



استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم وأثر ذلك على الإفصاح عن المعلومات المستقبلية

إعداد

د. نرمين علي محمد المر

مدرس المحاسبة والمراجعة بكلية التجارة جامعة بورسعيد

dr.nermeenelmor@gmail.com

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد الخامس - العدد الأول - الجزء الثاني - يناير ٢٠٢٤

التوثيق المقترح وفقاً لنظام APA:

المر، نرمين علي محمد (٢٠٢٤). استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم وأثر ذلك على الإفصاح عن المعلومات المستقبلية. المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط، ٣(٢)ج٢، ١١٢٥-١١٧٧.

استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم وأثر ذلك على الإفصاح عن المعلومات المستقبلية

د. نرمين علي محمد المر

المخلص

استهدف البحث معرفة أثر استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم علي الإفصاح عن المعلومات المالية المستقبلية في البيئة المصرية، حيث تناول الباحث العلاقة بين عوائد الأسهم والإفصاح عن المعلومات المستقبلية في الفكر المحاسبي، كما عرض الباحث دور تقنيات تعلم الآلة في التنبؤ بالمعلومات المحاسبية من خلال تحليل منهجية تقنيات تعلم الآلة، وأخيراً تم تناول أثر التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة علي الإفصاح عن المعلومات المستقبلية. وبلغ مجتمع الدراسة ٢٤٤ شركة من الشركات المقيدة في سوق الأوراق المالية المصري وتم الحصول عليها من بيانات مؤشر EGX 30، ويعبر هذا المؤشر عن الشركات الأكثر تداولاً في سوق الأوراق المالية المصري، وذلك خلال الفترة الزمنية من ٢٠١٤ إلى ٢٠٢١، وبلغت عينة الدراسة ٢٤٠ مشاهدة (٣٠ شركة × ٨ سنوات)، وقام الباحث بإجراء مقارنة بين نماذج تعلم الآلة والنماذج التقليدية المتمثلة في التقليدية (أسلوب تحليل Probit، وأسلوب تحليل الانحدار المتعدد) للتنبؤ بعوائد الأسهم

وتوصل الباحث إلى وجود فروق جوهرية ذات دلالة إحصائية بين عوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية وبين عوائد الأسهم المتنبأ بها باستخدام تقنيات تعلم الآلة، كما أشارت الدراسة إلى أنه لا يوجد تأثير ذو دلالة إحصائية لعوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية علي الإفصاح عن المعلومات المستقبلية، بينما بلغ التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة التي تتمثل في: شجرة القرارات، والشبكات العصبية، وآلية نقل الدعم، والشبكة البايزية، تفسر نسبة ٦٢,١٨٪، ٦٦,١٨٪، ٧١,٢٥٪، ٧٥,٣٦٪ من التغير في الإفصاح عن المعلومات المستقبلية.

الكلمات الدالة: تعلم الآلة، التنبؤ بعوائد الأسهم، المعلومات المستقبلية، شجرة القرارات، الشبكات العصبية، آلية ناقلات الدعم، الشبكة البايزية.

المحور الأول: الإطار العام للبحث

١. طبيعة المشكلة

لقد أدت إخفاقات المنشآت كشركة Parmalat, Enron إلى مطالبة أطراف مختلفة كالمستثمرين والمنظمين وأصحاب المصلحة الآخرين بمزيد من الشفافية والإفصاح الشامل بسبب العدد المتزايد من حالات فشل الشركات والأزمات المالية، وتعد المعلومات المستقبلية من أكثر أنواع المعلومات المطلوبة بشدة من قبل أصحاب المصلحة، واستجابةً لهذا الطلب تضطر الشركات إلى مراجعة استراتيجيات أعمالها الحالية من خلال دمج المعلومات المستقبلية في تقاريرها السنوية لتظل قادرة على المنافسة في بيئة الأعمال، ومن ثم خلق ميزة تنافسية مستدامة (Choi, A., et al., (2022)، حيث تتعلق المعلومات المستقبلية بنوعية المعلومات المتعلقة بالتوقعات المستقبلية التي تمكن مستخدميها من تقييم أداء الشركات في المستقبل، وتحتوي تلك المعلومات على خطط الإدارة وتقييم للفرص والمخاطر المتوقعة حول عمليات وأنشطة الشركة، ويمكن الإفصاح عن المعلومات المستقبلية في التقارير المالية السنوية أو التقارير الفترية أو من خلال الاتصال المباشر بالمحللين الماليين وأصحاب المصالح (Dey, P. K., et al. (2020).

ونتيجة للتغيرات المتتالية في بيئة الأعمال والدوافع الاستثمارية ومطالب أصحاب المصالح أصبح دور الإفصاح عن المعلومات المستقبلية في سوق الأوراق المالية ضروري لأن البيئة الاقتصادية ديناميكية للغاية ومن ثم لا تعتمد على المعلومات التاريخية فقط، حيث لا يمكن للإفصاح عن المعلومات التاريخية تلبية احتياجات أصحاب المصلحة المتنوعة من المعلومات، ومع التغيير السريع في البيئة الاقتصادية أصبح للمعلومات التاريخية عيوب وبالتالي لا تتمكن من تقديم رؤى كافية لأصحاب المصالح التي تساعدهم في التنبؤ بعوامل الفرص والمخاطر وخطط الإدارة المتوقعة، حيث تقوم الإدارة بتقييم اتجاهات السوق الحالية للإجابة على أصحاب المصلحة بوصف ما تخطط له الشركة (Mahboub, R. M. (2019).

ويتضح من ذلك أن الأسواق المالية تتسم بالكفاءة عندما تعكس المعلومات القديمة والجديدة بسرعة في السعر الحالي للأوراق المالية (Khoa, B. T., & Huynh, T. T. (2021)، لذا تعد عوائد الأسهم من أهم الإفصاحات التي تساعد المستثمرين في اتخاذ القرارات نظراً لأنها تعبر عن مؤشر مالي يحتوي على العديد من المعلومات الحالية للشركة وهذا بدوره يساعد على تنبؤات ما يحدث في المستقبل، فغالباً كانت توقعات عوائد الأسهم مصدر قلق فهي تعتبر مشكلة صعبة نظراً لتعلقها بتنبؤ السلاسل الزمنية في سوق الأوراق المالية فهو سوق غير خطي وديناميكي حيث يتأثر سعر السهم بالعديد من العوامل كالأحداث السياسية، سياسات الشركة، الأوضاع الاقتصادية، أسعار الفائدة، مشاعر المستثمرين، لذا تم استخدام التكنولوجيا على نطاق واسع للتنبؤ في سوق الأوراق المالية (Ma, Y., et L. (2021).

ويعد التنبؤ بعوائد الأسهم من أهم مكونات المعلومات المستقبلية وأكثرها ملائمة لاتخاذ القرارات الاستثمارية، وتنتشر هذه التنبؤات ضمن القوائم المالية المستقبلية التي ينبغي أن تحتوي على كيفية حساب رقم الربح والتنبؤ بالتدفقات النقدية وعناصر المركز المالي (Khoa, B. T., & Huynh, T. T. (2021)، ولقد أدى التطور الاقتصادي السريع إلى تزايد عدد الأنشطة المالية بشكل متزايد في

السنوات الأخيرة وساعد ذلك في تغيير مسار الأعمال كما أثر علي سوق الأوراق المالية، حيث أفاد البنك الدولي في عام ٢٠١٨ أن رسملة سوق الأسهم في جميع أنحاء العالم قد تجاوزت ٦٨,٦٥٤ تريليون دولار أمريكي، ومن ثم زاد الاهتمام بتداول الأسهم علي مدي السنوات القليلة الماضية نتيجة للتقدم التكنولوجي لذا يبحث المستثمرين عن أدوات وتقنيات من شأنها زيادة الربح وتقليل المخاطر بالإضافة إلي إن التنبؤ بسوق الأسهم ليس مهمة بسيطة نظراً لطبيعته غير الخطية والديناميكية وغير موثوقة كالتنبؤ بالسلاسل الزمنية الذي يفحص البيانات السابقة علي الفور ويقدر قيم البيانات المستقبلية .Rouf, N., et al. (2021)

وتعتبر خطوة الاختيار المسبق للسهم عالي الجودة أمر بالغ الأهمية لنجاح إدارة المحافظ الاستثمارية، وبعد خطوة الاختيار المسبق للأسهم عادة ما يحاول المستثمرون الأفراد تحديد العائد المستقبلي لأسهمهم الاستثمارية وبعد ذلك يحتاج المستثمرون أيضاً إلى حساب وزن الاستثمار الأمثل لكل سهم تم اختياره قبل إجراء الاستثمار التجاري، ونظراً لأن عوائد الأسهم قصيرة الأجل تتأثر بشكل كبير بمشاعر المستثمرين ، ليس من المعقول استخدام متوسط العائد التاريخي كما هو متوقع علي عوائد الأسهم قصيرة الأجل، ولذلك يجب دمج التنبؤ بعوائد الأسهم مع تقنيات جديدة لتحسين المحفظة المالية الاستثمار ومن ضمن هذه التقنيات تعلم الآلة التي أظهرت أداء واعد في تنبؤات سوق الأوراق المالية (Ma, Y., et L. (2021)

وأكد Bao, Y., et al. (2020) علي أن المجال البارز لتقنيات تعلم الآلة هو التنبؤ المالي بالأزمات في المستقبل من خلال البيانات المالية المتاحة للجمهور ، وهذا بدوره يعطي فرصة لعلاج هذه الأزمات في الوقت المناسب، واتفق معه Sun, T. (2019) حين ذكر أنه بالرغم من اعتبار الشبكات العصبية تقنية تقليدية لتعلم الآلة تم تطبيقها إلا أنها تقنية غامضة يصعب إظهار المسار التي تتبعه للوصول إلي نتائجها، فالشبكات العصبية وباقي تقنيات تعلم الآلة كآلية ناقلات الدعم والغابة العشوائية تعد تقنيات مفيدة بسبب قوتها التنبؤية بدلاً من قابليتها للتفسير.

وتعتبر تقنيات تعلم الآلة مجموعة فرعية من الذكاء الاصطناعي فهي برنامجاً حسابياً يتعلم تلقائياً الأنماط والاتجاهات من البيانات التاريخية دون أن يتم برمجتها بشكل صحيح من قبل الإنسان (Huang, F., No, et al. (2022)، وأكدت دراسة Aly, H. G., et al. (2023) علي أنها عبارة عملية تحليل للبيانات باستخدام التقنيات، وإيجاد الأنماط الضمنية ، وتطبيق الأنماط الموجودة لعمل تنبؤات حول المستقبل ، وتتمثل تقنيات تعلم الآلة في آلية ناقلات الدعم، الشبكات العصبية، شجرة القرارات، الغابة العشوائية ، وتتكون تقنية الغابة العشوائية من عدد كبير من أشجار القرار الفردية التي تعمل كمجموعة وتختار تلك التقنية مجموعة فرعية عشوائياً من مجموعة التدريب وتقوم كل شجرة قرار بعمل تنبؤ ثم تقوم الغابة العشوائية بجمع الأصوات من أشجار القرار المختلفة لتحديد الفئة النهائية من هذه الأصوات، بينما تعد تقنية آلية نقل الدعم خاضعة للإشراف فهي تقنية ذات قيمة للتنبؤ باتجاه حركة الأسعار في السوق من خلال عملها علي زيادة الأداء في التعرف علي الأنماط ثم التنبؤ بالسلاسل الزمنية المالية وتقوم أيضاً بتدريب الشبكات الخطية للحصول علي المستوي الأمثل الذي يفصل البيانات بدون خطأ . Akyildirim, E., et al. (2023)

واستناداً لما سبق يمكن استخدام تقنيات تعلم الآلة للوصول لدقة أعلى في التنبؤ بعوائد الأسهم وذلك لتقليل عدم تماثل المعلومات بين الإدارة وأصحاب المصلحة وللحد من ممارسات إدارة الأرباح، ونظراً لأهمية دقة التنبؤ بعوائد الأسهم للمعلومات المستقبلية تتمثل مشكلة البحث في قياس أثر التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية في البيئة المصرية.

١/١ أهمية البحث

تتبع الأهمية العلمية للبحث من كونه إضافة جديدة للأدبيات المحاسبية وذلك لتحليله واختبار أثر استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم على الإفصاح عن المعلومات المستقبلية وهو ما يساهم في تخفيض تقلبات عوائد الأسهم وعدم تماثل المعلومات بين الإدارة وأصحاب المصلحة وهذا بدوره يزيد من جودة الإفصاح عن المعلومات المستقبلية، بينما تتمثل الأهمية العملية في زيادة حاجة أصحاب المصلحة ومستخدمي المعلومات المالية لزيادة جودة المعلومات المحاسبية والتي تساعدهم في تحسين القرارات الاستثمارية، فمن خلال استخدام تقنيات تعلم الآلة في التنبؤ يستطيع مستخدمي التقارير المالية وخاصة المستثمرين تقييم الفرص الاستثمارية بشكل أفضل.

٢/١ أهداف البحث

يتمثل الهدف الرئيسي لهذا البحث في معرفة أثر استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم على الإفصاح عن المعلومات المالية المستقبلية، ويتفرع منه عدة أهداف فرعية وهي:

١. المقارنة بين الطرق التقليدية وتقنيات تعلم الآلة في التنبؤ بعوائد الأسهم.
٢. معرفة أثر استخدام تقنيات تعلم الآلة على التنبؤ بعوائد الأسهم.
٣. تحديد أكثر التقنيات دقة في التنبؤ بعوائد الأسهم وقياس أثرها على الإفصاح عن المعلومات المالية المستقبلية.

٣/١ منهج البحث

يتبع الباحث المنهج الاستقرائي من خلال الاطلاع على المصادر العلمية المتعلقة بموضوع البحث، كما اعتمد على البحث المكتبي سواء من خلال الإصدارات المهنية أو الدراسات الأكاديمية المرتبطة بموضوع البحث، كما قام الباحث باتباع المنهج الاستنباطي لاستكشاف وتفسير طبيعة العلاقة بين استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم والإفصاح عن المعلومات المستقبلية ثم اشتقاق فروض البحث.

٤/١ مجال البحث

يقتصر البحث علي دراسة أثر استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم علي الإفصاح عن المعلومات المستقبلية، ويتمثل مجتمع الدراسة في عدد الشركات المقيدة في سوق الأوراق المالية المصري والتي بلغ عددها ٢٤٤ شركة يمكن الحصول عليها من بيانات مؤشر EGX 30، حيث يعبر هذا المؤشر عن الشركات الأكثر تداولاً في سوق الأوراق المالية المصري، وذلك خلال الفترة الزمنية من ٢٠١٤ إلى ٢٠٢١ على اعتبار أن هذه الفترة الزمنية هي الفترة الأكثر استقراراً في سوق الأوراق المالية لتجنب الأحداث السياسية والاقتصادية الشاذة، وقد سجلت عينة الدراسة ٢٤٠ مشاهدة (٣٠ شركة × ٨ سنوات)، وبحذف القيم الشاذة والمتطرفة التي تبلغ ٤٨ مشاهدة وبحذف البيانات المفقودة والتي يبلغ عددها ١٣ مشاهدة يصبح العدد النهائي لعينة الدراسة هو ١٧٩ مشاهدة.

٥/١ تقييم الدراسات المحاسبية ذات الصلة واشتقاق الفروض البحثية

يتمثل الهدف من عرض وتحليل الدراسات السابقة للمتغيرات البحثية محل الدراسة في مجال استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم، الإفصاح عن المعلومات المستقبلية، لمعرفة ما تم التوصل إليه من نتائج وتوصيات للاستفادة منها في استنتاج الفجوة البحثية العلمية في موضوعات تقنيات تعلم الآلة ودورها في التنبؤ بعوائد الأسهم والإفصاح عن المعلومات المستقبلية واستكمال جوانب هذا البحث.

١/٥/١ الدراسات الخاصة باستخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم

هدفت دراسة Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, (2020) A. إلى تقليل مخاطر التنبؤ باتجاهات سوق الأسهم من خلال استخدام تقنيات تعلم الآلة والتعلم العميق، واختارت الدراسة أربع مجموعات من أسواق الأوراق المالية وهي المالية المتنوعة، والبترو، والمعادن غير المعدنية، والمعادن الأساسية في بورصة طهران لإجراء تقييمات تجريبية، وقارنت الدراسة تسع تقنيات لتعلم الآلة وهي شجرة القرارات، الغابة العشوائية، التعزيز التدريجي، تعزيز التدرج الأقصى، آلية نقل الدعم، الأقرب جار، الانحدار اللوجستي، الشبكة العصبية الاصطناعية، وتقنيتان من التعلم العميق وهما الشبكة العصبية المتكررة والذاكرة طويلة المدى، وتوصلت نتائج الدراسة إلى أن نتائج التقييم بالنسبة للبيانات المستمرة تبين أن الشبكة العصبية المتكررة والذاكرة طويلة المدى يتفوقان على نماذج التنبؤ الأخرى مع وجود اختلاف كبير، وفي حالة التقييم للبيانات الثنائية أوضحت أن تقنيات التعلم العميق أيضاً هي الأفضل في التنبؤ.

وتناولت دراسة Nõu, A., Lapitskaya, D., Eratalay, M. H., & Sharma, R. (2021) استخدام تقنيات تعلم الآلة ونماذج الاقتصاد القياسي ونموذج هجين من الشبكات العصبية الاصطناعية ونموذج اقتصادي قياسي في التنبؤ بعوائد وتقلبات الأسهم في دول البلطيق، واستخدمت الدراسة مؤشر أسعار OMX Bsltic Benchmark من ٢٠٠١/٩/٤ إلى ٢٠٢١/٣/١، وتوصلت الدراسة إلى أن تقنيات تعلم الآلة كتقنية آلية نقل الدعم والأقرب جار تحسن من التنبؤ بعوائد وتقلبات الأسهم بشكل أفضل من النماذج التقليدية.

أما دراسة Khoa, B. T., & Huynh, T. T. (2021) تناولت منهج حديث لاتخاذ قرارات المستثمرين عن طريق تقنيات تعلم الآلة، واستخدمت الدراسة البيانات التاريخية للأسهم في محفظة VN-Index وVN30 للشراء والبيع خلال فترة يوم واحد بموجب منهج النافذة المتدرجة لاختبار بورصة مدينة هوشي منه (HoSE) من خلال اختبار تشغيل وإجراء تداول الأسهم باستخدام آلية نقل الدعم (SVM) والانحدار اللوجستي، وأظهرت نتائج الدراسة أن الانحدار اللوجستي وSVM توفر استراتيجية تداول الأسهم للمستثمرين على المدى القصير لزيادة أرباح التداول إلى الحد الأقصى وذلك لأن لهما طرق تداول فعالة مثبتة حيث بلغت متوسط دقة التنبؤ تصل إلى ٩٢,٤٨٪.

وقامت دراسة Ma, Y., Han, R., & Wang, W. (2021) بالجمع بين توقع العائد في تكوين المحفظة وتقنيات تعلم الآلة والتعلم العميق في عملية الاختيار المسبق للأسهم من قبل تشكيل محفظة الأسهم وفي تحسين أدائها والتنبؤ بعوائدها، واستندت الدراسة على البيانات التاريخية لمدة ٩ سنوات من ٢٠٠٧ إلى ٢٠١٥ من مؤشر الأسهم المكونة لمؤشر الأوراق المالية الصينية China

Securities 100، حيث استخدمت الدراسة تقنيتي لتعلم الآلة وهما الغابة العشوائية وآلية نقل الدعم وثلاثة تقنيات للتعلم العميق وهما الشبكة العصبية والتعلم العميق متعدد الطبقات والشبكة العصبية التلافيفية، وأظهرت نتائج الدراسة أن تقنية الغابة العشوائية RF ومتوسط التباين مع نموذج التنبؤ MVF يتفوقا على التقنيات الأخرى. بالإضافة إلي كما يؤدي معدل الدوران المرتفع إلى تآكل ما يقرب من نصف إجمالي عائداتها خاصة بالنسبة لـ RF + OF و RF + MVF، وأن تقنيات RF + MVF لا تزال تحقق أفضل أداء بين تقنيات MVF ونموذج أوميغا مع دعم الانحدار المتجه التنبؤ (SVR + OF) هو الأفضل أي أن أداء RF + MVF أفضل من SVR + OF، ولذلك أوصت الدراسة المستثمرين ببناء نموذج MVF للتنبؤ بالاستثمار التجاري اليومي.

وبحثت دراسة (Dang, N. H., Van Vu, T. T., & Le Dao, T. N. (2022)) في العلاقة بين المعلومات المحاسبية المنعكسة في بيانات التقارير المالية وعوائد الأسهم في السوق الفيتنامية واقتربت الدراسة نموذج لتحديد العلاقة، كما استخدمت الدراسة تقنيات تعلم الآلة في التنبؤ بهذه العلاقة من خلال استخدامها للبيانات التي حصلت عليها من الشركات الفيتنامية خلال الفترة من ٢٠٠٩ إلى ٢٠٢٠، وتوصلت الدراسة إلي أن تقنية تعزيز التدرج لديها أداء أفضل للتقرير الذاتي، وأن للنسب المالية كنمو الدخل التشغيلي وتقلب أرباح الأسهم وعائد الأرباح ونسبة الاحتفاظ بالنقدية وجودة الاستحقاق تأثير كبير علي عوائد الأسهم.

كما فحصت دراسة (Akyildirim, E., Nguyen, D. K., Sensoy, A., & Šikić, M. (2023)) ما إذا كانت تقنية تحليلات البيانات المقدمة للعملاء في الوقت الفعلي ببورصة اسطنبول يمكن استخدامها بنجاح في التنبؤ بالعوائد الزائدة خلال اليوم علي المؤشر المعياري بمساعدة تقنيات تعلم الآلة المختلفة، وأوضحت نتائج الدراسة أن تقنية تحليلات البيانات توفر نسب تنبؤ كبيرة تزيد عن ٥٠٪ مع نسب ربح مثالية يمكن أن تصل إلي ٣٣٪، وأشارت الدراسة إلي أن الانحدار اللوجستي يقدم تنبؤ بالعائدات الزائدة بشكل أفضل في التحليل طويل الأجل.

وناقشت دراسة (Rafiuddin, A., Gaytan, J. C. T., Ahmed, G., & Alshurideh, M. (2023)) إمكانية التنبؤ بعوائد الأسهم من خلال استخدام ثلاث تقنيات لتعلم الآلة وذلك بالتطبيق علي سوق الأسهم المكسيكية، وتوصلت الدراسة إلي أن تقنية ANN تقدم نتائج واعدة في التنبؤ بعوائد سعر السهم ولكن تفوق عليها تقنية SVM في الأداء لأنها تقوم بحل مشكلة البرمجة التربيعية المقيدة خطأً.

كما قارنت دراسة (Fieberg, C., Metko, D., Poddig, T., & Loy, T. (2023)) بين أداء نموذج الانحدار الخطي وأداء تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم المقطعية، واعتمدت الدراسة علي البيانات الشهرية لما يقرب من ١٢٠٠٠ سهم فردي من ١٦ شركة اقتصادية أوروبية خلال الفترة ١٩٩٠-٢٠١٩، وأظهرت نتائج الدراسة أن تقنيات تعلم الآلة تحسن من التنبؤ بعوائد الأسهم، وأشارت إلي أن المستثمرين لا يتحملون مخاطر إضافية من استخدام تقنيات تعلم الآلة مقارنةً بنموذج الانحدار الخطي، وأشارت تحليلات أخرى للدراسة إلي أن تقنيات تعلم الآلة تولد قيمتها المضافة في الأسواق عندما يميل المستثمر العادي إلي خسارة المال.

٢/٥/١ الدراسات الخاصة بالعلاقة بين الإفصاح عن المعلومات المستقبلية وعوائد الأسهم

طورت دراسة (Arya, A., Mittendorf, B., & Ramanan, R. N. (2017) نموذجاً لفحص كيفية تأثير الإفصاحات المحاسبية على فائدة القرار لردود فعل السوق لعوائد الأسهم، كما بحثت في ما هي فائدة المعلومات المستقبلية الواردة في التقارير المحاسبية بالنسبة لأصحاب المصلحة، وتوصلت الدراسة إلي أن المعلومات المستقبلية مفيدة لأنها تساعد أصحاب المصلحة بشكل أفضل، ويترتب علي هذا وجود علاقة بين التقارير المحاسبية وأسعار الأسهم في توجيه استراتيجيات الشركة، فكلما استثمرت الشركة في المعلومات المستقبلية زادت من تحسين دقة الإفصاحات المحاسبية.

كما قامت دراسة (Utami, W., Wahyuni, P. D., & Nugroho, L. (2020) بالتحقيق في العوامل التي تؤثر على سيولة الأسهم لشركات قطاع التصنيع المدرجة في بورصة إندونيسيا، واستخدمت الدراسة المتغيرات المستقلة المتمثلة في الإفصاح عن المعلومات المستقبلية، والملكية المؤسسية، والملكية الأجنبية، وأداء مجلس الإدارة مع عدم تماثل المعلومات كمتغير متوسط، وسيولة الأسهم كمتغير تابع، وتمثل عينة الدراسة في شركات قطاع التصنيع المدرجة في البورصة الإندونيسية (IDX) وتم اختيار العينات بناءً على طريقة أخذ العينات العشوائية، وتم حساب عدد العينات بناءً على معادلة Slovin، وبلغت العينة ٥٩ مصنعاً، وكانت بيانات التقارير السنوية لمدة سنتين، ومعاملات الأسهم من ٢٠١٦ إلى ٢٠١٧. وأظهرت نتائج الدراسة أن الإفصاح عن المعلومات المستقبلية له تأثير كبير على عدم تماثل المعلومات، كما أشارت الدراسة إلي أن عدم تماثل المعلومات والملكية الأجنبية لهما تأثير كبير على سيولة الأسهم، في حين أن عدم تماثل المعلومات تتوسط العلاقة بين الإفصاحات المستقبلية وسيولة الأسهم.

وفحصت دراسة (Anwar, N. A. M., Kamarudin, F., Noordin, B. A. A., Hussain, H. I., & Mihardjo, L. W. (2021) تأثير مستوى الإفصاح عن المعلومات المستقبلية على عوائد الأسهم للشركة، كما بحثت في ما إذا كان هيكل ملكية الشركة كمتغير معدل إما لإضعاف أو تعزيز العلاقة بين جودة الإفصاح عن المعلومات المستقبلية وعوائد أسهم الشركة، واستخدمت الدراسة العوائد غير العادية، وعوائد الأرباح المعدلة، ونماذج أسعار معدلة كنماذج تجريبية لفحص كل آثار إفصاح عن المعلومات المستقبلية وعواملها المعتدلة على عوائد الأسهم لـ ١٦٨ شركة ماليزية عامة مدرجة، وبناءً على تحليل الانحدار المقطعي أوضحت النتائج أن مستوى الإفصاح وجودته عن المعلومات المستقبلية إيجابي ويرتبط بشكل كبير بعوائد الأسهم للشركة في ظل نموذج عائد الأرباح، وأن هيكل الملكية يلعب أيضاً دوراً مهماً في تعديل العلاقة بين جودة الإفصاح عن المعلومات المستقبلية وعوائد الأسهم للشركة من خلال تعزيز العلاقة.

وناقشت دراسة (Widiastuti, H., Utami, E. R., & Purnamasari, E. (2022) العلاقة بين الإفصاح عن المعلومات المستقبلية (FLID) وأداء الشركة وقيمة الشركة خلال جائحة COVID-19، وتمثل مجتمع هذه الدراسة في الشركات المدرجة في بورصة إندونيسيا (IDX)، واستخدمت الدراسة طرق أخذ العينات الهادفة بناءً على معايير محددة، وبلغت العينة الإجمالية ٤٧٨ ملاحظة، وقامت بتحليل البيانات بناءً على الانحدارات المتعددة باستخدام برنامج EViews، وأظهرت نتائج الدراسة أن الإفصاح عن المعلومات المستقبلية لم يؤثر على قيمة الشركة، بالرغم من إن أداء الشركة له تأثير إيجابي على قيمة الشركة، وأشارت الدراسة إلي أن التفاعل بين أداء الشركة والمعلومات المستقبلية يؤثر بشكل إيجابي على قيمة الشركة.

كما استهدفت دراسة (الشعراوي، ٢٠٢٣) قياس أثر مستوي الإفصاح عن المعلومات المستقبلية علي كفاءة سوق الاوراق المالية بالتطبيق علي الشركات المدرجة بالبورصة المصرية، وبلغت عينة الدراسة ٤٠ شركة من الشركات غير المالية المدرجة بالبورصة المصرية وفقاً لمؤشر EGX100 في الفترة ٢٠١٨-٢٠٢٠، واعتمدت الدراسة في قياس مستوي الإفصاح عن المعلومات المستقبلية علي مؤشر للإفصاح عن المعلومات المستقبلية مكون من ٢٥ بند للمعلومات المستقبلية من خلال استخدام تحليل المحتوي للقوائم والتقارير السنوية، كما استخدمت الدراسة مؤشر حجم التداول كمقياس لكفاءة سوق الأوراق المالية، وتوصلت نتائج الدراسة إلي أن متوسط مستوي الإفصاح عن المعلومات المستقبلية في التقارير السنوية لشركات العينة بلغت نسبة ٥٧,٣٪، وأوضحت الدراسة وجود علاقة موجبة معنوية بين حجم الشركة وكفاءة سوق الأوراق المالية، كما أشارت الدراسة إلي وجود تأثير إيجابي معنوي لمستوي الإفصاح عن المعلومات المستقبلية علي كفاءة سوق الأوراق المالية.

وفي ضوء الدراسات السابقة التي ناقشت العلاقة بين الإفصاح عن المعلومات المستقبلية وعوائد الأسهم اتفقت معظم الدراسات كدراسة؛ (Anwar, N. A. ; Arya, A., et al. (2017) ; M., et al. (2021) ; (الشعراوي، ٢٠٢٣) على أن مستوى الإفصاح وجودته عن المعلومات المستقبلية له تأثير إيجابي علي عوائد الأسهم بالإضافة إلي أنه يساعد علي تقليل تقلبات عوائد الأسهم، فكلما استثمرت الشركة في المعلومات المستقبلية زادت من تحسين دقة الإفصاحات المحاسبية وهذا يساعد علي تقليل عدم تماثل المعلومات بين أصحاب المصلحة وإدارة الشركة ومن ثم تساهم في زيادة كفاءة سوق الأوراق المالية، وعلي عكس ذلك أوضح (Widiastuti, H., et al. (2022) أن الإفصاح عن المعلومات المستقبلية لم يؤثر علي قيمة الشركة.

وبالنسبة للدراسات التي تناولت استخدام تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم اتفق أغلبيتها كدراسة؛ (Ma, Y., ; Khoa, B. T., & Huynh, T. T. (2021) ; Nõu, A., et al. (2021) ; et al. (2021) ; Rafiuddin, A., et al. (2023) ; Fieberg, C., et al. (2023) علي أن تقنيات تعلم الآلة كتقنية آلية نقل الدعم والأقرب تقنيات تعلم الآلة تحسن من دقة التنبؤ بعوائد الأسهم ولكن اختلفت تلك الدراسات علي نوعية تلك التقنيات حيث أكد (Nõu, A., et al. (2021) علي أن تقنيات تعلم الآلة كتقنية آلية نقل الدعم والأقرب جار تحسن من التنبؤ بعوائد وتقلبات الأسهم بشكل أفضل من النماذج التقليدية، في حين فضل (Rafiuddin, A., et al. (2023) أن تقنية الشبكات العصبية الاصطناعية كونها تقدم أداء أعلى دقة وينتج عنها أفضل أداء لاستراتيجية التداول، بينما أظهر (Khoa, B. T., & Huynh, T. T. (2021) ; Rafiuddin, A., et al. (2023) أن تقنية SVM توفر استراتيجية تداول الأسهم للمستثمرين علي المدى القصير لزيادة أرباح التداول إلى الحد الأقصى وذلك لأن لهما طرق تداول فعالة مثبتة، بالإضافة إلي قيامها بحل مشكلة البرمجة التربيعية المقيدة خطياً. وبناءً علي ما سبق عرضه تتمثل الفجوة البحثية في إمكانية الاستفادة من تقنيات تعلم الآلة في تحسين التنبؤ بعوائد الأسهم وهذا بدوره يزيد من جودة الإفصاح عن المعلومات المستقبلية.

وبناءً علي تم عرضة من الدراسات السابقة يمكن اشتقاق الفروض البحثية علي النحو التالي:

الفرض الأول: لا توجد فروق جوهرية ذات دلالة إحصائية بين عوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية وبين عوائد الأسهم المتنبأ بها باستخدام تقنيات تعلم الآلة.

الفرض الثاني: لا يوجد تأثير ذو دلالة إحصائية لعوائد الأسهم المنتبأ بها باستخدام الأساليب التقليدية (أسلوب تحليل Probit، أسلوب تحليل الانحدار المتعدد) على الإفصاح عن المعلومات المستقبلية.

الفرض الثالث: لا يوجد تأثير ذو دلالة إحصائية لعوائد الأسهم المنتبأ بها باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

٦/١ خطة البحث

يستعرض الباحث ما تبقى من البحث من خلال محورين أساسيين، حيث يتناول المحور الثاني الدراسة النظرية من خلال عرض وتوضيح العلاقة بين عوائد الأسهم والإفصاح عن المعلومات المستقبلية في ضوء المعايير المحاسبية المرتبطة وأثر استخدام تقنيات تعلم الآلة على هذه العلاقة، أما المحور الثالث تناول الدراسة التطبيقية واختبار الفروض البحثية، واختتم البحث بعرض أهم النتائج والتوصيات والأبحاث المستقبلية التي توصل إليها الباحث.

المحور الثاني: الدراسة النظرية

يهتم المستثمرين اهتماماً شديداً بتحقيق الأرباح عند الاستثمار في سوق الأوراق المالية، ولذلك عوائد الأسهم من أهم العوامل لاختيار سهم معين من قبل المستثمرين، وتعرف العوائد على أنها التدفق النقدي الفعلي الذي حصل عليه المستثمر خلال فترة زمنية معينة، فهي تعبر عن إجمالي المكاسب أو الخسائر المحققة من الاستثمار خلال فترة معينة ويتكون من توزيعات الأرباح والتغير في قيمة السهم خلال الفترة، ويحتاج هذا المستثمر لمعلومات تساعدهم في تقدير العوائد وتقييم المخاطر المرتبطة بالتدفقات النقدية المتوقعة (Bansal, M., Ali, A., & Choudhary, B. (2021) ، ولذلك يبحث المستثمرين والمساهمين عن المعلومات اللازمة التي تسمح لهم بتقييم مستوى أداء الشركة والوضع المالي لها وهذا ما يوفره الإفصاح المحاسبي الذي يساعد على اتخاذ قرارات استثمارية جيدة من خلال تعظيم قيمة أصولهم عن طريق الاستثمار في أسهم الشركات لأنها توفر أهم الإمكانيات على المدى الطويل للعوائد على أساس مقايضة العائد والمخاطر. (Dang, N. H., et al. (2022)

١/٢ أهمية عوائد الأسهم في ضوء المعايير المحاسبية المرتبطة

تمثل عوائد الأسهم المبالغ أو نسب الأرباح المحققة من الاستثمار التي ينتظرها المستثمرين، فهي تعبر عن قدرة أصول الشركة على تحقيق دخل ويمكن التعبير عنه بنسبة العائد حيث تمثل هذه النسبة ربحية الشركة في كافة عملياتها التشغيلية وغير التشغيلية على الاستثمار خلال فترة زمنية معينة (Mall, P., & Gupta, K. (2019) ، وتعرف أيضاً بأنها عبارة عن تدفقات نقدية يحصل عليها المستثمر نتيجة لحمله مخاطر السهم لفترة زمنية معينة ، أي أنها تعبر عن التدفقات النقدية التي يحصل عليها المستثمر بسبب تعامله في أسهم شركة ما خلال فترة زمنية معينة. PHAM, C. B. (2020). T., et al.

وتتمثل الفئات المهمة بعوائد الأسهم في المساهمين، المستثمرين، الإدارة، المحللين الماليين، وأصحاب المصلحة، بحيث تستخدمه الأطراف المستفيدة في تقييم أداء إدارة الشركة لخلق القيمة للأسهم ومن ثم التنبؤ بالتدفقات النقدية المستقبلية، ومن المؤشرات الشائع استخدامها في التنبؤ بعوائد الأسهم هي مؤشرات متعلقة بالأداء المالي والتشغيلي للشركة ويمكن أن تساعد في التنبؤ بالأداء المستقبلي للشركة، ويعد التنبؤ بعوائد الأسهم من أهم النسب المالية المستخدمة في التنبؤ بأداء الشركة، ويعتمد التنبؤ بحركات سوق الأوراق المالية علي تقديم المعلومة بدقة، من خلال تتبع السوق والتحكم فيه. (Kumar, D., et al. (2022)

ويري الباحث أن عوائد الأسهم أحد المقاييس الهامة لربحية الشركة ومن ثم تستخدم كمقياس للأداء الكلي للشركة عن طريق تحليلها مالياً، وتستخدم أيضاً كمقاييس هامة جداً لنجاح المدراء الماليين في إدارة الشركة، بالإضافة إلي كونها مؤشر هام ومستخدم من قبل الكثير من المحللين الماليين مقياساً لأداء الأسهم، وتساعد عوائد الأسهم أيضاً المحللين الماليين في أداء مهامهم عند تقييم أداء الشركة نظراً لإعطائها مقياساً لمجمل الأداء.

وتنتج أهمية عوائد الأسهم من قياسها لنشاط وأداء الشركة قبل ما يتأثر بتوزيع الإدارة وقبل أن يتم تحديد ما يوزع منه وما يحتجز منه، إذ تعتبر عوائد الأسهم مهمة للإدارة لأنها تساعد في تقييم المخاطر والاستثمارات التي تديرها ومن ثم تستطيع تقييم أدائها (Chordia, T., et al. (2017) ، ويهتم المستثمرين بعوائد الأسهم المتوقعة للشركة خاصةً عوائد السهم العادي علي اعتبار أن تحقيق تدفقات نقدية مستقبلية تنعكس بشكل أكبر علي ما يحصل عليه حامل السهم من التوزيعات النقدية، بالإضافة إلي دخولها في حساب أحد النسب المالية المستخدمة بشكل واسع في تقييم السهم، فمن خلال ربطها بأرباح الشركة المتوقعة بحيث يتمكن المحللين الماليين من معرفة ما إذا كانت قيمة أسهم الشركة أكبر أو أقل من قيمتها الحالية.

ويري الباحث أن عوائد الأسهم تساعد أيضاً في التنبؤ بمستقبل الشركة من حيث الربحية والتدفقات النقدية لذا ينظر إليها المستثمرين كمؤشر هام لاتخاذ القرارات، فهي رقم محاسبي يفسر العديد من المعلومات المفيدة لأصحاب المصلحة بشكل عام وللمستثمرين بشكل خاص، فهي توضح نصيب كل مساهم من صافي ربح الشركة، لذا طالبت بها معايير المحاسبة عن طريق الإفصاح عنها في قائمة الدخل، فالإفصاح عن أرباح الشركة يوفر معلومات عن الأحداث المختلفة التي تمت خلال السنة، حيث يمثل الربح المحقق للأسهم أحد مقاييس الربحية الجيدة التي تستخدم لقياس الأداء ومن خلاله يتم الحصول علي المعلومات الهامة للتحليل المالي، كما يمكن مقارنة هذا الربح المحقق للأسهم مع ما تحققه الشركات الأخرى لمعرفة الوضع المالي للشركة، بالإضافة إلي إمكانية استخدام عوائد الأسهم في التنبؤ بالأرباح ومعدلات النمو الداخلي والتدفقات النقدية.

ويمكن استخدام المعلومات المالية والمحاسبية للشركة بشكل فعال لتقييم فرص الاستثمار للمستثمرين، وتنقسم تلك المعلومات إلي معلومات داخلية وخارجية وفقاً لمصدر المعلومات، حيث يتم الحصول علي المعلومات الخارجية من سوق الأوراق المالية بينما تأتي المعلومات الداخلية من البيانات المالية لذا يمكن للمساهمين والمستثمرين الاعتماد علي المعلومات المحاسبية في البيانات المالية لتقييم عوائد الأسهم بمرور الوقت عند اتخاذ قرارات الاستثمار (Dang, N. H., et al. (2022)

حيث صدر معيار المحاسبة الأمريكي SFA.28 في عام ١٩٩٧ الخاص بالقياس والإفصاح عن عوائد الأسهم، وتم تطبيقه في الشركات التي لديها أسهم عادية حالية أو أسهم عادية محتملة، حيث

طالب هذا المعيار الإفصاح عن عوائد الأسهم في حالة هيكل بسيط لرأس المال ، كما طالب بالعرض المزدوج لعوائد الأسهم الأساسي والمخفض في قائمة الدخل للشركة التي لديها هيكل مركب لرأس المال، ويتم احتساب عوائد الأسهم الأساسية بقسمة الدخل المتاح لحملة الأسهم علي المتوسط المرجح لعدد الأسهم العادية القائمة خلال الفترة، وبالنسبة لعوائد الأسهم المخفضة التي تعكس التخفيض المحتمل لعوائد الأسهم التي يمكن أن تحدث إذا تم تحويل الأوراق المالية إلي أسهم عادية، McEnroe, J. E., & Mindak, M. (2020); J. E., & Sullivan, M. (2018).

كما أصدر مجلس معايير المحاسبة الدولية IASB معيار المحاسبة الدولي رقم (٣٣) والذي يتناول ربحية الأسهم ويطبق علي الشركة التي تتداول أسهمها العادية أو أسهمها العادية المحتملة، وعلي الشركات التي هي في طريقها لإصدار أسهم عادية أو أسهم عادية محتملة في سوق الأوراق المالية، ويتم قياس عوائد الأسهم الأساسية من خلال قسمة صافي ربح الفترة أو خسارتها المنسوب لحملة الأسهم العادية بعد خصم أرباح الأسهم الممتازة علي متوسط عدد الأسهم العادية خلال الفترة، وعند احتساب صافي ربح الفترة أو خسارتها من خلال إدراج جميع بنود الإيرادات والمصروفات المعترف بها خلال الفترة سواء كان مصروف الضرائب أو بنود غير عادية، ويراعي خصم قيمة صافي الربح المنسوب لحملة الأسهم الممتازة من صافي الربح للفترة لكي يتم احتساب صافي الربح أو الخسارة للفترة والمنسوبة لحملة الأسهم العادية (McEnroe, J. E., & Mindak, M. (2020); van Zyl, W., & Uliana, E. (2022) ;

بينما يتم حساب المتوسط المرجح لعدد الأسهم العادية بعدد الأسهم العادية القائمة في بداية الفترة بعد تعديله بعدد الأسهم العادية التي قامت الشركة بإعادة شرائها ويطلق عليها أسهم الخزانة، ويطلب معيار المحاسبة الدولي رقم (٣٣) احتساب عوائد الأسهم المخفضة من خلال تعديل صافي الربح المنسوب لحملة الأسهم العادية والمتوسط المرجح لعدد الأسهم العادية القائمة بتأثيرات جميع الأسهم العادية المحتملة، ويرتفع صافي ربح الفترة والمنسوب للأسهم العادية بقيمة توزيعات الأرباح بعد خصم الضريبة والفائدة المعترف بها خلال الفترة الخاصة بالأسهم العادية المحتملة، ويتم تعديلها بأي تغييرات في الإيرادات والمصروفات التي تنتج من تحويل أسهم عادية محتملة، بينما يرتفع المتوسط المرجح لعدد الأسهم العادية المتداولة بالمتوسط المرجح لعدد الأسهم العادية الإضافية التي ستكون قائمة علي افتراض تحويل جميع الأسهم العادية المحتملة، McEnroe, J. E., & Mindak, M. (2020); van Zyl, W., & Uliana, E. (2022) ; M. (2020)

كما طالب معيار المحاسبة الدولي رقم (٣٣) أن تعرض الشركة عوائد الأسهم الأساسية والمخفضة في صلب قائمة الدخل لكل فئة من الأسهم العادية التي لها حق مختلف للمشاركة في صافي ربح الفترة، لذا ينبغي علي الشركة عرض عوائد الأسهم الأساسية والمخفضة بنفس درجة الوضوح لكل الفترات المعروضة ويتم عرض تلك العوائد حتي في حالة خسارة الأسهم، وطالب أيضاً بالإفصاح عن المبالغ المستخدمة في صورة بسط في حساب الحصة الأساسية والمراجعة من الأرباح لكل سهم، وتسوية تلك القيم مع صافي الربح أو الخسارة للفترة، بالإضافة إلي الإفصاح عن المتوسط المرجح لعدد الأسهم العادية المستخدم كمقام في احتساب العائد علي الأسهم الأساسية المستخدمة كمقام في احتساب عوائد الأسهم الأساسية والمخفضة وتسوية تلك المقامات مع بعضها البعض، وهذا ساعد علي قابلية القوائم المالية للمقارنة، وأخيراً طالب المعيار الشركات بوصف معاملات الأسهم العادية أو المحتملة باستثناء تلك التي تتم محاسبتها وفقاً للفقرة ٦٤ والتي تحدث بعد تاريخ قائمة المركز المالي والتي كان من الممكن أن تغير بشكل كبير عدد من الأسهم العادية المحتملة المتداولة في نهاية الفترة إذا حدثت تلك المعاملات قبل نهاية فترة التقرير. McEnroe, J. E., & Mindak, M. (2020); van Zyl, W., & Uliana, E. (2022)

بينما تم إصدار معيار المحاسبة المصري رقم (٢٢) الخاص بعوائد الأسهم بعنوان "نصيب السهم في الأرباح"، ويطبق هذا المعيار علي الشركات التي تكون أسهمها العادية الحالية أو المحتملة مقيدة في البورصة المصرية، وعلي الشركات التي في طريقها لإصدار أسهم عادية حالية أو محتملة في البورصة المصرية، وفي عام ٢٠٢٣ تعديل نطاق تطبيق المعيار ليصبح ملزم علي القوائم المالية المستقلة أو المجموعة أو المنفردة المصدرة لجميع الشركات، ويتم حساب النصيب الأساسي للسهم في الأرباح من خلال استخدام الأرباح أو الخسائر الخاصة بحاملي الأسهم العادية للشركة، والأرباح أو الخسائر من الأنشطة المستمرة الخاصة بحاملي الأسهم العادية إذا تم عرضها، ويتم حسابه بقسمة صافي أرباح أو خسائر الفترة الخاصة بحملة الأسهم العادية للشركة علي المتوسط المرجح لعدد الأسهم العادية القائمة خلال الفترة.

ويري الباحث أنه من مزايا الإفصاح عن عوائد الأسهم توازن السوق، الحد من المضاربة علي الأسهم، تقليل عامل المخاطرة، تحسين قرارات المستثمرين، الحد من قرارات خروج المستثمرين من السوق، وأخيراً زيادة حركة التداول في السوق، وبالرغم من هذه المزايا إلا أنه يوجد بالإفصاح عن عوائد الأسهم عيوب ومنها انخفاض مصداقية عوائد الأسهم نتيجة للتلاعب بالأرباح المحاسبية من قبل الإدارة لتحقيق أهداف معينة وذلك باستخدامها للبدائل المحاسبية المسموح بها في المعايير المحاسبية بالإضافة إلي احتمالية وجود ممارسات غش في القوائم المالية.

٢ / ٢ الإفصاح عن المعلومات المستقبلية في ضوء المعايير المرتبطة

أصبحت المعلومات المستقبلية ركيزة أساسية بالتقارير المالية للشركات المقيدة بسوق الأوراق المالية في الوقت الحالي نظراً لتقديمها لمعلومات مستقبلية عن خطط وتوجيهات الشركات والتي تحتوي علي أنشطة الاستثمار المستقبلية للشركة وإيراداتها المتوقعة، وهذا ما تفتقده المعلومات التاريخية والتي تعتبر المكون الرئيسي للتقرير المالي التقليدي المقدم لأصحاب المصالح، ولهذا تعتبر المعلومات المستقبلية من عوامل الجذب للاستثمارات وذلك لاهتمام المستثمرين بالمعلومات المستقبلية واعتبارها مفيدة جداً في عمليات صنع القرار لديهم، بالإضافة لكونها محرك أساسي للأسهم من حيث كمية التداول أو السعر في سوق الأوراق المالية، Papaj-Wliskočka, E., & Strojek-Filus, M. (2019).

ويتضح أنه يمكن تصنيف المعلومات المنشورة في التقارير المالية إلي نوعين وهما المعلومات التاريخية والمعلومات المستقبلية حيث تشير المعلومات التاريخية إلي البيانات التاريخية والأحداث الماضية، أما المعلومات المستقبلية تشمل الإفصاح عن البيانات والأحداث الحالية والمستقبلية والتي يمكن أن تتراوح بين الإيرادات والأرباح المتوقعة والتدفقات النقدية المستقبلية بالإضافة إلي المعلومات غير المالية التي تحتوي علي الاستراتيجيات والمخاطر المحتمل أن تؤثر علي النتائج الحالية والأهداف المتوقعة بشكل مباشر، أي أنها تقدم معلومات إضافية عن المتطلبات الإلزامية (الباز، ٢٠٢٢).

ويقصد بالمعلومات المستقبلية من وجهة نظر معيار المراجعة المصري رقم (٣٤٠٠) الخاص باختبار المعلومات المستقبلية، بأنها المعلومات المالية المبنية علي افتراضات عن الأحداث التي قد تقع في المستقبل ورد فعل الشركة تجاهها، فهي تخضع للحكم الشخصي بدرجة كبيرة وقد تكون في صورة تنبؤات أو تقديرات مستقبلية أو كليهما، كما تناولتها إرشاد تعليق الإدارة ضمن إصدارات IFRS في ٢٠١٠ علي أنها معلومات عن المستقبل وتشمل توقعات الأداء والخطط التي سوف تعرض لاحقاً كمعلومات تاريخية بالإضافة إلي احتياج إعدادها للخبرة الذاتية للإدارة وممارسات الحكم المهني.

بينما عرفها (Papaj-Wlisłocka, E., & Strojek-Filus, M. (2019)) علي أنها وصف للأحداث المتعلقة بالأداء السابق للشركة وتتصف بمخاطر عدم التأكد من تحقيقها كما تأخذ في اعتبارها النشاط المستقبلي للشركة والتوقعات المستقبلية، فهي تتناول أنشطة الاستثمار المستقبلية، والإيرادات المتوقعة للشركة، خطط المبيعات، والإجراءات المخطط لها في مجال تحسين عرض المبيعات، أما (Menicucci, E. (2018)) تناول المعلومات المستقبلية علي أنها معلومات حول المستقبل فهي تقدم في صورة بيانات مالية كاملة أو بند من بنود القوائم المالية وتعرض هذه البيانات لمحة عن المستقبل بتوقع نتائج العمل المحتملة، ويتم إعدادها كأداة داخلية لمساعدة الإدارة، وكأداة للمستثمرين للإجابة علي كثير من الأسئلة حول مستقبل الشركة.

ويوجد فرق بين إعداد المعلومات المحاسبية بهدف التنبؤ والذي يعتمد علي توفير معلومات لأصحاب المصلحة عن ما تتوقع إدارة الشركة حدوثه، وبين إعداد المعلومات المستقبلية بهدف التصور أي يقوم معدي التقارير بتوفير معلومات عما لا تتوقع إدارة الشركة حدوثه ولكن من الممكن حدوثه، ويلزم مراعاة بعض العوامل التي قد تؤثر علي الشركة كحالة الاقتصاد القومي، والتغيرات في التشريعات الضريبية، والموارد الاقتصادية المتاحة، وأشارت الدراسة إلي وجود اتجاهين للمعلومات المستقبلية فالأول هو التنبؤات المستقبلية التي تقدم معلومات تم إعدادها وفقاً لافتراضات الإدارة التي تتوقع حدوثها مستقبلاً والخطط المعدة لمواجهةها، أما الاتجاه الثاني هو التقديرات المستقبلية التي يقدم معلومات تم إعدادها وفقاً لمواقف افتراضية يمكن حدوثها مستقبلاً (الباز، ٢٠٢٢؛ إبراهيم، ٢٠٢٣).

ويتضح مما سبق أن المعلومات المستقبلية تشمل القوائم المالية الأساسية كقائمة الدخل وقائمة المركز المالي وقائمة التدفقات النقدية ومؤشرات الأداء المحاسبي، وينبغي أن تحتوي هذه القوائم علي خانات للنتائج المالية لفترات محاسبية سابقة ويعتمد عليها عند إعداد التنبؤات مما يسمح بإجراء المقارنات، ويحتاج إعداد هذه القوائم إلي قدر كبير من الحكم الشخصي للإدارة وإلي درايتها بالأحداث المستقبلية التي يمكن أن تتعرض لها الشركة، بالإضافة إلي استخدام أساليب التنبؤ والطرق الإحصائية لإعدادها، وقد ينشأ مخاطر لإعداد المعلومات المستقبلية نتيجة لظهور اختلاف بين تلك المعلومات والقوائم المالية الفعلية بعد انتهاء السنة المالية وبين توافر حسن النية لدي الإدارة واتباعها للإرشادات الخاصة بتنظيم الإفصاح عن المعلومات المستقبلية.

ويمكن تصنيف المعلومات المستقبلية إلي مجموعتين تتمثل المجموعة الأولى في معلومات مستقبلية قابلة للتحقق كالمعلومات الخاصة بالسهم التي يهتم بها المستثمرين لتحديد موقفهم تجاه الاحتفاظ بالسهم أو بيعها، ومؤشرات الأداء المحاسبي التي تفيد المستثمرين في تقييم موقف السيولة للشركة ومدى ملائمة رأس المال وكفاءة توظيف الموارد المتاحة وموقف الربحية، معلومات خاصة بالتنبؤ بالتدفقات النقدية حيث تهتم الإدارة بالتدفقات النقدية المتوقعة أثناء عملية التخطيط وإعداد الموازنات النقدية وتقديم التفسيرات الخاصة بالفرق بين صافي الربح المحاسبي وصافي تدفقات العمليات التشغيلية، معلومات خاصة بالربحية المستقبلية وتعتبر تلك المعلومات الركيزة الأساسية في تقييم النشاط الاقتصادي للشركة كما تعد من أكثر عناصر القوائم المالية أهمية وملائمة للمستثمرين، معلومات عن الإنفاق الاستثماري ومصرفات البحوث والتطوير حيث تعتمد ربحية الشركة علي قدرتها علي تحقيق استثمارات إضافية لذا يحتاج المستثمرين للتنبؤات عن النفقات الاستثمارية لتحسين قدراتهم علي التنبؤ بالأرباح المستقبلية وعوائد الأسهم بالإضافة إلي الإفصاح عن المبالغ المخصصة لإنفاق علي نشاط البحوث والتطوير، معلومات عن المركز المالي في نهاية الفترات المستقبلية حيث يحتاج إليها المستثمرين للحكم علي قوة المركز المالي للشركة، التنبؤ بالأصول غير الملموسة والتي تساهم بنسبة كبيرة في الأرباح السنوية (سعد الدين، ٢٠١٤).

أما المجموعة الثانية تتمثل معلومات تكميلية متعلقة بالأداء المالي والتي تحتوي علي المخاطر المحيطة بالتوقعات المالية وأثارها المحتملة علي الأداء المالي المستقبلي، معلومات خاصة بهيكل الملكية والتي تحتوي علي هيكل المساهمين ونسبة الملكية، ومناقشة وتعليق الإدارة علي الأداء المالي للعام الماضي مقارنة بالتنبؤات السابقة وأسباب زيادة أو انخفاض الأرباح، والطرق والسياسات المحاسبية المستخدمة لإعداد القوائم المالية المستقبلية وإذا كان إعدادها متفق مع القوائم المالية التاريخية ومع مبادئ المحاسبية (سعد الدين، ٢٠١٤).

وقدم المجمع الأمريكي للمحاسبين القانونيين AICPA تعريف للإفصاح عن المعلومات المستقبلية علي أنه الإفصاح عن المعلومات الخاصة بالفرص والتهديدات وخطط الإدارة في المستقبل، أما معهد المحاسبين القانونيين بإنجلترا ICWA عرفه علي أنه الإفصاح عن أي معلومات قد يكون لها تأثير علي القوائم المالية والأداء المستقبلي للشركة كأهداف واستراتيجية الإدارة والمخاطر التي قد تواجه الشركة والتنبؤات والأداء المتوقع للشركة، في حين تناوله معهد المحاسبين القانونيين الكندي CPA- Canada علي أنه الإفصاح المتعلق بالأداء والأحداث المحتمل حدوثها ويتم توقعها بناءً علي الظروف الاقتصادية المتوقعة، وتحتوي المعلومات المستقبلية علي الأداء المالي، التدفقات النقدية المستقبلية، تقييم الفرص والمخاطر، خطط الإدارة (علي، ٢٠٢١).

وأكد علي ذلك مجلس معايير المحاسبة المالية FASB في الإطار المفاهيمي الصادر في ٢٠١٦ علي أن جودة وفاعلية التقارير المالية تتوقف علي قدرتها في توفير معلومات للمستخدمين عن التدفقات النقدية المستقبلية بالإضافة إلي التوقعات بالأحداث المستقبلية وإجراء التقييمات في حالة عدم التأكد وهذا علي المستوي الدولي، كما أصدرت مجلس معايير المحاسبة الدولية IASB إرشاد تعليقات الإدارة ضمن إصدارات معايير التقارير المالية الدولية IFRS عام ٢٠١٠ والذي استهدف حث منشآت الأعمال علي نشر معلومات تكميلية وإضافة للقوائم المالية تمثل المعلومات المستقبلية كأحد العناصر الرئيسية فيها (إبراهيم، ٢٠٢٣).

وتكمن أهمية الإفصاح عن المعلومات المستقبلية في فهم أصحاب المصلحة لعمليات الشركة المستقبلية مما يعزز شرعية الشركة وبالتالي يعزز استمرار تدفق التمويل للشركة، ويساعد أيضاً علي تلبية احتياجات أصحاب المصلحة من معلومات متعلقة بالشركة مما يساعدهم علي اتخاذ قرارات رشيدة وهذا بدوره يدعم موقفها المالي وضمان نجاحها واستمرارها في الأجل الطويل، ويتضح من ذلك أن الإفصاح عن المعلومات المستقبلية يوفر إشارات إيجابية لأصحاب المصلحة حول موقف الشركة التنافسي وسمعتها، ونظراً لتقديمها لمعلومات تساعد في تقييم الإدارة والتي يترتب عليها تقييم مدي توافر الكفاءات الإدارية التي تستطيع التعامل مع التغيرات المستقبلية مما يحسن أداء الشركة في المستقبل.

وأكد الدليل المصري لحوكمة الشركات بالإصدار الثالث علي أهمية الإفصاح عن المعلومات المحاسبية وذلك لضرورة إفصاح الشركات عن المعلومات المالية وغير المالية التي تهم المساهمين وأصحاب المصلحة، فهي تحتوي علي المعلومات الداخلية التي تشمل علي أهداف الشركة ورؤيتها وطبيعة نشاطها واستراتيجيتها وخططها المستقبلية، لذا أكد الدليل علي ضرورة توافر الإفصاح والشفافية لتوطيد العلاقة مع كافة أصحاب المصلحة ومن ثم يؤثر ذلك بشكل إيجابي علي أصحاب المصلحة، وينبغي علي الشركة أن تصدر تقرير سنوي يحتوي علي ملخص لتقرير مجلس الإدارة والقوائم المالية بالإضافة إلي كافة المعلومات الأخرى التي تهم المستفيدين من التقارير المالية، ويضم هذا التقرير استراتيجية الشركة وأنشطتها الحالية والمستقبلية، كما ينبغي عرض تقرير مجلس الإدارة علي الجمعية العمومية والجهات الرقابية (علي، ٢٠٢١).

ومن وجهة نظر أخري أوضح (Dey, P. K., et al. (2020) أن الإفصاح عن المعلومات المستقبلية يعتمد علي تقديم التنبؤات الاقتصادية وغير الاقتصادية وتحتوي التنبؤات الاقتصادية علي الإيرادات والربحية والتدفقات النقدية بينما تتمثل التنبؤات غير الاقتصادية في المخاطر والخطط والاستراتيجيات العامة للشركة مع التركيز علي الأجل القصير وهذا يدعم المركز التنافسي للشركة ومن ثم تمكن أصحاب المصلحة من اتخاذ القرارات، وأكد (Mousa, G. A., & Elamir, E. A. (2018) علي أن أهمية المعلومات المستقبلية تنبع من قدرتها علي توفير فهم أفضل لأصحاب المصلحة عن الأداء المالي المستقبلي للشركة ومقارنته بالأداء الحالي وذلك لأن المعلومات التاريخية غير قادرة لوحدها علي توضيح الوضع المالي للشركة.

بينما يري (Papaj-Wliscocka, E., & Strojek-Filus, M. (2019) وجود بعض العيوب للإفصاح عن المعلومات المستقبلية وهي وجود بها احتمالية عدم التأكد من حدوثها، بالإضافة إلي أنه مع سهولة الوصول للمعلومات المستقبلية يمكن للمنافسين الوصول إلي خطط الاستثمار المتعلقة بالشركة والإطلاع علي خططها المستقبلية، ومن ثم يمكنهم استخدام ذلك ضد الشركة، لذا يتوجب علي الشركة الموازنة بين فوائد الإفصاح عن المعلومات المستقبلية ومخاطر استغلالها من المنافسين.

ويري الباحث أن الإفصاح عن المعلومات المستقبلية يوفر معلومات مالية وغير مالية وهذا بدوره يساعد أصحاب المصلحة علي فهم وضع الأنشطة المستقبلية للشركة، كما يساعد علي تقييم وضع الإدارة وقدرتها علي مواكبة أي تغيرات مستقبلية، وهذا يحقق هدف التقرير المالي الذي أشار إليه الإطار المفاهيمي ٢٠١٨، وهذا يتوافق مع رأي AICPA بأن المعلومات التي ينبغي الإفصاح عنها لأصحاب المصلحة يجب أن تحتوي علي البيانات المالية وغير المالية، ومناقشات وتحليلات الإدارة، والإفصاح عن المعلومات المستقبلية بالإضافة إلي المعلومات المتعلقة بالشركة والمساهمين والإدارة، لذا يعد الإفصاح عن المعلومات المستقبلية أحد أبعاد تحسين جودة التقارير المالية للشركات، حيث توفر المعلومات المستقبلية لأصحاب المصلحة معلومات عن أهداف واستراتيجيات الشركة المستقبلية وما هي المخاطر المحتملة ومن ثم يستطيع المستخدم الخارجي للتقارير المالي التنبؤ بالتدفقات النقدية ومعدلات الأرباح المتوقعة.

٣/٢ تقييم تقنيات تعلم الآلة في ضوء ما ورد بالفكر المحاسبي

نتيجة لتقدم بيئة الأعمال الإلكترونية اتجهت الكثير من الشركات إلي التوسع في تطبيق أنظمة الذكاء الاصطناعي والتشغيل الإلكتروني للبيانات والتي من ضمنها تقنيات تعلم الآلة، كما تم استخدام تقنيات الذكاء الاصطناعي من قبل شركات المحاسبة الأربعة الكبرى كشركة KPMG, IBM Watson لتحليل كميات كبيرة من البيانات المنظمة وغير المنظمة المتعلقة بالمعلومات المالية للشركة (Sun, T. (2019) ، حيث يختلف منهج تعلم الآلة عن المنهج الأساليب التقليدية فهو موجه للتنبؤ في حين أن المنهج التقليدي موجه للتفسير، أي أن منهج تعلم الآلة يركز بشكل أساسي علي التنبؤ خارج العينة بالمتغير التابع بدلاً من تفسير المتغير التابع ضمن العينة. van Der Heijden, H. (2022)، كما تستخدم تقنيات تعلم الآلة خوارزميات إحصائية لتوفير القدرة علي التعلم وتحسين الأداء بشكل تدريجي في جزء محدد من خلال قيامها بعملية تحليل البيانات والتي تستخدم فيها التقنيات لإيجاد الأنماط الضمنية ومن ثم تطبيق الأنماط الموجودة لعمل تنبؤات حول المستقبل. Hunt, J. O., et al. (2022).

ويمكن تعريف تقنيات تعلم الآلة بأنها أحد فروع الذكاء الاصطناعي التي تُمكن الحاسب الآلي من أداء مهام تتصف بالذكاء حيث تقوم هذه التقنيات بعمليات معقدة بعد التعلم من البيانات بدلاً من اتباع القواعد المبرمجة مسبقاً (Ding, K., et al. (2020) ، وذلك عن طريق استخدام البيانات التاريخية كمدخلات والتنبؤ بالنتائج غير المبرمجة بشكل صحيح، فهي تحول 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, X., et al., (2022).

بينما ذكرها Sun, T. (2019) علي كونها ممارسة استخدام التقنيات لتحليل البيانات، ومعرفة الأنماط الأساسية، وتطبيق نمط البيانات المكتسبة أو الاتجاه لعمل التنبؤات فعلي سبيل المثال يستخدم البنك تقنيات تعلم الآلة لبناء نموذج التنبؤ بمخاطر الائتمان من خلال تحليل كميات كبيرة من البيانات التاريخية، وتقوم تلك التقنيات بعمل قائمة لسمات لكل بند من البيانات كالمبلغ المتراكم للسحب النقدي، وتكرار فواتير العميل، وعدد الأيام التي ظلت فيها المعاملات السابقة غير مدفوعة، وخصائص العميل كالعمر والمهنة والدخل السنوي.

وبناء علي ذلك تتمثل أنواع تقنيات تعلم الآلة في تقنيات خاضعة للإشراف والتي تعد أحد طرق التعلم التي تعمل علي برمجة الآلة بمجموعة من البيانات المصنفة لكي تعطي للآلة خبرة تستطيع عن طريقها استخراج الأنماط لتطبيقها علي البيانات خلال مرحلة التنبؤ، وتقوم هذه التقنيات علي أساس فئات المخرجات المحددة المستهدفة مسبقاً كتقنية أقرب جار وتقنية آلية ناقله الدعم، Eachempati, P., et al. (2021)، بينما تعتبر التقنيات غير الخاضعة للإشراف كالتعلم العميق والتي هي أحد طرق التعلم الذي يتم فيها برمجة الآلة بمجموعة من البيانات غير المصنفة وتحاول الآلة استخراج الأنماط بنفسها وهذا النوع يتم استخدامه عندما يتواجد كمية هائلة من البيانات غير المصنفة، وأخيراً يوجد تقنيات شبه خاضعة للإشراف فهي عبارة عن نموذج تعلم سلوكي يعتمد علي التجربة والخطأ لكي يتكون لدي الآلة الخبرات في البيانات الديناميكية (Ding, K., et al., (2020).

ويري الباحث أن تقنيات تعلم الآلة قادرة علي التعمق في البيانات الضخمة ولديها القدرة أيضاً علي حل الأنماط المعقدة في تلك البيانات والتي تصعب علي الطرق التقليدية، وبعد ذلك تقوم باختيار أفضل حل للمتغيرات ومن ثم يمكنها عمل تنبؤات دقيقة من خلال استخدام البيانات التاريخية كمدخلات والتنبؤ بالنتائج غير المبرمجة بشكل صحيح، فهي لديها القدرة علي تحول البيانات الخام إلي بيانات منتظمة ومفهومة ومن ثم معلومات مفيدة.

تتمثل تقنيات تعلم الآلة في تقنية شجرة القرارات، تقنية الغابة العشوائية، تقنية الشبكات العصبية الاصطناعية، تقنية أشجار الانحدار المعزز، تقنية آلية التدرج المعزز، تقنية الشبكة العصبية متعددة الطبقات، تقنية الشبكة العصبية للذاكرة طويلة المدى، تقنية آلية نقل الدعم، وتتكون تقنية شجرة القرارات (DT) من مجموعة من العقد، وتنشئ كل عقدة خطوة تمثل قيمة أحد المتغيرات المستقلة، على سبيل المثال إذا اكتشفت التقنية أن زيادة الأرباح تكون أكثر ترجيحاً للشركات ذات القيم الكبيرة من إجمالي الأصول مقارنة بالشركات ذات القيم الصغيرة لإجمالي الأصول، فإنها تشكل عقدة لها جانبان مهمان، الأول: هو تحديد إجمالي الأصول، والثاني هو تحديد القيمة المثلى لتقسيم الملاحظات إلى مجموع الأصول الكبيرة والصغيرة، وبناء علي ذلك تنشئ شجرة القرار عقدة إضافية وتعمل هذه الخطوة على الوصول لأفضل حل في كل عقدة بهدف إيجاد أفضل حل، وبالرغم من قيامها بتحديد أفضل بديل للعقدة الحالية لكنها لا تأخذ بعين الاعتبار العقد المستقبلية، مما يعني أنها تستمر في إنشاء عقد إضافية (Hunt, J., et al. (2019).

فبالرغم من كون تقنية شجرة القرارات مفيدة في التصنيف والتنبؤ إلا أنها قد تكون ذات قدرات محدودة لتعلم البيانات، ويعاب عليها بالتباين العالي مما يعني أن تغييراً طفيفاً في العينة يمكن أن يؤدي إلى تغيير كبير في الشجرة النهائية وهذا يعني أنها قد تقوم بالإفراط في استيعاب بيانات التدريب، بينما تعمل الغابة العشوائية على تحسين دقة أشجار القرار باستخدام تقنية المجموعة (Hunt, J., et al. (2019).

وتعد تقنية الغابة العشوائية (RF) قادرة على أداء مهام الانحدار والتصنيف، وتقوم هذه التقنية علي فكرة الجمع بين عدة أشجار قرار من خلال إنشاء ملف "غابة" من شجرة القرارات، فهي عبارة عن أسلوب تعلم آلة يقوم باستخراج المعلومات من البيانات ويعرضها في شكل بناء شجرة، وتتكون الغابة العشوائية من أشجار القرار وتكيس الأشجار، وذلك بهدف تحديد الناتج النهائي بدلاً من الاعتماد علي شجرة قرارات فردية من أجل تقليل التباين في النموذج، وبشكل عام كلما ارتفع مستوى عدد الأشجار الفردية كان أداء الغابة العشوائية أفضل في التنبؤ، وتتميز هذه التقنية بأنها مرنة وسريعة وتتصف بالتصنيف البسيط ولذلك تكون قابلة للتطبيق علي معالجة البيانات واسعة، كما يمكن تطبيقها بسهولة على مجموعات البيانات التي تحتوي على بيانات مفقودة، ويمكنها تحديد القيم المتطرفة والمجموعات الطبيعية (Ding, K., et al. (2020); Vijn, M., et al. (2020).

أما تقنية أشجار الانحدار المعزز (BRT) تقوم بالتنبؤات على أساس مجموعات كبيرة من المعلومات بدون افتراضات خطية ولديها القدرة علي التعامل مع مشاكل التنبؤ دون التجهيز وتعطي هذه التقنية تحليل خالي من التحايل علي البيانات، كما توفر BRT أيضاً إطاراً طبيعياً لتقييم الأهمية النسبية من المتنبئين المختلفين في التنبؤ بالعوائد الزائدة والتقلبات (Rossi, A. G. (2018)، كما تستخدم تقنية آلية التدرج المعزز (GBM) أسلوب المجموعة لتعزيز التدريب الجديد لنماذج التنبؤ المتعلقة بأخطاء النماذج السابقة، وتحويل نماذج التنبؤ الضعيفة إلى أقوى، ويكمن الهدف من التعزيز في تقليل أخطاء النموذج عن طريق إضافة المتعلمين الضعفاء أي أشجار الانحدار بعد الإضافة أشجار جديدة، فإن إجراء التعلم يصحح الأخطاء اللاحقة التي حدثت في السابق ويحسن التنبؤات لتقليل المخلفات بطريقة متدرجة النسب بعد أن يصل عدد الأشجار إلى نقطة النهاية، ولكن لن يؤدي إضافة المزيد من الأشجار إلى تحسين أداء التنبؤ (Ding, K., et al. (2020).

في حين أن تقنية شجرة الانحدار المعزز بالتدرج (GBRT) تعبر عن طريقة للانحدار لشرح احتمالات الأخطاء، وتتمتع هذه التقنية بميزة مفاهيمية إضافية تتعلق بطرق الانحدار التقليدية كالمربعات الصغرى العادية، وتلتقط هذه التقنية العلاقة بين البيانات الخاطئة والبيانات المالية، مما يمكن المعدين والمستثمرين والمحللين من إجراء تقييم أفضل للمتنبئين بالأخطاء، ومن ثم القيام بوضع خطة مناسبة لاتخاذ الإجراءات الوقائية، أي أن هذه التقنية تعمل بشكل أفضل علي القياس القائم علي الاحتمالية والتوقعات بحدوث أخطاء، وتؤدي تلك التقنية أداء أفضل في فصل البيانات غير صحيحة عن البيانات الجيدة (Bertomeu, J., et al. (2021).

بينما تعد تقنية الشبكة العصبية الاصطناعية (ANN) قادرة علي محاكاة وتحليل الأنماط المعقدة في البيانات غير المنظمة مقارنة بمعظم الطرق التقليدية، تستخدم التقنية البنية الأساسية للشبكة العصبية التي تحتوي علي خلايا عصبية ذات طبقات مختلفة، والتي تتكون من ثلاثة طبقات وهما طبقة المدخلات وطبقات مخفية أو تنشيط وطبقات المخرجات، حيث تتلقى طبقة المدخلات البيانات الأولية للمتغيرات التفسيرية وفيها تتساوي عدد العقد في طبقة المدخلات مع عدد المتغيرات التوضيحية،

وبالتالي ترتبط طبقة المدخلات بالطبقات المخفية والتي تطبق تحولات معقدة على البيانات الواردة ونقل المخرجات إلى الطبقات المخفية التالية، ويسمى إخراج ملف الطبقة النهائية بطبقة المخرجات التي تمثل معلومات عالية المستوى تم استخراجها من البيانات الأولية (Vijh, M., et al. (2020)، ويتم استخدامها بشكل متكرر في التنبؤات المالية باستخدام البيانات النصية والرقمية (Rouf, N., et al. (2021)، وأظهر (Martins, A. I. (2022) أن تطبيق تقنية الشبكة العصبية التي تتضمن متغيرات محاسبية أساسية يؤدي إلى تنبؤات أكثر دقة من نماذج التنبؤ.

وتعتبر تقنية الشبكة العصبية للذاكرة طويلة المدى (LSTM) نوع من الشبكات العصبية المتكررة التي يمكنها الاحتفاظ بذاكرة الإدخال داخلياً وهذا يجعلها مناسبة بشكل خاص لحل المشكلات التي تتضمن بيانات متسلسلة كالسلاسل الزمنية (Eachempati, ; Yadav, A., et al. (2020)، بينما تعمل تقنية آلية نقل الدعم (SVM) علي زيادة الأداء في التعرف علي الأنماط ثم التنبؤ بالسلاسل الزمنية المالية والتسويق وتقدير إنتاجية التصنيع، وتصنع تلك التقنية أفضل اتجاه للقرار وتستطيع تقسيم فئات مختلفة بحيث يمكن تصنيف نقاط البيانات الجديدة والتنبؤ بها بشكل صحيح، كما ينتج عنه مصنفاً ثنائياً ويسمى بالطبقات الفائقة الفاصلة المثلي عن طريق رسم خرائط غير خطية للغاية لمواجهة الإدخال، ثم تبني نموذج خطي لتقدير وظيفة القرار باستخدام حدود الفئة غير الخطية علي أساس دعم التمييز، وأخيراً تقوم بتدريب الشبكات الخطية للحصول علي المستوي الأمثل الذي يفصل البيانات بدون خطأ (Chen, X., et al. (2022).

أما تقنية الشبكة البايزية (BN) التي تعرف باسم شبكة بايز أو شبكة الاعتقاد أو شبكة اتخاذ القرار أو الشبكات السببية أو شبكات الاحتمالات البيانية فهي عبارة عن نموذج رسومي احتمالي يمثل مجموعة من المتغيرات أو الصفات واعتمادهم الشرطي باستخدام رسم بياني دوري موجه DAG، ويحتوي هذا الرسم البياني DAG علي الصفات الموجهة فقط وتمثل كل عقدة في الرسم خاصية ويمثل كل سهم احتمالاً مستقلاً، أي يمكن من خلال هذا الرسم البياني التعرف علي العقد الأكثر أهمية، وغالباً ما تستخدم هذه التقنية لتمثيل العلاقات السببية كما تمكن مستخدميها من حساب احتمالية حدوث حدث ما، لذا تشكل منهج للنمذجة الفعالة في إدارة المخاطر (Chan, L. S., et al. (2023).

٤/٢ التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة كمرتكز لتحسين جودة الإفصاح عن المعلومات المستقبلية

يتضح أن عوائد الأسهم شديدة التقلب، حيث يحدث التقلب المفرط في أسعار الأسهم عندما يتصرف المستثمرون وفقاً لأسباب سلوكية، أو عند مواجهتهم لحالة من عدم التأكد عند التعرف على الأساسيات، لذا يصعب التنبؤ بالتداول السلوكي وهذا يدل علي أن جزءاً مهماً من العوائد سيكون غير متوقع (Green, J., & Zhao, W. (2022)، واتفق مع هذا الرأي (Rouf, N., et al. (2021). علي أن هناك ارتباط كبير بين أسعار الأسهم والأحداث المتعلقة بالأسهم علي الويب عندما يتم استخراج معلومات الحدث من الإنترنت للتنبؤ بأسعار الأسهم وهذه الطريقة يطلق عليها التنبؤ بعوائد الأسهم التي يحررها الحدث، فمن خلال شبكات التواصل الاجتماعي يقوم الأشخاص بتوليد كميات هائلة من البيانات، والتي تؤثر على تصورات المستخدمين واهتماماتهم.

ولذلك يعد تحليل تصورات المستخدمين مجال دراسة يتعامل مع اهتمامات الناس ومعتقداتهم تجاه الشركة، حيث تسمح المعلومات التي توفرها وسائل التواصل الاجتماعي لتقنيات تعلم الآلة باستكشاف آراء واسعة حيث تساعد تلك الوسائل في استكشاف التصورات والإطلاع على بيانات السلاسل الزمنية الرقمية للأسهم وهذا يعزز دقة التنبؤ بعوائد الأسهم، ومن ضمن هذه التقنيات تقنية الشبكات العصبية التي تقدم دقة أعلى لتصنيف التعليقات القائمة على الأسهم المنشورة في الشبكات الاجتماعية للمتداولين (Eachempati, P., et al. (2021).

وينبغي الاعتماد على تقنيات تعلم الآلة لاستخراج تصورات المستثمرين والتنبؤ بها، حيث تقوم تلك التقنيات بتصنيف هذه التصورات من خلال تدريب تلك التقنيات مسبقاً عليها، أو من خلال استخدامها في سياقات متعددة لتوليد أنماط تصنيف جديدة وهذه الطريقة تعد ميزة مهمة في تقنيات تعلم الآلة، ومن ضمن هذه التقنيات تقنية الشبكات العصبية التي تقوم بهذه المهمة بشكل متكرر على كل كلمة في المستند. ولهذا فإن تقنيات تعلم الآلة تعد الحل الأمثل والمناسب للتعامل مع بيانات السلاسل الزمنية كبيانات سوق الأوراق المالية، حيث تشتمل تلك التقنيات على نظام يساعد على تخزين معلومات أكثر فهي تقوم بمعالجة المعلومات الفعلية ومقارنتها ومن ثم زيادة دقة التصنيف لتحليل التصورات وبالتالي تزيد من جودة التنبؤ بعوائد الأسهم وهذا بدوره يزيد من جودة الإفصاح عن المعلومات المالية المستقبلية (Eachempati, P., et al. (2021).

وقد تتيح الزيادة في حجم وتوافر معلومات الإفصاح اختبار مختلف النظريات الاقتصادية ذات بيانات كبيرة، حيث تعتبر المعلومات الناتجة من إفصاح الشركات معقدة لأنها تحتوي على كلا النوعين من البيانات الكمية والمعلومات النصية النوعية المستخرجة من الإفصاحات والأخبار وآراء الخبراء والمدونات الصغيرة لوسائل التواصل الاجتماعي (Eachempati, P., et al. (2021)، ونظراً لإشارة فرضية السوق الفعال إلى مفهوم الكفاءة أي الاستيعاب السريع للمعلومات بدلاً من الموارد التي تنتج أقصى إنتاج كما هو الحال في مجالات الاقتصاد الأخرى، حيث تعرف المعلومات بأنها أخبار يمكن أن تؤثر على الأسعار ولا يمكن التنبؤ بها، بينما يمكن تعريف مفهوم الكفاءة في سوق رأس المال بشكل آخر وهو أن الأسعار في السوق تعكس دائماً المعلومات المتاحة ويطلق على ذلك كفاءة السوق (Khoa, B. T., & Huynh, T. T. (2021).

لذا يعد اختيار الطريقة المناسبة للتنبؤ أمر ضروري وذلك لأن البيانات غير المنظمة الناتجة عن التطورات الاقتصادية جعلت طرق المعالجة التقليدية غير قادرة على التنبؤ، ونتيجة للتحيز والقيود المفروضة على القوة المعرفية الذي قد لا يتمكن بعض البشر من سرعة فهم عمليات الإفصاح، ولكن تستطيع تقنيات تعلم الآلة تحديد كيفية استخلاص النص من إفصاحات الشركة بغض النظر عن جمع البيانات المالية التاريخية للأسهم، بالإضافة إلى قدرتها على استخلاص التصورات بالرغم من احتياجها لمزيد للتأكد من دقتها، والدليل على ذلك قدرة تقنية الشبكات العصبية الالتفافية على التنبؤ باتجاه عوائد السهم بشكل أكثر دقة من النماذج التقليدية وذلك لأن التنبؤ بعوائد السهم يحركه الحدث والذي يلزمه التنقيب عن النص من العناوين الرئيسية للأخبار (Eachempati, P., et al. (2021).

كما ساعدت تقنيات تعلم الآلة على استبعاد التناقضات في إفصاحات المحللين والمستثمرين، من خلال قيامها بتقليل البيانات وتحويلها إلى متغيرات رقمية قابلة للقراءة والتفسير والتحليل (Eachempati, P., et al. (2021)، حيث تتعلم تقنيات تعلم الآلة الأنماط المخفية للبيانات بطريقة تحكمها توليفة محددة من البارامترات المفرطة، وبعد ذلك تستطيع تحديد التركيبة المثلى من المعلمات الفائقة التي تنتج نموذجاً مع التنبؤ الأكثر دقة والذي يعتمد على التجربة والخطأ (Khoa, B. T., & Huynh, T. T. (2021).

وقد يجذب المستثمرين إلي المعلومات النصية بدلاً من الأرقام الكمية الموضحة في تقارير المحللين، وقد يتفاعل المستثمرين مع الأخبار السلبية من المحتوى الكمي الإيجابي، وبالرغم من وجود علاقة سلبية بين توقعات النمو طويلة الأجل للمحللين والعوائد المستقبلية المعدلة حسب المخاطر، وبالتالي تؤدي التقديرات العالية للمحللين الخاصة بنمو الأرباح المستقبلية إلي عوائد ضعيفة علي حقوق الملكية في فترات لاحقة، ولكن من خلال استخدام تقنيات تعلم الآلة للبيانات غير المنظمة من إعلانات ما بعد الأرباح يتوقع أن تؤدي تحليلات النص إلي إمكانية التنبؤ علي المدى الطويل لعوائد الأسهم أكثر من المعلومات الكمية، كما تساعد تلك التقنيات في الإفصاح عن توقعات الأرباح المستقبلية .Eachempati, P., et al. (2021).

حيث تقوم تقنيات تعلم الآلة في عملية التنبؤ بعوائد الأسهم بجمع البيانات المناسبة التي توفر كمية هائلة من بيانات الإدخال الضرورية لتدريب تقنية الشبكة العصبية، ويمكن توضيح أنواع تلك البيانات كالتالي: (Jiang, W. (2021)

١. بيانات السوق: التي تتعلق بجميع أنشطة التداول التي تحدث في سوق الأوراق المالية، وتعتبر تلك البيانات هي الخيار الأفضل والأكثر استخداماً لأنها توفر أكبر قدر من عينة البيانات.
٢. بيانات النص: التي تشير إلي النص الذي ساهم به الأفراد كوسائل التواصل الاجتماعي والأخبار وعمليات البحث علي الويب، وتعتبر بيانات النص نوع من البيانات البديلة والتي يصعب جمع كل هذه البيانات ومعالجتها بالطرق التقليدية بالرغم من كونها قد تقدم معلومات مفيدة لم توفرها بيانات السوق.
٣. بيانات الاقتصاد الكلي: التي تعكس بيانات مؤشرات سعر المستهلك وإجمالي الناتج المحلي وتعكس هذه المؤشرات جودة تقدم أو هبوط سوق الأوراق المالية.
٤. بيانات الرسم البياني للمعرفة: التي تعبر عن حركة الأسهم التي قد تتأثر بنفس القطاع أو نفس الأخبار.
٥. بيانات الصورة: التي تستوحي من نجاح الشبكات العصبية التلافيفية في معالجة الصور ثنائية الأبعاد وتستخدم تقنيات تعلم الآلة المخططات كصور إدخال لتوقع عوائد الأسهم، بينما تقوم الأقمار الصناعية باستخدام الصور ومقاطع الفيديو لمراقبة أوضاع الشركات وقد تكون هذه البيانات في التنبؤ بعوائد الأسهم.
٦. البيانات الأساسية: ويعد هذا النوع من البيانات الأكثر شيوعاً وهو البيانات المحاسبية التي تم الإفصاح عنها كل فترة مالية كالأصول والإلتزامات وحقوق الملكية.
٧. بيانات التحليلات: التي تشير إلي البيانات التي يمكن استخراجها من التقارير كالتوصية ببيع أو شراء الأسهم، وتعد البنوك الاستثمارية هي أكثر الشركات التي تقوم بعمل تحليل عميق لنماذج أعمال الشركات وأنشطتها، ويمكن أن توفر هذه التقارير معلومات للتقييم بالرغم من كونها مكلفة ولكن يحتاجها المستثمرين لتحقيق الربح أو لاتخاذ قرارات استثمارية أفضل.

وهذا ما اتفقت معه دراسة Kumar, D., et al. (2022) عندما ذكرت أن تقنيات تعلم الآلة تقوم بجمع البيانات في الوقت الفعلي من مصادر مختلفة أما من مواقع الويب أو مجموعة البيانات السابقة، وبعد جمع تلك البيانات تتم المعالجة لإزالة الضوضاء والمعلومات الأخرى ثم يمكن أن تكون معالجة البيانات مفيدة للتنبؤ بسوق الأسهم، كما تقوم تقنيات تعلم الآلة ببعض وظائف محلل البيانات ويتقسيم مجموعة البيانات إلي فئتين فرعتين وهما التفاصيل المالية والتنبؤية، وتعد هذه التفاصيل مفيدة جداً لاتخاذ قرارات استثمارية أفضل في سوق الأسهم.

وهذا ما أكدت عليه دراسة Jiang, W. (2021) حين ذكرت أن تقنية الشبكات العصبية العميقة مدعومة بجمع البيانات الضخمة من الويب بالإضافة إلي إمكانية المعالجة المتوازية لوحدة معالجة الرسومات، ويتضح من ذلك أن قدرة تقنيات تعلم الآلة قوية في التعامل مع البيانات الضخمة وتعلم العلاقة اللاخطية بين ميزات الإدخال وهدف التنبؤ، كما أكدت الدراسة علي قدرة تقنيات تعلم الآلة علي جمع الأخبار من الإنترنت وبيانات تويتر التي توفر مصادر جديدة للتنبؤ بعوائد الأسهم، بينما تقوم تقنية الشبكات العصبية بعمل رسم بياني عصبي تظهر فيه الشبكات التي تستخدم بيانات الرسم البياني المعرفي المختلفة كأفكار جديدة لتوقع سوق الأوراق المالية ومن ثم التنبؤ بعوائد الأسهم، وأظهر (2021) Khoa, B. T., & Huynh, T. T. أيضاً أن تقنية SVM تعتبر أداة قيمة للتنبؤ باتجاه حركة السعر في السوق نظراً لأن عوائد الاستثمار المرتفعة غالباً ما تخفي المخاطر الأساسية، لذا يجب تبرير نتائج الاستثمار وفقاً لزيادة مستوي الثقة في تقييم أداء الاستثمار وذلك من خلال زيادة الإفصاح عن المعلومات المستقبلية، واتفقت في ذلك دراسة (2023) Rafiuddin, A., et al. علي تفوق تقنية SVM عن باقي التقنيات الأخرى في الأداء حيث أنها تقوم بحل مشكلة البرمجة التربيعية المقيدة خطياً.

كما يمكن الاستفادة من تقنيات تعلم الآلة في التنبؤ بعوائد الأسهم من خلال تقديمها لتأكيد مقطعي للبيانات النصية والرقمية الموضحة في الإفصاحات، وتقديمها لملاحظات علي الحسابات والسياسات المحاسبية المعتمدة بهدف تقييم الاستحقاقات المبنية في الحسابات، بالإضافة إلي قدرتها علي دمج معلومات الإفصاحات الإلزامية مع الإفصاحات الطوعية والأخبار ووسائل الإعلام والتقارير والمدونات، كما تستطيع الحصول علي معلومات من مصادر أخرى، وقدرتها أيضاً علي تحليل تقارير لجنة المراجعة في وقت واحد لإظهار التناقضات في الإفصاح وتحليل تقارير المحللين الماليين أيضاً، بالإضافة إلي قيامها بفحص الإشارات غير اللفظية للإفصاحات والمقابلات مع الرؤساء التنفيذيين، وهذا بدوره يساعد علي تحسين دقة التنبؤ بعوائد الأسهم ومن ثم جذب المستثمرين من خلال تحسين الإفصاح عن المعلومات المستقبلية (2021) Eachempati, P., et al.

وتقدم أيضاً تقنيات تعلم الآلة طرق جديدة للعثور علي أنماط في الأرقام المحاسبية مما يساعد المنظمين علي مراقبة ممارسات إعداد التقارير، بالإضافة إلي قيامها بتطوير نموذج التنبؤ وقيامها بتسجيل البنود ألياً مما يساعد في اكتشاف أي مبالغة في قائمة الأرباح باستخدام نسب البيانات المالية (2021) Bertomeu, J., et al., وهذا يساعد في التنبؤ بعوائد الأسهم ودعم الإفصاح عن المعلومات المستقبلية.

ولذلك يمكن استخدام تقنيات تعلم الآلة كجهاز مراقبه لضبط معنويات السوق عن طريق التأكد من إجراءات إفصاح الشركات في الوقت المناسب وبدقة عالية لتفادي التداول من الداخل، ويمكن أيضاً الاستفادة منها في تقليل قدرة الشركات علي إدارة معلوماتها من خلال تقديمها لاستراتيجيات إفصاح جديدة للإدارة وهذا بدوره يزيد من الإفصاح عن المعلومات المستقبلية بصورة معقولة . Eachempati, P., et al. (2021)

وأكد Chang, V., et al. (2021) علي دقة تقنيات تعلم الآلة في التنبؤ ببيانات سوق الأسهم من خلال قيامها بالجمع بين التطبيق العملي للتقنيات واستراتيجية التداول الفنية كمؤشر القوة العكسية للتداول التقني ، كما حققت الدراسة في أداء الاستراتيجية الفنية لتداول الأسهم علي مختلف المحافظ في سياق سوق الأسهم الأمريكية، وتوصلت إلي دقة تقنية الشبكة العصبية في التنبؤ بعوائد الأسهم، بينما أوضح Yang, C., et al. (2020) أن الشبكة العصبية للذاكرة طويلة المدى LSTM مزودة بجهاز تشفير آلي للتنبؤ بسوق الأوراق المالية ومن خلاله تستطيع التنبؤ بعوائد الأسهم، ومن وجهة نظر Rafiuddin, A., et al. (2023) تقنية ANN تقدم نتائج واعدة في التنبؤ بعوائد سعر السهم.

ومن وجهة نظر أخري يمكن الاستفادة من تقنيات تعلم الآلة في عمل التحليل الأساسي والتحليل الفني، حيث يقوم التحليل الأساسي بتقييم سعر السهم بناءً علي قيمته العادلة، بينما يعتمد التحليل الفني فقط علي أساس الرسوم البيانية واتجاهات، ويمكن استخدام المؤشرات الفنية كمميزات إدخال مصممة لتقنيات تعلم الآلة، واتفق معه Daul, S., et al. (2022) علي أن تقنية الأشجار المعززة وتقنية الشبكات العصبية تستفيد من الميزات كتغيرات الأسعار وأحجام التداول بشكل متجانس وتتفوق علي النماذج الخطية، وبعد ذلك تقوم بتفاعل هذه الميزات لزيادة جودة التنبؤ بعوائد الأسهم، وأكد Sezer, O. B., et al. (2017) علي أن تقنية الخوارزمية الجينية تحسن من معلمات التحليل الفني ثم تنقلها إلي تقنية الشبكات العصبية لعمل التنبؤات ومن خلال الدمج بينهما يتم تصميم تنبؤات تداول الأسهم وبالتالي يتم تحسين التنبؤات بعوائد الأسهم.

أما دراسة Rossi, A. G. (2018) قدمت أدلة جديدة علي إمكانية التنبؤ بعوائد الأسهم وتقلباتها الشهري باستخدام تقنية أشجار الانحدار المعزز، وأظهرت أن أداء تلك التقنية يتفوق في الأداء عن النماذج المعيارية، حين استطاعت تلك التقنية توليد مخصصات مربحة للمحفظة حتى للمستثمرين ذوي التباين المتوسط عندما يتم حساب احتكاكات السوق، بينما ناقش Ma, Y., et al. (2021) نموذجاً مقترحاً لاختيار الأسهم باستخدام تقنية SVR وتقنية الخوارزمية الجينية ، وطبقت الدراسة النموذج المقترح من خلال استخدام تقنية SVR للتنبؤ بالعوائد المستقبلية لكل سهم حيث تم استخدام تقنية الخوارزمية الجينية لتحسين معلمات النموذج وميزات الإدخال، وبعد ذلك تم ترتيب الأسهم من حيث أعلي مرجح متساوية لبناء محفظة، وأظهرت النتائج التجريبية أن أداء النموذج المقترح أعطي أداء أفضل للاستثمار من المعايير.

واتفقت دراسة Rouf, N., et al. (2021) علي إمكانية استخدام الخوارزمية الجينية في ضبط المعلمات لتوليد أفضل قاعدة تداول، كما أكد علي نجاح تقنية الشبكة البايزية في تحليل التصورات للبيانات النصية من مصادر متعددة، في حين رأي Chan, L. S., et al. (2023) إمكانية استخدام تقنية الشبكة البايزية BN في قياس الأهمية النسبية للأسهم من خلال قيامها بترتيب الأسهم ذات العائد الأعلى ثم الأقل، وأوضح أيضاً إمكانية الاستفادة منها في عمل قائمة للاتجاهات المتعلقة بتدفق اضطرابات السوق.

ولكن استنتج (Martins, A. I. (2022) أن استخلاص القواعد من تقنية الشبكة العصبية باستخدام تقنية الخوارزمية الجينية أكثر دقة بشكل ملحوظ من تقنية الإدراك متعدد الطبقات (MLP)، في حين اقترح (Paiva, F. D., et al.(2019) نموذج فريد في صنع القرارات الاستثمارية للتداول اليومي في سوق الأوراق المالية وقد تم تطويره بدمج SVM ونموذج التباين المتوسط لنموذج اختيار المحفظة، وقامت الدراسة بمقارنة النموذج المقترح مع اثنين من النماذج الأخرى، وتوصل إلي أن النموذج المقترح كان الأفضل أداءً.

ويستخلص الباحث تفوق تقنيات تعلم الآلة علي الأساليب التقليدية في عملية استخراج الميزات المؤتمتة وذلك لأن تلك التقنيات تجعل المستند النصي مفهوماً وقابلاً للقراءة آلياً، كما تقوم باستخلاص الأفكار من خلال تحديد المعلومات المهمة واستردادها من مصادر سواء كانت نصوص أو صوت أو صورة أو فيديو، لذا يمكن تحويل كمية كبيرة من البيانات النوعية التي لم يتم استكشافها سابقاً من مصادر إلي بيانات كمية يمكن قراءتها آلياً، لهذا يمكن للشركات استخدام تقنيات تعلم الآلة في تحليل البيانات حول الموضوعات العامة التي تتوفر من المقالات الإخبارية ومنصات وسائل التواصل الاجتماعي، وتدريب تلك التقنيات علي البيانات المالية لتحليل التصورات التي تفيد في عمليات التنبؤ بعوائد الأسهم وهذا بدوره يساعد في زيادة جودة المعلومات المستقبلية.

المحور الثالث: الدراسة التطبيقية

تهدف الدراسة الحالية إلى دراسة أثر استخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم على الإفصاح عن المعلومات المستقبلية، ولكي يتمكن الباحث من تحقيق هذا الهدف سوف يقوم بإجراء التحليل الإحصائي أولاً: باستخدام تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم على طول السلسلة الزمنية للعينة والتي استقرت عليها العديد من الدراسات المحاسبية (Nõu, A., ; Rossi, A. G. (2018) ; Ma, Y., et al. (2021) ; Khoa, B. T., & Huynh, T. T. (2021) ; et al. (2021) ; Fieberg, C., et al. (2023) ; Rafiuddin, A., et al. (2023) في أن أهمها يتمثل في: استخدام تقنية آلية نقل الدعم (SVM)، وتقنية شجرة القرارات (DT)، وتقنية الشبكات العصبية (NN)، وتقنية الشبكة البايزية (BN). وثانياً: سيقوم الباحث باستخدام الأساليب الإحصائية التقليدية للتنبؤ بعوائد الأسهم والتي يتمثل أهمها في كلٍ من: أسلوب تحليل انحدار Probit، وأسلوب تحليل الانحدار المتعدد، وثالثاً: سيقوم الباحث باختبار الفروق الجوهرية بين عوائد الأسهم المتنبأ بها باستخدام تقنيات تعلم الآلة والأساليب التقليدية للتنبؤ، رابعاً: دراسة أثر التنبؤ بعوائد الأسهم (باستخدام تقنيات تعلم الآلة، تقليدياً) على الإفصاح عن المعلومات المستقبلية، وذلك على النحو التالي:

١/٣ مجتمع وعينة الدراسة:

يتمثل مجتمع الدراسة في مجموعة المفردات أو العناصر التي يتوافر فيها خصائص ظاهرة معينة، ونظراً لصعوبة تجميع البيانات من جميع أفراد المجتمع يمكن اختيار عينة ممثلة له (Saunders, M., et al., 2009)، ويتمثل مجتمع هذه الدراسة في كافة الشركات المقيدة في سوق الأوراق المالية المصري، وأنه وفقاً لمراجعة بيانات الشركات المقيدة في البورصة المصرية تبين أن عددها ٢٤٤ شركة.

ونظراً لأن مجتمع الدراسة يعبر عن عدد الشركات المقيدة في سوق الأوراق المالية المصري والتي يمكن جمع بياناتها من المصادر الثانوية المتمثلة في التقارير المالية المنشورة، ومن ثم فإن الباحث سيعتمد على استخدام العينة التحكيمية العمدية التي تخضع لمجموعة من الشروط التي تتمثل في:

١. أن تكون الشركة في الفترة الزمنية من ٢٠١٤ إلى ٢٠٢١ على اعتبار أن هذه الفترة الزمنية هي الفترة الأكثر استقراراً في سوق الأوراق المالية لتجنب الأحداث السياسية والاقتصادية الشاذة.
 ٢. أن تكون الشركة من الشركات الأكثر تداولاً بسوق الأوراق المالية المصري والتي يمكن الحصول عليها من بيانات مؤشر EGX 30، حيث يعبر هذا المؤشر عن الشركات الأكثر تداولاً في سوق الأوراق المالية المصري.
 ٣. أن تكون الشركة مقيدة في السوق على طول فترة الدراسة وألا يكون قد تم استبعادها تماماً خلال فترة الدراسة إطلاقاً.
 ٤. اتفاق عينة الدراسة مع الشروط التي تستلزم تطبيق قياس متغيرات الدراسة، وفقاً لما تم عرضه بنماذج القياس من منظور الدراسات ذات الصلة.
- وباتباع الشروط الموضحة سابقاً، يتبين أن عينة الدراسة قد سجلت ٢٤٠ مشاهدة (٣٠ شركة × ٨ سنوات)، وبحذف القيم الشاذة والمتطرفة التي تبلغ ٤٨ مشاهدة وبحذف البيانات المفقودة والتي يبلغ عددها ١٣ مشاهدة يصبح العدد النهائي لعينة الدراسة هو ١٧٩ مشاهدة.

كما اعتمد الباحث على كافة البيانات اللازمة لإتمام الدراسة الحالية المتمثلة في القوائم المالية للشركات المدرجة بالبورصة المصرية ومحل التطبيق بعينة الدراسة، وتقارير مجالس الإدارة وما يتعلق بها من إيضاحات. وتم الحصول على هذه البيانات من خلال العديد من المواقع الإلكترونية على شبكة الانترنت والمتمثلة في:

• موقع البورصة المصرية (<https://www.egx.com.eg>)

• موقع معلومات مباشر (<https://www.mubasher.info>)

٢/٣ تعريف متغيرات الدراسة وتحديد معلومات التنبؤ:

في إطار تحقيق هدف الدراسة الحالي، يمكن للباحث تقسيم هذه الجزئية إلى قسمين مختلفتين باختلاف الغرض المخصص لكل قسم منهما، وذلك على النحو التالي:

١/٢/٣ تعريف متغيرات الدراسة لغرض إجراء التحليل التقليدي:

يتمثل المتغير المستقل محل اهتمام الدراسة الحالية في التنبؤ بعوائد الأسهم، ويمكن تعريف التنبؤ بعوائد الأسهم بأنه قدرة العوائد المحققة في الفترات الماضية على التنبؤ بالعوائد المستقبلية، فإذا كانت القدرة التنبؤية مرتفعة تصحح معلومات الربحية الحالية أكثر فعالية في التنبؤ بالعوائد المستقبلية (Mazumder, M. M. M., (2016)، وفي هذه الدراسة يتم قياس قابلية التنبؤ بالعوائد المستقبلية من خلال اتباع نموذج Collins, D. W., et al. (1994) للتنبؤ بالأرباح والعوائد لقياس التنبؤ بالأرباح، ويعمل هذا النموذج على التنبؤ بالعوائد والأرباح على مدار فترتين مستقبليتين فقط، ويمكن للباحث عرض النموذج على النحو التالي:

$$R_t = \beta_0 + \beta_1 X_t + \sum_{k=1}^2 \beta_{k+1} X_{t+k} + \sum_{k=1}^2 \beta_{k+N+1} R_{t+k} + \beta_{2N+2} E_{t-1} + \beta_{2N+3} AG_t + \varepsilon$$

حيث أن:

$$R_t = \text{عوائد الأسهم في الفترة } t$$

$$R_{t+k} = \text{عوائد الأسهم في الفترة } t+k$$

$$X_t = \text{التغير في ربحية السهم للفترة } t \text{ مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية } t-1$$

$$X_{t+1} = \text{التغير في ربحية السهم للفترة } t+1 \text{ مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية } t-1$$

$$X_{t+2} = \text{التغير في ربحية السهم للفترة } t+2 \text{ مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية } t-1$$

$$E_{t-1} = \text{ربحية السهم للفترة } t-1 \text{ مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية } t-1$$

$$AG_t = \text{معدل النمو في الأصول الثابتة للفترة } t$$

كما يتمثل المتغير التابع للدراسة في الإفصاح عن المعلومات المستقبلية للشركة، ويمكن للباحث قياس هذا المتغير باستخدام أسلوب تحليل المحتوى للقوائم المالية، وذلك استناداً إلى مؤشر إفصاح من تصميم الباحث استناداً إلى الدراسات السابقة ذات الصلة في هذا الموضوع. ويمكن عرض محتويات هذا المؤشر الإفصاحي من خلال الجدول التالي:

أولاً: معلومات عن المخاطر المستقبلية	
١	العقود والإتفاقيات المستقبلية.
٢	مخاطر تأثير الأحداث الجارية (سياسية أو اجتماعية أو اقتصادية) على الأداء المستقبلي.
٣	المخاطر المحيطة بالتوقعات المالية وأسبابها وأثارها المحتملة على الأداء المالي المستقبلي.
٤	الإفصاح عن المخاطر (السياسية والبيئية والتكنولوجية ومخاطر الأعمال أو الصناعة أو السوق).
٥	يتم تحديث المعلومات المستقبلية المنشورة على موقع الشركة باستمرار.
ثانياً: معلومات عن الخطط المستقبلية	
٦	خطط البحث والتطوير للشركة المستقبلية.
٧	خطط الإنفاق الرأسمالي للشركة المستقبلية.
٨	خطط الإستثمار في الطاقة المستقبلية.

المجلة العلمية للدراسات والبحوث المالية والتجارية (م ٥، ع ١٦، ج ٢، يناير ٢٠٢٤)

د. نرمين علي محمد المر

٩	الخطط المستقبلية لمنح الحوافز، وخطط الترفقيات للعاملين.
١٠	الإفصاح عن المبادرات المستقبلية للحد من الآثار السلبية البيئية للمنتجات والخدمات.
ثالثاً: المعلومات المالية المستقبلية	
١١	الأرباح المتوقعة للشركة.
١٢	المبيعات المستهدفة للشركة.
١٣	التدفقات النقدية المتوقعة للشركة.
١٤	سعر السهم المتوقع للشركة.
١٥	تكلفة الإنتاج المتوقعة للشركة.
١٦	توزيعات الأرباح المتوقعة للشركة.
١٧	موقف السيولة المتوقع للشركة.
١٨	الحصة السوقية المتوقعة للشركة.
١٩	النفقات الرأسمالية المتوقعة للشركة.
٢٠	صافي الدخل المتوقع للشركة.
٢١	نصيب السهم في صافي الربح المتوقع.
٢٢	التغير المتوقع في هيكل التمويل.
٢٣	الإلتزامات المتوقعة.
٢٤	مناقشة وتحليل للوضع المالي المستقبلي للشركة.
رابعاً: المعلومات غير المالية المستقبلية	
٢٥	الإفصاح عن مؤشرات أداء مستقبلية تتعلق بالبعد الاجتماعي للشركة.
٢٦	الإفصاح عن المعاملات المستقبلية مع الأطراف ذوى العلاقة.
٢٧	الإفصاح عن السياسات والمعايير والإفتراضات التي بنيت عليها التوقعات المستقبلية.
٢٨	مناقشة وتعليق الإدارة على أداء العام الماضي مقارنة بالتنبؤات السابقة.
٢٩	الإفصاح عن المتغيرات الاقتصادية والسياسية ذات التأثير الجوهري على أهداف الشركة.
٣٠	الإفصاح عن المبادرات المستقبلية لتخفيف الآثار البيئية لمنتجات الشركة.

والجدير بالذكر أن أدوات القياس السابق ذكرها تم تعريفها لغرض القيام بالتحليل التقليدي المعتمد على نماذج الانحدار المتعدد الخطية والتي تفترض أهمية وجود مجموعة من المتغيرات الضابطة والتي تهدف إلى تحييد أثر المتغير المستقل على المتغير التابع وهي المتغيرات التي تتعلق بمستوى الإفصاح عن المعلومات المستقبلية والتي يمكن حصرها في الجدول التالي:

المتغير	الرمز	أداة القياس
الرافعة المالية	LEV	إجمالي الديون مقسوماً على حقوق الملكية
معدل نمو الشركة	GR	معدل التغير في إيرادات المبيعات
معدل العائد على الأصول	ROA	إجمالي الأرباح قبل الفوائد والضرائب مقسوماً على إجمالي الأصول
حجم الشركة	SIZE	لوغاريتم القيمة الدفترية لإجمالي أصول الشركة

٢/٢/٣ تعريف معلمات التنبؤ لغرض استخدام أدوات التحليل المعاصرة (تقنيات تعلم الآلة):

ويقصد بمعلمات التنبؤ كافة المتغيرات التي يمكن استخدامها للتنبؤ بعوائد الأسهم المستقبلية في هذه الدراسة، فنظراً لأن الدراسة الحالية تستهدف استخدام تقنيات تعلم الآلة الحديثة للتنبؤ بعوائد الأسهم المستقبلية، تصبح (X1, X2, X..... Xn) هي المعيرة عن معلمات التنبؤ، ومن ثم فإنه يمكن للباحث بناء معلمات التنبؤ بالعوائد المستقبلية استناداً إلى الدراسات السابقة ذات الصلة على النحو التالي:

المعلمة	التفسير
X1	عوائد الأسهم في الفترة t
X2	التغير في ربحية السهم للفترة t مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية t-1
X3	التغير في ربحية السهم للفترة t+1 مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية t-1
X4	التغير في ربحية السهم للفترة t+2 مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية t-1
X5	ربحية السهم للفترة t-1 مقسوماً على سعر السهم نهاية الشهر الرابع التالي للسنة المالية t-1
X6	معدل النمو في الأصول الثابتة للفترة t
X7	نسبة النقدية ويتم حسابها بإجمالي النقدية وما يكافئها مقسومة على الالتزامات المتداولة
X8	نسب التداول السريع ويمكن حسابها بإجمالي الأصول سريعة السيولة مثل النقدية وما يكافئها وحسابات العملاء وأوراق القبض
X9	نسبة التداول ويمكن حسابها بإجمالي الأصول المتداولة على الالتزامات المتداولة
X10	رأس المال العامل / إجمالي الأصول
X11	التدفقات النقدية التقليدية وتساوي مجموع صافي الدخل والفوائد والضرائب والإهلاك
X12	إجمالي أسعار الأسهم على الأرباح في نهاية السنة
X13	معدل دوران النقدية ويتم قياسه بالمبيعات على متوسط النقدية

٣/٣ الاختبارات القبلية للتأكد من استقراريه البيانات بالسلسلة الزمنية:

يتطلب تطبيق أسلوب السلاسل الزمنية للمتغيرات المحاسبية المرتبطة بالوضع الاقتصادي على طول السلاسل الزمنية التأكد من استقرارية البيانات، حيث أن استخدام التقنيات الحديثة لتعلم الآلة وحتى استخدام الأساليب الإحصائية التقليدية سيكون عديم الجدوى، إذا ما كانت البيانات تتسم بالتقلب والخروج عن المسار المستقر لما يشوب البيانات في هذه الحالة من تقلبات تضر بالعملية التنبؤية.

ولما كانت أسعار الأسهم من أكثر المتغيرات المحاسبية تأثراً بالأوضاع الاقتصادية والسياسية المحيطة، لذا يهتم الباحث بالتحقق من استقرارية البيانات داخل السلسلة الزمنية أولاً. ويمكن تحقيق ذلك من خلال إجراء اختباري Levin-Lin-Chu & Hadri LM لقياس مستوى استقرار البيانات داخل السلسلة الزمنية، وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (١) نتائج اختبارات الاستقرارية (جذر الوحدة) لبيانات الدراسة

Variables	Levin-Lin-Chu		Hadri LM test	
	Statistic	p-value	Statistic	p-value
X1	-7.966	0.021	24.854	0.592
X2	-3.378	0.009	-52.832	0.556
X3	-18.439	0.003	-55.363	0.554
X5	-11.069	0.016	-40.916	0.581
X6	-3.820	0.029	-36.267	0.610
X7	-11.445	0.025	-15.422	0.603
X8	9.998	0.034	-31.251	0.563
X9	15.103	0.007	-29.943	0.587
X10	12.822	0.003	15.258	0.588
X11	11.421	0.007	16.812	0.593
X12	9.466	0.001	13.521	0.327
X13	10.256	0.012	17.481	0.216

المصدر من إعداد الباحث اعتماداً على نتائج التحليل الإحصائي STATA V.14

يوضح الجدول السابق اختبارات جذر الوحدة لأبعاد متغيرات الدراسة، وقد بينت النتائج باستخدام اختبار Levin-Lin-Chu الذي يوضح استقرارية البيانات عند جميع الأبعاد وعدم وجود أي فروقات، كما تبين معنوية كافة المتغيرات، ثم تم إجراء اختبار Hadri LM الذي يبين عدم وجود جذر وحدة لأي بعد من أبعاد المتغيرات من خلال عدم معنوية كافة المتغيرات.

٤/٣ التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة

تنقسم تقنيات تعلم الآلة الأكثر شهرة في المجال المحاسبي إلى أربعة أنواع مختلفة تتمثل في: استخدام تقنية آلية نقل الدعم (SVM)، وأسلوب شجرة القرارات (DT)، والشبكات العصبية (NN)، وأسلوب الشبكة العصبية (BN)، وينتج عن استخدام تقنيات تعلم الآلة أشكال التنبؤ والأخطاء الموجودة به في إطار ثلاثة مستويات للملائمة للنموذج تتمثل في: Training set وهي المجموعة الإحصائية التي يتم الاعتماد عليها في ملائمة معلمات كل نموذج عند القيام بعملية التنبؤ وهي تمثل نسبة ٦٠٪ من عملية التنبؤ، ثم يتم الاستناد إلى Ten-fold cross-validation لأداء إجراءات تحديد ملائمة النموذج وذلك بعد اكتمال نسبة ٦٠٪ من الملائمة في الخطوة السابقة Training set وأخيراً تقسيم درجة الملائمة بنسب ٧٥٪ للمؤشر Train، ٢٥٪ للمؤشر Test وذلك لعدم المبالغة في درجات الملائمة والسيطرة على عدم استقرار البيانات، ويمكن استخدام كافة الطرق السابقة في التحليل للوصول إلى المستويات الثلاث السابقة على النحو التالي:

١/٤/٣ شجرة القرارات (DT) كأحد تقنيات تعلم الآلة للتنبؤ بعوائد الأسهم

تقوم تقنية شجرة القرارات بتقسيم البيانات إلى مجموعات وتتميز كل مجموعة بميزة معينة وذلك بغرض تحليل تلك البيانات، فمن خلال تقسيمها إلى مجموعات فرعية بناء على الخصائص والمميزات التي تتوافر بها تظهر جودتها، وتستخدم تلك التقنية مؤشر الكثافة للبيانات في اتجاه معين وذلك للقيام بتقسيم البيانات إلى مجموعات فرعية، كما تستخدم طريقة تحليل المكونات الرئيسية (Principle Component analysis) بغرض تحليل البيانات والقيام بعملية التنبؤ، وتعد تلك الطريقة إحصائية متعارف عليها فهي تسعى لاختزال العوامل بين المجموعات المختلفة ولكن بشرط أن تكون كل مجموعة مستقلة في حد ذاتها، ثم تقوم بتشكيل نموذج يمكن من خلاله التنبؤ بالنماذج السابق ذكرها، وقام الباحث بتشغيل طريقة تحليل المكونات الرئيسية بهدف الوصول إلى المجموعات الفرعية لنماذج التنبؤ، وتوصل من خلال تلك الطريقة إلى مصفوفة العوامل المدورة التالية في الجدول رقم (٢) التالي:

جدول رقم (٢): مصفوفة العوامل المدورة للمكونات الرئيسية للنموذج

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
X1	0.092	-0.112	0.225	0.084	0.096	0.756	-0.166
X2	-0.075	0.056	-0.044	-0.055	0.897	0.026	0.049
X3	-0.211	-0.144	0.474	0.455	-0.031	-0.284	0.263
X4	0.017	-0.002	-0.017	0.047	0.070	0.039	0.873
X5	-0.349	0.014	0.590	-0.046	0.139	-0.013	0.077
X6	-0.078	0.076	-0.161	-0.042	-0.096	0.686	0.386
X7	0.722	0.015	-0.128	0.057	0.086	0.029	0.156
X8	0.210	0.677	0.183	-0.253	-0.131	-0.126	0.201
X9	-0.011	0.756	-0.086	0.289	0.341	0.039	-0.142
X10	-0.271	0.047	0.705	-0.126	0.108	0.129	-0.024
X11	0.677	0.032	0.055	-0.072	-0.098	0.008	-0.135
X12	0.036	0.006	-0.057	0.903	-0.021	0.076	0.014
X13	0.284	0.469	0.186	0.125	0.403	-0.046	0.080
Eigenvalue	1.476	1.365	1.325	1.183	1.140	1.106	1.010
Variance explained (%)	10.512	9.971	9.595	9.434	9.029	8.983	8.669
Cum. variance explained (%)	10.512	20.483	30.078	39.512	48.540	57.524	66.193

ويتبين للباحث من النتائج الواضحة بالجدول السابق أن النموذج الحالي للدراسة قد انقسم إلى سبعة نماذج فرعية من PC1 إلى PC7 وكل نموذج من هذه النماذج يحتوي على مجموعة من المتغيرات الرئيسية التي تؤثر على التنبؤ بأسعار الأسهم، فمثلاً المكون PC1 يشمل المتغيرات X11 & X7 بينما يشمل المكون PC2 على المتغيرات من X8 & X9 & X13 وهكذا، وقد نتج عن التفاعل بين النماذج المختلفة للمكونات الرئيسية عن نتائج التشغيل الآلية للتنبؤ بأسعار الأسهم عن النتائج المختلفة لمستوى الدقة والخطأ في التنبؤ بأسعار الأسهم وكذلك المساحة تحت المنحنى من خلال الجدول التالي:

جدول رقم (٣): نتائج دقة استخدام شجرة القرارات للتنبؤ بعوائد الأسهم

Model	مستوى الدقة Accuracy (%)	مستوى الخطأ error (%)	قيمة F	المساحة تحت المنحنى ROC
Training set	0.885	0.115	0.856	0.867
Ten-fold cross-validation	0.612	0.388	0.456	0.411
Train (75%)-Test (25%) split	0.677	0.323	0.581	0.671

ويتضح من الجدول السابق ارتفاع مستويات الدقة على مستوى Training Set للبيانات والتي تعد مجموعة البيانات محل الاختبار الرئيسي، فهي تعبر عن القيم التنبؤية التي توقعتها التقنية الرئيسية لشجرة القرارات، وتشير تلك النتائج إلى ارتفاع مستوى الدقة في هذه النتائج بما يقارب ٨٨,٥٪ أي أن القيم التي تنبأت بها تلك التقنية تتصف بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ١١,٥٪. ومما يدل ذلك اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٠,٨٥٦.

وعلى مستوى اختبار الصلاحية والمتانة تبين أن مستوى الدقة في النتائج يبلغ ٦١,٢٪، وتبلغ ٦٧,٦٪ على مستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data.

وطبقاً لما أورده Hosmer, D. W., & Lemeshow, S. (2000) فيما يتعلق بمستويات الدقة في حساب المساحة تحت المنحنى تبين أن الدرجات المعيارية للمساحة تحت المنحنى تأخذ المدى التالي:

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

ونظراً لأن المساحة تحت المنحنى لنموذج Training Set تبلغ ٨٦,٧٪ فإنها تعتبر جيدة 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 ٤١,١٪، ٦٧,١٪ وهي ضعيفة على التوالي وفقاً للنموذج المعياري وهو ما يدل على تفوق شجرة القرارات على التنبؤات التقليدية.

٢/٤/٣ الشبكات العصبية (N N) للتنبؤ بعوائد الأسهم:

تستخدم تقنية الشبكات العصبية الدوال غير الخطية للتنبؤ بالمعلومات المستقبلية بناء على البيانات التاريخية بالإضافة إلى مجموعة من العوامل المحيطة بالظاهرة محل التنبؤ، ويمكن من خلالها استخدام أسلوب المحاكاة للوصول إلى أفضل البدائل الممكنة للتنبؤ بعوائد الأسهم، وقد نتج عن المحاكاة التي استخدمت تقنيات الشبكة العصبية التنبؤات التالية لعينة الدراسة.

جدول رقم (٤): نتائج دقة استخدام الشبكات العصبية للتنبؤ بعوائد الأسهم

Model	مستوى الدقة Accuracy (%)	مستوى الخطأ error (%)	قيمة F	المساحة تحت المنحنى ROC
Training set	0.918	0.082	0.912	0.905
Ten-fold cross-validation	0.712	0.288	0.667	0.555
Train (75%)-Test (25%) split	0.756	0.244	0.682	0.711

يوضح الجدول السابق ارتفاع مستويات الدقة على مستوى Training Set للبيانات وهي مجموعة البيانات محل الاختبار الرئيسي، وتعبّر عن القيم التنبؤية التي تنبأت بها الخوارزمية الرئيسية للشبكات العصبية، وتشير تلك النتائج الى ارتفاع مستوى الدقة في هذه النتائج بما يقارب ٩١,٨٪ أي أن القيم التي توقعتها التقنية تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٨,٢٪ ويدل ذلك على اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٩١٢,٠، وعلى مستوى اختبار الصلاحية والمتانة يتضح أن مستوى الدقة في النتائج يبلغ ٧١,٢٪، وتبلغ ٧٥,٦٪ على مستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data.

ووفقاً لما أورده Hosmer, D. W., & Lemeshow, S. (2000) فيما يتعلق بمستويات الدقة في حساب المساحة تحت المنحنى أتضح أن الدرجات المعيارية للمساحة تحت المنحنى تأخذ المدى التالي:

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

ونظراً لأن المساحة تحت المنحنى لنموذج Training Set تبلغ ٩٠,٥٪ فإنها تعتبر ممتازة وفقاً للجدول المعياري السابق أما على مستوى المتانة ومستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data فيتضح أن المساحات تحت المنحنى تبلغ ٥٥,٥٪، ٧١,١٪ على التوالي وفقاً للنموذج المعياري وهو ما يدل على تفوق الشبكات العصبية على التنبؤات التقليدية.

٣/٤/٣ تقنية آلية نقل الدعم (SVM) للتنبؤ بعوائد الأسهم:

تعمل تقنية آلية نقل الدعم علي زيادة الأداء في التعرف علي الأنماط ثم التنبؤ بالسلاسل الزمنية المالية، فهي تصنع أفضل اتجاه للقرار وتستطيع تقسيم فئات مختلفة بحيث يمكن تصنيف نقاط البيانات الجديدة والتنبؤ بها بشكل صحيح، حيث ينتج عنها مصنفاً ثنائياً ويسمي بالطبقات الفاتقة الفاصلة المثلي عن طريق رسم خرائط غير خطية للغاية لموجهات الإدخال، ثم تبني نموذج خطي لتقدير وظيفة القرار باستخدام حدود الفئة غير الخطية علي أساس دعم التمييز، ثم بعد ذلك تقوم بتدريب الشبكات الخطية للحصول علي المستوي الأمثل الذي يفصل البيانات بدون خطأ، وقد توصلت نتائج التحليل الإحصائي إلي الآتي التالي:

جدول رقم (٥): نتائج دقة استخدام آلية نقل الدعم للتنبؤ بعوائد الأسهم

Model	مستوى الدقة Accuracy (%)	مستوى الخطأ error (%)	قيمة F	المساحة تحت المنحنى ROC
Training set	0.962	0.038	0.995	0.967
Ten-fold cross-validation	0.775	0.225	0.775	0.658
Train (75%)-Test (25%) split	0.796	0.204	0.721	0.753

يتبين من الجدول السابق ارتفاع مستويات الدقة على مستوى Training Set للبيانات والتي تعبر عن مجموعة البيانات محل الاختبار الرئيسي، كما تعبر عن القيم التنبؤية التي تنبأت بها تقنية آلية نقل الدعم، وتشير تلك النتائج إلى ارتفاع مستوى الدقة في هذه النتائج بما يقارب ٩٦,٢٪ أي أن القيم التي تنبأت بها التقنية تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٣,٨٪ ويدل ذلك علي اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٠,٩٩٥.

وعلى مستوى اختبار الصلاحية والمثانة تبين أن مستوى الدقة في النتائج يبلغ ٧٧,٥٪، وتبلغ ٧٩,٦٪ على مستوى التداخل بين البيانات الأصلية والمتنبأ بها Training VS Testing Data.

وطبقاً لما أورده Hosmer, D. W., & Lemeshow, S. (2000) فيما يتعلق بمستويات الدقة في حساب المساحة تحت المنحنى تبين أن الدرجات المعيارية للمساحة تحت المنحنى تأخذ المدى التالي:

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

ونظراً لأن المساحة تحت المنحنى لنموذج Training Set تبلغ ٩٦,٧٪ 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 ٦٥,٨٪، ٧٥,٣٪ على التوالي وفقاً للنموذج المعياري وهو ما يدل على تفوق آلية نقل الدعم على التنبؤات التقليدية.

٤/٤/٣ تقنية الشبكة البايزية (BN) للتنبؤ بعوائد الأسهم:

تعرف الشبكة البايزية بأنها نموذج رسومي احتمالي الذي يمثل مجموعة من المتغيرات والتبعيات الشرطية عبر رسم بياني دوري موجه (DAG). وتعتبر الشبكات البايزية مثالية لأخذ حدث واقع والتنبؤ باحتمالية أن يكون أحد الأسباب المحتملة العديدة هو العامل المساهم، حيث يمكن للشبكة البايزية أن تمثل العلاقات الاحتمالية بين الإضطراب والأعراض، وبالنظر إلى الأعراض يمكن استخدام الشبكة لحساب احتمالات وجود اضطرابات مختلفة، ويمكن للباحث استخدام الشبكة البيزية والتوصل إلى النتائج التالية:

جدول رقم (٦): نتائج دقة استخدام الشبكة البايزية للتنبؤ بعوائد الأسهم

Model	مستوى الدقة Accuracy (%)	مستوى الخطأ error (%)	قيمة F	المساحة تحت المنحنى ROC
Training set	0.978	0.028	0.997	0.971
Ten-fold cross-validation	0.785	0.215	0.811	0.715
Train (75%)-Test (25%) split	0.823	0.177	0.805	0.736

يوضح الجدول السابق ارتفاع مستويات الدقة على مستوى Training Set للبيانات وهي مجموعة البيانات محل الاختبار الرئيسي، وتعتبر عن القيم التنبؤية التي تنبأت بها التقنية الشبكة البايزية، وتشير تلك النتائج إلى ارتفاع مستوى الدقة في هذه النتائج بما يقارب ٩٧,٨٪ أي أن القيم التي تنبأت بها التقنية تتسم بارتفاع مستوى الدقة حيث أن مستوى الخطأ التنبؤي بها يبلغ ٢,٨٪ ومما يدل ذلك اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٠,٩٩٧.

وعلى مستوى اختبار الصلاحية والمتانة تبين أن مستوى الدقة في النتائج يبلغ ٧٨,٥٪، وتبلغ ٨٢,٣٪ على مستوى التداخل بين البيانات الأصلية والمنتبأ بها Training VS Testing Data.

وطبقاً لما أورده Hosmer, D. W., & Lemeshow, S. (2000) فيما يتعلق بمستويات الدقة في حساب المساحة تحت المنحنى تبين أن الدرجات المعيارية للمساحة تحت المنحنى تأخذ المدى التالي:

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

ونظراً لأن المساحة تحت المنحنى لنموذج Training Set تبلغ ٩٧,١٪ فإنها تعتبر ممتازة وفقاً للجدول المعياري السابق أما على مستوى المئاة ومستوى التداخل بين البيانات الأصلية والمتنبأ بها Training VS Testing Data فيتبين أن المساحات تحت المنحنى تبلغ ٧١,٥٪، ٧٣,٦٪ على كلا المستويين وفقاً للنموذج المعياري وهو ما يدل علي تفوق الشبكة البايزية على التنبؤات التقليدية.

٥/٣ التنبؤ بعوائد الأسهم باستخدام الأساليب التقليدية

يهدف الباحث في هذا الجزء من الدراسة إلى استخدام الأساليب التقليدية للتنبؤ بعوائد الأسهم وهي الأساليب الإحصائية المتعارف عليها في المجال المحاسبي وتمثل في كلٍ من: أسلوب تحليل الانحدار المتعدد وأسلوب تحليل Probit، وسيتم تشغيل كلا النموذجان والحصول منهما على تنبؤات لعوائد الأسهم توازي التنبؤات المستخرجة من تقنيات تعلم الآلة، كما سيتم تقدير مستوى الدقة والمساحة تحت المنحنى لكليهما لمقارنة مستوى الدقة بهما بالنماذج الحديثة (تقنيات تعلم الآلة). وقد توصلت نتائج التحليل الإحصائي إلي النتائج التالية:

١/٥/٣ تشغيل نموذج (Probit) للتنبؤ بعوائد الأسهم:

يسعي الباحث في هذا الجزء من الدراسة إلى تشغيل نموذج Collins, D. W., et al. (1994) والسابق عرضه في موضع سابق من هذا الجزء من الدراسة، وذلك لاستخراج احتمالية وجود قيمة تنبؤية لعوائد الأسهم لكل مشاهدة على حدة من خلال الحصول على قيمة تنبؤية لعوائد الأسهم.

ومن ثم يصبح هذا النموذج هو الذي يوفر البيانات اللازمة لاستخراج قاعدة القرار التي يتم على أساسها الحكم بجودة القيم التنبؤية لعوائد الأسهم أم لا، وبالتالي تنحصر نتائج هذا النموذج في التحقق من جودته ومطابقته لتحقيق الحلول المثلى على أن يتم استخراج القم الاحتمالية الخاصة بعوائد الأسهم واسقاطها على نماذج اختبار الفروض، وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (٧): نتائج تحليل Probit النموذج الأول (Model 1)

Parameter	Estimate	Std. Error	Z	Sig.	Predicted sign	Actual Result
Xt	2.505	0.220	11.404	0.000	+	+
Xt+1	4.236	0.811	3.507	0.000	+	+
Xt+2	5.436	0.793	3.812	0.000	+	+
Rt+1	3.114	0.003	2.328	0.004	+	+
Rt+2	2.288	0.478	2.602	0.007	+	+
Ept-1	0.262	0.153	1.716	0.086	+	NS
Agt	0.053	0.520	0.101	0.919	+	NS
Intercept	-3.715	1.303	-2.851	0.004		-
Optimal Solution Found	Yes					
N	179					
Chi-Square	425.793					
Sig.	0.615					

ويتبين من نتائج هذا الجدول أن النموذج تم من خلاله التوصل إلى الحلول المثلى للاحتتمالات المتوقعة حيث تبين أن (optimal solution found = Yes) ومن ثم فإن هذا النموذج قادراً على التنبؤ الاحتمالي بعوائد الأسهم بشكل ناجح أي أن النموذج متطابق.

كما يلاحظ معنوية المتغيرات الخاصة بالتنبؤ بعوائد الأسهم، ومن ثم يتبين أن له تأثير معنوي على احتمالية وجود تنبؤات مختلفة لعوائد الأسهم على مستوى كل مشاهدة من المشاهدات المدرجة بعينة الدراسة. وفيما يتعلق بنتائج اختبار كا^٢ لحسن المطابقة فيتبين جودة مطابقة النموذج، حيث تشير جودة المطابقة إلى الفروق بين القيم المشاهدة المدرجة بالنموذج والقيم المتوقعة المستخرجة منه، وعدم معنوية قيم كا^٢ دليل على أن الفروق بين القيم المشاهدة والقيم المتوقعة ضئيلة جداً ولا يوجد لها أي معنوية إحصائية، ومن ثم يصبح من المنطقي أنه كلما تقل الفروق بين القيم الفعلية والقيم المتوقعة كلما ازدادت جودة النموذج، وبالتالي يتضح من الجدول السابق عدم معنوية قيم كا^٢ حيث أن المعنوية كانت ٠,٦١٥ وهي أكبر من ٠,٠٥. وأخيراً، أظهرت نتائج تحليل Probit للنموذج السابق مجموعة القيم المتوقعة لعوائد الأسهم وتم مقارنتها بالقيم الفعلية.

٢/٥/٣ نتائج تشغيل نموذج الانحدار المتعدد للتنبؤ بعوائد الأسهم:

يتبين للباحث من خلال تشغيل نموذج Collins, D. W., et al. (1994) وجود مجموعة من النتائج الإحصائية التي يمكن إبرازها من خلال الجدول التالي:

جدول رقم (٨): نتائج تشغيل نموذج (Collins, D. W., et al. (1994)

Variable	Returns predictability model		
	Coef.	t-stat.	p-value
Constant	-2.5387	-0.99	0.322
Xt	3.2417	1.94	0.054
Xt+1	3.4336	14.37	0.000
Xt+2	13.0928	5.73	0.000
Rt+1	-2.3688	-0.39	0.696
Rt+2	2.4396	0.40	0.690
Ept-1	0.4926	0.21	0.833
Agt	0.1230	0.29	0.775
N	179		
F.value	84.23		
Sig.	0.000		
F. Sig.	7.84		
VIF (Max)	52.21%		
Adj. R2			

وبالنظر إلى معنوية المعاملات الخاصة بالمتغيرات المدرجة بالنموذج يتضح معنوية المعاملات X_{t+1} , X_{t+2} وكلاهما يحمل إشارة موجبة، وهو ما يدل على أن المستثمرين على الوضع الحالي للمعلومات المالية أكثر قدرة على التنبؤ بالعوائد المستقبلية. أي أن المستثمرين في البيئة المصرية الحالية تحقق لهم معلومات القوائم المالية نسبة جيدة تمكنهم من إجراء التنبؤات المستقبلية بالعوائد. وعلاوة على ذلك يتبين أن القوة التفسيرية للنموذج التقليدي تبلغ ٥٥,٢١٪ وهو ما يشير إلى أن النموذج قادر على تحقيق مستوى كفاءة ٥٥,٢١٪ للتنبؤ بالعوائد المستقبلية.

وأخيراً، تم حساب مستوى الدقة في هذه النماذج والمساحة تحت المنحنى أيضاً لغرض استخدام المقارنات الإحصائية بين التقنيات الحديثة لتعلم الآلة والأساليب التقليدية المتمثلة في تحليل الانحدار المتعدد وتحليل Probit ، وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (٩): نتائج دقة استخدام الأساليب التقليدية للتنبؤ بعوائد الأسهم

Model	مستوى الدقة Accuracy (%)	مستوى الخطأ error (%)	قيمة F	المساحة تحت المنحنى ROC
Probit Regression	0.785	0.215	0.884	0.758
Multiple Regression	0.764	0.236	0.712	0.712

يوضح الجدول السابق ارتفاع مستويات الدقة لكلا النموذجين، وتشير تلك النتائج إلى ارتفاع مستوى الدقة في هذه النتائج بما يقارب ٧٨,٥٪، ٧٦,٤٪ على التوالي أي أن القيم التي تتنبأ بها أسلوب تحليل Probit وتحليل الاتحدار المتعدد، وما يدل ذلك علي اقتراب قيمة F من الواحد الصحيح وهي تبلغ ٠,٧١٢، ٠,٨٨٤ على التوالي.

وفيما يتعلق بالمساحة تحت المنحنى فقد تبين من نتائج التحليل الإحصائي أن المساحة تحت المنحنى تبلغ ٧٥,٨٪، ٧١,٢٪ على التوالي وهي قيمة عادلة ولا شك ولكنها أقل من القيم الموجودة بالتقنيات الحديثة.

٦/٣ نتائج اختبارات الفروض الإحصائية:

لأغراض التحقق من الأثر الفعلي لتقنيات تعلم الآلة على التنبؤ بعوائد الأسهم على الإفصاح المستقبلي قام الباحث باختبار فروض الدراسة على النحو التالي:

١/٦/٣ نتائج اختبارات الفروق الجوهرية بين القيم المتنبأ بها لتقنيات تعلم الآلة والأساليب التقليدية:

يتنبأ هذا الفرض بمدى وجود فروق جوهرية بين قيمة عوائد الأسهم التي تم التنبؤ بها من خلال التقنيات الحديثة، وقيمة عوائد الأسهم التي تم التنبؤ بها من خلال الأساليب التقليدية وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (١٠): نتائج اختبارات الفروق الجوهرية بين التقنيات الحديثة وتحليل Probit

	Variables	Mean	T	Sig. (2-tailed)
Pair (1)	Stock Return predicted by Decision Tree	2.311	3.238	0.000
	Stock Return predicted by Probit Regression	1.125		
Pair (2)	Stock Return predicted by Neural Network	3.215	4.205	0.000
	Stock Return predicted by Probit Regression	1.125		
Pair (3)	Stock Return predicted by SVM	2.437	3.512	0.000
	Stock Return predicted by Probit Regression	1.125		
Pair (3)	Stock Return predicted by Bayesian Network	3.621	4.618	0.000
	Stock Return predicted by Probit Regression	1.125		

ويتبين من نتائج الجدول السابق وجود فروق جوهرية ومعنوية بين تحليل Probit كأحد الأساليب التقليدية والتقنيات الحديثة والجدير بالذكر أن قيم T موجبة على مستوى كافة التقنيات الحديثة وهو ما يشير إلى تحيزها نحو التقنيات الحديثة، وهو ما يتفق مع ارتفاع مستويات الدقة في الجزء السابق من التحليل حيث أنها تبلغ ٨٨,٥٪، و٩١,٨٪، و٩٦,٢٪، و٩٧,٨٪ على التوالي لكل من: شجرة القرار، والشبكات العصبية، وآلية نقل الدعم، والشبكة البايزية، بينما يبلغ مستوى الدقة لتحليل Probit ٧٨,٥٪.

جدول رقم (١١): نتائج اختبارات الفروق الجوهرية بين الأساليب الحديثة وتحليل الانحدار المتعدد

	Variables	Mean	T	Sig. (2-tailed)
Pair (1)	Stock Return predicted by Decision Tree	2.311	3.218	0.000
	Stock Return predicted by multiple Regression	1.812		
Pair (2)	Stock Return predicted by Neural Network	3.215	4.115	0.000
	Stock Return predicted by multiple Regression	1.812		
Pair (3)	Stock Return predicted by SVM	2.437	3.315	0.000
	Stock Return predicted by multiple Regression	1.812		
Pair (3)	Stock Return predicted by Bayesian Network	3.621	4.522	0.000
	Stock Return predicted by multiple Regression	1.812		

ويتبين من نتائج الجدول السابق وجود فروق جوهرية ومعنوية بين تحليل الانحدار المتعدد كأحد الأساليب التقليدية والتقنيات الحديثة والجدير بالذكر أن قيم T موجبة على مستوى كافة الأساليب الحديثة وهو ما يشير إلى تحيزها نحو التقنيات الحديثة، وهو ما يتفق مع ارتفاع مستويات الدقة سابقة الذكر في الجزء السابق من التحليل حيث أنها تبلغ ٨٨,٥٪، ٩١,٨٪، ٩٦,٢٪، ٩٧,٨٪ على التوالي لكل من: شجرة القرار، والشبكات العصبية، وآلية نقل الدعم، والشبكة البايزية، بينما يبلغ مستوى الدقة لتحليل الانحدار المتعدد ٧٦,٤٪.

وتأسيساً على النتائج السابقة، يمكن للباحث قبول الفرض الإحصائي الأول للدراسة على الشكل البديل التالي: توجد فروق جوهرية ذات دلالة إحصائية بين عوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية وبين عوائد الأسهم المتنبأ بها باستخدام تقنيات تعلم الآلة.

٢/٦/٣ أثر التنبؤ بعوائد الأسهم باستخدام الأساليب التقليدية على الإفصاح عن المعلومات المستقبلية:

قام الباحث في هذا الجزء من الدراسة بتشغيل نموذج الانحدار الرئيسي للدراسة للتنبؤ بأثر التنبؤ بعوائد الأسهم باستخدام الأساليب التقليدية على الإفصاح عن المعلومات المستقبلية، وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (١٢): نتائج اختبار أثر التنبؤ بعوائد الأسهم باستخدام الأساليب التقليدية على الإفصاح عن المعلومات المستقبلية

Variables	Panel (A)			Panel (B)		
	Coef.	T-Stat.	P-Value	Coef.	T-Stat.	P-Value
Constant	0.118	1.649	0.117	0.121	1.587	0.059
Stock Return predicted by Probit Regression	0.551	1.354	0.112	---	---	---
Stock Return predicted by multiple Regression	---	---	---	0.579	1.611	0.156
LEV	0.528	1.298	0.066	0.334	1.541	0.113
GR	0.469	1.423	0.115	0.327	1.477	0.090
ROA	0.260	1.413	0.102	0.308	1.612	0.067
SIZE	0.256	1.551	0.068	0.291	1.667	0.118
N	179			179		
R2	45.18%			41.03%		
F-Value	38.12			35.36		
VIF (Max)	1.12			1.37		
Study Model:	$FD = \beta_0 + \beta_1 \text{TPSR} + \beta_2 \text{LEV} + \beta_3 \text{GR} + \beta_4 \text{ROA} + \beta_5 \text{SIZE} + \varepsilon$					

يتبين من نتائج التحليل الإحصائي بالجدول السابق أن القوة التفسيرية للنموذج تبلغ ٤٥,١٨٪، ٤١,٠٣٪ على التوالي، وهو ما يشير إلى أن التنبؤ بعوائد الأسهم باستخدام أسلوب تحليل Probit، والتنبؤ بعوائد الأسهم من خلال أسلوب تحليل الانحدار المتعدد يفسران نسبة ٤٥,١٨٪، ٤١,٠٣٪ من التغير في الإفصاح عن المعلومات المستقبلية.

وفيما يتعلق بمعنوية النتائج في العمود الأول (Panel A) تبين للباحث عدم معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام تحليل Proit حيث أن $(\beta = 0.551; T\text{-Stat.} = 1.354 < 2; \text{Sig.} = 0.112 > 0.05)$ ، ومن ثم يمكن القول بعدم وجود أي تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام أسلوب تحليل Probit على الإفصاح عن المعلومات المستقبلية.

وفيما يتعلق بمعنوية النتائج في العمود الثاني (Panel B) تبين للباحث عدم معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام تحليل الانحدار المتعدد حيث أن $(\beta = 0.579; T\text{-Stat.} = 1.611 < 2; \text{Sig.} = 0.156 > 0.05)$ ، ومن ثم يمكن القول بعدم وجود أي تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام أسلوب تحليل الانحدار المتعدد على الإفصاح عن المعلومات المستقبلية.

وبناء على النتائج التي تم التوصل إليها في العمود الأول (Panel A) والعمود الثاني (Panel B) يمكن للباحث قبول الفرض الإحصائي الثاني للدراسة على الشكل العدم التالي: لا يوجد تأثير ذو دلالة إحصائية لعوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية (أسلوب تحليل Probit، وأسلوب تحليل الانحدار المتعدد) على الإفصاح عن المعلومات المستقبلية.

٣/٦/٣ أثر التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية:

قام الباحث في هذا الجزء من الدراسة بتشغيل نموذج الانحدار الرئيسي للدراسة للتنبؤ بأثر التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية، وقد أسفرت نتائج التحليل الإحصائي عن الجدول التالي:

جدول رقم (١٣): نتائج اختبار أثر التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية

Variables	Panel (A)			Panel (B)			Panel (C)			Panel (D)		
	Coef.	T-Stat.	P-Value	Coef.	T-Stat.	P-Value	Coef.	T-Stat.	P-Value	Coef.	T-Stat.	P-Value
Constant	0.701	1.402	0.134	0.717	1.469	0.144	0.715	1.312	0.163	0.595	1.655	0.069
Stock Return predicted by Decision Tree	0.385	2.382	0.000	---	---	---	---	---	---	---	---	---
Stock Return predicted by Neural Network	---	---	---	0.570	2.647	0.003	---	---	---	---	---	---
Stock Return predicted by SVM	---	---	---	---	---	---	0.575	2.531	0.007	---	---	---
Stock Return predicted by Bayesian Network	---	---	---	---	---	---	---	---	---	0.660	2.645	0.022
LEV	0.495	1.519	0.143	0.449	1.764	0.152	0.426	1.276	0.109	0.373	1.590	0.143
GR	0.482	1.674	0.075	0.333	1.373	0.152	0.361	1.729	0.113	0.338	1.745	0.146
ROA	0.373	1.695	0.093	0.316	1.485	0.116	0.321	1.310	0.114	0.287	1.451	0.084
SIZE	0.346	1.315	0.067	0.278	1.363	0.079	0.319	1.324	0.132	0.282	1.608	0.110
N	179			179			179			179		
R2	62.18%			66.18%			71.25%			75.36%		
F-Value	47.22			58.12			61.03			71.21		
VIF (Max)	1.27			1.45			1.12			1.35		
Study Model:	$FD = \beta_0 + \beta_1 \text{MLSR} + \beta_2 \text{LEV} + \beta_3 \text{GR} + \beta_4 \text{ROA} + \beta_5 \text{SIZE} + \varepsilon$											

يتبين من نتائج التحليل الإحصائي بالجدول السابق أن القوة التفسيرية للنموذج تبلغ ٦٢,١٨٪، ٦٦,١٨٪، ٧١,٢٥٪، ٧٥,٣٦٪ على التوالي، وهو ما يشير إلى أن التنبؤ بعوائد الأسهم باستخدام تقنيات تعلم الآلة التي تتمثل في: شجرة القرارات، والشبكات العصبية، وآلية نقل الدعم، والشبكة البايزية تفسر نسبة ٦٢,١٨٪، ٦٦,١٨٪، ٧١,٢٥٪، ٧٥,٣٦٪ من التغير في الإفصاح عن المعلومات المستقبلية.

وفيما يتعلق بمعنوية النتائج في العمود الأول (Panel A) يبين للباحث معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام شجرة القرارات حيث أن $(\beta = 0.385; T\text{-Stat.} = 2.382 > 2; \text{Sig.} = 0.000 < 0.05)$ ، ومن ثم يمكن القول بوجود تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام تقنية شجرة القرارات كأحد تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

وبالنسبة لنتائج العمود الثاني (Panel B) يتبين للباحث معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام الشبكات العصبية حيث أن $(\beta = 0.570; T\text{-Stat.} = 2.647 > 2; \text{Sig.} = 0.003 < 0.05)$ ، ومن ثم يمكن القول بوجود تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام أسلوب الشبكات العصبية كأحد تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

وفيما يتعلق بمعنوية النتائج في العمود الثالث (Panel C) يتبين للباحث معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام آلية نقل الدعم حيث أن $(\beta = 0.575; T\text{-Stat.} = 2.531 > 2; \text{Sig.} = 0.007 < 0.05)$ ، ومن ثم يمكن القول بوجود تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام تقنية آلية نقل الدعم تعلم كأحد تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

وبالنسبة لنتائج العمود الرابع (Panel D) يتبين للباحث معنوية المتغير الخاص بالتنبؤ بعوائد الأسهم باستخدام الشبكة البايزية حيث أن $(\beta = 0.660; T\text{-Stat.} = 2.645 > 2; \text{Sig.} = 0.022 < 0.05)$ ، ومن ثم يمكن القول بوجود تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام تقنية الشبكة البايزية كأحد تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

وبناء على النتائج التي تم التوصل إليها في الأعمدة الأربعة يمكن للباحث قبول الفرض الإحصائي الثالث للدراسة على الشكل البديل التالي: يوجد تأثير ذو دلالة إحصائية لعوائد الأسهم المتنبأ بها باستخدام تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.

النتائج والتوصيات والتوجيهات البحثية

بناء على ما تم عرضه في الإطار النظري وما استنتجه الباحث من التحليل الإحصائي للدراسة يمكن عرض أهم النتائج والتوصيات على النحو التالي:

١. يوجد للإفصاح عن المعلومات المستقبلية المالية تأثير كبير على أسواق رأس المال نظراً لأن تقلبات الأسهم مرتبطة بعدم تناسق المعلومات وازدياد مخاطر الشركة.
 ٢. يعد التنبؤ بعوائد الأسهم من أهم مكونات المعلومات المستقبلية وأكثرها ملائمة لاتخاذ القرارات الاستثمارية.
 ٣. تنسم تقنيات تعلم الآلة بالقدرة علي التعمق في البيانات الضخمة وحل الأنماط المعقدة في تلك البيانات والتي تصعب علي الطرق التقليدية.
 ٤. لا تقتصر تقنيات تعلم الآلة علي تحليل البيانات المالية المنظمة التقليدية فحسب بل يمكنه أيضاً تحليل البيانات شبة المنظمة أو غير المنظمة، ومن ثم تعتبر تقنيات تعلم الآلة مناسبة لتحليل معنويات المستثمرين والتنبؤ بحركة سوق الأسهم.
 ٥. يوجد فروق جوهرية ومعنوية بين تحليل Probit والانحدار المتعدد كأحد الأساليب التقليدية والتقنيات الحديثة، حيث يتضح ارتفاع مستويات الدقة لتقنيات تعلم الآلة، فقد بلغت ٨٨,٥٪، ٩١,٨٪، ٩٦,٢٪، ٩٧,٨٪ على التوالي لكل من: شجرة القرارات، والشبكات العصبية، وآلية نقل الدعم، والشبكة البايزية، بينما بلغ مستوى الدقة ٧٨,٥٪، ٧٦,٤٪ لتحليل Probit والانحدار المتعدد على التوالي .
 ٦. يتبين أن التنبؤ بعوائد الأسهم باستخدام أسلوب تحليل Probit ، والتنبؤ بعوائد الأسهم من خلال أسلوب تحليل الانحدار المتعدد يفسران نسبة ٤٥,١٨٪، ٤١,٠٣٪ من التغير في الإفصاح عن المعلومات المستقبلية.
 ٧. توصل الباحث لعدم وجود تأثير لعوائد الأسهم المتنبأ بها باستخدام الأساليب التقليدية (تحليل Probit، تحليل الانحدار المتعدد) على الإفصاح عن المعلومات المستقبلية.
 ٨. كما تبين للباحث من خلال التحليل الإحصائي وجود تأثير معنوي لعوائد الأسهم المتنبأ بها باستخدام تقنيات (شجرة القرارات، الشبكات العصبية، ناقلات الدعم ، الشبكة البايزية) كأحد تقنيات تعلم الآلة على الإفصاح عن المعلومات المستقبلية.
- وبناء على ما تم عرضه من نتائج توصل الباحث إلى ضرورة عمل دورات تدريبية لإدارة الشركات والمحاسبين لتعليمهم تقنيات تعلم الآلة ، وضرورة اهتمام الهيئات المهنية المحاسبية وهيئة سوق المال بمصر بتقنيات تعلم الآلة ومطالبة الشركات المقيدة بالبورصة بتطبيقها وذلك لقدرتها علي تحليل كافة العوامل والمتغيرات التي تؤثر علي عوائد الأسهم ، مع ضرورة تحديث المعايير المحاسبية والإصدارات المهنية بما تم استحداثه في ضوء تطبيق هذه التقنيات .
- هذا ويوصي الباحث بإجراء المزيد من الدراسات البحثية التي تتناول أثر استخدام تقنيات تعلم الآلة في التنبؤ بممارسات إدارة الأرباح علي جودة التقارير المالية، وإجراء المزيد من الدراسات عن استخدام تقنيات تعلم الآلة في التنبؤ بالأرباح الفصلية وأثر ذلك على جودة المعلومات المستقبلية ، وإجراء المزيد من الدراسات عن استخدام تقنيات تعلم الآلة في التنبؤ بالتقديرات المحاسبية وانعكاساتها على جودة القوائم المالية .

قائمة المراجع

المراجع العربية:

١. إبراهيم، نهلة محمد السيد. (٢٠٢٣). الدور التفاعلي لاستخدام تحليلات البيانات الضخمة والإفصاح المحاسبي عن المعلومات المستقبلية على الربحية في البنوك السعودية. *المجلة العلمية للدراسات والبحوث المالية والتجارية*، ٤ (١) ٢، ٧٧١ - ٨١٨.
٢. الشعراوي، حاتم عبد الفتاح. (٢٠٢٣). أثر مستوي الإفصاح عن المعلومات المستقبلية على كفاءة سوق الأوراق المالية: دراسة تطبيقية على الشركات المدرجة بالبورصة المصرية. *المجلة العلمية للدراسات والبحوث المالية والتجارية*، ٤ (١) ٢، ٤٣٥ - ٤٩٢.
٣. الباز، ماجد مصطفى علي. (٢٠٢٢). أثر العلاقات السياسية للشركات على الإفصاح عن المعلومات المستقبلية وإنعكاسها على كفاءة القرارات الاستثمارية: بالتطبيق على الشركات المقيدة بالبورصة المصرية. *مجلة الإسكندرية للبحوث المحاسبية*، ٦ (٣)، ١٤١ - ٢٠٠.
٤. سعد الدين، إيمان محمد. (٢٠١٤). إطار مقترح للمعلومات المالية المستقبلية واختباره من منظور المستثمرين في سوق الأوراق المالية: دراسة ميدانية. *مجلة التجارة والتمويل*، ٣٤ (١)، ٢٢٧ - ٣٢٤.
٥. علي، صالح علي صالح. (٢٠٢١). دراسة واختبار العلاقة بين الخصائص التشغيلية للشركات ومستوي الإفصاح عن المعلومات المستقبلية في الشركات غير المالية المقيدة بالبورصة المصرية. *مجلة الإسكندرية للبحوث المحاسبية*، ٥ (٣)، ٧٣ - ١٢٨.

المراجع الأجنبية:

1. Anwar, N. A. M., Kamarudin, F., Noordin, B. A. A., Hussain, H. I., & Mihardjo, L. W. (2021). Disclosure level and quality effect of forward – looking information on firms stock return : the moderating effect of ownership structure . *Transformations in Business & Economics*, 20(1).
2. Arya, A., Mittendorf, B., & Ramanan, R. N. (2017). Synergy between accounting disclosures and forward-looking information in stock prices. *The accounting review*, 92(2), 1-17.
3. 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.
4. Aly, H. G., Elguoshy, O. R., & Metwaly, M. Z. (2023). Machine Learning Algorithms and Auditor's Assessments of the Risks Material Misstatement: Evidence from the Restatement of Listed London Companies. *disclosure*, 15, 16.
5. Bansal, M., Ali, A., & Choudhary, B. (2021). Real earnings management and stock returns: moderating role of cross-sectional effects. *Asian Journal of Accounting Research*, 6(3), 266-280.

6. Bao, Y., Ke, B., Li, B., Yu, Y. J., & Zhang, J. (2020). Detecting accounting fraud in publicly traded US firms using a machine learning approach. *Journal of Accounting Research*, 58(1), 199-235.
7. Bertomeu, J., Cheynel, E., Floyd, E., & Pan, W. (2021). Using machine learning to detect misstatements. *Review of Accounting Studies*, 26, 468-519.
8. Chordia, T., Goyal, A., & Shanken, J. A. (2017). Cross-sectional asset pricing with individual stocks: betas versus characteristics. *Available at SSRN 2549578*.
9. Chang, V., Man, X., Xu, Q., & Hsu, C. H. (2021). Pairs trading on different portfolios based on machine learning. *Expert Systems*, 38(3), e12649.
10. Choi, A., Kristian, J., Joseph, C., & Voon, B. H. (2022). Determinants of Forward-Looking Information Disclosure by Top Malaysian Companies within a Resource-Based View Framework. *Management & Accounting Review*, 21(3).
11. Chan, L. S., Chu, A. M., & So, M. K. (2023). A moving-window bayesian network model for assessing systemic risk in financial markets. *PloS one*, 18(1), e0279888.
12. Collins, D. W., Kothari, S. P., Shanken, J., & Sloan, R. G. (1994). Lack of timeliness and noise as explanations for the low contemporaneous return-earnings association. *Journal of Accounting and Economics*, 18(3), 289-324.
13. 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.
14. Dang, N. H., Van Vu, T. T., & Le Dao, T. N. (2022). Accounting information and stock returns in Vietnam securities market: Machine learning approach. *Contabilidad y Negocios*, 17(33), 94-118.
15. Daul, S., Jaisson, T., & Nagy, A. (2022). Performance attribution of machine learning methods for stock returns prediction. *The Journal of Finance and Data Science*, 8, 86-104.
16. 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(3), 1098-1134.

-
-
17. Dey, P. K., Roy, M., & Akter, M. (2020). What determines forward-looking information disclosure in Bangladesh?. *Asian Journal of Accounting Research*, 5(2), 225-239.
 18. Eachempati, P., Srivastava, P. R., Kumar, A., Tan, K. H., & Gupta, S. (2021). Validating the impact of accounting disclosures on stock market: A deep neural network approach. *Technological Forecasting and Social Change*, 170, 120903.
 19. Fieberg, C., Metko, D., Poddig, T., & Loy, T. (2023). Machine learning techniques for cross-sectional equity returns' prediction. *OR Spectrum*, 45(1), 289-323.
 20. Green, J., & Zhao, W. (2022). Forecasting earnings and returns: A review of recent advancements. *The Journal of Finance and Data Science*.
 21. 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.
 22. Hunt, J., Myers, J., & Myers, L. (2019). Improving earnings predictions with machine learning. *Unpubl. Work. Pap.*
 23. Huang, F., No, W. G., Vasarhelyi, M. A., & Yan, Z. (2022). Audit data analytics, machine learning, and full population testing. *The Journal of Finance and Data Science*, 8, 138-144.
 24. Hosmer, D. W., & Lemeshow, S. (2000). Applied logistic regression (2nd ed.). *New York: Wiley*.
 25. Jiang, W. (2021). Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, 184, 115537.
 26. Khoa, B. T., & Huynh, T. 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*, 2021.
 27. Kumar, D., Sarangi, P. K., & Verma, R. (2022). A systematic review of stock market prediction using machine learning and statistical techniques. *Materials Today: Proceedings*, 49, 3187-3191.
 28. Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165, 113973.

-
-
29. Mall, P., & Gupta, K. (2019). Impact of merger announcements on stock returns of acquiring firms: Evidence from INDIA. *Journal of Commerce & Accounting Research*, 8(1), 46-53.
 30. McEnroe, J. E., & Sullivan, M. (2018). An empirical analysis of an alternative model of Financial Accounting Standard no. 128: Earnings per share. *Accounting Research Journal*.
 31. McEnroe, J. E., & Mindak, M. (2020). An empirical analysis of an application of an alternative measurement model on international accounting standard 33, earnings per share. *Accounting Research Journal*.
 32. Mahboub, R. M. (2019). The determinants of forward-looking information disclosure in annual reports of Lebanese commercial banks. *Academy of Accounting and Financial Studies Journal*, 23(4), 1-18.
 33. Mousa, G. A., & Elamir, E. A. (2018). Determinants of forward-looking disclosure: evidence from Bahraini capital market. *Afro-Asian Journal of Finance and Accounting*, 8(1), 1-19.
 34. Martins, A. I. (2022). Earnings prediction using machine learning methods and analyst comparison (Doctoral dissertation).
 35. Menicucci, E. (2018). Exploring forward-looking information in integrated reporting: a multi-dimensional analysis. *Journal of Applied Accounting Research*, 19(1), 102-121.
 36. Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165, 113973.
 37. Mazumder, M. M. M. (2016). Exploring the impact of ownership structure on earnings predictability: Insights from Japan. *Indian journal of corporate governance*, 9(2), 97-121.
 38. Nõu, A., Lapitskaya, D., Eratalay, M. H., & Sharma, R. (2021). Predicting stock return and volatility with machine learning and econometric models: A comparative case study of the Baltic stock market. *Available at SSRN 3974770*.
 39. Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8, 150199-150212.

-
-
40. PHAM, C. B. T., VU, T. M. T., NGUYEN, L. H., & NGUYEN, D. D. (2020). Audit quality and stock return co-movement: Evidence from Vietnam. *The Journal of Asian Finance, Economics and Business (JAFEB)*, 7(7), 139-147.
 41. Papaj-Wlisłocka, E., & Strojek-Filus, M. (2019). Forward-looking information disclosure as a risk factor in accounting—The case of Poland. In *Multiple Perspectives in Risk and Risk Management: ERRN 8th European Risk Conference 2018, Katowice, Poland, September 20-21* (pp. 125-141). Springer International Publishing.
 42. Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, 115, 635-655.
 43. Rafiuddin, A., Gaytan, J. C. T., Ahmed, G., & Alshurideh, M. (2023). Machine Learning Techniques for Stock Market Predictions: A Case of Mexican Stocks. In *The Effect of Information Technology on Business and Marketing Intelligence Systems* (pp. 1833-1843). Cham: Springer International Publishing.
 44. Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H. C. (2021). Stock market prediction using machine learning techniques: a decade survey on methodologies, recent developments, and future directions. *Electronics*, 10(21), 2717.
 45. Rossi, A. G. (2018). Predicting stock market returns with machine learning. *Georgetown University*.
 46. Sun, T. (2019). Applying deep learning to audit procedures: An illustrative framework. *Accounting Horizons*, 33(3), 89-109.
 47. Sezer, O. B., Ozbayoglu, M., & Dogdu, E. (2017). A deep neural-network based stock trading system based on evolutionary optimized technical analysis parameters. *Procedia computer science*, 114, 473-480.
 48. Saunders, M., Lewis, P., & Thornhill, A. (2009). *Research methods for business students. Pearson education*.
 49. Utami, W., Wahyuni, P. D., & Nugroho, L. (2020). Determinants of stock liquidity: forward-looking information, corporate governance, and asymmetric information. *The Journal of Asian Finance, Economics and Business (JAFEB)*, 7(12), 795-807.

-
-
50. van Zyl, W., & Uliana, E. (2022). Fixing diluted earnings per share: Recognising the dilutive effects of employee stock options. *Accounting & Finance*, 62(2), 2993-3019.
 51. van der Heijden, H. (2022). Predicting industry sectors from financial statements: An illustration of machine learning in accounting research. *The British Accounting Review*, 101096.
 52. Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock closing price prediction using machine learning techniques. *Procedia computer science*, 167, 599-606.
 53. Widiastuti, H., Utami, E. R., & Purnamasari, E. (2022). FORWARD-LOOKING INFORMATION DISCLOSURE AND FIRM VALUE IN THE PANDEMIC ERA. *Jurnal Riset Akuntansi Kontemporer*, 14(2), 261-269.
 54. Yang, C., Zhai, J., & Tao, G. (2020). Deep learning for price movement prediction using convolutional neural network and long short-term memory. *Mathematical Problems in Engineering*, 2020.
 55. Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100.

The effect of using machine learning techniques in predicting stock returns on the disclosure of future information

Dr. Nermin Ali Almor

Abstract:

The research aimed to find out the effect of using machine learning techniques in predicting stock returns on the disclosure of future financial information in the Egyptian environment. The researcher dealt with the relationship between stock returns and the disclosure of future information in accounting thought. The researcher also presented the role of machine learning techniques in predicting accounting information using machine learning techniques, and finally the impact of predicting stock returns using machine learning techniques on disclosing future information was dealt with.

The study population amounted to 244 companies listed in the Egyptian stock market and were obtained from the data of the EGX 30 index, and this index expresses the most traded companies in the Egyptian stock market, during the time period from 2014 to 2021. The sample of the study was 240 observations (30 companies x 8 years), and the researcher made a comparison between machine learning models and traditional models (probit analysis method, and multiple regression analysis method) to predict stock returns.

The researcher concluded that there are significant differences between the predicted stock returns using traditional methods and the predicted stock returns using machine learning techniques. The study also indicated that there is no statistically significant effect of predicted stock returns using traditional methods on the disclosure of future information, while prediction of stock returns using machine learning techniques represented in: decision tree, neural networks, support vector machine, Bayesian network, It explains 62.18%, 66.18%, 71.25%, 75.36% of the change in the disclosure of forward-looking information.

Keywords: Machine Learning, Prediction of Stock Returns, Forward-Looking Information, Decision Tree, Neural Networks; Support Vector Machine, Bayesian Network.