

قياس أثر استخدام نموذج آلة متجه الدعم Support Vector Machine على دقة التنبؤات المالية - دراسة تطبيقية على شركات المقيدة في سوق الأوراق المالية المصرية

د/ رشا مصطفى عبد الحميد الجوهري

مدرس بقسم المحاسبة والمراجعة

كلية التجارة

جامعة عين شمس

المستخلص:

الهدف من الدراسة: يتمثل هدف الدراسة في قياس أثر تطبيق تقنية آلة متجه الدعم (SVM) كإحدى تقنيات الذكاء الاصطناعي في تحسين دقة التنبؤات المالية في سوق الأوراق المالية المصرية، وذلك من خلال تحسين دقة التنبؤ بالتدفقات النقدية.

منهجية الدراسة: اعتمدت الباحثة في تحقيق الهدف البحثي على دراسة وتحليل الدراسات السابقة ذات الصلة بموضوع البحث، بالإضافة إلى إجراء دراسة تطبيقية على مجموعة من الشركات المقيدة في سوق الأوراق المالية المصرية، وتم استخدام برنامج (MATLAB R2022b) لتطبيق تقنية آلة متجه الدعم (SVM) وذلك للتنبؤ بالتدفقات النقدية.

نتائج الدراسة: أسفرت نتائج الدراسة التطبيقية عن ما يلي:

١. انخفاض قيمة المتوسط المطلق لخطأ التنبؤ (MAE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان المتوسط المطلق لخطأ التنبؤ بالتدفقات النقدية (MAE) ما بين القيمة (٠,٠١٠٢) والقيمة (٠,٠٢٢٥).
٢. انخفاض قيمة متوسط الخطأ التربيعي (MSE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان متوسط الخطأ التربيعي (MSE) لخطأ التنبؤ بالتدفقات النقدية (MSE) ما بين القيمة (٠,٠٠٣٠) والقيمة (٠,٩٦٦٤).

٣. إنخفاض قيمة الجذر التربيعي لخطأ التنبؤ (RMSE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان الجذر التربيعي لخطأ التنبؤ بالتدفقات النقدية (RMSE) ما بين القيمة (٠,٠٥٤) والقيمة (٠,٩٨٣٠).
الكلمات المفتاحية: تقنيات الذكاء الاصطناعي- آلة متجه الدعم -- التدفقات النقدية المستقبلية- التنبؤات المالية- الشبكات العصبية الاصطناعية- المنطق الضبابي- التقارير الرقمية.

Measure the impact of using the Support Vector Machine model on the accuracy of financial predictions - An applied study On companies registered in the Egyptian stock market
Abstract:

Purpose: The aim of the study is to measure the impact of applying the Support Vector Machine technique as one of the Artificial Intelligence techniques in improving the accuracy of financial predictions in the Egyptian stock market, by improving the accuracy of predicting cash flows.

Methodology: The researcher relied on studying and analyzing previous studies related to the research topic, in addition to conducting an empirical study on a group of companies listed on the Egyptian Stock Exchange, and a program was used (MATLAB R٢٠٢٢b) to apply the Support Vector Machine technique to predict cash flows.

Findings: The results of the applied study showed the following:

١. The absolute average error (MAE) for all (SVM) models has decreased, where the absolute average error for cash flows prediction (MAE) ranged between (٠,٠١٠٢) and (٠,٠٢٢٥).
٢. The mean squared error (MSE) value for all (SVM) models has decreased, where the mean squared error for cash flows prediction (MSE) ranged between (٠,٠٠٣٠) and (٠,٩٦٦٤).
٣. The root mean squared error (RMSE) value for all (SVM) models has decreased, where the root mean squared error for cash flows prediction (RMSE) ranged between (٠,٠٠٥٤) and (٠,٩٨٣٠).

Keywords: Artificial Intelligence Techniques - Support Vector Machine – Future Cash Flows– Financial Predictions- Artificial Neural Networks- Fuzzy Logic- Digital Reports.

المقدمة

التقارير المالية تشوبها الكثير من أوجه القصور، التي أدت إلى زيادة اهتمام الشركات المهنية والباحثين بقضية جودة التقارير المالية، وذلك باعتبارها المصدر الرئيسي للحصول على المعلومات المحاسبية التي تُستخدم في إتخاذ القرارات المختلفة، وخصوصاً بعد الأزمات الاقتصادية التي واجهتها البورصات العالمية وإنهيار شركات مالية عملاقة (إلهام محمد، ٢٠١٦، ص٣٦)، ويعتمد التنبؤ بمقدار وتوقيت التدفقات النقدية المستقبلية ودرجة التأكد المتعلقة بها على جودة المعلومات المحاسبية، فهي تمثل إحدى المدخلات الهامة التي يستخدمها المستثمرين في إتخاذ القرارات، فحاجتهم للمعلومات عن التدفقات النقدية المستقبلية تعتمد على أن قيمة استثماراتهم هي القيمة الحالية للتدفقات النقدية المستقبلية، كما أن قدرة الشركات على توليد تدفقات نقدية مستقبلية ينعكس على قيمة أسهمها، وقيام المستثمرين بتوقع

التدفقات النقدية المستقبلية يسمح لهم بالتنبؤ بأسعار الأسهم (منذر محمد وآخرون ٢٠٢٢، ص ٦- عصام عبدالمنعم، ٢٠١٧، ص ٣- Financial Dictionary, ٢٠١٩).

تُعتبر التكنولوجيا الحديثة من أكثر العوامل تأثيرًا على بيئة عمل شركات الأعمال، حيث سمحت بدخول إمكانات وقدرات جديدة وعديدة لتؤثر في بيئة العمل، وبالتالي غيرت التكنولوجيا ثقافة الشركة إلى ثقافة معتمدة على التكنولوجيا ومن أدوات هذه التكنولوجيا تقنيات الذكاء الاصطناعي، وتقوم تقنيات الذكاء الاصطناعي بدورًا هامًا في خلق بيئة عمل أكثر قابلية للتنبؤ مما يؤدي إلى تقليل المخاطر المالية، وذلك من خلال الاعتماد على مجموعة من الخوارزميات المعقدة التي تمكنها من التعامل مع البيانات الضخمة ومعالجتها في وقت قياسي للتنبؤ بالأوضاع المالية والتنافسية لشركات الأعمال، وذلك بتحويلها من مجرد معلومات متراكمة وغير مفهومة إلى معلومات ذات قيمة يمكن استغلالها والاستفادة منها بعد ذلك، وبالتالي تؤثر هذه الميزة في التعرف على الفرص المتاحة والمخاطر المحتملة المستقبلية، والتي تتطلب إتخاذ قرارات بشأنها بشكل سريع (Fintechnews, ٢٠١٨, p. ١٦٠). كما أنه وفقًا لأهمية تطبيق تقنيات الذكاء الاصطناعي في المجال المحاسبي، إقترحت الباحثة نموذج علمي يمكن تطبيقه عمليًا من أجل تحسين دقة التنبؤات المالية، وذلك من خلال التنبؤ بالتدفقات النقدية المستقبلية باستخدام نموذج (SVM) وهو إحدى نماذج الذكاء الاصطناعي.

١. مشكلة الدراسة

أحدثت تقنيات الذكاء الاصطناعي (Artificial Intelligence Techniques) تطور كبير في مجال تكنولوجيا المعلومات (Information Tecnonology)، حيث يُعتبر الذكاء الاصطناعي إحدى فروع علوم الحاسب الآلي، ويتضمن تكوين أجهزة وبرمجيات ذكية تعمل وتتفاعل مثل العنصر البشري، وهو تسمية شاع استخدامها للإشارة إلى مجال العلوم الذي يكون هدفه الرئيسي هو تمكين

برامج الحاسب الآلي بالقدرة على تنفيذ بعض المهام مثل المنطق والتخطيط والتعلم والإدراك، كما يشمل الذكاء الاصطناعي مجموعة من القدرات المختلفة والمتشابهة كالإبداع والمعرفة والوعي الشخصي، كما يُساعد التسارع المتزايد لتطور الذكاء الاصطناعي الاستراتيجي في إعادة هيكلة أعمالهم ونماذجهم، وهذا الذي يدعم ارتباط الذكاء الاصطناعي بالعمليات التجارية الخاصة بالشركة وتداخله معها.

أمام الواقع الذي يعكس المخالفات المالية، وتلك الضغوط التي تعكس قلق حملة الأسهم والمجتمع بصفة عامة، والنتائج التي تعكس تضليل مُستخدمي المعلومات المحاسبية والتأثير السلبي على كفاءة سوق الأوراق المالية، زاد الاهتمام بتطبيق تقنيات الذكاء الاصطناعي حيث ثبت فعاليتها في إكتشاف الإحتيال والتلاعب بالقوائم المالية في العديد من الأبحاث السابقة، كما ثبت دقة تلك التقنيات في التنبؤات المالية، ولتوفير معلومات محاسبية تتسم بالجودة والدقة قام الباحثة باستخدام نموذج علمي يعتمد على تقنيات الذكاء الاصطناعي وهو عبارة عن تطبيق تقنية (Support Vector Machine) على بيانات التدفقات النقدية للشركات للتأكد على دقة التنبؤات المالية عند استخدام تقنيات الذكاء الاصطناعي، ومثل هذا النموذج من شأنه أن يسمح بتحليل مستمر لكميات ضخمة من البيانات (Big Data)، كما أنه سوف يكون أكثر دقة من أجل إتخاذ القرارات الإستثمارية، بما يؤدي إلى زيادة دقة التنبؤ بالتدفقات النقدية لشركات الأعمال، ومما سبق يمكن للباحثة صياغة مشكلة البحث في التساؤل التالي:

ما هو دور تقنية آلة متجه الدعم (Support Vector Machine) في تحسين دقة التنبؤات المالية؟

٢. الدراسات السابقة

تتناول الباحثة في هذا الجزء الدراسات السابقة التي تناولت تقنية (Support Vector Machine) وهي من إحدى تقنيات الذكاء الاصطناعي ودورها في زيادة دقة التنبؤات المالية، وفي هذا الصدد فقد هدفت دراسة (Paulius&Gintautas, ٢٠١١) بعنوان "SVM and XBRL Based Decision Support System for Credit Risk Evaluation"، إلى تقديم

إطار لتقييم مخاطر الائتمان ونموذجاً لتنفيذه بطريقة شاملة ومستقلة عن طريق تطبيق تقنيات الذكاء الاصطناعي، ويدعم هذا الإطار تقنية آلة متجه الدعم (SVM) المطبقة على نطاق واسع كأساس للتقييم الذكي، ولغة تقارير الأعمال الموسعة (XBRL) التي يتم تطويرها وتنفيذها ودعمها على نطاق واسع من قِبل الحكومات والسلطات التنظيمية، وتناولت الدراسة تقنية (SVM) باعتبارها إحدى تقنيات الذكاء الاصطناعي التي تُمثل حلاً فعالاً للعديد من المشاكل المختلفة المتعلقة بالتعرف على الأنماط، والتصنيف، والانحدار، والتنبؤ، بما في ذلك التنبؤ المالي وتقييم مخاطر الائتمان، وتوصلت الدراسة إلى أن تقنية (SVM) أثبتت أنها حل فعال في مجال التنبؤ بالمخاطر الائتمانية مع نتائج مماثلة أو أفضل من معظم تقنيات الذكاء الاصطناعي الأخرى مثل الشبكات العصبية الاصطناعية والخوارزميات الجينية، كما أن النماذج الهجينة الذكية القائمة على تقنية (SVM) أثبتت أنها أكثر دقة وفعالية، حيث يجب اختيار نموذج تنبؤي يتيح تنفيذ واختبار واستخدام نماذج ذكية في مؤسسات الائتمان وذلك للتنبؤ بإفلاس الشركات.

تناولت دراسة (Gerlein,et al., ٢٠١٦, p.٢) بعنوان " Evaluating machine learning classification for financial trading: An empirical approach"، تقييم مدى فعالية تطبيق تقنيات الذكاء الاصطناعي في المجال المحاسبي من خلال التعرف على مدى دقة نتائج التصنيف بعد تطبيق تعلم الآلة (Machine Learning) في التنبؤات المالية، وذكرت الدراسة أنه من المحتمل أن تكون التنبؤات المالية هي أهم تطبيق من خلال استخدام (Machine Learning) للتغلب على البيانات في الأسواق المالية، وتستخدم غالبية التقنيات القائمة على ML للتداول المؤشرات الفنية (Technical Indicators) كجزء من سمات التدريب المستخرجة من السلسلة المالية بدلاً من استخدام الأسعار الأولية كمتجه للتدريب، وتوصلت الدراسة إلى أن النماذج الهجينة التي تتكون من نموذج إحصائي خطي وخوارزمية تعلم آلي غير خطية، أكثر فعالية في التنبؤات المالية المستقبلية.

كما هدفت دراسة (Guang Yih Sheu, ٢٠١٩) بعنوان " Classification of the Priority of Auditing XBRL Instance Documents with Fuzzy Support Vector Machines Algorithm"، إلى التعرف على أثر استخدام إحدى تقنيات الذكاء الاصطناعي المتمثلة في آلة متجه الدعم (SVM) المعتمدة على المنطق الضبابي في تصنيف التقارير المالية الرقمية التي تم إعدادها وفقاً للغة XBRL من حيث أولويات المراجعة، وذلك لكي يتم اكتشاف الاحتيال المالي في التقارير المالية، وذكرت الدراسة أن اكتشاف التقارير الاحتيالية يستغرق وقتاً طويلاً إذا كان الحجم الإجمالي للمستندات المطلوب فحصها كبيراً، وتقوم آلة متجه الدعم (SVM) بتصنيف البيانات المدخلة، ويتم البحث بعد ذلك عن المستوى الفائق، الذي يفصل البيانات المدخلة إلى فئتين، ويستمر هذا البحث حتى يتم العثور على أفضل سطح فاصل، ويتم تدريب تلك التقنية بالاعتماد على مبدأ تقليل الخطأ إلى الحد الأدنى وذلك بين القيم المتوقعة والقيم الفعلية، وتوصلت الدراسة إلى أن آلة متجه الدعم تستخدم تقنية تسمى خدعة نواة (kernel trick) حيث تأخذ النواة فضاء إدخال منخفض الأبعاد وتحوله إلى مساحة ذات أبعاد أعلى، أي أن تقنية (SVM) تحول نواة المسائل غير القابلة للفصل إلى مسائل قابلة للفصل عن طريق إضافة المزيد من الأبعاد إليها، مما يجعل تقنية (SVM) أكثر قوة ومرونة ودقة، مما انعكس على سرعة ودقة اكتشاف الاحتيال المالي في التقارير المالية.

أما دراسة (Amos&Rimona, ٢٠١٩) بعنوان " Earning Movement Prediction Using Machine Learning-Support Vector Machines (SVM)"، فقد هدفت إلى استخدام تقنيات الذكاء الاصطناعي في التنبؤ بحركة الأرباح من خلال تطبيق تقنية آلة متجه الدعم (SVM)، وأشارت الدراسة إلى أنه يتم الاعتماد على التنبؤ بحركة الأرباح في العديد من الأسواق المالية وذلك بهدف تقييم أداء شركات الأعمال وإتخاذ قرارات الاستثمار، وتوصلت الدراسة إلى أن نموذج التنبؤ بحركة الأرباح باستخدام تقنية (SVM)؛ سيسمح بالتحليل المستمر لكميات ضخمة من البيانات، مما يؤدي إلى إتخاذ قرارات استثمارية دقيقة، كما أن النماذج

التي تستخدم تقنية (SVM) تتفوق على النماذج الإحصائية التقليدية، حيث تتحسن نماذج التنبؤ المالي عند استخدام تقنيات الذكاء الاصطناعي بشكل عام وتقنية (SVM) بشكل خاص.

كما هدفت دراسة (Isaac,et al., ٢٠٢٠) بعنوان "Efficient Stock-Market Prediction Using Ensemble Support Vector Machine" إلى استخدام إحدى تقنيات الذكاء الاصطناعي وهي تقنية آلة متجه الدعم (SVM) في التنبؤ بأسعار الأسهم، وأشارت الدراسة إلى أن التقدم في تقنيات الذكاء الاصطناعي قد مهد الطريق في السنوات الأخيرة لتوقع أفضل وأكثر دقة لأسعار الأسهم، حيث اكتسبت تقنية (SVM) في الآونة الأخيرة شعبية كبيرة بين خوارزميات تعلم الآلة (Machine Learning) المستخدمة للتنبؤ بسوق الأوراق المالية، وهدفت الدراسة أيضًا إلى بيان أهمية استخدام تقنية (SVM) في التعامل مع الأنماط غير الخطية المعقدة وذلك للتغلب على عيوبها عند التنبؤ بأسعار الأسهم، وتوصلت الدراسة إلى أن تقنية (SVM) تفوقت في الأداء على خوارزميات (Machine Learning) الأخرى مثل شجرة القرار، والشبكة العصبية في توقع حركة سعر السهم قبل ١٠ أيام، وأظهرت تقنية (SVM) دقة تنبؤ أفضل بنسبة (٩٣,٧٪) مقارنة بتقنية شجرة القرار وكانت النسبة (٧٥,٣٪)، أما تقنية الشبكة العصبية كانت النسبة (٨٠,١٪)، كما أن الدقة البالغة (٩٣,٧٪) التي حققتها تقنية (SVM)، سوف تؤدي إلى تعظيم أرباح المستثمرين في بورصة الأوراق المالية.

٣. التعقيب على الدراسات السابقة وتحديد الفجوة البحثية

من خلال عرض واستقراء الدراسات السابقة الخاصة بتقنيات الذكاء الاصطناعي، تستخلص الباحثة ما يلي:

- أهمية تطبيق تقنيات الذكاء الاصطناعي في الأسواق المالية، حيث أن الاستثمارات والأسواق المالية تنتقل إلى مرحلة متطورة وهي مرحلة الذكاء الاصطناعي والتكنولوجيا المالية باستخدام النظام المالي الرقمي.

- يقدم (Machine Learning) منهجية توفر وسائل جديدة لاستكشاف الأنماط المعقدة في البيانات، كما أن المحاسبين سوف يجدون أن نتائجهم ستكون أكثر دقة في تحليل البيانات لأغراض اتخاذ القرار بعد استخدام تقنيات الذكاء الاصطناعي.
- يجب على المحاسبين الاهتمام بشكل جيد بالتقنيات الحديثة في مجالات المعلومات والمعرفة ومحاولة فهمها والتكيف معها وإدماجها في نظام المعلومات المحاسبي، واعتبارها جزءاً منه وليس أداة مستقلة في أيدي مهندسي المعلومات الذين قد يستقلون بهذه النظم وينافسون بها محاسبي نظم المعلومات المحاسبية، وذلك لأن الذكاء الاصطناعي ومجالاته المختلفة يمثل هدفاً للمحاسب ينبغي التركيز عليه.

وفقاً لما سبق ترى الباحثة؛ أن الفجوة البحثية التي تتطلب المزيد من الدراسة تتمثل في ضرورة استخدام تقنيات الذكاء الاصطناعي من أجل تحسين دقة التنبؤات المالية، وتهدف الدراسة إلى سد جزء من الفجوة في الدراسات السابقة فيما يتعلق بالتنبؤ بالتدفقات النقدية المستقبلية من خلال استخدام تقنية آلة متجه الدعم (SVM)، مما يساهم في تحسين دقة التنبؤات المالية.

٤. هدف الدراسة

تهدف الباحثة من خلال هذه الدراسة إلى بيان قياس أثر تطبيق تقنية آلة متجه الدعم (SVM) كإحدى تقنيات الذكاء الاصطناعي في تحسين دقة التنبؤات المالية، من خلال زيادة دقة التنبؤ بالتدفقات النقدية المستقبلية، كما يهدف البحث لدراسة هذه المشكلة في بيئة الأعمال المصرية، وبالتالي يمكن أن يكون له مساهمة في إثراء البحث المحاسبي الأكاديمي في هذا المجال.

٥. أهمية الدراسة

تتمثل الأهمية العلمية للدراسة في تناولها لموضوع هام وهو قياس أثر تطبيق تقنية آلة متجه الدعم (SVM) عند التحقق من جودة التقارير المالية بدلالة دقة التنبؤات المالية، وإبراز ما ينبغي أن تكون عليه محتوى التقارير المالية، وتستمد الدراسة أهميتها العملية من خلال توجيه الاهتمام نحو دور تقنية آلة متجه الدعم (SVM) واستخداماتها المحاسبية، وكيفية تحقيق الاستفادة لكل من المستثمرين في اختيار الشركة التي يرغب الاستثمار فيها،

والبنوك لإتخاذ قرارات منح الائتمان، وأيضاً الإدارة في التعرف على تحديد مسار الشركة وتوسيع النشاط وتحديد مصادر التمويل المناسبة.

٦. فرض الدراسة

لتحقيق هدف الدراسة يمكن صياغة الفرض التالي:

" يوجد تأثير معنوي بين تطبيق تقنية آلة متجه الدعم (SVM) وبين دقة التنبؤات المالية "

٧. التاصيل النظرى للدراسة

٧/١ مفهوم الذكاء الاصطناعي

عرف (Spacey,J.,٢٠١٦,p.١٨) الذكاء الاصطناعي بأنه "أحد التكنولوجيات التي صُممت لكي تتعلم وتطور من نفسها وعادةً تُستخدم لحل المشكلات أو الأمور المُعقدة التي يصعب حلها بالطرق التقليدية"، حيث يُحاول الذكاء الاصطناعي أثناء تنفيذ بعض المهام تكرار أو تقليد الذكاء البشري.

بينما عرف (Dan.W.Patterson,٢٠١٧,p.٤٨) الذكاء الاصطناعي على أنه " فرع من فروع علوم الحاسبات الذي يهتم بدراسة وتكوين أنظمة حاسوبية تظهر بعض صيغ الذكاء"، حيث تم برمجة هذه الأنظمة للحصول على معلومات واستنتاجات حول المشكلة القائمة، كما توجد امكانيات أخرى لهذه الأنظمة مثل فهم اللغات الطبيعية (Natural Language) أو أي امكانيات تحتاج إلى ذكاء إصطناعي عندما تنفذ من قبل العنصر البشري.

كما يمكن تعريف الذكاء الاصطناعي بأنه تلك الوسائل التي تؤدي إلى حلول للمشاكل المُعقدة اعتماداً على برامج الحاسب الآلي، وذلك من خلال تطبيق مجموعة من العمليات التي تعمل على مُحاكاة تفكير العنصر البشري في الوصول إلى الاستنتاجات، بمعنى أنها تُحاول أن تُحاكي الذكاء البشري في التوصل إلى النتائج (محمد عبداللطيف، ٢٠١٤، ص٥٠).

٧/٢ تقنيات الذكاء الاصطناعي

تُعتبر تقنيات الذكاء الاصطناعي من أهم التطورات في جميع المجالات عامةً وفي مجال المحاسبة خاصةً، وتُعرف على أنها سلوكيات وخصائص متطورة تتسم بها برامج الحاسب الآلي، والتي تُساعد في محاكاة القدرات الذهنية والبشرية، ومن أهم خصائصها قدرتها على التعلّم والإستنتاج وسرعة إتخاذ قرارات بشأن الأحداث غير المتوقعة والتي لم يتم برمجتها في برامج الحاسب الآلي، وذلك للمساهمة في تحقيق أهداف ومهام محددة، وتتضمن العديد من التقنيات الحديثة والتي بدأ البحث مؤخرًا عن إمكانية إستخدامها في مجال المحاسبة ومنها تعلم الآلة (Machine Learning)، الشبكات العصبية الاصطناعية، والمنطق الضبابي، وآلة متجه الدعم، وغيرها (مها محي الدين، ٢٠١٩، ص ٣)، ومن أهم تقنيات الذكاء الاصطناعي ما يلي:

٧/٢/١ آلة مُتجه الدعم (Support Vector Machine)

ظهرت تقنية آلة متجه الدعم في عام ١٩٩٣، حيث قُدمت من قبل الباحثين (Guyon & Boser)، وهي عبارة عن مجموعة أساليب مُرتبطة بطرق ومناهج تعلم الآلة وتُستخدم في تصنيف البيانات، وتنتمي إلى مجموعة المُصنّفات الخطية للبيانات والملفات الإحصائية، وهي أداة للتنبؤ وتستخدم نظرية التعلّم كأداة لتحقيق أقصى قدر من الدقة التنبؤية مع تجنب الإفراط تلقائيًا في معالجة البيانات، حيث يمكن تعريفها بأنها أنظمة تستخدم مساحة فرضية مبنية على الوظائف الخطية في مساحة متعددة الأبعاد وفق خوارزمية التي تنفذ التمييز بين البيانات المستمدة من نظرية التعلّم الإحصائية (Liu hongjiu, ٢٠١٠, p. ٤).

كما تُعد تقنية آلة متجه الدعم من أشهر طرق التصنيف المبني على أنظمة الحاسب الآلي، والتي تعتمد على إيجاد منحنى أو مستوى معين يفصل العينات المُدخلة عن بعضها البعض، وتتميز بقدرتها على تصنيف المسائل ذات الفئات الثنائية، حيث تقوم هذه الخوارزمية بحساب سطح أو مجموعة أسطح في بُعد آخر يختلف طوله عن طول مُتجه الخصائص (Vikramaditya, ٢٠١٠, p. ٦٤)، كما تتحدد دقة الخوارزم بقدرته على الفصل بين الخصائص بحيث تكون أقرب عينة من كلا الخصائص أبعد

ما يكون عن بعضهما البعض وهو ما يُسمى بالهامش، وبصفة عامة كلما زاد هامش الفصل كلما قل الخطأ في حالة التعميم لجزء البيانات الغير خاص بمرحلة التكرار والتعلم، وبالرغم مما تبدو عليه المشكلة من سهولة، إلا أنه في أغلب الأحيان لا يمكن الفصل بين الخصائص خطيًا، وحينها نلجأ لتحويل محاور مُتجهات الخصائص لُبعد أعلى بحيث يتم الفصل بينهم بسطح، ويراعى في هذا المنظور العبء الحسابي فيتم حساب الضرب القياسي للمُتجهات بواسطة دالة المصفوفة (-Hua ١٠, p. ٢٠١٤, Cheng).

٧/٢/١/١ مفهوم تقنية آلة متجه الدعم (SVM)

هي إحدى تقنيات الذكاء الاصطناعي التي يمكن أن تساعد في حل مشاكل تصنيف البيانات الضخمة (Big Data)، وهي عبارة عن أسلوب يجمع بين النظرية الإحصائية والتعلم الخاضع للإشراف (Supervised Machine Learning)، طورت من قبل الباحثة (Vapnik) عام ١٩٩٨، حيث تعتمد فكرة تقنية آلة متجه الدعم على البحث على أفضل طريقة لتقسيم البيانات إلى مجموعتين بوضع مستوى فائق (Hyper plane) بينهما بغض النظر عن طبيعة البيانات سواء كانت قابلة للفصل الخطي أو لا، وهنا تكمن مصدر قوتها (Shan ٢٠٧, p. ٢٠١٦, Suthaharan).

٧/٢/١/٢ كيفية عمل تقنية آلة متجه الدعم (SVM)

تقنية آلة متجه الدعم عبارة عن منهج تدريب ثنائي، تُستخدم لتصنيف بيانات التدريب (Training Data) إلى صنفين (موجب، وسالب) مثلاً، حيث يتم تدريبها بالاعتماد على مبدأ تقليل الخطأ إلى الحد الأدنى وذلك بين القيم المتوقعة والقيم الفعلية، كما أن ذلك سيقال احتمال حدوث الأخطاء عند تطبيق الخوارزمية على النماذج الجديدة، وعند استخدام تقنية آلة متجه الدعم في عمليات التصنيف، تستطيع تلك التقنية إيجاد أفضل سطح فاصل وذلك حتى يتم فصل الأمثلة الموجبة عن الأمثلة السالبة، حيث يتم إختيار السطح الفاصل لكي تكون المسافة متواجدة بين أقرب مثال موجب وسالب، كما أن هذا السطح الفاصل يكون أكبر ما يمكن، ولهذا تكون عملية التصنيف

لبيانات الاختبار صحيحة، وأثبتت تلك التقنية نجاحها في التغلب على الكثير من المشكلات مثل معالجة الصور (Image Processing)، تصنيف النصوص (Text Classification)، وتحليل الأسواق المالية (Saif, S., et al., ٢٠١٢, p. ٣٢).

حيث يكون السطح الفاصل مُعرف بمجموعة من النقاط نتاج ضربهم القياسي مع مُتجه في الإحداثيات الجديدة (ذات البُعد الأعلى) والتي تكون ثابتة، إن عملية تصنيف البيانات تُعد من أكثر عمليات المُحاكاة شيوعاً، بوجود نقاط البيانات التي تتميز بعدة خصائص، ويكون الهدف هو تصنيف نقطة جديدة وتحديد إلى أي من الخصائص تنتمي، حيث ينظر لنقطة البيان على أنها مُتجه له عدد من الخصائص، وإذا تم الفصل بسطح بعده ينقص عنه بواحد يكون التصنيف خطأً، ويكون غير خطياً ما عدا ذلك، وفي حالة توافر أكثر من فاصل خطي يتم اختيار الفاصل الذي يضمن هامش أوسع بين أقرب نقطتين من الخصائص المختلفة لبعضها، وهو ما يسمى بالمستوى ذو الهامش الأكبر (Yunqian Ma, ٢٠١٤, p. ٣٣).

تم استخدام أسلوب تعلم الآلة المُستند إلى تقنية آلة متجه الدعم في الغالب للتعرف على الأنماط في العديد من المجالات، حيث أثبتت هذه التقنية كفاءتها من أي تقنية أخرى للتعرف على الأنماط الأكثر استخداماً، مثل الشبكات العصبية الاصطناعية (ANN)، وتصنيف (Basiean classification)، والأداء الذي تقدمه تقنية آلة متجه الدعم أعلى نسبياً إذا كان يحتوي على مجموعة بيانات كبيرة (large dataset) لتعميم المشكلة، وتتمثل القوة الرئيسية لتقنية آلة متجه الدعم في أن تدريب البيانات سهل نسبياً، حيث تقيس هذه التقنية بشكل جيد نسبياً البيانات عالية الأبعاد (high dimensional data) ويمكن التحكم صراحةً في المفاضلة بين تعقيد التصنيف والخطأ، وهناك الكثير من النطاق المستقبلي لهذه التقنية في كافة المجالات لتحسين دقة التنبؤ (Ashis Pradhan, ٢٠١٢, p. ٤).

٧/٣ استخدامات تقنية آلة متجه الدعم (SVM)

تُستخدم هذه التقنية في تطبيقات تصنيف وتجزئة الصور (Image Classification and Segmentation)، وتصنيف النصوص (Category Assignment)، وتصنيف البريد الإلكتروني فيما إذا كان مزيف (Spam Email) أو حقيقي (Ham Email)، كذلك تحليل الآراء (Sentiment Analysis)، وغيرها، كما تُستخدم في التطبيقات البيولوجية وغيرها من العلوم (Paulius & Gintautas, ٢٠١١, p. ٣).

تم استخدام أسلوب تعلم الآلة المُستند إلى تقنية آلة متجه الدعم في الغالب للتعرف على الأنماط في العديد من المجالات، حيث أثبتت هذه التقنية كفاءتها من أي تقنية أخرى للتعرف على الأنماط الأكثر استخدامًا، مثل الشبكات العصبية الاصطناعية (ANN)، وتصنيف (Basiean classification)، والأداء الذي تقدمه تقنية آلة متجه الدعم أعلى نسبيًا إذا كان يحتوي على مجموعة بيانات كبيرة (large dataset) لتعميم المشكلة، وتتمثل القوة الرئيسية لتقنية آلة متجه الدعم في أن تدريب البيانات سهل نسبيًا، حيث تقيس هذه التقنية بشكل جيد نسبيًا البيانات عالية الأبعاد (high dimensional data) ويمكن التحكم صراحةً في المفاضلة بين تعقيد التصنيف والخطأ، وهناك الكثير من النطاق المستقبلي لهذه التقنية في كافة المجالات لتحسين دقة التنبؤ (Ashis Pradhan, ٢٠١٢, p. ٤).

٧/٤ الإفصاح عن التنبؤات المالية والمعلومات المستقبلية

تقوم شركات الأعمال بتصميم نماذج من أجل إعداد التنبؤات المالية (Financial Forecasts) بغرض التعرف على المعلومات المستقبلية التي تُستخدم في عرض كلاً من المركز المالي ونتائج الأعمال والتدفقات النقدية المتوقعة للشركات، وذلك وفقاً لافتراضات إدارة تلك الشركات للأحداث المتوقعة حدوثها، وتُعتبر التنبؤات المالية أهم مشكلة تواجهها الشركة عند إعداد القوائم المالية المستقبلية؛ وذلك لأن عدم مصداقية ودقة تلك التنبؤات، يؤدي إلى عدم ثقة كافة الأطراف المستفيدة من المعلومات المستقبلية المنشورة؛ وبالتالي لا يوجد منفعة من

تلك المعلومات، مما بالطبع يؤدي إلى صعوبة إعداد القوائم المالية المستقبلية خاصة في ظل تحيز الإدارة عند إعداد التنبؤات المالية (مصطفى إبراهيم، ٢٠١٤، ص ٢٢).

١/٤/٧ اتجاهات الإفصاح عن التنبؤات المالية

هناك اتجاهين متعارضين من قبل الشركات حول القيام بالإفصاح عن المعلومات المالية للمستثمرين بغرض القيام بالتنبؤات المالية، وهما: (زكي محمود، ٢٠١٣، ص ٩٤)، (هلال عبدالفتاح، ٢٠١٤، ص ٢٨٩)، (إلهام محمد، ٢٠١٦، ص ٣٣)

■ **الاتجاه الأول: يقضي بعدم إلزام الشركات بالإفصاح عن التنبؤات المالية، وذلك للأسباب التالية:**

١. أن قيام الشركات بالإفصاح عن المعلومات المستقبلية التي تتعلق بنشاطها وما سوف تتخذه من خطط مستقبلية؛ قد يضر بمركزها التنافسي.
٢. أن إدارة الشركات ليس لديها القدرة على توفير الإمكانات التي تُحقق الدقة اللازمة في إعداد التنبؤات المالية.
٣. أن إفصاح الشركات عن التنبؤات المالية للمستثمرين وعدم تمكنها من تحقيقها؛ قد يُسفر عنه اهتزاز هذه الشركات وتعرض إدارتها للمساءلة القانونية وبالتالي التأثير العكسي على إدارتها.
٤. تتسم التنبؤات المالية بالحساسية الشديدة للمتغيرات الاقتصادية والاجتماعية والسياسية، مما يؤدي إلى عدم دقة تلك التنبؤات.
٥. إلزام الشركات بالإفصاح عن التنبؤات المالية؛ قد يدفع الإدارة إلى إعداد تنبؤات مستقبلية يسهل تحقيقها، وبالتالي عدم الاجتهاد للوصول إلى نتائج أفضل، حتى في ظل توافر القدرة على تحقيق ذلك.
٦. قد لا يعلم مستخدمي المعلومات ما مدى دقة وحدود التنبؤات المالية التي تم الإفصاح عنها، وبالتالي يتم اتخاذ القرارات على أساس أن تلك التنبؤات سوف تتحقق، على الرغم من أنها تتسم بعدم التأكد ونادرًا ما تتحقق.

■ الاتجاه الثاني: يقضي بضرورة قيام الشركات بالإفصاح عن التنبؤات المالية، وذلك للأسباب التالية:

١. أن إفصاح الشركات عن التنبؤات المالية يُعتبر بمثابة محتوى إضافي يتم تقديمه لكافة الأطراف المستفيدة، كما يُعتبر إحدى الخصائص الهامة التي يجب أن يتسم بها نظام المعلومات.
٢. عند قيام إدارة الشركات بإعداد التنبؤات المالية؛ ستكون أكثر دقة من إعداد تلك التنبؤات بواسطة المحلل المالي، وذلك لأن الإدارة تملك المعرفة الكاملة بكافة الأنشطة الداخلية للمنظمة، كما أن الإفصاح عنها يُمكن المحللين الماليين من إعداد تنبؤات مالية أفضل وبالتالي عدم اللجوء إلى التخمين عند اتخاذ القرارات الاستثمارية.
٣. عند قيام إدارة الشركات بالإفصاح عن التنبؤات المالية سيجعلها متاحة إلى جميع الأطراف المستفيدة سواء كانت الداخلية أو الخارجية، وليست مقصورة على المحللين الماليين.
٤. سوف تعمل إدارة الشركات التي أفصحت عن تنبؤاتها المالية على تحقيقها، لأن ذلك سوف يعود عليها بالمنفعة من خلال زيادة ثقة المستثمرين بها وبالتالي يجذب الاستثمارات إليها.
٥. إن الهدف من نشر التقارير المالية هو إمداد كافة المستثمرين الحاليين والمرتقبين والدائنين وأيضاً مستخدمي التقارير المالية على اختلافهم بجميع المعلومات التي تُمكنهم من تقدير موعد وقيمة وكذلك احتمالات الحصول على عائد استثماراتهم بالشركة، وبالتالي فإن التنبؤات المالية التي تقوم الشركات بإعدادها عن الفترات القادمة يجب أن يتم الإفصاح عنها ضمن تقاريرها المالية.
٦. يتم تداول التنبؤات المالية بالفعل الآن ولكنها تكون بصورة غير رسمية وأيضاً غير خاضعة للرقابة، كما أنها تكون في بعض الأحيان مضللة وغير متاحة بصورة متساوية لكافة المستثمرين، وبالتالي يجب إخضاع تلك التنبؤات لمزيد من الرقابة.

٧/٤/٢ التنبؤ بالتدفقات النقدية المستقبلية

يُعتبر التنبؤ بالتدفقات النقدية المستقبلية ضروريًا عند القيام بتحليل الاستثمار وتقييم أداء شركات الأعمال، حيث تؤثر قدرة الشركة على توليد التدفقات النقدية على أسعار الأسهم، وذلك وفقاً لمجلس معايير المحاسبة الدولية (IASB) (IFRS ٢٠١٠a, Foundation)، حيث يجب توفير المعلومات اللازمة لمساعدة مُستخدمي القوائم المالية عند التنبؤ بالتدفقات النقدية المستقبلية باعتباره واحداً من الأهداف الرئيسية للتقارير المالية (Farshadfar & Monem, ٢٠١٣, p. ١١١).

كما أشارت قائمة مفاهيم المحاسبة المالية رقم (١) عام ١٩٧٨ فقرة (٣٧) إلى أن الهدف الرئيسي من نشر التقارير المالية هو توفير معلومات تُساعد كافة الأطراف المستفيدة مثل المستثمرين والدائنين وغيرهم؛ لكي يتم استخدامها في تقييم حجم وتوقيت وظروف عدم التأكد المحيطة بالتدفقات النقدية، وبالإضافة إلى ذلك تم التأكيد في فقرة رقم (٤٤) على أن معلومات الأرباح لها قدرة تنبؤية أفضل من استخدام التدفقات النقدية الحالية عند التنبؤ بالتدفقات النقدية المستقبلية (Barth, et.al., ٢٠٠٣, p. ٢٨ & Cohen, ٢٠٠١, p. ٢).

تُمكن معلومات التدفقات النقدية المستخدمين من فهم وتقييم أفضل للأداء التشغيلي الحقيقي للمنظمة وأيضاً الاستقرار المالي خاصة عندما تكون جودة أرباح الشركة منخفضة، ويُساعد التحديد الدقيق للتدفقات النقدية على إتخاذ قرارات مالية هامة وفقاً للتوقعات المستقبلية بشأن استمرارية الشركة أو إفلاسها، حيث أنها تُشير إلى قدرة الشركة على دفع توزيعات الأرباح، كما أنها تُمثل مقياساً للربحية والمركز المالي للشركة، ولهذا فإن التنبؤ بالتدفقات النقدية له فائدة كبيرة لجميع مستخدمي القوائم المالية من مديري الشركات والمستثمرين والمحللين الماليين أو غيرهم (Yoo & pae, ٢٠١٣, p. ٣٩).

وفي هذا الصدد، يهتم المستثمرين بالتدفقات النقدية؛ حيث أنها تُمثل مُدخلات لنماذج الاستثمار الخاصة بهم، والتي تُساعدهم في معرفة ما مدى قدرة الشركة على دفع توزيعات الأرباح، وتقيس التدفقات النقدية أيضاً القدرة التشغيلية للشركة على

مقابلة التعاقدات المالية اليومية، وبالتالي يُركز المحللين الماليين على توجه اهتمام المستثمرين بتحليل معلومات التدفقات النقدية وذلك عند اتخاذهم لقرارات الاستثمار في الأسهم، ويهتم الدائنين بقرارات الملاءمة المالية المتعلقة بالشركات، وكذلك تهتم وكالات التصنيف باستمرارية الشركة وقدرتها على دفع الديون عند إستحقاقها، وبالتالي يجب مراعاة تحديد المتغيرات الهامة في التنبؤ بالتدفقات النقدية والتي يجب تضمينها في نموذج التنبؤ، وأيضًا يجب اختيار نوع وبنية النماذج بعناية لتوفير تنبؤ أكثر دقة (Li, et.al., ٢٠١٥, p. ٢٤).

ومن زاوية أخرى، يلجأ العديد من المحللين الماليين إلى التنبؤ بالتدفقات النقدية إلى جانب التنبؤ بالأرباح، وذلك لأن التدفقات النقدية تُساعد في تجنب الإستدلالات الخاطئة الناتجة عن سوء فهم الأرباح المحاسبية التي تم إعدادها وفقًا لأساس الإستحقاق المحاسبي، ويُشار إلى الأرباح في بعض الأحيان بصافي الدخل (Net Icome) وهي مجموع كل من صافي الدخل النقدي وصافي الدخل الائتماني (الإستحقاقات)، ويعتمد صافي الدخل الائتماني على التعاملات الائتمانية مع عملاء الشركة والمتوقع تسويتها بشكل نقدي في فترة مالية لاحقة، ومن الممكن أن تقوم الشركة بتجاهل الإفصاح عن حجم الائتمان المُعطى للعملاء في معلومات التدفقات النقدية، مما قد يؤدي إلى تضليل المستثمرين عن مخاطر نقص النقدية في الشركة (Bilinski, ٢٠١٤, p. ٤٠١).

حيث يعتمد غالبية الأطراف المستفيدة من التقارير المالية من عملاء وموردين وأيضًا المستثمرين الحاليين والمرتقبين على إجمالي الأرباح ومكوناتها التي تشمل التدفقات النقدية من الأنشطة التشغيلية والإستحقاقات وذلك عند التنبؤ بالتدفقات النقدية المستقبلية، وقد إتخذت النماذج التطبيقية دقة المعلومات التي تم الإفصاح عنها كمقياس لجودتها، حيث تم تفسير الدقة بأنها تحقيق مستوى مُحدد من التنبؤ بالتدفقات النقدية المستقبلية وذلك في ظل المرونة وحرية التصرف التي تم السماح بها من خلال الإلتزام بتطبيق المبادئ المحاسبية (GAAP)، وبالتالي فإنه كلما زادت دقة التنبؤ كلما

زادت جودة الأرباح المُفصح عنها وبالتالي تزيد دقة التنبؤ بالتدفقات النقدية المستقبلية (Cohen, 2003, p. 10).

كما تُمكن قدرة مديري المشروعات وشركات الأعمال على التنبؤ بالتدفقات النقدية المستقبلية الموثوق بها من مراقبة وإدارة تدفق تكاليف المشروعات، ولذلك ينبغي على المديرين أن يرصدوا التقدم المُحقق في المشروعات باستخدام بيانات التدفقات النقدية التي تتسم بخصائص فريدة، بوصفها بيانات سلاسل زمنية (Min-Yuan&Andreas, 2011, p. 56).

٧/٥ مساهمة تقنية التمثيل المرئي للبيانات في تحسين جودة عرض المعلومات المحاسبية

أصبحت تقنيات الذكاء الاصطناعي تُقدم أفضل الطرق والممارسات؛ لكي تكون عملية تحليل التقارير المالية والإفصاح عنها تتم بطريقة تلقائية وذلك على جميع مستويات الشركة، وتُعتبر تقنية التمثيل المرئي للبيانات (Visualization) من أهم هذه التقنيات، حيث تهدف تلك التقنية إلى عرض البيانات كصورة مرئية وبالتالي تُمكن من تمثيل كميات ضخمة من البيانات على شاشة واحدة، كما أنه يتم استخدام تقنية (Visuailzation) لإنشاء لوحات تحكم متقدمة للقيام بتلك المهمة، وتهدف أيضًا إلى استغلال النظام البصري البشري؛ لكي يتم استخراج المعلومات من البيانات، كما أن العقل البشري قادر على إدراك ومعالجة الصور بمعدل يصل إلى ٦٠ ألف مرة أسرع من إدراك ومعالجة البيانات النصية، مما يؤدي إلى فهم وتحليل مجموعات البيانات المُعقدة لكي يتم تحديد الهيكل والأنماط، والاتجاهات لتلك المجموعات، وأيضًا الشدوذ والعلاقات بين البيانات (Trigo,et.al., 2014, p. 120).

وفي هذا الصدد؛ يمكن استخدام أدوات تقنية (Visuailzation) أو لوحات التحكم (Dashboards) لزيادة جودة عرض البيانات التي يتم تجميعها في وقت حدوثها، كما أن تلك الأدوات تحتوي على مقاييس لأداء الأعمال، وتستطيع رصد وتتبع جميع التغيرات الفورية والسريعة التي تطرأ على البيانات التي تم عرضها، وتُساعد في عرض التغيرات والقيام بتعديل البيانات المعروضة وفقًا لها؛ الأمر الذي

يؤدي إلى مساعدة الإدارة وجميع المشاركين في السوق على تقييم أداء الشركات على المدى البعيد، وأيضاً الحصول على صورة أكثر شمولية عن أداء تلك الشركات في الوقت الحالي والتنبؤ بأدائها في المستقبل؛ بهدف اتخاذ القرارات الفورية والرشيدة بكفاءة وفعالية (Gepp,et.al., ٢٠١٧, p.١٠٧).

كما تزداد أهمية تقنية (Visuailzation) في بيئة البيانات الضخمة (Big Data) حيث التغير السريع في البيانات وبالتالي الحاجة إلى ربط تلك البيانات بمصادر (Horita,et.al., ٢٠١٧, p.١٧)، وتُعتبر أسرع وسيلة تُساعد في رصد أي إنحراف محاسبي أو إداري يحدث في البيانات وأيضاً الكشف عن الأخطاء سواء كانت متعمدة أو غير متعمدة التي تحدث عند إدخال البيانات، وبالتالي يستطيع المحاسب أن يكتشف الأخطاء والإنحرافات المحاسبية بسهولة إذا تم كسر نمط البيانات (Umesh& Kagan, ٢٠١٥, p.٤٢)، ومن الفوائد التي توفرها تقنية (Visuailzation) للمحاسبين أنها تمكنهم من فهم وتحليل البيانات المتنوعة ومتعددة المصادر بسهولة، كما أن تلك التقنية لا تتطلب فهم الخوارزميات المستخدمة سواء كانت الرياضية أو الإحصائية المُعقدة (Alawadhi, ٢٠١٥, p.٥٥).

أي أن هذه التقنية تُمكن متخذي القرارات ومحليي البيانات من استخلاص وفهم النتائج في ظل بيئة البيانات الضخمة المُعقدة، حيث تم إثبات أن تقنية التمثيل المرئي للبيانات لها قيمة كبيرة في فهم وتحليل البيانات؛ وذلك خاصّة عندما يكون أهداف الاستكشاف غير معروفة بالنسبة للبيانات، كما يمكن اعتبارها من أفضل تقنيات العرض المستخدمة في توصيل المعلومات لكافة المستخدمين وفقاً لمتطلبات كل فئة على حدة، وتتطلب تقنية (Visuailzation) التكامل مع جهد الإنسان لتحليل وتحديد النتائج من عروضها التفاعلية (Interactive Displays) وتتضمن التقنيات الصوت (Audio)، الجداول (Tabular)، المصفوفات (Matrices)، الرسوم البيانية (Charts)، الإسقاط الهرمي (Hierarchical Projection)، التقنيات المعتمدة على الرسم البياني (Graph-Based Techniques)، العرض الديناميكي (Dynamic Presentation) (Zhang & Zhou, ٢٠٠٤, p.٥١٥)، وفيما

يلي مساهمة تقنية (Visualailzation) كأحدى تقنيات الذكاء الاصطناعي في تحسين جودة عرض المعلومات المحاسبية:

١. القابلية للفهم (Understandability)

حيث هناك صعوبة بالنسبة للمستخدمين في فهم ما تحتويه التقارير المالية، وأوصت البحوث السابقة عند الرغبة في نشر المعلومات لكافة المستفيدين ضرورة الاعتماد على طريقة الرسوم البيانية وأيضًا الاستفادة من حاسة البصر والرسوم المعبرة؛ وذلك للحد من المشكلات الناتجة عن توصيل المعلومات بلغة وأسلوب المحاسبين ورجال الأعمال، حيث أنه لا يفهمها إلا عدد قليل ومتخصص من متخذي القرارات الاقتصادية، ويمكن هنا الاستفادة من مزايا تقنية (Visualization) في عرض نتائج القوائم المالية بطريقة سهلة وقابلة للفهم وذلك لكي يتم توصيل كافة المعلومات للمستخدم النهائي في شكل صور أو رسوم بيانية أو غيره، حيث تقوم تلك التقنية باختصار عرض آلاف الأرقام في صورة واحدة، مما يؤدي إلى مساهمة تلك التقنية في تحسين إحدى خصائص جودة المعلومات المحاسبية المرتبطة بالمستخدم نفسه وليس المعلومة المحاسبية في حد ذاتها وهي القابلية للفهم (Chintalapati & Jyotsna, ٢٠١٣, p.٧٢٠).

٢. الملاءمة (Relevance)

تُركز تقنيات الذكاء الاصطناعي على بناء نماذج دقيقة لاستخدامها في القيام بالتنبؤات المستقبلية واستكشاف السلوك والتعرف على الأنماط المختلفة؛ مما يُساعد على تقدير القرارات الصحيحة وإتخاذها في الوقت المناسب، على سبيل المثال الاعتماد على بيانات الدخل السابق لكي يتم استخدامه لفهم سلوك الدخل الحالي وبالتالي التنبؤ بسلوك الدخل المستقبلي، وأيضًا التنبؤ بالتدفقات النقدية وسعر السهم وغيرها من التطبيقات المالية، وبالتالي فإن الاعتماد على استخدام تقنيات الذكاء الاصطناعي في القيام بالتنبؤات المالية يُحسن من خاصية الملاءمة وكذلك القيمة التنبؤية والتغذية المرتدة للمعلومات (Zhang & Zhou, ٢٠٠٤, p.٥١٣).

٣. القابلية للمقارنة (Comparability)

يمكن تحسين خاصية القابلية للمقارنة من خلال الاعتماد على استخدام تقنيات الذكاء الاصطناعي؛ حيث أنه عند بناء النموذج الذي يُستخدم في تحليل البيانات المالية فإنه يعتمد على متغيرات معينة، تُستخدم في بناء النموذج وأيضاً يحتفظ بتلك البيانات على المدى البعيد حتى في ظل بيئة البيانات الضخمة، وبالتالي يستطيع هذا النموذج أن يقوم بمقارنة بيانات الشركة الواحدة عبر السنوات المختلفة أو مقارنة بياناتها مع بيانات شركة أخرى حتى وإن اختلفت المعايير المحاسبية وبذلك فإنه يحقق الإتساق (Consistency) (Nagano & Moraes, ٢٠١٣, p. ٢٨٣).

٧/٦ دور تقنية آلة متجه الدعم (SVM) في تحسين دقة التنبؤات المالية

تم دراسة قدرة المعلومات المحاسبية على التنبؤ باتجاه حركة الأرباح في الدراسات المحاسبية باستخدام العديد من الأساليب، وتم استخدام تقنيات النمذجة الإحصائية الخطية التقليدية (The traditional linear statistical modeling techniques) مثل تحليل الانحدار اللوجستي المتعدد (stepwise multivariate logistic regression analysis) في معظم الحالات، وعندما لا يكون التقريب الخطي (linear approximation) صحيحاً، فإن دقة النماذج الإحصائية التقليدية تنخفض إلى حد كبير (Etemadi, et.al., ٢٠١٥, p. ٥٨)، وكانت تلك هي نقطة البداية لاستخدام النماذج غير الخطية للتنبؤ بالأرباح المحاسبية عندما تبين للبحوث أنه قد تكون هناك علاقة غير خطية بين بعض المتغيرات المحاسبية والأرباح المستقبلية، وتتميز بيانات السلاسل الزمنية المالية (Financial time series data) بعدم الثبات (non-stationary) والفوضى (chaos) وإرتفاع درجة عدم اليقين (high degree of uncertainty)، ولذلك فإن استخدام تقنية آلة متجه الدعم (SVM) في ظل الاعتماد على خوارزميات تعلم الآلة (Machine Learning's Algorithms) لتحليل العلاقة بين البيانات المالية والأرباح في المستقبل، يكتسب أهمية واسعة النطاق بسبب قدرة هذه التقنية على تحليل ورسم الخرائط للبيانات غير الخطية (Chandwani & Saluja, ٢٠١٤, p. ١٢).

تعتمد تقنية (SVM) على تقسيم البيانات إلى ثلاث مجموعات فرعية، مجموعة واحدة للتدريب (Training)، ومجموعة واحدة للإختبار (Testing)، ومجموعة أخرى للتحقق من الصحة (Validating)، حيث يتم استخدام مجموعة التدريب لتطوير نموذج التنبؤ الخاص بتقنية (SVM)، ويتم استخدام مجموعة الإختبار لتقييم قدرة التنبؤ الخاصة بتقنية (SVM)، وعادةً ما تكون مجموعة التحقق من الصحة جزءًا من مجموعة الإختبار وتستخدم لتجنب مشكلة التجهيز الزائد (Over-Fitting Problem) أو لتحديد نقطة التوقف لعملية التدريب، كما لا يوجد نهج معين في تقسيم البيانات بأحجام مناسبة إلى مجموعة تدريب ومجموعة إختبار، ومع ذلك هناك العديد من العوامل التي يجب أخذها في الإعتبار عند إتخاذ القرار، وأبرزها خصائص المشكلة، ونوع البيانات، وحجم البيانات المتاحة، وتم إقتراح أنه يجب أن تحتوي مجموعة التدريب على ٧٠٪ من البيانات ومجموعة التحقق ٢٠٪ والإختبارات ١٠٪ لنماذج التنبؤ غير الخطية (Shadi, ٢٠١٥, p. ٢٩).

نتيجة لما سبق؛ تُستخدم تقنية (SVM) بكثرة في عمليات تصنيف البيانات والتنبؤ، وفي السابق كان هناك الكثير من الدراسات حول استخدام تقنية الشبكات العصبية الاصطناعية (ANN) في هذه المجالات، خاصةً في مجال التنبؤ، ومع ذلك في سوق الأوراق المالية نظرًا لأن البيانات غالبًا ما تحتوي على ضوضاء (Noise) وأبعاد معقدة، ويقصد بذلك البيانات التي تحتوي على كم كبير من المعلومات الزائدة التي لا تحتوي على معنى ويطلق عليها اسم الضوضاء في التحليل الإحصائي، وبالتالي فإن تواجد مثل هذه البيانات الضوضائية الخالية من المعنى في نماذج التنبؤ قد يؤدي إلى توقعات خاطئة، مما يجعل من الضروري تصفية بيانات المدخلات منها، وتُعد مهمة التصنيف من أهم مزايا تقنية (SVM)، حيث تم استخدام تقنية (SVM) بنجاح في مجال التنبؤ، ويمكن لتقنية (SVM) معالجة البيانات ذات الأبعاد الأعلى بشكل أفضل حتى مع وجود قدر منخفض نسبيًا من مجموعة التدريب، بالإضافة إلى ذلك يمكن أن تقدم قدرة جيدة على التعميم للنموذج المعقد (Complex Model) (Shu & Rung, ٢٠٠٧, p. ٦٣).

بذلك يتمثل الاختلاف الأكبر بين تقنية (SVM) والطرق التقليدية الأخرى في أن تقنية (SVM) لا تهدف إلى إعداد نموذج للتنبؤ يقوم بأدنى حد من الأخطاء كما هو الحال مع التقنيات الأخرى، ولكنها تهدف إلى بناء نماذج موثوقة (Reliable models)، ويسمى هذا المبدأ بتقليل المخاطر الهيكلية (Structural Risk Minimization)، حيث تهدف إلى بناء نموذج هيكلي لا يحتوي على مخاطر كبيرة تؤدي إلى إرتكاب أخطاء في البيانات المستقبلية (Rosillo & Fuente, 2014, p. 492).

٨. الدراسة التطبيقية

تسعى الباحثة من خلال الدراسة التطبيقية إلى تقديم نموذج مقترح لزيادة دقة التنبؤات المالية من خلال تطبيق تقنيات الذكاء الاصطناعي عن طريق أسلوب (Machine Learning) وباستخدام تقنية آلة متجه الدعم (SVM)، باعتبار أن توفير معلومات عن التدفقات النقدية المستقبلية هي الهدف الرئيسي للتقارير المالية، حيث يرتبط مفهوم جودة التقارير المالية بأهدافها، وبالتالي فإن تحقيق أهم أهدافها يساهم في تحسين جودتها.

٨/١ مجتمع وعينة الدراسة

يشمل مجتمع وعينة الدراسة التطبيقية الشركات المقيدة في البورصة المصرية ضمن مؤشر سوق المال المصري (EGX١٠٠)، حيث تم اختيار عينة من مجتمع الدراسة وفقاً للمحددات التالية؛ وهي أن تكون التقارير المالية للشركات كاملة بحيث توفر جميع البيانات اللازمة لحساب متغيرات الدراسة خلال الفترة الزمنية (٢٠١٧-٢٠٢١)، وألا تكون الشركة قد تعرضت للشطب أو الاندماج أو التوقف خلال فترة الدراسة، كما تم إستبعاد البنوك وشركات التأمين وصناديق الإستثمار لما لها من طبيعة خاصة ومختلفة عن باقي الشركات في القطاعات المختلفة، وقد تم إختيار عدد (٧٠) شركة من (١٢) قطاع، ويوضح الجدول التالي الشركات محل الدراسة التطبيقية.

جدول رقم (١)

حجم عينة الدراسة وفقاً لطبيعة القطاع الاقتصادي

م	إسم القطاع	عدد الشركات
١	قطاع موارد أساسية	٨
٢	قطاع رعاية صحية وأدوية	٦
٣	قطاع خدمات ومنتجات صناعية وسيارات	٥
٤	قطاع عقارات	٩
٥	قطاع اتصالات وإعلام وتكنولوجيا المعلومات	٤
٦	قطاع أغذية ومشروبات وتبغ	١٢
٧	قطاع طاقة وخدمات مساندة	٣
٨	قطاع تجارة وموزعون	٣
٩	قطاع مقاولات وإنشاءات هندسية	٧
١٠	قطاع منسوجات وسلع معمرة	٤
١١	قطاع مواد البناء	٦
١٢	قطاع ورق ومواد تعبئة وتغليف	٣
	الإجمالي	٧٠

المصدر: إعداد الباحثة اعتماداً على موقع البورصة المصرية

تعتبر الشركات محل الدراسة التطبيقية هي الأكثر نشاطاً من حيث القيمة في البورصة المصرية لمدة خمسة سنوات متتالية من عام ٢٠١٧ حتى عام ٢٠٢١، كما تم اختيارها بشرط توافر خمسة قوائم مالية متتالية على الأقل، والتي توافرت عنها كافة المعلومات المتعلقة بمتغيرات الدراسة خلال الفترة الزمنية محل البحث، وقد تم جمع بيانات الدراسة من القوائم المالية المنشورة وكذلك الإيضاحات المتممة لها للشركات عينة الدراسة من موقع معلومات مباشر مصر بالإضافة إلى مواقع الشركات الممثلة لعينة الدراسة على شبكة الإنترنت.

٨/٢ منهج الدراسة التطبيقية

تم الاعتماد على ستة متغيرات للتنبؤ بالتدفقات النقدية من الأنشطة التشغيلية المستقبلية (Cash Flow From Operations) باعتبارها الأكثر تأثيراً في التنبؤ بالتدفقات النقدية، وذلك وفقاً للدراسات السابقة مثل

دراسة (Daniel A. Cohen, ٢٠٠٣) ودراسة (Barth, et., al, ٢٠٠١) ودراسة (Lorek & Willinger, ٢٠١٠)، والمتغيرات هي؛
جدول رقم (٢)

متغيرات ورموز الدراسة التطبيقية

الرمز	المتغير
Current CFO	التدفقات النقدية من الأنشطة التشغيلية الحالية
ΔAR	التغير في حسابات القبض
ΔINV	التغير في المخزون
ΔAP	التغير في حسابات الدفع
DEPR	الإهلاك
OTHER	أخرى

وتم الحصول على قيم المتغير أخرى (OTHER) من خلال المعادلة التالية:

$$\text{Other} = \text{EARN} - (\text{CFO} + \Delta AR + \Delta INV - \Delta AP - \text{DEPR})$$


كما تم الحصول على قيم المتغير (EARN) من قائمة الدخل والمقصود به هو صافي الدخل بعد الضرائب، وتم تجميع البيانات في مجموعة بيانات (Datasets) وبالتالي لم تكن هناك قيم مفقودة أو مكررة، أي أنه تم تجميع البيانات بشكل يراعي جودتها، كما تم عمل (Normalization) لجميع قيم المتغيرات كل على حدة وذلك نظرًا للاختلاف بين حجم الشركات محل الدراسة التطبيقية، وهي طريقة لإعادة قياس البيانات والسمات باستخدام تدريب معين بحيث يتم حصرها في مدى محدد مثلاً من (صفر إلى ١) ويتم حساب القيم المناظرة لهذه القيم باعتبارها حدود عظمى ودنيا من كل القيم المتوفرة في قاعدة البيانات.

٨/٣ التنبؤ بالتدفقات النقدية باستخدام تقنية آلة متجه الدعم (SVM) لاختبار صحة فرض الدراسة: لاختبار صحة فرض الدراسة التطبيقية تم استخدام تقنية آلة متجه الدعم (SVM) للتنبؤ بالتدفقات النقدية من الأنشطة التشغيلية للشركات محل الدراسة التطبيقية، وفيما يلي خطوات تطبيق تقنية (SVM) في التنبؤ بالتدفقات النقدية:

١. تشغيل برنامج (MATLAB): ويتم ذلك من خلال الضغط على قائمة (Start) واختيار (MATLAB R2022b)، وتظهر الشاشة الرئيسية للبرنامج كما هو موضح بالشكل رقم (١) التالي:

شكل رقم (١)

الشاشة الرئيسية لبرنامج (MATLAB R2022b)




٢. إدخال متغيرات الدراسة في برنامج (MATLAB): حيث تم إعداد (Data sets) للشركات محل الدراسة التطبيقية في ملف (Excel)، وتم تقسيمهم في ثلاثة أجزاء، وذلك على النحو التالي:

- الجزء الأول (Data All): عبارة عن جميع بيانات المتغيرات المستقلة الستة بالإضافة إلى بيانات المتغير التابع وهو التدفقات النقدية من الأنشطة التشغيلية، ويتكون من (٢٨٠) صف و (٧) أعمدة.

- الجزء الثاني(Data Inputs): عبارة عن بيانات المتغيرات المستقلة الستة فقط، ويتكون من (٢٨٠) صف و(٦) أعمدة.
- الجزء الثالث(Data Target): عبارة عن بيانات المتغير التابع فقط، ويتكون من (٢٨٠) صف وعمود واحد فقط.
- ولإدخال(Data sets) في برنامج (MATLAB)، تم ذلك من خلال كتابة الأوامر التالية في (Command window)، كما هو موضح بالشكل رقم (٢):
- ◆ الأمر(DataAll=[];): وذلك لإدخال قيم المتغيرات المستقلة والمتغير التابع.
- ◆ الأمر(DataInputs=[];): وذلك لإدخال قيم المتغيرات المستقلة فقط.
- ◆ الأمر(DataTarget=[];): وذلك لإدخال قيم المتغير التابع فقط وهو التدفقات النقدية من الأنشطة التشغيلية.

شكل رقم (٢)

كيفية كتابة الأوامر في(Command Window)




ويتم بعدها فتح ثلاثة أوراق عمل داخل قائمة (Workspace) بنفس الأسماء وفقاً للأوامر التي تم كتابتها، ثم تم فتح ملف الـ (Excel) الذي يحتوي على الـ (Data sets)، وتم نسخ محتويات ورقة العمل الخاصة بـ (Data All) عن طريق الضغط على (Ctrl+c) ثم تم فتح ورقة العمل الخاصة أيضاً بالـ (Data All) في قائمة (Workspace) ببرنامج الـ (MATLAB) وتم الضغط على (Ctrl+v)، وذلك لإدخال قيم المتغيرات المستقلة وقيم المتغير التابع في البرنامج، ثم تم تكرار هذه الخطوة لتفريغ وإدخال محتويات كل من ورقة العمل الخاصة بـ (Data Inputs) وهي المتغيرات المستقلة، وورقة العمل الخاصة بـ (Data Target) وهي المتغير التابع.

٣. إعداد نموذج التنبؤ لتدريب البيانات باستخدام (Machine Learning):

تم ذلك عن طريق إختيار قائمة (APPS) في الشاشة الرئيسية لبرنامج الـ (MATLAB)، ثم تم إختيار (Regression Learner)، والذي يُستخدم لتدريب نماذج الإنحدار المستخدمة لعمل التنبؤات بإستخدام تعلّم الآلة الخاضع للإشراف (Supervised Machine Learning)، ويظهر الشكل رقم (٣) التالي:

شكل رقم (٣) الشاشة الخاصة بـ (Regression Learner)



ويتضح من الشكل السابق عند الضغط على (New Session) لإدخال الـ Data sets في النموذج، وإختيار ملف (Data All) في خانة (Data Set Variable)، ومن قائمة (Validation) تم إختيار (Holdout Validation) وذلك للتحقق من البيانات، وتم تحديد نسبة مئوية من البيانات لإستخدامها كمجموعة تحقق وهي (٣٠٪)، ثم يقوم التطبيق بتدريب النموذج على مجموعة التدريب وتقييم أدائه من خلال مجموعة التحقق، كما يعتمد النموذج المستخدم للتحقق على جزء فقط من البيانات، لذا فإن (Holdout Validation) مناسب فقط لمجموعات البيانات الكبيرة (Large Data Sets)، ثم يتم تدريب النموذج النهائي بإستخدام مجموعة

قياس أثر استخدام نموذج آلة متجه الدعم Support Vector Machine على دقة التنبؤات المالية ...

د/ رشأ مصطفى محمد الحميد الجوهري

البيانات الكاملة (Full Data Set)، ثم تم الضغط على (Start Session) وذلك لتدريب النموذج، كما هو موضح بالشكل رقم (٤).

شكل رقم (٤)

خطوات تدريب نموذج التنبؤ باستخدام (Machine Learning)

Data set

Data Set Variable: DataAll (280x7 double)

☒ Use columns as variables
☐ Use rows as variables

Response

☒ From data set variable
☐ From workspace

column_7 (double) 0 .. 0.8

Predictors

	Name	Type	Range
☒	column_1	double	0 .. 0.8
☒	column_2	double	0 .. 0.8
☒	column_3	double	0 .. 0.8
☒	column_4	double	0 .. 0.8

Add All Remove All Refresh

[How to prepare data](#)

Validation

Validation Scheme: Holdout Validation

Recommended for large data sets. The app selects a percentage of the data to use as a validation set.

Percent held out: 30

[Read about validation](#)

Test

☒ Set aside a test data set

Percent set aside: 10

Use a test set to evaluate model performance after tuning and training models. To import a separate test set instead of partitioning the current data set, use the Test Data button after starting an app session.

[Read about test data](#)

Start Session Cancel

٤. إستدعاء تقنية (Support Vector Machine) لتدريب نموذج التنبؤ:

تم فتح قائمة (VIEW) ثم تم اختيار (All SVMs) من خانة (Support Vector Machine)، حيث يوجد (٦) أنواع من تقنية (SVM) التي تُستخدم في التنبؤ، وهي

- (SVM Linear).
- (SVM Quadratic).
- (SVM Cubic).

• (SVM Fine Gaussian).


• (SVM Medium Gaussian).

• (SVM Coarse Gaussian).

ثم تم الضغط على (Train) وذلك للبدء في تدريب نموذج التنبؤ باستخدام تقنية (SVM)، وبعد الإنتهاء من عملية التدريب يظهر الشكل رقم (٥)، وذلك بعد حساب كل من (RMSE&MAE) لكل أنواع تقنية (SVM)، وذلك حتى يتم المقارنة بين نتائج التنبؤ، ومعرفة أيًا منهما أكثر توافقًا مع طبيعة البيانات التي تم إدخالها.

شكل رقم (٥)

شاشة البرنامج بعد الإنتهاء من عملية تدريب نموذج التنبؤ




٥. تصدير نتائج نموذج التنبؤ (Export of prediction model results):

حيث تم تصدير نتائج التنبؤ الخاصة بجميع أنواع تقنية (SVM)، وذلك من خلال الضغط على النوع الأول من تقنية SVM وهو (SVM Linear) في قائمة (Modles) ثم من خلال اختيار (Generate Function) من قائمة (EXPORT) تم تغيير مسمى نموذج التنبؤ الخاص بهذا النوع من (Train Regression Model) إلى (SVM Linear)، ثم تم الضغط على (Ctrl+s) وذلك لحفظ التغييرات، ثم تم الحصول على النتائج من خلال اختيار (Export Model)، ثم ظهر مربع الحوار الذي يحتوي على (EXPORT the current trained model to a workspace) ثم تم كتابة إسم النموذج الذي تم تدريبه وهو (SVM Linear) وتم الضغط على (Ok)، كما هو موضح من خلال الشكل رقم (٦)، وتم تكرار نفس الخطوات لباقي الـ (Modles) الخاصة بتقنية (SVM)، وذلك حتى يتم تصدير نتائج نماذج التنبؤ الخاصة بتقنية (SVM) إلى قائمة (workspace).

شكل رقم (٦)

يوضح تصدير نتائج نموذج التنبؤ (SVM Linear)




٦. المقارنة بين النتائج الفعلية والنتائج المقدرة باستخدام تقنية (SVM):
للحصول على النتائج المقدرة باستخدام تقنية الـ (SVM) بعد الإنتهاء من عملية التنبؤ وذلك لجميع الـ (Modles) الخاصة بتقنية الـ (SVM)، تم كتابة الأوامر التالية في (Command window)

```
outputSVMLIN = SVMLinear,predictFcn(DataInputs);
outputSVMQUA = SVMQuadratic,predictFcn(DataInputs);
outputSVMCUB = SVMCubic,predictFcn(DataInputs);
outputSVMFG = SVMFineGaussian,predictFcn(DataInputs);
outputSVMMG = SVMMediumGaussian,predictFcn(DataInputs);
outputSVMCG = SVMCoarseGaussian,predictFcn(DataInputs);
```

وبعد كتابة تلك الأوامر، تم الحصول على النتائج المقدرة للمتغير التابع وهو التدفقات النقدية من الأنشطة التشغيلية في قائمة (workspace) وذلك لجميع نماذج التنبؤ الستة الخاصة بتقنية الـ (SVM)، كما هو موضح بالشكل رقم (٧).

شكل رقم (٧)

كيفية الحصول على نتائج تقنية الـ (SVM)



❖ وكانت نتائج مقاييس الحكم على دقة التنبؤ باستخدام تقنية (SVM) كما يلي:

جدول رقم (٣) نتائج التنبؤ باستخدام تقنية (SVM)

المعيار				تقنية SVM
(RMSE)	(MSE)	(MAE)	متوسط الدقة التنبؤية	
٠,٠٠٥٤	٠,٠٠٣٠	٠,٠١٧٣	٩٣,٤١	SVM Linear
٠,٤٢٣٣	٠,١٧٩٢	٠,٠١٠٢	٩١,٦١	SVM Quadratic
٧٤٩,٢	٥٦١٣٠,٦	٩,٣٦٤٢	٥,٧٢	SVM Cubic
٠,٩٦١٩	٠,٠٩٢٥	٠,٠١٩١	٩٤,١٥	SVM Fine Gaussian
٠,٩٦٠٦	٠,٩٢٢٩	٠,٠١٩٩	٩٣,٧٧	SVM Medium Gaussian
٠,٩٨٣٠	٠,٩٦٦٤	٠,٠٢٢٥	٩٣,١٤	SVM Coarse Gaussian

يتضح من الجدول رقم (٣) إرتفاع متوسط الدقة التنبؤية لجميع الـ (Modles) الخاصة بتقنية (SVM) ما عدا (SVM Cubic) حيث أنها لا تتوافق مع طبيعة مجموعات البيانات (Datasets) التي تم استخدامها في عملية التنبؤ وذلك لأنها تتطلب مجموعة بيانات كبيرة للتدريب (Big Data) أكبر من (Datasets) الخاصة بالدراسة وقد تم استبعاد نتائج هذا الـ (Model)، وبلغ متوسط الدقة التنبؤية بالتدفقات النقدية ما بين (٩١,٦١٪) كحد أدنى وذلك عند (SVM Quadratic)، وبين (٩٤,١٥٪) كحد أقصى عند (SVM Fine Gaussian)، حيث أنه كلما إرتفعت درجة الدقة التنبؤية كلما زادت قوة نموذج التنبؤ.

يتضح أيضاً إنخفاض قيمة المتوسط المطلق لخطأ التنبؤ (MAE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان المتوسط المطلق لخطأ التنبؤ بالتدفقات النقدية (MAE) ما بين (٠,٠١٠٢) كحد أدنى وذلك عند (SVM Quadratic)، وبين (٠,٠٢٢٥) كحد أقصى عند (SVM Coarse Gaussian)، حيث أنه كلما إنخفضت قيمة (MAE) كلما زادت قوة نموذج التنبؤ.

يتضح أيضاً إنخفاض قيمة متوسط الخطأ التربيعي (MSE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان متوسط الخطأ التربيعي (MSE) لخطأ التنبؤ بالتدفقات النقدية (MSE) ما بين (٠,٠٠٣٠) كحد أدنى وذلك عند (SVM Linear)، وبين (٠,٩٦٦٤) كحد أقصى عند (SVM Coarse Gaussian)، حيث أنه كلما إنخفضت قيمة (MSE) كلما زادت قوة نموذج التنبؤ.

كما يتضح أيضاً إنخفاض قيمة الجذر التربيعي لخطأ التنبؤ (RMSE) لجميع الـ (Modles) الخاصة بتقنية (SVM)، حيث كان الجذر التربيعي لخطأ التنبؤ بالتدفقات النقدية (RMSE) ما بين (٠,٠٠٥٤) كحد أدنى وذلك عند (SVM Linear)، وبين (٠,٩٨٣٠) كحد أقصى عند (SVM Coarse Gaussian)، حيث أنه كلما إنخفضت قيمة (RMSE) كلما زادت قوة نموذج التنبؤ.

مما سبق يتضح صحة فرض الدراسة وهو:

" يوجد تأثير معنوي بين تطبيق تقنية آلة متجه الدعم (SVM) وبين دقة التنبؤات المالية "

٩. نتائج الدراسة

- أن تقنية آلة متجه الدعم (SVM) من أهم تقنيات الذكاء الاصطناعي، وإنه يجب الاعتماد عليها بكثرة في المجال المحاسبي وخاصة عند إعداد التنبؤات المستقبلية، نتيجة لما تتمتع به قدرة فائقة في تصنيف بيانات المدخلات بدقة.
- تمثلت نتائج نموذج الدراسة في إرتفاع متوسط الدقة التنبؤية لنموذج (SVM)، وبلغ متوسط الدقة التنبؤية بالتدفقات النقدية ما بين (٩١,٦١٪) كحد أدنى وذلك عند (SVM Quadratic)، وبين (٩٤,١٥٪) كحد أقصى عند (SVM Fine Gaussian)، حيث أنه كلما إرتفعت درجة الدقة التنبؤية كلما زادت قوة نموذج التنبؤ.
- إنخفاض قيم (MAE) & (MSE) & (RMSE) لنموذج (SVM)، وكلما إنخفضت قيم تلك المقاييس دل ذلك على الكفاءة العالية لنموذج التنبؤ، مما يعني تحسن المقدرة التنبؤية لنماذج الذكاء الاصطناعي.

١٠. توصيات الدراسة

في ظل مشكلة الدراسة وأهدافها وفروضها والنتائج التي تم التوصل إليها، توصي الباحثة بما يلي:

- يجب العمل على وضع سياسات تنظيمية أكثر دقة باستخدام أساليب ذكية تستند إلى البيانات الضخمة المالية للتنبؤ بالمخاطر المالية في المستقبل.
- ضرورة الإستعانة بأنواع أخرى من الأنظمة الهجينة للتنبؤ بالتدفقات النقدية أو للتنبؤات المالية عموماً مثل النظام الذي يجمع بين الشبكات العصبية الاصطناعية والخوارزميات الجينية.

مراجع الدراسة

أولاً: المراجع العربية

١. إلهام محمد عبداللطيف، (٢٠١٦)، "تحسين جودة التقارير المالية باستخدام أسلوب التنقيب في البيانات- دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٢. زكي محمود عطوة يوسف، (٢٠١٣)، "دوافع وأثار الإفصاح الإختياري عن المعلومات المحاسبية مع دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٣. عصام عبدالمنعم إسماعيل، (٢٠١٧)، "مقدرة التدفقات النقدية التشغيلية والربح المحاسبي في التنبؤ بالتدفقات النقدية التشغيلية المستقبلية: دراسة تطبيقية على الشركات المقيدة بالبورصة المصرية"، مجلة كلية التجارة للبحوث العلمية، العدد الأول، المجلد الرابع والخمسون، كلية التجارة، جامعة الإسكندرية.
٤. محمد عبداللطيف زايد، (٢٠١٤)، "استخدام نماذج السلاسل الزمنية والشبكات العصبية للتنبؤ بأسعار الصرف في العراق"، المجلة المصرية للدراسات التجارية، كلية التجارة، جامعة المنصورة.
٥. مصطفى إبراهيم الفقي، (٢٠١٤)، "أثر المحتوى الإعلامي للقوائم المالية المستقبلية على قيمة المنشأة مع دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٦. منذر محمد، وآخرون (٢٠٢٢)، "أثر تفعيل تقنيات الذكاء الاصناعي على تعزيز أنشطة المراجعة الداخلية- دراسة ميدانية"، مجلة الإسكندرية للبحوث المحاسبية، العدد ٣، المجلد ٦، ص ١-٤٠.
٧. مها محي الدين عبدالقادر، (٢٠١٩)، "أثر التكامل بين نظم الخبرة والشبكات العصبية على تحسين كفاءة وفعالية المراجعة الخارجية-دراسة ميدانية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.

٨. هلال عبدالفتاح عفيفي، (٢٠١٤)، "العلاقة بين إدارة الأرباح وعدم تماثل المعلومات: هل هناك تأثير للإفصاح الاختياري؟: دراسة تحليلية إختبارية على الشركات المساهمة المصرية"، **مجلة البحوث التجارية**، جامعة الزقازيق، المجلد السادس والثلاثين، العدد الأول.

ثانيًا: المراجع الأجنبية

١. Alawadhi, A. (٢٠١٥). The application of data visualization in auditing. Doctoral dissertation, **Rutgers University-Graduate School-Newark**.
٢. Amos Baranes, Rimona Palas. (٢٠١٩). Earning Movement Prediction Using Machine Learning-Support Vector Machines (SVM). **Journal of Management Information and Decision Sciences**, ٢٢(٢).
٣. Ashis Pradhan. (٢٠١٢). Support vector machine – A Survey. **International Journal of Emerging Technology and Advanced Engineering**, ٢(٨).
٤. Ashis Pradhan. (٢٠١٢). Support vector machine – A Survey. **International Journal of Emerging Technology and Advanced Engineering**, ٢(٨).
٥. Barth, M., Cram, D., & Nelson, K. (٢٠٠١). Accruals and the Prediction of future cash flows. **The Accounting Review**, ٧٦(١), ٢٧-٥٨.
٦. Bilinski, P. (٢٠١٤). Do Analysts Disclose Cash Flow Forecasts with Earnings Estimates when Earnings Quality is Low?. **Journal of Business Finance and Accounting**, ٤١(٣).
٧. Chandwani, D., & Saluja, M.S. (٢٠١٤). Stock direction forecasting techniques: An empirical study combining machine learning system with market indicators in the Indian context, **International Journal of Computer Applications**, ٩٢(١١), ٨-١٧.
٨. Cohen, D. (٢٠٠٣). Quality of Financial Reporting Choice: Determinates and Economic Consequences. **Retrieved from www.ssrn.com**.
٩. Eduardo A. Gerlein, Martin McGinnity, Ammar Belatreche, Sonya Coleman. (٢٠١٦). Evaluating Machine Learning Classification for

- Financial Trading: An Empirical Approach, **Expert Systems with Applications**, ٥٤, ١٩٣-٢٠٧.
١٠. Etemadi, H., Ahmadpour, A., & Moshashaei, S.M. (٢٠١٥). Earnings per share forecast using extracted rules from trained neural network by genetic algorithm. **Computational Economics**, ٤٦(١), ٥٥-٦٣.
١١. Farshadfar, S., and Monem, R. (٢٠١٣). Further evidence on the usefulness of direct method cash-flow components for forecasting future cash-flows. **The International Journal of Accounting**, ٤٨, ١١١-١٢٣.
١٢. Financial Dictionary, Expected Future Cash Flows, (٢٠١٩), accessed on November ١٩, ١٠١٩, at: <https://financial-dictionary.com/Expected+future+cash+flows>. The free dictionary.
١٣. Fintechnews Singapore. (٢٠١٨). the Potential of AI in Banking. Retrieved from: <http://fintechnews.sg/٢٧١٦٠/ai/thepotential>.
١٤. Gepp, A., Linnenluecke, M. K., O'Neill, T., & Smith, T. (٢٠١٧). Big data techniques in auditing research and practice: Current trends and future opportunities. **Journal of Accounting Literature**, ٤٠, ١٠٢-١١٥.
١٥. Guang Yih Sheu.(٢٠١٩). Classification of the Priority of Auditing XBRL Instance Documents with Fuzzy Support Vector Machines Algorithm, **Journal of Autonomous Intelligence**, ٢(٢).
١٦. Horita, F. E., de Albuquerque, J. P., Marchezini, V., & Mendiondo, E. M. (٢٠١٧). Bridging the gap between decision-making and emerging big data sources: an application of a model-based framework to disaster management in Brazil. **Decision Support Systems**, ٩٧, ١٢-٢٢.
١٧. Hua-Cheng Yin.(٢٠١٤). A Novel Machine Learning Model for Risk Management. Proceedings of the First Asia Pacific **Conference on Global Business, Economics, Finance and Social Sciences** (AP١٤ Singapore Conference).

١٨. Isaac Kofi Nti*, Adebayo Felix Adekoya, and Benjamin Asubam Weyori.(٢٠٢٠). Efficient Stock-Market Prediction Using Ensemble Support Vector Machine, **published by De Gruyter**, ١٠, ١٥٣-١٦٣.
١٩. Liu Hongjiu .(٢٠١٠). An Application Of Support Vector Machine For Evaluating Credit Risk Of Bank. Proceedings Of The ٧th **International Conference On Innovation And Management** ,December ٤-٥, , Wuhan, China.
٢٠. Min-Yuan Cheng, Andreas F.V. Roy.(٢٠١١). Evolutionary fuzzy decision model for cash flow prediction using time-dependent support vector machines. **International Journal of Project Management** ٢٩ ,pp. ٥٦-٦٥.
٢١. Nagano, M., and Moraes, M.(٢٠١٣).Accounting Information Systems: An Intelligent Agent Approach. **African Journal of Business Management**, ٧(٤), ٢٧٣-٢٨٤.
٢٢. Paulius Danenas, Gintautas Garsva,(٢٠١١),” Svm And Xbrl Based Decision Support System For Credit Risk Evaluation”, publication at: <https://www.researchgate.net/publication/٢٦٦٥٥٧٣١٢>.
٢٣. Paulius Danenas, Gintautas Garsva,(٢٠١١),” Svm And Xbrl Based Decision Support System For Credit Risk Evaluation”, publication at: <https://www.researchgate.net/publication/٢٦٦٥٥٧٣١٢>.
٢٤. Rosillo, R.; Giner, J. & and De la Fuente, D. (٢٠١٤).Stock Market simulation using support vector machines. **Journal of Forecasting**, ٣٣(٦), ٤٨٨-٥٠٠.
٢٥. Saif, S., et al.(٢٠١٢).Finding rules for audit opinions prediction through data mining methods. **European online Journal of Natural and Social Sciences**, ١(٢), ٢٨-٣٦.
٢٦. Shadi M. Basal.(٢٠١٥). Comparison between Support Vector Machine & Box-Jenkins Methodology for Forecasting PALTEL’S Stock Market Prices. **Al-Azhar University-Gaza**.

٢٧. Shan Suthaharan.(٢٠١٦). **Machine Learning Models and Algorithms for Big Data.**
٢٨. Shuo Han, Rung-Ching Chen.(٢٠٠٧). Using SVM with Financial Statement Analysis for Prediction of Stocks. Retrieved from <http://scholarworks.lib.csusb.edu/ciima/vol٧/iss٤/٨>.
٢٩. Spacey, J. (٢٠١٦). Branches of Artificial Intelligence (AI). Simplifiable. Retrieved from <https://simplicable.com>.
٣٠. Trigo, A., Belfo, F., & Estébanez, R. P. (٢٠١٤). Accounting information systems: The challenge of the real-time reporting. **Procedia Technology**, ١٦, ١١٨-١٢٧.
٣١. Umesh, U. N., & Kagan, M. (٢٠١٥). Data Visualization in Marketing. **Journal of Marketing Management**, ٣(٢), ٣٩-٤٦.
٣٢. Vikramaditya Jakkula.(٢٠١٠). Tutorial on Support Vector Machine (SVM). School of EECS, **Washington State ,University**, Pullman.
٣٣. Yoo, C., & Pae, J.(٢٠١٣). Estimation and Prediction Tests of Cash Flow Forecast Accuracy. **Journal of Forecasting**, Vol.٣٢.
٣٤. Yunqian Ma & Guodong Guo.(٢٠١٤). **Support Vector Machines Applications**. Springer International Publishing Switzerland.
٣٥. Zhang ,D. & Zhou ,L .(٢٠٠٤).Discovering Golden Nuggets :Data mining in Financial Application. IEEE Transactions on systems MAN, AND cybernetics-partc:**applications and Reviews**, ٣٤(٤).