٠٩ | ٠.١٠ | ٠.٢٥ | X5 | |
| ١.٠٠ | ٠.٠٠ | ٠.٠٤ | ٠.٠٥ | X6 | |
| ١.٠٠ | ٠.٠٠ | ٠.١٤ | ٠.٣٦ | X7 | |
| ٤.٠٠ | ١.٠٠ | ٠.٠٩ | ١.٢٧ | X8 | |
| ١.٠٠ | ٠.٠٠ | ٠.١٥ | ٠.٠٧ | X9 | |
| ١.٠٠ | ٠.٠٠ | ٠.٠٣ | ٠.٠٢ | X10 | |
| ٢٢.٠٠ | ٥.٠٠ | ٠.١٠ | ١٠.٧١ | X11 | |
| ٦.٠٠ | ٢.٠٠ | ٠.٠٣ | ٣.٢٥ | X12 | |
| ٠.٧١ | ٠.١٢ | ٠.٠٦ | ٠.٦٢ | X13 | |
| ٣.١١ | ٠.٨٩ | ٠.٠٨ | ١.٣٦ | X14 | |
| ٣.٢١ | ٠.٥٧ | ٠.٠٣ | ٠.٨٦ | X15 | |

ويتضح لدى الباحث من خلال العرض السابق أن نتائج الإحصاء الوصفي تشير إلى اعتدالية البيانات وتوزيعها القابل للمقارنة بين الدراسات ذات الصلة.

٥/٣ تحليل البيانات باستخدام أساليب تعلم الآلة

ينتج عن استخدام أساليب تعلم الآلة أشكال التنبؤ والأخطاء الموجودة به في إطار ثلاثة مستويات للملائمة للنموذج، حيث يتمثل المستوى الأول في Training set والتي تعبر عن المجموعة الإحصائية التي يتم الاعتماد عليها في ملائمة معلمات كل نموذج عند القيام بعملية التنبؤ وهي تمثل نسبة ٨٥% من عملية التنبؤ، وبعد اكتمال هذه النسبة يتم الاعتماد على المستوى الثاني المتمثل في Ten-fold cross-validation لأداء إجراءات تحديد ملائمة النموذج، وأخيراً في المستوى الثالث يتم تقسيم درجة الملائمة بنسب ٧٥% للمؤشر Train و ٢٥% للمؤشر Test وذلك لعدم المبالغة في درجات الملائمة والسيطرة على عدم استقرار البيانات. ويمكن استخدام كافة المستويات الثلاثة على النحو التالي:


١/٥/٣ خوارزمية الجار الأقرب (K-Nearest Neighbour)

تعتبر خوارزمية الجار الأقرب عن البحث عن انتماءات النقطة المجهولة في حالة تعدد مجموعات البيانات المختلفة المحيطة بهذه النقطة، من خلال قيامه القيام بتصنيف عينة غير معروفة اعتماداً على التصنيف المعروف لجيرانها، كما يمكنه التنبؤ به من خلال مقارنة السجلات الشبيهة بالسجل المراد التنبؤ له وتقدير القيمة المجهولة لهذا السجل وفقاً لمعلومات تلك السجلات، فبشكل عام يمكن أن تكون قاعدة التصنيف هذه ضعيفة لأنها تستند إلى قاعدة واحدة في عينة معروفة (علي، ٢٠٢٣)، ومن ثم فإن هذه الخوارزمية تساعد في عملية التصنيف، وبناء على استخدام أساليب تلك الخوارزمية، فقد أظهرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (٤): نتائج دقة استخدام خوارزمية الجار الأقرب للتنبؤ بالتقديرات المحاسبية

| Model | مستوى الدقة Accuracy (%) | مستوى الخطأ (%) error | قيمة F | المساحة تحت المنحنى ROC |
|------------------------------|-----------------------------|--------------------------|--------|----------------------------|
| Training set | 0.923 | 0.077 | 0.913 | 0.904 |
| Ten-fold cross-validation | 0.707 | 0.293 | 0.669 | 0.624 |
| Train (75%)-Test (25%) split | 0.740 | 0.260 | 0.695 | 0.716 |

ويتضح من الجدول السابق أنه وفقاً لمستوي Training Set للبيانات يوجد به ارتفاع مستويات الدقة والتي تعد مجموعة البيانات محل الاختبار الرئيسي المعبرة عن القيم التنبؤية التي تنبأ بها أسلوب الجار ، وهذا يدل على ارتفاع مستوى الدقة في هذه النتائج بما يعادل ٩٢.٣% مما يشير إلى أن القيم التي تنبأت بها هذه الأسلوب تنسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٧.٧% أي أن قيمة F تقترب من الواحد الصحيح وهي تبلغ ٠.٩١٣ ، وعلى مستوى اختبار Ten-fold cross-validation أتضح أنه مستوى الدقة يبلغ ٧٠.٧٠%، أما مستوى Train (75%)-Test (25%) split يبلغ ٧٤% على مستوى التداخل بين البيانات الأصلية والمتنبأ بها Training VS Testing Data. وفيما يتعلق بالمساحة تحت المنحنى فقد أوضحت نتائج التحليل الإحصائي أن المساحة تحت المنحنى لأسلوب الجار الأقرب كانت على النحو التالي:



Diagonal segments are produced by ties.

وفي هذا الشأن أوضحت دراسة (Hosmer & Lemeshow, 2000) أن مستويات الدقة المتعلقة بحساب المساحة تحت المنحنى تبين أن الدرجات المعيارية للمساحة تحت المنحنى تأخذ المدى التالي:

| المدى | درجة الجودة |
|---------|-------------|
| ١٠٠-٩٠% | ممتاز |
| ٩٠-٨٠% | جيد |
| ٨٠-٧٠% | عادل |
| ٧٠-٦٠% | ضعيف |
| ٦٠-٥٠% | فاشل |

وتبلغ المساحة تحت المنحنى لنموذج Training Set ٩٠.٤% وهذا يعتبر ممتاز وفقاً للجدول المعياري السابق ، أما على مستوى المتانة ومستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data فيتبين أن المساحات تحت المنحنى تبلغ ٦٢.٤%، ٧١.٦% وهي ضعيفة وعادلة على التوالي وفقاً للنموذج المعياري، ويتضح من ذلك تفوق خوارزمية الأقرب جار على التنبؤات اليدوية.

٢/٥/٣ خوارزمية الشبكات العصبية (Neural Network)

تعتبر خوارزمية الشبكات العصبية نوع آخر من خوارزميات تعلم الآلة والتي تتكون من طبقات متعددة من العقد المترابطة فيما بينها بيانات الإدخال والإخراج، وتقوم كل طبقة بتحويل بيانات الإدخال الخاصة بها إلى بيانات أكثر للتمثيل ثم يتم إدخالها للطبقة التالية، وتحتوي الشبكة العصبية الاصطناعية على ثلاثة أنواع من الطبقات وهما المدخلات وطبقات مخفية وطبقة المخرجات، حيث تتلقى طبقة المدخلات


البيانات الأولية للمتغيرات التفسيرية ويساوي عدد العقد في طبقة الإدخال عدد المتغيرات التوضيحية، وبالتالي ترتبط طبقة المدخلات بالطبقات المخفية والتي تطبق تحولات معقدة على البيانات الواردة ونقل المخرجات إلى الطبقات المخفية التالية، وتسمى الطبقة النهائية بطبقة المخرجات التي تمثل معلومات عالية المستوى المستخرجة من البيانات الأولية (Ding, et al., 2020).

كما تقوم خوارزمية الشبكات العصبية باستخدام الدوال غير الخطية للتنبؤ بالأحداث المستقبلية بناء على البيانات التاريخية لمجموعة من العوامل المحيطة بالظاهرة محل التنبؤ، حيث أنها تعمل باستخدام أسلوب المحاكاة للوصول إلى أفضل السيناريوهات الممكنة للتنبؤ بشكل التقديرات المحاسبية، وقد أوضحت المحاكاة باستخدام الخوارزميات للشبكات العصبية عن التنبؤات التالية لعينة الدراسة.

جدول رقم (٥): نتائج دقة استخدام خوارزمية الشبكات العصبية للتنبؤ بالتقديرات المحاسبية

| Model | مستوى الدقة Accuracy (%) | مستوى الخطأ (%) error | قيمة F | المساحة تحت المنحنى ROC |
|------------------------------|-----------------------------|--------------------------|--------|----------------------------|
| Training set | 0.956 | 0.044 | 0.915 | 0.910 |
| Ten-fold cross-validation | 0.715 | 0.285 | 0.645 | 0.600 |
| Train (75%)-Test (25%) split | 0.785 | 0.215 | 0.687 | 0.708 |

يتبين من الجدول السابق ارتفاع مستويات الدقة على مستوى Training Set للبيانات حيث تعبر تلك عن القيم التنبؤية التي تتنبأ بها أسلوب الشبكات العصبية، وقد بلغ ارتفاع مستوى الدقة حوالي ٩٥.٦% أي أن القيم التي تنبأت بها الخوارزمية تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٤.٤% ومما يدل ذلك اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٠.٩١٥، في حين بلغ مستوى الدقة في مستوى Ten-fold cross-validation ٧١.٥%، أما مستوى Training VS Testing Data بلغ ٧٨.٥%، وبالنسبة للمساحة تحت المنحنى فقد تبين من نتائج التحليل الإحصائي أن المساحة تحت المنحنى للشبكات العصبية كانت على النحو التالي:



Diagonal segments are produced by ties.

وبما أن مستوى Training Set بلغ ٩١% فإنها تعتبر ممتازة وفقاً للجدول المعياري السابق أما على مستوى المتانة ومستوى التداخل بين البيانات الأصلية والمتنبأ بها Training VS Testing Data فيتبين أن المساحات تحت المنحنى تبلغ ٦٠%، ٦٨.٧٠% وهي ضعيفة لكلا المستويين على التوالي وفقاً للنموذج المعياري وهذا يعني تفوق الشبكات العصبية على التنبؤات اليدوية.


٣/٥/٣ خوارزمية الغابات العشوائية (Random Forest)

تعتبر خوارزمية الغابات العشوائية عن أسلوب للتعلم الآلي تم تطويرها بناءً على مجموعة من أشجار القرار، وتستخدم هذه الأسلوب للتصنيف، الانحدار ومهام أخرى، فهو يجمع بين التصنيف المتعدد وأشجار الانحدار (CART) للتنبؤ غير الخطي (Amel-Zadeh, et al., 2020)، وعادةً ما تتمتع خوارزمية الغابة العشوائية بدقة أفضل مقارنةً بشجرة القرار. ويمكن للباحث استخدام الغابات العشوائية والتوصل إلى النتائج التالية:

جدول رقم (٦): نتائج دقة استخدام خوارزمية الغابات العشوائية للتنبؤ بالتقديرات المحاسبية

| Model | مستوى الدقة Accuracy (%) | مستوى الخطأ (%) error | قيمة F | المساحة تحت المنحنى ROC |
|------------------------------|-----------------------------|--------------------------|--------|----------------------------|
| Training set | 0.928 | 0.072 | 0.908 | 0.908 |
| Ten-fold cross-validation | 0.720 | 0.280 | 0.671 | 0.619 |
| Train (75%)-Test (25%) split | 0.760 | 0.240 | 0.698 | 0.708 |

ويتضح من الجدول السابق ارتفاع مستويات الدقة في المستوى Training Set للبيانات وهذا يعني أن القيم التنبؤية التي تنبأ بها أسلوب الغابات العشوائية يصل إلي ما يقارب ٩٢.٨% أي أن القيم التي تنبأ بها الأسلوب تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٧.٢% ، أي أن قيمة F تقترب من الواحد الصحيح وتقدر قيمتها ٠.٩٠٨ ، أما مستوى Ten-fold cross-validation يبلغ ٧٢%، بينما بلغ مستوى Training VS Testing Data ٧٦% على مستوى التداخل بين البيانات الأصلية والمتنبأ بها. وفيما يتعلق بالمساحة تحت المنحنى فقد تبين من نتائج التحليل الإحصائي أن المساحة تحت المنحنى للغابات العشوائية كانت على النحو التالي:



Diagonal segments are produced by ties.

ونظراً لأن المساحة تحت المنحنى لنموذج Training Set تبلغ ٩٠.٨% فإنها تعتبر ممتازة وفقاً للجدول المعياري السابق أما على مستوى المتانة ومستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data فيتبين أن المساحات تحت المنحنى تبلغ ٦١.٩%، ٧٠.٨% وهي ضعيفة وعادلة لكلا المستويين على التوالي وفقاً للنموذج المعياري وهو ما يبرهن تفوق الغابات العشوائية على التنبؤات اليدوية.

٤/٥/٣ خوارزمية تعلم الآلة الإشرافي (Support Vector Machine)


تعد خوارزمية تعلم الآلة الإشرافي أيضاً من خوارزميات تعلم الآلة الذي يعمل على زيادة الأداء في التعرف على الأنماط ثم التنبؤ بالسلاسل الزمنية المالية والتسويق وتقدير إنتاجية التصنيع، كما ينتج عنه مصنفاً ثنائياً ويسمى بالطبقات الفائقة الفاصلة المثلي عن طريق رسم خرائط غير خطية للغاية لمواجهة الإدخال، فهي تقوم بالتوصل إلي حلاً فريداً ومثالياً، وبالنسبة لدوره في حل مشاكل التنبؤ المالي بالدقة والمقبولية يتم من خلال قياس تنبؤات معينة لانحرافات التقديرات عن القيم المرصودة (Chen, et al. 2022)، وأكدت دراسة (Fischer, et al., 2020) علي دقة تنبؤ تعلم الآلة الإشرافي كخوارزمية تعلم خاضعة للإشراف بالأرباح الفصلية بدقة عالية، كما أوضح أن خوارزمية تعلم الآلة الإشرافي تعمل بشكل أفضل في التنبؤ.

وتستخدم هذه الخوارزمية برنامج التشغيل الإلكتروني Python للحصول على نتائج التنبؤ بالتقديرات المحاسبية، حيث تساعد هذه اللغة البرمجية على ضم وتشغيل خوارزميات تعلم الآلة، والجدير بالذكر أن هذه الخوارزمية تقوم بعمل التنبؤات استناداً إلى البيانات التي تم تغذيتها على النظام، وقد أوضحت نتائج التحليل الإحصائي عن التالي:

جدول رقم (٧): نتائج دقة استخدام خوارزمية تعلم الآلة الإشرافي للتنبؤ بالتقديرات المحاسبية

| Model | مستوى الدقة Accuracy (%) | مستوى الخطأ (%) error | قيمة F | المساحة تحت المنحنى ROC |
|------------------------------|-----------------------------|--------------------------|--------|-------------------------------|
| Training set | 0.920 | 0.080 | 0.907 | 0.906 |
| Ten-fold cross-validation | 0.720 | 0.280 | 0.649 | 0.602 |
| Train (75%)-Test (25%) split | 0.748 | 0.252 | 0.697 | 0.724 |

يتبين من الجدول السابق أن مستوى Training Set للبيانات يرتفع به مستويات الدقة للبيانات محل الاختبار الرئيسي، وقد ارتفع مستوى الدقة في هذه النتائج بما يقارب ٩٢% أي أن القيم التنبؤية التي تنبأت بها الأسلوب الرئيسية لتعلم الآلة الإشرافي تتسم بارتفاع مستوى الدقة، وهذا يعني أن مستوى الخطأ التنبؤي بها يبلغ ٨% أي أن قيمة F اقتربت من الواحد الصحيح وهي تبلغ ٠.٩٠٧، كما بلغ مستوى Ten-fold cross-validation ٧٢%، في حين بلغ مستوى Training VS Testing Data ٧٤.٨% على مستوى التداخل بين البيانات الأصلية والمتنبأ بها. وفيما يتعلق بالمساحة تحت المنحنى فقد تبين من نتائج التحليل الإحصائي أن المساحة تحت المنحنى لتعلم الآلة الإشرافي كانت على النحو التالي:



Diagonal segments are produced by ties.

وفي ظل بلوغ مستوى Training Set ٩٠.٦% في المساحة تحت المنحنى فهذا يعتبر نسبة ممتازة وفقاً للجدول المعياري السابق، بينما بلغ مستوى Ten-fold cross-validation ومستوى Training VS Testing Data ٦٠.٢%، ٧٢.٤% في المساحات تحت المنحنى وهي ضعيفة وعادلة لكلا المستويين على التوالي وفقاً للنموذج المعياري وهذا يدل على تفوق تعلم الآلة الإشرافي على التنبؤات اليدوية.

٦/٣ نتائج التنبؤ باستخدام الطرق التقليدية

يستخدم الباحث في هذا الجزء من الدراسة الأساليب التقليدية للتنبؤ بالتقديرات المحاسبية وتعتبر هذه الأساليب الإحصائية المتعارف عليها في المجال المحاسبي

والمتمثلة في أسلوب تحليل Probit، وسيتم تشغيل هذا الأسلوب والحصول منه على تنبؤات بالتقديرات المحاسبية بالتوازي مع التنبؤات المستخرجة من أساليب تعلم الآلة، وقد أوضحت نتائج التحليل الإحصائي عن النتائج التالية:

جدول رقم (٨): نتائج تحليل أسلوب Probit

| Parameter | Estimate | Std. Error | Z | Sig. |
|-------------------------------|----------------|------------|-------|-------|
| X1 | 4.055 | 0.333 | 4.757 | 0.007 |
| X2 | 5.044 | 0.101 | 6.622 | 0.038 |
| X3 | 6.715 | 0.333 | 7.152 | 0.004 |
| X4 | 5.981 | 0.392 | 6.165 | 0.036 |
| X5 | 7.160 | 0.256 | 6.651 | 0.010 |
| X6 | 3.121 | 0.201 | 6.608 | 0.036 |
| X7 | 7.397 | 0.087 | 7.258 | 0.031 |
| X8 | 6.435 | 0.421 | 6.884 | 0.019 |
| X9 | 3.706 | 0.063 | 3.521 | 0.034 |
| X10 | 4.674 | 0.399 | 7.405 | 0.042 |
| X11 | 5.118 | 0.155 | 3.127 | 0.040 |
| X12 | 4.350 | 0.235 | 5.896 | 0.040 |
| X13 | 6.797 | 0.068 | 5.363 | 0.022 |
| X14 | 3.465 | 0.140 | 6.315 | 0.043 |
| X15 | 7.308 | 0.198 | 7.109 | 0.043 |
| Intercept | 1.563 | 0.321 | 0.610 | 0.005 |
| Optimal Solution Found | Yes | | | |
| N | 125 | | | |
| Chi-Square | 371.458 | | | |
| Sig. | 0.725 | | | |

ويتضح من نتائج الجدول السابق أن نتائج تحليل أسلوب Probit توصلت للحلول المثلى للاحتمالات المتوقعة حيث أتضح أن (optimal solution found = Yes) ، وهذا يعني أن هذا الأسلوب له القدرة على التنبؤ بالتقديرات المحاسبية بشكل ناجح أي أن الأسلوب متطابق، كما أتضح معنوية المتغيرات الخاصة بالتنبؤ بالتقديرات

المحاسبية، مما يعني أن له تأثير معنوي على احتمالية وجود تنبؤات مختلفة بالتقديرات المحاسبية على مستوى كل مشاهدة من المشاهدات المدرجة بعينة الدراسة، أما نتائج اختبار كا² لحسن المطابقة أوضحت للباحث جودة مطابقة النموذج .

وذلك نظراً لأنه كلما انخفضت الفروق بين القيم الفعلية والقيم المتوقعة كلما ازدادت جودة النموذج، فقد أشارت جودة المطابقة إلى الفروق بين القيم المشاهدة المدرجة بالنموذج والقيم المتوقعة المستخرجة منه، فعدم معنوية قيم كا² دليل على أن الفروق بين القيم المشاهدة والقيم المتوقعة ضئيلة جداً ولا يوجد لها أي معنوية إحصائية، وفي ضوء ذلك توصلت نتائج الجدول إلى عدم معنوية قيم كا² حيث أن المعنوية كانت ٠.٧٢٥ وهي أكبر من ٠.٠٥. وأخيراً، أظهرت نتائج تحليل أسلوب Probit للنموذج السابق مجموعة القيم المتوقعة للتقديرات المحاسبية وتم مقارنتها بالقيم الفعلية والمنتبأ بها باستخدام خوارزميات تعلم الآلة.

٧/٣ نتائج اختبارات الفروض الإحصائية

لأغراض التحقق من الأثر الفعلي لخوارزميات تعلم الآلة على التنبؤ بالتقديرات المحاسبية وأثر ذلك علي ممارسات تمهيد الدخل، لذا قام الباحث باختبار فروض الدراسة على النحو التالي:

١/٧/٣ نتائج اختبارات الفروق الجوهرية بين القيم المتنبأ بها لتمهيد الدخل عن طريق التقديرات المحاسبية وفقاً لخوارزميات تعلم الآلة والأساليب التقليدية (الفرض الإحصائي الأول للدراسة):

يتنبأ هذا الفرض بمدى وجود فروق جوهرية بين قيمة التقديرات المحاسبية المطبقة لغرض تمهيد الدخل التي تم التنبؤ بها من خلال الأساليب الحديثة، وقيمة التقديرات المحاسبية المتنبأ بها باستخدام الأساليب التقليدية التي تم التنبؤ بها من خلال الأساليب التقليدية وقد أوضحت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (٩): نتائج اختبارات الفروق الجوهرية بين الأساليب الحديثة وتحليل Probit للتنبؤ بالتقديرات المحاسبية

| | Variables | Mean | T | Sig. (2-tailed) |
|-----------------|---|-------|-------|-----------------|
| Pair (1) | Accounting Estimates predicted by K-Nearest Neighbour | 4.350 | 4.570 | 0.000 |
| | Accounting Estimates predicted by Probit Regression | 1.462 | | |
| Pair (2) | Accounting Estimates predicted by Neural Network | 6.003 | 5.159 | 0.000 |
| | Accounting Estimates predicted by Probit Regression | 2.170 | | |
| Pair | Accounting Estimates predicted by | 4.255 | 6.111 | 0.000 |

| | Variables | Mean | T | Sig. (2-tailed) |
|-------------|---|-------|-------|-----------------|
| (3) | Random Forest | | | |
| | Accounting Estimates predicted by Probit Regression | 1.487 | | |
| Pair | Accounting Estimates predicted by SVM | 4.443 | 5.609 | 0.000 |
| (3) | Accounting Estimates predicted by Probit Regression | 2.163 | | |

ويتضح من ذلك الجدول السابق وجود فروق جوهرية ومعنوية بين تحليل Probit كأحد الأساليب التقليدية وخوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية والجدير بالذكر أن قيم T موجبة على مستوى كافة خوارزميات تعلم الآلة وهذا يدل على تحيز تلك الفروق لخوارزميات تعلم الآلة، وهذا يتوافق مع ارتفاع مستويات الدقة التي سبق عرضها، ولذلك يمكن للباحث قبول الفرض الإحصائي الأول للدراسة على الشكل البديل التالي: توجد فروق جوهرية ذات دلالة إحصائية بين مستوى تمهيد الدخل عن طريق التنبؤ بالتقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية المنتبأ بها باستخدام الأساليب التقليدية.

٢/٧/٣ نتائج اختبارات الفروق الجوهرية بين القيم المتنبأ بها لتمهيد الدخل عن طريق التقديرات المحاسبية لخوارزميات تعلم الآلة والقيم الفعلية (الفرض الإحصائي الثاني للدراسة):

يتنبأ هذا الفرض بمدى وجود فروق جوهرية بين قيمة التقديرات المحاسبية المطبقة لغرض تمهيد الدخل التي تم التنبؤ بها من خلال خوارزميات تعلم الآلة، وقيمة التقديرات المحاسبية الفعلية لعينة الدراسة وقد أوضحت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (١٠): نتائج اختبارات الفروق الجوهرية بين خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية لغرض تمهيد الدخل والتقديرات المحاسبية الفعلية

| | Variables | Mean | T | Sig. (2-tailed) |
|-------------|---|-------|-------|-----------------|
| Pair | Accounting Estimates predicted by K-Nearest Neighbour | 5.990 | 4.366 | 0.000 |
| (1) | Actual Accounting Estimates | 1.588 | | |
| Pair | Accounting Estimates predicted by Neural Network | 5.050 | 4.118 | 0.000 |
| (2) | Actual Accounting Estimates | 1.458 | | |
| Pair | Accounting Estimates predicted by | 6.012 | 7.719 | 0.000 |

| | Variables | Mean | T | Sig. (2-tailed) |
|------|---------------------------------------|-------|-------|-----------------|
| (3) | Random Forest | | | |
| | Actual Accounting Estimates | 1.345 | | |
| Pair | Accounting Estimates predicted by SVM | 4.119 | 5.086 | 0.000 |
| (3) | Actual Accounting Estimates | 2.303 | | |

ويتضح من ذلك وجود فروق جوهرية ومعنوية بين القيم الفعلية للتقديرات المحاسبية وخوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية، ونظراً لأن قيم T موجبة على مستوى كافة خوارزميات تعلم الآلة وهذا يدل على تحيزها نحو خوارزميات تعلم الآلة، وهو ما يتوافق مع نسب ارتفاع مستويات الدقة السابق عرضها، ولذلك يمكن للباحث قبول الفرض الإحصائي الثاني للدراسة على الشكل البديل التالي: *توجد فروق جوهرية ذات دلالة إحصائية بين مستوى تمهيد الدخل عن طريق التنبؤ بالتقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية الفعلية لعينة الدراسة.*

رابعاً: نتائج البحث وتوصياته وأهم مجالات البحث المترحة

بناء على ما تم عرضه في الإطار النظري ولما استنتجه الباحث من التحليل الإحصائي للدراسة يمكن عرض أهم النتائج التي تم التوصل إليها المتمثلة في الآتي:

1. احتمالية تلاعب المديرين بقيمة التقديرات المحاسبية عن عمد، وذلك لاعتمادها على تقييمات ذاتية للأحداث المستقبلية مما يتيح للمديرين المرونة الكافية في تحديد التقديرات المحاسبية.
2. تدل ممارسة تمهيد الدخل على قيام الإدارة بتقليل مستوى الأرباح الحالية عمداً كمحاولة منها لتقليل الانحرافات غير الطبيعية للأرباح من خلال استخدامها لبعض الممارسات لتخفيض الأرباح في الفترات التي تحقق فيها الشركة أرباح عالية وإضافتها للفترات التي تنخفض فيها الأرباح عن الحد المسموح به.
3. تقدم خوارزميات تعلم الآلة تنبؤات من خلال استخدام مجموعات كبيرة من البيانات وذلك على عكس أساليب التنبؤ التقليدية التي تفرض بنية محددة على العلاقات بين المتغيرات.
4. يتضح ارتفاع مستويات الدقة بمستوي Training Set للبيانات التي تنبأ بها خوارزمية الأقرب جار بنسبة 92.3%، كما توصل إلي ارتفاع مستويات الدقة في المستوى Training Set للبيانات إلي ما يقارب 92.8% أي أن القيم التي تنبأ بها خوارزمية الغابة العشوائية تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ 7.2%.

٥. تبين وجود فروق جوهرية ذات دلالة إحصائية بين تمهيد الدخل عن طريق التقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية المتنبأ بها باستخدام الأساليب التقليدية.
٦. وجود فروق جوهرية ومعنوية بين الأساليب التقليدية المتمثلة في أسلوب Probit وبين خوارزميات تعلم الآلة للتنبؤ بالتقديرات المحاسبية .
٧. يوجد فروق جوهرية ذات دلالة إحصائية بين تمهيد الدخل عن طريق التقديرات المحاسبية باستخدام خوارزميات تعلم الآلة والتقديرات المحاسبية الفعلية لعينة الدراسة.

وأخيراً تقترح الدراسة مجالات لبحوث مستقبلية ، تتضمن ما يلي:

- تحسين المحفظة مع التنبؤ بالعائد باستخدام التعلم العميق والتعلم الآلي
- تحسين توقعات الأرباح والعوائد غير الطبيعية باستخدام التعلم الآلي.
- خوارزميات التعلم الآلي وتقييمات المراجعين للمخاطر.

خامساً: المراجع

- المراجع العربية
 ١. أحمد ، محمد عزام عبد المجيد، (٢٠٢٣) ، الإفصاح عن التقديرات المحاسبية وأثرها على قرارات الاستثمار ، مجلة البحوث المالية والتجارية ، كلية التجارة ، جامعة بورسعيد، ١(٢٤) ، ١٧٤-٢١٨.
 ٢. أبو نصار، محمد؛ حميدات، جمعه؛ ٢٠١٣، معايير المحاسبة والابلاغ المالي الدولية، الجوانب النظرية والعملية، المكتبة الوطنية، عمان، الاردن.
 ٣. قرار وزير الاستثمار رقم ٦٩ لسنة ٢٠١٩ بشأن معايير المحاسبة المصرية، الطبعة الأولى، الهيئة العامة لشئون المطابع الاميرية.
- المراجع الأجنبية
 4. Abozaid, E. M., Elshaabany, M. M., & Diab, A. A. (2020). The impact of audit quality on narrative disclosure: Evidence from Egypt. *Academy of Accounting and Financial Studies Journal*, 24(1), 1-14.
 5. Amel-Zadeh, A., Calliess, J. P., Kaiser, D., & Roberts, S. (2020). Machine learning-based financial statement analysis. Available at SSRN 3520684.

6. Albrecht, A., Glendening, M., Kim, K., & Lee, K. J. (2023). Material changes in accounting estimates and the usefulness of earnings. *Review of Accounting Studies*, 1-40.
7. Almaqtari, F. A., Farhan, N. H., Salmony, M. Y., Al-Ahdal, W. M., & Mishra, N. (2021, November). Earning management estimation and prediction using machine learning: A systematic review of processing methods and synthesis for future research. In *2021 International Conference on Technological Advancements and Innovations (ICTAI)* (pp. 291-298). IEEE.
8. Akyildirim, E., Nguyen, D. K., Sensoy, A., & Šikić, M. (2023). Forecasting high-frequency excess stock returns via data analytics and machine learning. *European Financial Management*, 29(1), 22-75.
9. Bertomeu, J. (2020). Machine learning improves accounting: discussion, implementation and research opportunities. *Review of Accounting Studies*, 25(3), 1135-1155.
10. Binz, O., Schipper, K., & Standridge, K. (2022). What can analysts learn from artificial intelligence about fundamental analysis?. Available at SSRN 3745078.
11. Barth, M. E., Li, K., & McClure, C. G. (2023). Evolution in value relevance of accounting information. *The Accounting Review*, 98(1), 1-28.
12. Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468-519.
13. Boone, J. P., Khurana, I. K., & Raman, K. K. (2023). Accounting estimation intensity, auditor estimation expertise, and managerial bias. *Accounting Horizons*, 1-28.
14. Chung, P. K., Geiger, M. A., Paik, D. G., & Rabe, C. (2022). Do Firms Time Changes in Accounting Estimates to Manage Earnings?. *Contemporary Accounting Research*, 39(2), 917-946.
15. Ch, F. N. (2020, March). The effect of financial performance to income smoothing practice in property and real estate

- companies listed on Indonesia Stock Exchange. In *Annual International Conference on Accounting Research (AICAR 2019)* (pp. 46-50). Atlantis Press.
16. Chollet, F. (2021). *Deep learning with Python*. Simon and Schuster.
 17. Chattopadhyay, A., Fang, B., & Mohanram, P. (2022). Machine Learning, Earnings Forecasting, and Implied Cost of Capital-US and International Evidence.
 18. Cain, C. A., K. S. Kolev, and S. McVay. 2020. Detecting opportunistic special items. *Management Science* , 66 (5): 2099–119.
 19. Cai, C. J., Jongejan, J., & Holbrook, J. (2019, March). The effects of example-based explanations in a machine learning interface. In *Proceedings of the 24th international conference on intelligent user interfaces* (pp. 258-262).
 20. Commerford, B. P., Dennis, S. A., Joe, J. R., & Ulla, J. W. (2022). Man versus machine: Complex estimates and auditor reliance on artificial intelligence. *Journal of Accounting Research*, 60(1), 171-201.
 21. Chen, X., Cho, Y. H., Dou, Y., & Lev, B. (2022). Predicting Future Earnings Changes Using Machine Learning and Detailed Financial Data. *Journal of Accounting Research*, 60(2), 467-515.
 22. Downes, J. F., Kang, T., Kim, S., & Lee, C. (2019). Does the mandatory adoption of IFRS improve the association between accruals and cash flows? Evidence from accounting estimates. *Accounting Horizons*, 33(1), 39-59.
 23. Ding, K., Lev, B., Peng, X., Sun, T., & Vasarhelyi, M. A. (2020). Machine learning improves accounting estimates: Evidence from insurance payments. *Review of accounting studies*, 25, 1098-1134.
 24. Egbunike, C. F., Igbinovia, I. M., Okafor, K. J., & Mmadubuobi, L. C. (2023). Residual audit fee and real income smoothing: evidence from quoted non-financial firms in Nigeria. *Asian Journal of Accounting Research*, 8(1), 66-79.

25. Firmansyah, A., & Irwanto, A. (2020). Do income smoothing, forward-looking disclosure, and corporate social responsibility decrease information uncertainty. *International Journal of Psychosocial Rehabilitation*, 24(7), 9513-9525.
26. Fauzi, M. (2019). The effect of tax planning, company value, and leverage on income smoothing practices in companies listed on Jakarta Islamic Index. *Journal of Islamic Accounting and Finance Research—Vol, 1*(1).
27. Fischer, J. A., Pohl, P., & Ratz, D. (2020). A machine learning approach to univariate time series forecasting of quarterly earnings. *Review of Quantitative Finance and Accounting*, 55, 1163-1179.
28. Hammami, A., & Hendijani Zadeh, M. (2022). Predicting earnings management through machine learning ensemble classifiers. *Journal of Forecasting*, 41(8), 1639-1660.
29. Hunt, J. O., Myers, J. N., & Myers, L. A. (2022). Improving earnings predictions and abnormal returns with machine learning. *Accounting Horizons*, 36(1), 131-149.
30. Hunt, J., Myers, J., & Myers, L. (2019). Improving earnings predictions with machine learning. *Unpubl. Work. Pap.*
31. Kureljusic, M., & Metz, J. (2023). The applicability of machine learning algorithms in accounts receivables management. *Journal of Applied Accounting Research*.
32. Kureljusic, M., & Reisch, L. (2022). Revenue forecasting for European capital market-oriented firms: A comparative prediction study between financial analysts and machine learning models. *Corporate Ownership & Control*, 19(2), 159-178.
33. Lestari, N., & Aeni, N. (2019, December). The Effect of audit quality and earnings management on firm performance. In *1st International Conference on Applied Economics and Social Science (ICAESS 2019)* (pp. 321-326). Atlantis Press.
34. Lang, M., Lins, K. V., & Maffett, M. (2012). Transparency, liquidity, and valuation: International evidence on when

- transparency matters most. *Journal of Accounting Research*, 50(3), 729-774.
35. Lau, C. K. (2021). Measurement uncertainty and management bias in accounting estimates: the perspective of key audit matters reported by Chinese firms' auditors. *Asian Review of Accounting*, 29(1), 79-95.
 36. Nangih, E., & Anichebe, A. S. (2021). Accounting estimates and misstatements in financial reports in Nigeria: A Survey of Small and Medium Enterprises. *Journal of Accounting and Financial Management*, 7(3), 50-59.
 37. Ojomadele, D. J., & Adejuwon, A. J. (2020). Creative accounting and corporate failure in Nigeria. *Global Scientific Journals*, 8(10), 1-14.
 38. Oyewo, B., Emebinah, E., & Savage, R. (2020). Challenges in auditing fair value measurement and accounting estimates: Some evidence from the field. *Journal of Financial Reporting and Accounting*, 18(1), 51-75.
 39. Pavic, I., Sacer, I. M., & Brozovic, M. (2016). Do Croatian quoted companies satisfy IFRS disclosure requirements of accounting estimates for investment property?. *Procedia Economics and Finance*, 39, 389-398.
 40. Petkov, R. (2020). Artificial intelligence (AI) and the accounting function—A revisit and a new perspective for developing framework. *Journal of emerging technologies in accounting*, 17(1), 99-105.
 41. Putri, L. G. A. A., & Suputra, I. D. G. D. (2019). The effect of disclosure of financial report and managerial ability on earnings management with audit quality as a moderating variable. *Journal of Finance and Accounting*, 10 (2): 33, 39.
 42. Ranta, M., Ylinen, M., & Järvenpää, M. (2023). Machine learning in management accounting research: Literature review and pathways for the future. *European Accounting Review*, 32(3), 607-636.

43. Salawu, R. O. (2022). Earnings smoothing and market share price: evidence from Nigeria. *Academy of Accounting and Financial Studies Journal*, 26(1), 1-14.
44. Sacer, I. M., Malis, S. S., & Pavic, I. (2016). The Impact of accounting estimates on financial position and business performance—case of non-current intangible and tangible assets. *Procedia Economics and Finance*, 39, 399-411.
45. Shaw, K. W., & Whitworth, J. D. (2022). Client importance and unconditional conservatism in complex accounting estimates. *Advances in Accounting*, 58, 100615.
46. Stein, S. E. (2019). Auditor industry specialization and accounting estimates: Evidence from asset impairments. *Auditing: A Journal of Practice & Theory*, 38(2), 207-234.
47. Tee, C. M. (2020). Political connections and income smoothing: Evidence of institutional investors' monitoring in Malaysia. *Journal of Multinational Financial Management*, 55, 100626.
48. Toumeh, A. A., & Yahya, S. (2019). A Review of Earnings Management Techniques: An IFRS Perspective. *Global Business & Management Research*, 11(3).