

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

د/ رشا مصطفى عبد الحميد الجوهرى

مدرس بقسم المحاسبة والمراجعة
كلية التجارة
جامعة عين شمس

المستخلص:

الهدف من الدراسة: يتمثل هدف الدراسة في قياس أثر تطبيق تقنية آلة متوجه الدعم (SVM) كإحدى تقنيات الذكاء الإصطناعي 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 متوجه الدعم (SVM) وذلك للتنبؤ بالتدفقات النقدية.

نتائج الدراسة: أسفرت نتائج الدراسة التطبيقية عن ما يلي:

- إنخفاض قيمة المتوسط المطلق لخطأ التنبؤ (MAE) لجميع الموديلات (Modles) الخاصة بـ (SVM)، حيث كان المتوسط المطلق لخطأ التنبؤ بالتدفقات النقدية (MAE) ما بين القيمة (0.0102) والقيمة (0.0225).
- إنخفاض قيمة متوسط الخطأ التربيعي (MSE) لجميع الموديلات (Modles) الخاصة بـ (SVM)، حيث كان متوسط الخطأ التربيعي (MSE) لخطأ التنبؤ بالتدفقات النقدية (MSE) ما بين القيمة (0.0030) والقيمة (0.9664).

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 (0.0054) والقيمة (0.9830).

الكلمات المفتاحية: تقنيات الذكاء الإصطناعي - آلة متوجه الدعم - التدفقات النقدية المستقبلية - التنبؤات المالية - الشبكات العصبية الإصطناعية - 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 R2022b) to apply the Support Vector Machine technique to predict cash flows.

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

1. The absolute average error (MAE) for all (SVM) models has decreased, where the absolute average error for cash flows prediction (MAE) ranged between (0.0102) and (0.0225).
2. The mean squared error (MSE) value for all (SVM) models has decreased, where the mean squared error for cash flows prediction (MSE) ranged between (0.0030) and (0.9664).
3. 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 (0.0054) and (0.9830).

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

المقدمة

التقارير المالية تشوّبها 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 علامة (إلهام محمد، ٢٠١٦، ص ٣٦)، ويعتمد التنبؤ بمقدار وتوقيت التدفقات النقدية المستقبلية ودرجة التأكيد المتعلقة بها على جودة المعلومات المحاسبية، فهي تمثل أحدى المدخلات الهامة التي يستخدمها المستثمرين في إتخاذ القرارات، ف حاجتهم 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 Financial، ٢٠٢٢، ص ٦ - عصام عبد المنعم، ٢٠١٧، ص ٣ - .Dictionary, 2019).

تعتبر التكنولوجيا الحديثة من أكثر العوامل تأثيراً على بيئة عمل شركات الأعمال، حيث سمحت بدخول إمكانات وقدرات جديدة وعديدة لتوثر في بيئة العمل، وبالتالي غيرت التكنولوجيا ثقافة الشركة إلى ثقافة معتمدة على التكنولوجيا ومن أدوات هذه التكنولوجيا تقنيات الذكاء الاصطناعي، وتقوم تقنيات الذكاء الاصطناعي بدوراً هاماً في خلق بيئة عمل أكثر قابلية للتنبؤ مما يؤدي إلى تقليل المخاطر المالية، وذلك من خلال الاعتماد على مجموعة من الخوارزميات المعقّدة التي تُمكّنها 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, 2018, p.160). كما أنه وفقاً لأهمية تطبيق تقنيات الذكاء الاصطناعي في المجال المحاسبي، إقترح الباحثة نموذج علمي يمكن تطبيقه عملياً 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) تطور كبير في مجال تكنولوجيا المعلومات (Information Techniques)، حيث يعتبر الذكاء الاصطناعي إحدى فروع علوم الحاسوب الآلي، ويتضمن تكوين أجهزة وبرمجيات ذكية تعمل وتفاعل مثل العنصر البشري، وهو تسمية شاع استخدامها للإشارة إلى مجال العلوم الذي يكون هدفه الرئيسي هو تمكين

برامج الحاسوب الآلي بالقدرة على تنفيذ بعض المهام مثل المنطق والتخطيط والتعلم والإدراك، كما يشمل الذكاء الاصطناعي مجموعة من القدرات المختلفة والمتباينة كابداع المعرفة والوعي الشخصي، كما يساعد 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 فلق حملة الأسماء والمجتمع بصفة عامة، والنتائج التي تعكس تضليل مستخدمي المعلومات المحاسبية والتاثير السلبي على كفاءة سوق الأوراق المالية، زاد الاهتمام بتطبيق تقنيات الذكاء الاصطناعي حيث ثبتت فعاليتها في إكتشاف الإحتيال والتلاعب بالقواعد المالية في العديد من الأبحاث السابقة، كما ثبتت دقة تلك التقنيات في التنبؤات المالية، ولتوفير معلومات محاسبية تتسم بالجودة والدقة قام الباحثة بإستخدام نموذج علمي يعتمد على تقنيات الذكاء الاصطناعي وهو عبارة عن تطبيق تقنية (Support Vector Machine) على بيانات التدفقات النقدية للشركات للتأكيد على دقة التنبؤات المالية عند إستخدام 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، وما سبق يمكن للباحثة صياغة مشكلة البحث في التساؤل التالي:

ما هو دور تقنية آلة متوجه 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,2011) بعنوان "SVM and XBRL Based Decision Support System for Credit Risk Evaluation" ، إلى تقديم

إطار لتقدير مخاطر الائتمان ونموذجًا لتنفيذها بطريقة شاملة ومستقلة عن طريق تطبيق تقنيات الذكاء الإصطناعي، ويدعم هذا الإطار تقنية آلة متوجه الدعم (SVM) المطبقة على نطاق واسع كأساس للتقدير الذكي، ولغة تقارير الأعمال الموسعة (XBRL) التي يتم تطويرها وتنفيذها ودعمها على نطاق واسع من قبل الحكومات والسلطات التنظيمية، وتناولت الدراسة تقنية (SVM) باعتبارها إحدى تقنيات الذكاء الإصطناعي التي تمثل حلًا فعالاً للعديد من المشاكل المختلفة المتعلقة بالتعرف على الأنماط، والتصنيف، والإنحدار، والتتبؤ، بما في ذلك التنبؤ المالي وتقدير 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 الإصطناعي الأخرى مثل الشبكات العصبية الإصطناعية والخوارزميات الجينية، كما أن النماذج الهجينية الذكية القائمة على تقنية (SVM) أثبتت أنها أكثر دقة وفعالية، حيث يجب اختيار نموذج تنبؤي يتيح تنفيذ اختبار واستخدام نماذج ذكية في مؤسسات الائتمان وذلك للتتبؤ بإفلاس الشركات.

Evaluating دراسة(2) Gerlein,et al.,2016,p.2)عنوان " machine learning classification for financial trading: An empirical approach ، تقدير مدى فعالية تطبيق تقنيات الذكاء الإصطناعي في المجال المحاسبي من خلال التعرف على مدى دقة نتائج التصنيف بعد تطبيق تعلم الآلة(Machine Learning) في التنبؤات المالية، وذكرت الدراسة أنه من المحمول أن تكون التنبؤات المالية هي أهم تطبيق من خلال استخدام(Machine Learning) للتقدير عن 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 كمتوجه للتدريب، وتوصلت الدراسة إلى أن النماذج الهجينية التي تتكون من نموذج إحصائي خطى وخوارزمية تعلم آلي غير خطية، أكثر فعالية في التنبؤات المالية المستقبلية .

كما هدفت دراسة (Guang Yih Sheu, 2019) بعنوان "Classification of the Priority of Auditing XBRL Instance Documents with Fuzzy Support Vector Machines Algorithm" إلى التعرف على أثر استخدام إحدى تقييمات الذكاء الإصطناعي المتمثلة في آلية متوجه الدعم (SVM) المعتمدة على المنطق الضبابي في تصنیف التقارير المالية الرقمية التي تم إعدادها وفقاً لغة 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 آلية متوجه 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 آلية متوجه 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 ومرنة ودقة، مما إنعكس على سرعة ودقة اكتشاف الاحتيال المالي في التقارير المالية.

أما دراسة (Amos & Rimona, 2019) بعنوان "Earning Movement Prediction Using Machine Learning-Support Vector Machines" فقد هدفت إلى استخدام تقييمات الذكاء الإصطناعي في التنبؤ بحركة الأرباح من خلال تطبيق تقنية آلية متوجه 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 تحسن نماذج التنبؤ المالي عند استخدام تقنيات الذكاء الاصطناعي بشكل عام وتقنية (SVM) بشكل خاص.

كما هدفت دراسة (Isaac,et al.,2020) بعنوان "Efficient Stock-" إلى "Market Prediction Using Ensemble Support Vector Machine" باستخدام إحدى تقنيات الذكاء الاصطناعي وهي تقنية آلة متوجه 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 أيضاً إلى بيان أهمية استخدام تقنية (SVM) في التعامل مع الأنماط غير الخطية المعقّدة وذلك للتلغلب 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 (١,٨٠٪)، 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 متقدمة وهي مرحلة الذكاء الاصطناعي والتكنولوجيا المالية باستخدام النظام المالي الرقمي.

- يقدم (Machine Learning) منهجية توفر وسائل جديدة لاستكشاف الأنماط المُعقدة في البيانات، كما أن المحاسبين سوف يجدون أن نتائجهم ستكون أكثر دقة في تحليل البيانات لأغراض إتخاذ القرار بعد استخدام تقنيات الذكاء الإصطناعي.
- يجب على المحاسبين الاهتمام بشكل جيد بالتقنيات الحديثة في مجالات المعلومات والمعرفة ومحاولة فهمها والتكييف معها وإدماجها في نظام المعلومات المحاسبي، واعتبارها جزءاً منه وليس أداة مستقلة في أيدي مهندسي المعلومات الذين قد يستقلون بهذه النظم وينافسون بها محاسبى نظم المعلومات المحاسبية، وذلك لأن الذكاء الإصطناعي و المجالاته المختلفة يمثل هدفاً للمحاسب ينبعي التركيز عليه .
وفقاً لما سبق ترى الباحثة؛ أن الفجوة البحثية التي تتطلب المزيد من الدراسة تمثل في ضرورة استخدام تقنيات الذكاء الإصطناعي 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 متوجه الدعم(SVM)، مما يُساهم في تحسين دقة التنبؤات المالية.

٤. هدف الدراسة

تهدف الباحثة من خلال هذه الدراسة إلى بيان قياس أثر تطبيق تقنية آلة متوجه الدعم (SVM) كإحدى تقنيات الذكاء الإصطناعي 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 متوجه الدعم(SVM) عند التحقق من جودة التقارير المالية بدلالة دقة التنبؤات المالية، وإبراز ما ينبغي أن تكون عليه محتوى التقارير المالية، و تستمد الدراسة أهميتها العملية من خلال توجيه الاهتمام نحو دور تقنية آلة متوجه الدعم(SVM) واستخداماتها المحاسبية، وكيفية تحقيق الاستفادة لكل من المستثمرين في اختيار الشركة التي يرغب الاستثمار فيها،

والبنوك لاتخاذ 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 متوجه الدعم (SVM) وبين دقة التنبؤات المالية ".

٧. التأصيل النظري للدراسة

٧/١ مفهوم الذكاء الاصطناعي

عرف (Spacey,J.,2016,p.18) الذكاء الاصطناعي بأنه "أحد التكنولوجيات التي صُمِّمت لكي تتعلم وتتطور من نفسها وعادةً تُستخدم لحل المشكلات أو الأمور المعقّدة التي يصعب حلها بالطرق التقليدية"، حيث يُحاول الذكاء الاصطناعي إنشاء تنفيذ بعض المهام تكرار أو تقليد الذكاء البشري.

بينما عرف(Dan.W.Patterson,2017,p.48) الذكاء الاصطناعي على أنه "فرع من فروع علوم الحاسوب 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 تتفذ من قبل العنصر البشري.

كما يمكن تعريف الذكاء الاصطناعي بأنه تلك الوسائل التي تؤدي إلى حلول المشاكل المعقّدة اعتماداً على برامج الحاسوب الآلي، وذلك من خلال تطبيق مجموعة من العمليات التي تعمل على محاكاة تفكير العنصر البشري في الوصول إلى الاستنتاجات، بمعنى أنها تُحاول أن تُحاكي الذكاء البشري في التوصل إلى النتائج (محمد عبداللطيف، ٢٠١٤، ص ٥٠).

٧/٢ تقنيات الذكاء الإصطناعي

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

آلة متوجه الدعم (Support Vector Machine)

ظهرت تقنية آلة متوجه الدعم في عام ١٩٩٣، حيث قدمت من قبل الباحثين (Guyon & Boser)، وهي عبارة عن مجموعة أساليب مرتبطة بطرق ومناهج تعلم الآلة وستستخدم في تصنیف البيانات، وتنتمي إلى مجموعة المصنفات الخطية للبيانات والملفات الإحصائية، وهي أداة للتنبؤ وستستخدم نظرية التعلم كأداة لتحقيق أقصى قدر من الدقة التنبؤية مع تجنب الإفراط تقليديًا 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 التعلم الإحصائية (Liu hongjiu, 2010, p.4).

كما تُعد تقنية آلة متوجه الدعم من أشهر طرق التصنيف المبني على أنظمة الحاسب الآلي، والتي تعتمد على إيجاد منحنى أو مستوى معين يفصل العينات المدخلة عن بعضها البعض، وتميز بقدرتها على تصنیف المسائل ذات الفئات الثانية، حيث تقوم هذه الخوارزمية بحساب سطح أو مجموعة سطح في بُعد آخر يختلف طوله عن طول متوجه الخصائص (Vikramaditya, 2010, p.64)، 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 التعلم لجزء البيانات الغير خاص بمرحلة التكرار والتعلم، وبالرغم مما تبدو عليه المشكلة من سهولة، إلا أنه في أغلب الأحيان لا يمكن الفصل بين الخصائص خطياً، وحينها نجأ لتحويل محاور متجهات الخصائص لبعد أعلى بحيث يتم الفصل بينهم بسطح، ويراعي في هذا المنظور العباء الحسابي فيتم حساب الضرب القياسي للمتجهات بواسطة دالة المصفوفة (Hua-Cheng,2014,p.10).

٧/٢/١١ مفهوم تقنية آلة متوجه الدعم (SVM)

هي إحدى تقنيات الذكاء الإصطناعي التي يمكن أن تساعد في حل مشاكل تصنیف 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 متوجه 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 الخطى أو لا، وهنا تكمن مصدر قوتها (Shan Suthaharan,2016,p.207).

٧/٢/١٢ كيفية عمل تقنية آلة متوجه الدعم (SVM)

تقنية آلة متوجه الدعم عبارة عن منهج تدريب ثنائي، تُستخدم لتصنيف بيانات التدريب (Training Data) إلى صفين (موجب، سالب) مثلاً، حيث يتم تدريبها بالاعتماد على مبدأ تقليل الخطأ إلى الحد الأدنى وذلك بين القيم المتوقعة والقيم الفعلية، كما أن ذلك سيقل إحتمال حدوث الأخطاء عند تطبيق الخوارزمية على النماذج الجديدة، وعند استخدام تقنية آلة متوجه الدعم في عمليات التصنيف، تستطيع تلك التقنية إيجاد أفضل سطح فاصل وذلك حتى يتم فصل الأمثلة الموجبة عن الأمثلة السالبة، حيث يتم اختيار 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 الإختبار صحيحة، وأثبتت تلك التقنية نجاحها في التغلب على الكثير من المشكلات مثل معالجة الصور(Image Processing)، تصنیف النصوص (Text Classification)، وتحليل الأسواق المالية(Saif,S.,et al.,2012,p.32).

حيث يكون السطح الفاصل مُعرف بمجموعة من النقاط نتاج ضربهم القياسي مع متجه في الإحداثيات الجديدة (ذات البُعد الأعلى) والتي تكون ثابتة، إن عملية تصنیف البيانات تُعد من أكثر عمليات المحاكاة شيوعاً، بوجود نقاط البيانات التي تتميز بعدة خصائص، ويكون الهدف هو تصنیف نقطة جديدة وتحديد إلى أي من الخصائص تتنمي، حيث ينظر لنقطة البيان على أنها متجه له عدد من الخصائص، وإذا تم الفصل بسطح بُعده ينقص عنه بوحد يكُون التصنیف خطياً، ويكون غير خطياً ما عدا ذلك، وفي حالة توافر أكثر من فاصل خطى يتم اختيار الفاصل الذي يضمن هامش أوسع بين أقرب نقطتين من الخصائص المختلفة لبعضها، وهو ما يسمى بالمستوى ذو الهمش الأكبر(Yunqian Ma,2014,p.33).

تم إستخدام أسلوب تعلم الآلة المستند إلى تقنية آلة متوجه الدعم في الغالب للتعرف على الأنماط في العديد من المجالات، حيث أثبتت هذه التقنية كفاءتها من أي تقنية أخرى للتعرف على الأنماط الأكثر إستخداماً، مثل الشبكات العصبية الإصطناعية(ANN)، وتصنيف(Basiean classification)، والأداء الذي تقدمه تقنية آلة متوجه الدعم أعلى نسبياً إذا كان يحتوي على مجموعة بيانات كبيرة (large dataset) لتعليم المشكلة، وتتمثل القوة الرئيسية لتقنية آلة متوجه 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 التصنیف والخطأ، وهناك الكثير من النطاق المستقبلي لهذه التقنية في كافة المجالات لتحسين دقة التنبؤ.(Ashis Pradhan,2012,p.4).

٧/٣ استخدامات تقنية آلة متوجه الدعم(SVM)

تُستخدم هذه التقنية في تطبيقات تصنيف وتجزئة الصور (Image Classification and Segmentation)، وتصنيف النصوص (Text Classification)، وتصنيف البريد الإلكتروني فيما إذا كان مزيف(Spam Email Assignment)، أو حقيقى(Ham Email)، كذلك تحليل الآراء(Sentiment Analysis)، وغيرها، كما تُستخدم في التطبيقات البيولوجية وغيرها من العلوم (Paulius& Gintautas,2011,p.3).

تم استخدام أسلوب تعلم الآلة المستند إلى تقنية آلة متوجه 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 الإصطناعية(ANN)، وتصنيف(Basiean classification)، والأداء الذي تقدمه تقنية آلة متوجه الدعم أعلى نسبياً إذا كان يحتوي على مجموعة بيانات كبيرة(large dataset) لعميم المشكلة، وتمثل القوة الرئيسية لتقنية آلة متوجه 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,2012,p.4).

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 كلًا من المركز المالي ونتائج الأعمال والتغيرات النقدية المتوقعة للشركات ، وذلك وفقًا لافتراضات إدارة تلك الشركات للأحداث المتوقع حدوثها، وتعتبر التنبؤات المالية أهم مشكلة تواجهها الشركة عند إعداد القوائم المالية المستقبلية؛ وذلك لأن عدم مصداقية ودقة تلك التنبؤات، يؤدي إلى عدم ثقة كافة الأطراف المستقبلية من المعلومات المستقبلية المنشورة؛ وبالتالي لا يوجد منفعة من

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

٧/٤ 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 الإمكانيات التي تحقق الدقة اللازمة في إعداد التنبؤات المالية.
٣. أن إفصاح الشركات عن التنبؤات المالية للمستثمرين وعدم تمكناها من تحقيقها؛ قد يُسفر عنه اهتزاز هذه الشركات وتعرض إدارتها للمساءلة القانونية وبالتالي التأثير العكسي على إدارتها.
٤. تتسم التنبؤات المالية بالحساسية الشديدة للتغيرات 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 التأكيد ونادرًا ما تتحقق.

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

١. أن إفصاح الشركات عن التنبؤات المالية يعتبر بمثابة محتوى إضافي يتم تقديمها لكافة الأطراف المستفيدة، كما يعتبر 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 بكلفة الأنشطة الداخلية للمنظمة، كما أن الإفصاح عنها يمكن المحللين الماليين من إعداد تنبؤات مالية أفضل وبالتالي عدم اللجوء إلى التخمين عند إتخاذ القرارات الاستثمارية.
٣. عند قيام إدارة الشركات بالإفصاح عن التنبؤات المالية سيجعلها متاحة إلى جميع الأطراف المستفيدة سواء كانت الداخلية أو الخارجية، وليس 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 تمكّنهم 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) (Foundation, 2010a) ، حيث يجب توفير المعلومات الازمة لمساعدة مستخدمي القوائم المالية عند التنبؤ بالتدفقات النقدية المستقبلية باعتباره واحداً من الأهداف الرئيسية للتقارير المالية (Farshadfar & Monem, 2013, p.111).

كما أشارت قائمة مفاهيم المحاسبة المالية رقم (١) عام ١٩٧٨ فقرة (٣٧) إلى أن الهدف الرئيسي من نشر التقارير المالية هو توفير معلومات تساعد كافة الأطراف المستفيدة مثل المستثمرين والدائنين وغيرهم؛ لكي يتم استخدامها في تقييم حجم وتوقيت وظروف عدم التأكيد المحيطة بالتدفقات النقدية، وبالإضافة إلى ذلك تم التأكيد في فقرة رقم (٤) على أن معلومات الأرباح لها قدرة تنبؤية أفضل من استخدام التدفقات النقدية الحالية عند التنبؤ بالتدفقات النقدية المستقبلية (Barth,et.al., 2001,p.28& Cohen,2003,p.2).

تمكن 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 تشير إلى قدرة الشركة على دفع توزيعات الأرباح، كما أنها تمثل مقياساً للربحية والمركز المالي للشركة، ولهذا فإن التنبؤ بالتدفقات النقدية له فائدة وقيمة كبيرة لجميع مستخدمي القوائم المالية من مديرى الشركات والمستثمرين والمحللين الماليين أو غيرهم (Yoo& pae,2013,p.39).

وفي هذا الصدد، يهتم المستثمرين بالتدفقات النقدية؛ حيث أنها تمثل مدخلات لنمذج الاستثمار الخاصة بهم، والتي تُساعدهم في معرفة ما مدى قدرة الشركة على دفع توزيعات الأرباح، وتقييم 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 إتخاذهم لقرارات الاستثمار في الأسهم، ويهتم الدائنين بقرارات الملاعنة 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، وأيضاً يجب اختيار نوع وبنية النماذج بعناية لتوفير تنبؤ أكثر دقة (Li,et.al.,2015,p.24).

ومن زاوية أخرى، يلجأ العديد من المحللين الماليين إلى التنبؤ بالتدفقات النقدية إلى جانب التنبؤ بالأرباح، وذلك لأن التدفقات النقدية تساعد في تجنب الإستدلالات الخاطئة الناتجة عن سوء فهم الأرباح المحاسبية التي تم إعدادها وفقاً لأساس الإستحقاق المحاسبى، ويُشار إلى الأرباح في بعض الأحيان بصفى الدخل (Net Income) وهي مجموع كل من صافى الدخل النقدي وصفى الدخل الانتماني (الإستحقاقات)، ويعتمد صافى الدخل الانتماني على التعاملات الانتمانية مع عملاء الشركة والمتوقع تسويتها بشكل نقدي في فترة مالية لاحقة، ومن الممكن أن تقوم الشركة بتجاهل الإفصاح عن حجم الانتمان المُعطى للعملاء في معلومات التدفقات النقدية، مما قد يؤدي إلى تضليل المستثمرين عن مخاطر نقص النقدية في الشركة (Bilinski,2014,p.401).

حيث يعتمد غالبية الأطراف المستفيدة من التقارير المالية من عملاء وموردين وأيضاً 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 الالتزام بتطبيق المبادئ المحاسبية (GAAP)، وبالتالي فإنه كلما زادت دقة التنبؤ كلما

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

كما ثُمِكن قدرة مديرى المشروعات بشركات 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 تسم بخصائص فريدة، بوصفها بيانات سلاسل زمنية (Min-Yuan&Andreas,2011,p.56).

٧/٥ مساعدة تقنية التمثيل المرئي للبيانات في تحسين جودة عرض المعلومات الحاسوبية

أصبحت تقنيات الذكاء الإصطناعي تُقدم أفضل الطرق والممارسات، لكي تكون عملية تحليل التقارير المالية والإفصاح عنها تم بطريقة تلقائية وذلك على جميع مستويات الشركة، وتعتبر تقنية التمثيل المرئي للبيانات (Visualization) من أهم هذه التقنيات، حيث تهدف تلك التقنية إلى عرض البيانات كصورة مرئية وبالتالي يمكن من تمثيل كميات ضخمة من البيانات على شاشة واحدة، كما أنه يتم استخدام تقنية (Visuailzation) لإنشاء لوحتات تحكم متقدمة للقيام بتلك المهمة، وتهدف أيضاً 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 المعقّدة لكي يتم تحديد الهيكل والأنماط، والاتجاهات لتلك المجموعات، وأيضاً الشذوذ وال العلاقات بين البيانات (Trigo,et.al.,2014,p.120).

وفي هذا الصدد؛ يمكن استخدام أدوات تقنية (Visuailzation) أو لوحتات 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، وتساعد في عرض التغيرات والقيام بتعديل البيانات المعروضة وفقاً لها؛ الأمر الذي

يؤدي إلى مُساعدة 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 إتخاذ القرارات الفورية والرشيدة بكفاءة وفعالية (Gepp,et.al., 2017, p.107).

كما تزداد أهمية تقنية (Visuailzation) في بيئة البيانات الضخمة (Big Data) حيث التغير السريع في البيانات وبالتالي الحاجة إلى ربط تلك البيانات بمصادرها (Horita,et.al.,2017,p.17)، وتعتبر أسرع وسيلة تساعد 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,2015,p.42) ، 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 المعقّدة (Alawadhi,2015,p.55).

أي أن هذه التقنية تُمكّن متذمّي القرارات ومحلّي البيانات من استخلاص وفهم النتائج في ظل بيئة البيانات الضخمة المعقّدة، 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)، وفيما

يلي مساهمة تقنية (Visuailzation) كإحدى 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 وأيضاً الاستفادة من حاسة البصر والرسوم المعايرة؛ وذلك للحد من المشكلات الناتجة عن توصيل المعلومات بلغة وأسلوب المحاسبين ورجال الأعمال، حيث أنه لا يفهمها إلا عدد قليل ومتخصص من متizzie 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, 2013, p.720).

٢. الملاءمة (Relevance)

تُركز تقنيات الذكاء الاصطناعي على بناء نماذج دقيقة لاستخدامها في القيام بالتنبؤات المستقبلية واستكشاف السلوك والتعرف على الأنماط المختلفة؛ مما يساعد 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، وأيضاً التنبؤ بالتدفقات النقدية وسعر السهم وغيرها من التطبيقات المالية، وبالتالي فإن الاعتماد على استخدام تقنيات الذكاء الاصطناعي في القيام بالتنبؤات المالية يحسن من خاصية الملاءمة وكذلك القيمة التنبؤية والتغذية المرتدة للمعلومات (Zhang & Zhou, 2004, p.513).

٣. القابلية للمقارنة (Comparability)

يمكن تحسين خاصية القابلية للمقارنة من خلال الاعتماد على استخدام تقنيات الذكاء الإصطناعي؛ حيث أنه عند بناء النموذج الذي يستخدم 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 (Nagano & Moraes, 2013, p.283) (Consistency).

٧/٦ دور تقنية آلة متوجه 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 stepwise multivariate techniques) مثل تحليل الإنحدار اللوجستي المتعدد (logistic regression analysis) في معظم الحالات، وعندما لا يكون التقرير الخطوي (linear approximation) صحيحاً، فإن دقة النماذج الإحصائية التقليدية تنخفض إلى حد كبير (Etemadi, et.al., 2015, p.58)، 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 السلسل الزمنية المالية (Financial time series data) بعدم الثبات (non-stationary) والفوضى (chaos) وإرتفاع درجة عدم اليقين (high degree of uncertainty) في ذلك فإن استخدام تقنية آلة متوجه 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, 2014, p.12).

تعتمد تقنية(SVM) على تقسيم البيانات إلى ثلاث مجموعات فرعية، مجموعة واحدة للتدريب (Training)، ومجموعة واحدة لـ الإختبار (Testing)، ومجموعة أخرى للتحقق من الصحة (Validating)، حيث يتم إستخدام مجموعة التدريب لتطوير نموذج التنبؤ الخاص بـ تقنية(SVM)، ويتم إستخدام مجموعة الإختبار لـ تقييم قدرة التنبؤ الخاصة بـ تقنية(SVM)، وعادةً ما تكون مجموعة التتحقق من الصحة جزءاً من مجموعة الإختبار وـ تُستخدم لـ تجنب مشكلة التجهيز الزائد (Over-Fitting Problem) أو لـ تحديد نقطة التوقف لـ عملية التدريب، كما لا يوجد نهج معين في تقسيم البيانات بأحجام مناسبة إلى مجموعة تدريب ومجموعة اختبار، ومع ذلك هناك العديد من العوامل التي يجب أخذها في الاعتبار عند إتخاذ القرار، وأبرزها خصائص المشكلة، ونوع البيانات، وحجم البيانات المتاحة، وتم اقتراح أنه يجب أن تحتوي مجموعة التدريب على ٧٠٪ من البيانات ومجموعة التتحقق ٢٠٪ والإختبارات ١٠٪ لنماذج التنبؤ غير الخطية (Shadi,2015,p.29).

نتيجة لما سبق؛ تُستخدم تقنية(SVM) بكثرة في عمليات تصنيف البيانات والتنبؤ، وفي السابق كان هناك الكثير من الدراسات حول إستخدام تقنية الشبكات العصبية الاصطناعية(ANN) في هذه المجالات، خاصةً في مجال التنبؤ، ومع ذلك في سوق الأوراق المالية نظراً لأن البيانات غالباً 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 إسم 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، وـ تُعد مهمة التصنيف من أهم مزايا تقنية(SVM)، حيث تم إستخدام تقنية(SVM) بنجاح في مجال التنبؤ، ويمكن لـ تقنية(SVM) معالجة البيانات ذات الأبعاد الأعلى بشكل أفضل حتى مع وجود قدر منخفض نسبياً من مجموعة التدريب، بالإضافة إلى ذلك يمكن أن تقدم قدرة جيدة على التعلم للنموذج المعقد(Complex Model). (Shu& Rung,2007,p.63)

بذلك يتمثل الإختلاف 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 الهيكيلية (Structural Risk Minimization)، حيث تهدف إلى بناء نموذج هيكلی 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 مقترن لزيادة دقة التنبؤات المالية من خلال تطبيق تقنيات الذكاء الإصطناعي عن طريق أسلوب (Machine Learning) وباستخدام تقنية آلة متوجه 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 يُساهم في تحسين جودتها.

١١ مجتمع وعينة الدراسة

يشمل مجتمع وعينة الدراسة التطبيقية الشركات المقيدة في البورصة المصرية ضمن مؤشر سوق المال المصري(EGX100)، 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 الإنداجم أو التوقف خلال فترة الدراسة، كما تم إستبعاد البنوك وشركات التأمين وصناديق الاستثمار لما لها من طبيعة خاصة و مختلفة عن باقي الشركات في القطاعات المختلفة، وقد تم اختيار عدد (٧٠) شركة من (١٢) قطاع، ويوضح الجدول التالي الشركات محل الدراسة التطبيقية.

جدول رقم (١)

حجم عينة الدراسة وفقاً لطبيعة القطاع الاقتصادي

م	اسم 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 إتصالات 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 موقع 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, 2003) ودراسة (Barth, et., al, 2001) دراسة (Lorek & Willinger, 2010)، 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	آخر

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

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

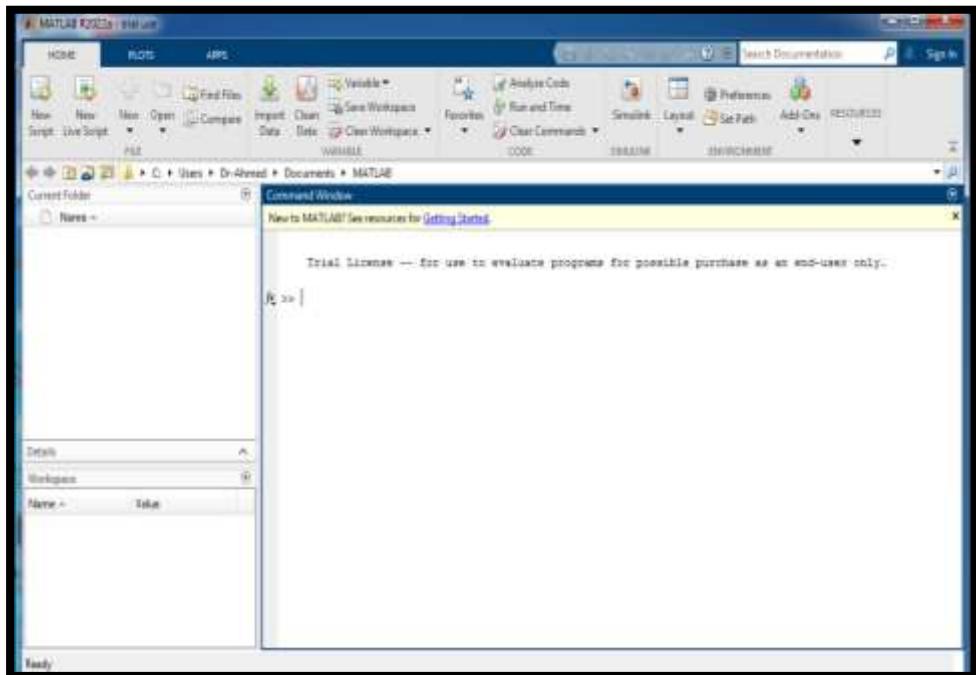
كما تم الحصول على قيمة المتغير (EARN) من قائمة الدخل والمقصود به هو صافي الدخل بعد الضرائب، وتم تجميع البيانات في مجموعة بيانات (Datasets) وبالتالي لم تكن هناك قيمة مفقودة أو مكررة، أي أنه تم تجميع البيانات بشكل يراعي جودتها، كما تم عمل (Normalization) لجميع قيم المتغيرات كلًّا على حدة وذلك نظرًا للإختلاف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

٣/ التنبؤ بالتدفقات النقدية باستخدام تقنية آلة متوجه الدعم (SVM) لاختبار صحة فرض الدراسة: لاختبار صحة فرض الدراسة التطبيقية تم استخدام تقنية آلة متوجه 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 واختيار (MATLAB R2022b) (Start)، وظهور الشاشة الرئيسية للبرنامج كما هو موضح بالشكل رقم (١) التالي:

شكل رقم (١)

الشاشة الرئيسية لبرنامج (MATLAB R2022b)



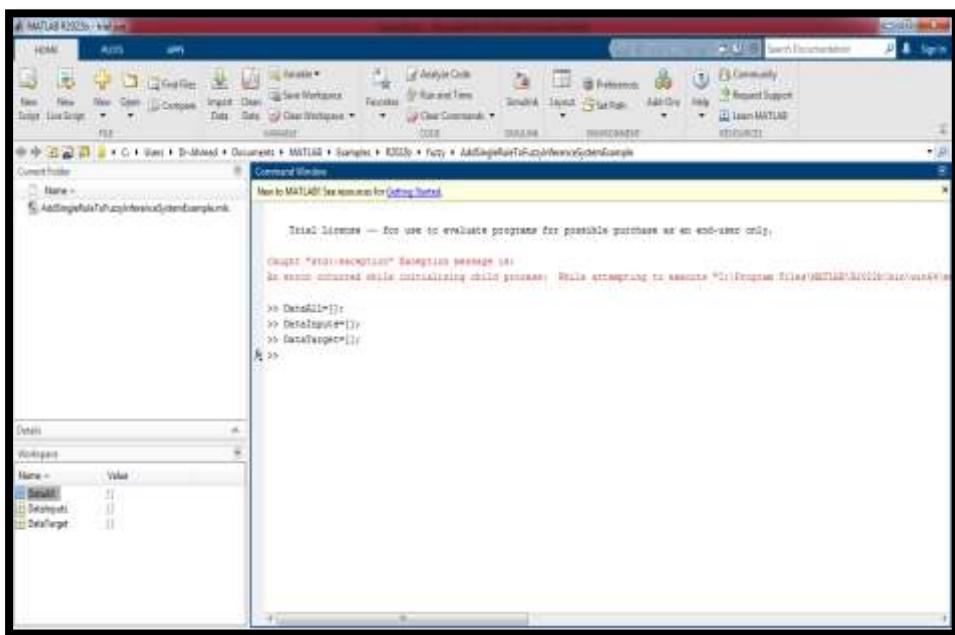
٢. إدخال متغيرات الدراسة في برنامج (MATLAB):

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، ويكون من (٢٨٠) صف و (٧) أعمدة.

- **الجزء الثاني(Data Inputs):** عبارة عن بيانات المتغيرات المستقلة الستة فقط، ويكون من (٢٨٠) صف و(٦) أعمدة.
 - **الجزء الثالث(Data Target):** عبارة عن بيانات المتغير التابع فقط، ويكون من (٢٨٠) صف وعمود واحد فقط.
- والإدخال(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)

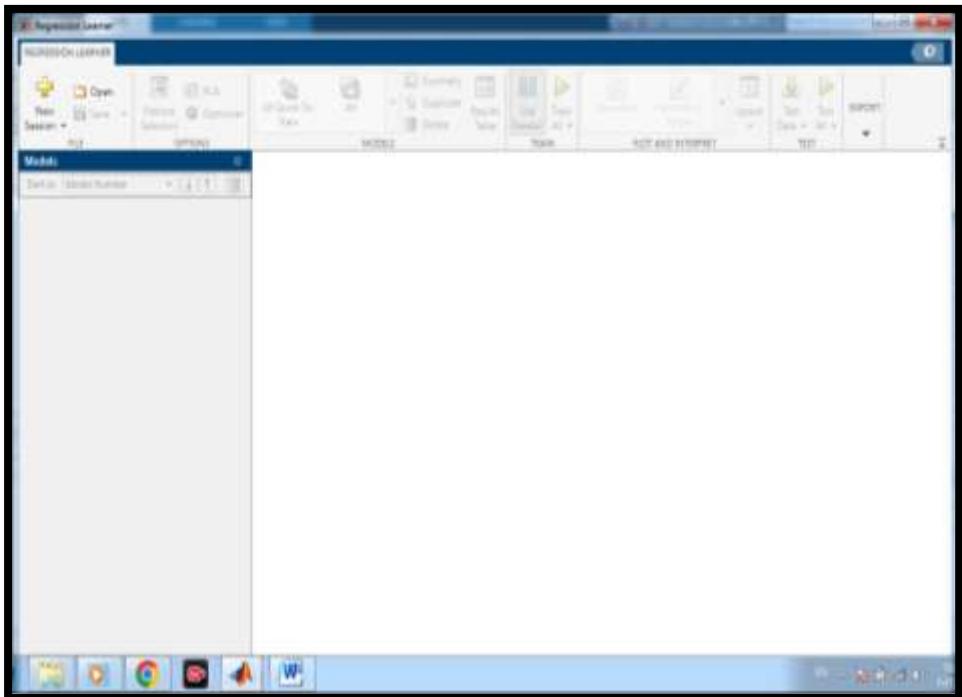


ويتم بعدها فتح ثلاثة أوراق عمل داخل قائمة (Workspace) بنفس الأسماء وفقاً للأوامر التي تم كتابتها، ثم تم فتح ملف (Excel) الذي يحتوي على (Data sets)، وتم نسخ محتويات ورقة العمل الخاصة بـ (Data All) عن طريق الضغط على (Ctrl+c) ثم تم فتح ورقة العمل الخاصة أيضاً بالـ (Data All) في قائمة (Workspace) ببرنامج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

٣. إعداد نموذج التنبؤ لتدريب البيانات بإستخدام (Machine Learning):
تم ذلك عن طريق اختيار قائمة (APPS) في الشاشة الرئيسية لبرنامج (MATLAB)، ثم تم اختيار (Regression Learner)، والذي يستخدم لتدريب نماذج الإنحدار المستخدمة لعمل التنبؤات بإستخدام تعلم الآلة الخاضع للإشراف (Supervised Machine Learning)، ويظهر الشكل رقم (٣) التالي:

شكل رقم (٣)

الشاشة الخاصة بـ (Regression Learner)

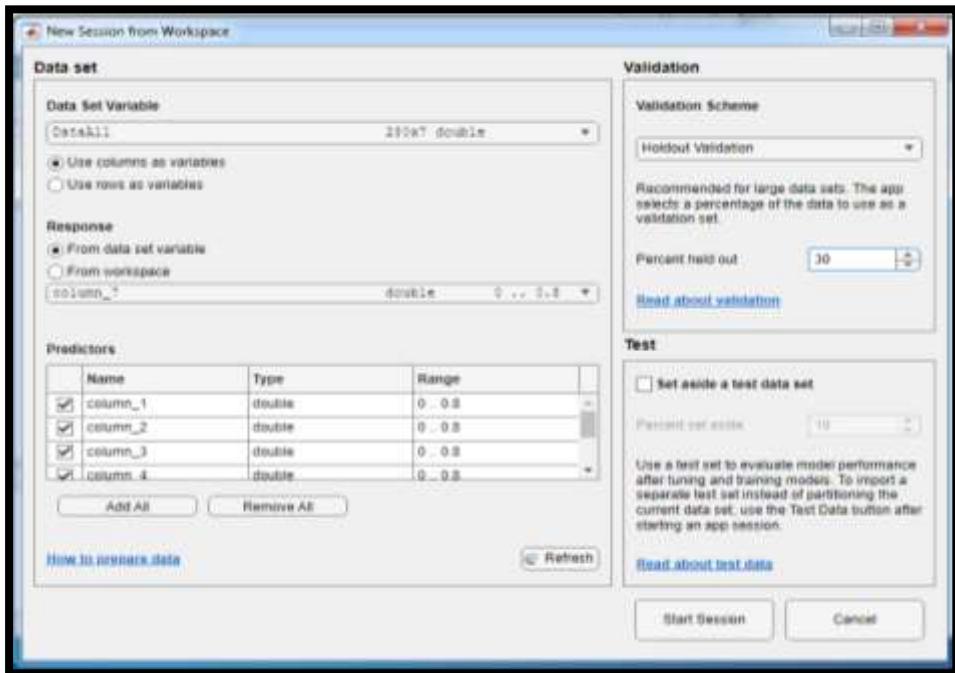


ويتضح من الشكل السابق عند الضغط على (New Session) لإدخال الـ (Data sets) في النموذج، وإختيار ملف (Data All) في خانة (Data Set Variable)، ومن قائمة (Validation) تم إختيار (Holdout Validation) وذلك للتحقق من البيانات، وتم تحديد نسبة مؤوية من البيانات لاستخدامها كمجموعة تحقق وهي (30%)، ثم يقوم التطبيق بتدريب النموذج على مجموعة التدريب وتقييم أدائه من خلال مجموعة التحقق، كما يعتمد النموذج المستخدم للتتحقق على جزء فقط من البيانات، لذا فإن (Holdout Validation) مناسب فقط لمجموعات البيانات الكبيرة (Large Data Sets)، ثم يتم تدريب النموذج النهائي بإستخدام مجموعة

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)



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

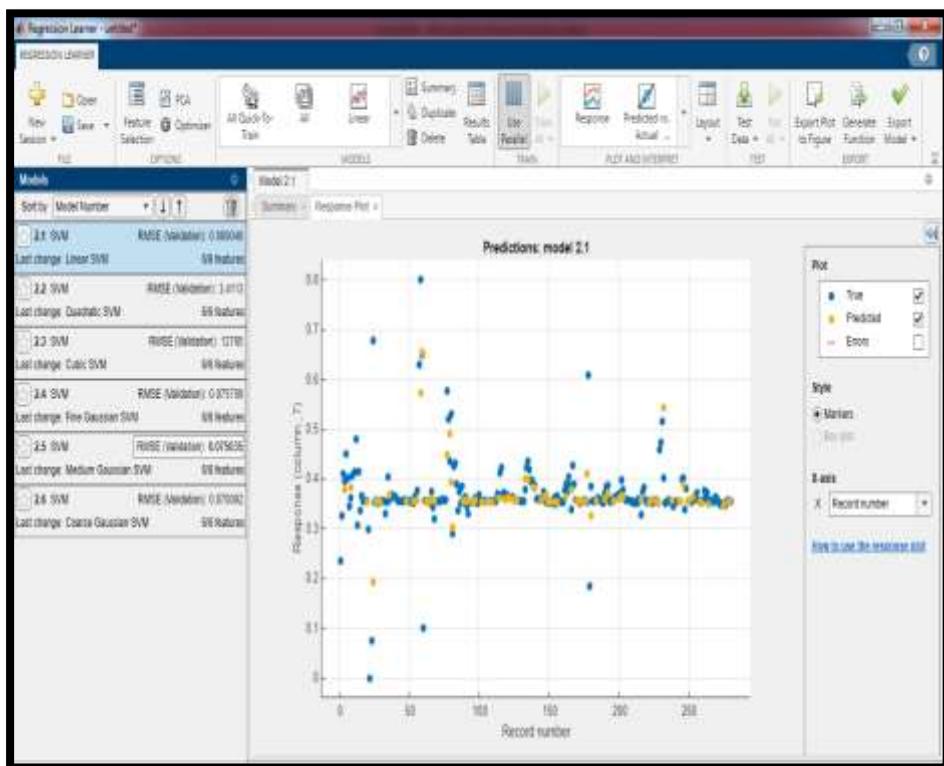
- .(SVM Linear)
- .(SVM Quadratic)
- .(SVM Cubic)

- .(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 كلّ من (RMSE&MAE) لكلّ أنواع تقنية (SVM)، وذلك حتى يتم المقارنة بين نتائج التنبؤ، ومعرفة أيّاً منها أكثر توافقاً مع طبيعة البيانات التي تم إدخالها.

شكل رقم (٥)

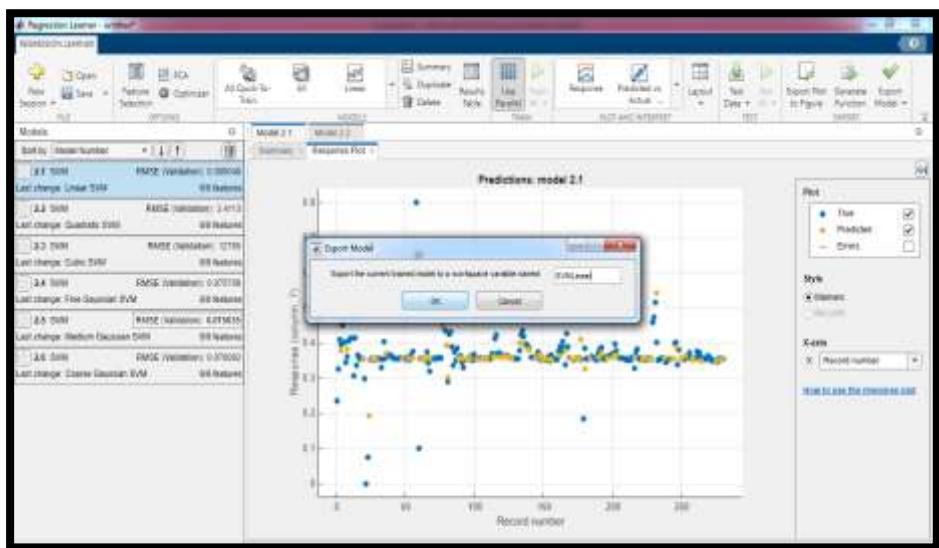
شاشة البرنامج بعد الإنتهاء من عملية تدريب نموذج التنبؤ



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 Train (EXPORT) تم تغيير مسمى نموذج التنبؤ الخاص بهذا النوع من (SVM Linear) إلى (Regression Model) ، 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 SVM model to a workspace)، ثم تم كتابة إسم النموذج الذي تم تدريبيه وهو (Linear) وتم الضغط على (Ok)، كما هو موضح من خلال الشكل رقم (٦)، وتم تكرار نفس الخطوات لباقي الموديلات (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)

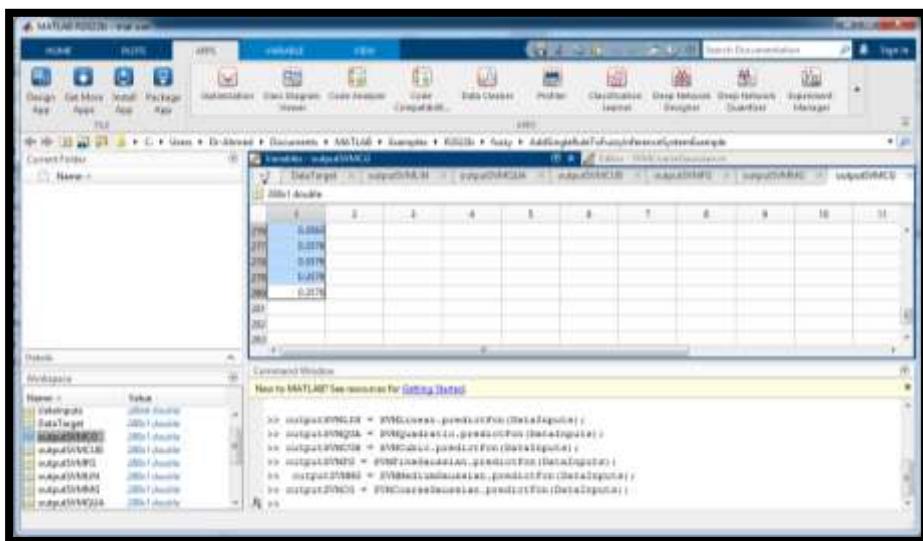


٦. المقارنة بين النتائج الفعلية والنتائج المقدرة باستخدام تقنية(SVM):
الحصول على النتائج المقدرة باستخدام تقنية(SVM) بعد الإنتهاء من عملية التتبؤ وذلك لجميع الـ(Modles) الخاصة بتقنية(SVM)، تم كتابة الأوامر التالية في (Command window)

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(SVM)، كما هو موضح بالشكل رقم(٧).

شكل رقم (٧)

كيفية الحصول على نتائج تقنية(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	
0.0054	0.0030	0.0173	93.41	SVM Linear
0.4233	0.1792	0.0102	91.61	SVM Quadratic
749.2	561306.6	9.3642	5.72	SVM Cubic
0.9619	0.0925	0.0191	94.15	SVM Fine Gaussian
0.9606	0.9229	0.0199	93.77	SVM Medium Gaussian
0.9830	0.9664	0.0225	93.14	SVM Coarse Gaussian

يتضح من الجدول رقم (٣) إرتفاع متوسط الدقة التنبؤية لجميع الـ(Modles) الخاصة بـ(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(91.61%) كحد أدنى وذلك عند (SVM Quadratic)، وبين(94.15%) كحد أقصى عند(SVM Fine Gaussian)، حيث أنه كلما ارتفعت درجة الدقة التنبؤية كلما زادت قوة نموذج التنبؤ.

يتضح أيضاً إنخفاض قيمة المتوسط المطلق لخطأ التنبؤ(MAE) لجميع الـ(Modles) الخاصة بـ(SVM)، حيث كان المتوسط المطلق لخطأ التنبؤ بالتدفقات النقدية (MAE) ما بين(0.0102) كحد أدنى وذلك عند (SVM Quadratic)، وبين(0.0225) 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 بـ (SVM)، حيث كان متوسط الخطأ التربيعي (MSE) لخطا التنبؤ بالتدفقات النقدية (MSE) ما بين (0.0030) كحد أدنى وذلك عند (SVM Linear)، وبين (0.9664) كحد أقصى عند (SVM Coarse Gaussian)، حيث أنه كلما إنخفضت قيمة (MSE) كلما زادت قوة نموذج التنبؤ.

كما يتضح أيضاً إنخفاض قيمة الجذر التربيعي لخطا التنبؤ (RMSE) لجميع الـ (Modles) الخاصة بـ (SVM)، حيث كان الجذر التربيعي لخطا التنبؤ بالتدفقات النقدية (RMSE) ما بين (0.0054) كحد أدنى وذلك عند (SVM Linear)، وبين (0.9830) 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 متوجه الدعم (SVM) وبين دقة التنبؤات المالية "

٩. نتائج الدراسة

- أن تقنية آلة متوجه الدعم (SVM) من أهم تقنيات الذكاء الإصطناعي، وإنه يجب الاعتماد عليها بكثرة في المجال المحاسبي وخاصة عند إعداد التنبؤات المستقبلية، نتيجة لما تتمتع به قدرة فانقة في تصنیف بيانات المدخلات بدقة.
- تمثلت نتائج نموذج الدراسة في ارتفاع متوسط الدقة التنبؤية لنموذج (SVM)، وبلغ متوسط الدقة التنبؤية بالتدفقات النقدية ما بين (٦١.٦١%) كحد أدنى وذلك عند (SVM Quadratic)، وبين (٩٤.١٥%) كحد أقصى عند (SVM Fine Gaussian)، حيث أنه كلما ارتفعت درجة الدقة التنبؤية كلما زادت قوة نموذج التنبؤ.
- إنخفاض قيم (MSE)&(MAE) لنموذج (SVM)، وكلما إنخفضت قيم تلك المقاديس دل ذلك على الكفاءة العالية لنموذج التنبؤ، مما يعني تحسن المقدرة التنبؤية لنماذج الذكاء الإصطناعي.

١٠. توصيات الدراسة

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

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

مراجع الدراسة

أولاً: المراجع العربية

١. إلهام محمد عبداللطيف، (٢٠١٦)، "تحسين جودة التقارير المالية بإستخدام أسلوب التقريب في البيانات- دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٢. زكي محمود عطوة يوسف، (٢٠١٣)، "د الواقع وأثر الإفصاح الإختياري عن المعلومات المحاسبية مع دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٣. عصام عبدالمنعم إسماعيل، (٢٠١٧)، "مقدمة 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 السلسل الزمنية والشبكات العصبية للتنبؤ بأسعار الصرف في العراق"، المجلة المصرية للدراسات التجارية، كلية التجارة، جامعة المنصورة.
٥. مصطفى إبراهيم الفقي، (٢٠١٤)، "أثر المحتوى الإعلامي لقواعد المالية المستقبلية على قيمة المنشأة مع دراسة تطبيقية"، بحث غير منشور، رسالة ماجستير، جامعة المنصورة، كلية التجارة.
٦. منذر محمد ،واخرون (٢٠٢٢)، "أثر تفعيل تقنيات الذكاء الاصناعي على تعزيز أنشطة المراجعة الداخلية- دراسة ميدانية"، مجلة الإسكندرية للبحوث المحاسبية، العدد ٣، المجلد ٦، ص ٤٠-٤١.
٧. مها محى الدين عبد القادر، (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 الإختياري؟ دراسة تحليلية اختبارية على الشركات المساهمة المصرية"، مجلة **البحوث التجارية**، جامعة الزقازيق، المجلد السادس والثلاثين، العدد الأول.

ثانياً: المراجع الأجنبية

1. Alawadhi, A. (2015). The application of data visualization in auditing. Doctoral dissertation, **Rutgers University-Graduate School-Newark**.
2. Amos Baranes, Rimona Palas.(2019). Earning Movement Prediction Using Machine Learning-Support Vector Machines (SVM). **Journal of Management Information and Decision Sciences**,22(2).
3. Ashis Pradhan.(2012). Support vector machine – A Survey. **International Journal of Emerging Technology and Advanced Engineering**,2(8).
4. Ashis Pradhan.(2012). Support vector machine – A Survey. **International Journal of Emerging Technology and Advanced Engineering**,2(8).
5. Barth, M., cram,D.,& Nelson,K.(2001).Accruals and the Prediction of future cash flows.**The Accounting Review**,76(1), 27-58.
6. Bilinski,P.(2014).Do Analysts Disclose Cash Flow Forecasts with Earnings Estimates when Earnings Quality is Low?. **Journal of Business Finance and Accounting** ,41(3).
7. Chandwani, D., & Saluja, M.S. (2014). Stock direction forecasting techniques : An empirical study combining machine learning system with market indicators in the Indian context, **International Journal of Computer Applications**, 92(11), 8-17.
8. Cohen, D.(2003).Quality of Financial Reporting Choice: Determinates and Economic Consequences. **Retrieved from www.ssrn.com**.
9. Eduardo A. Gerlein, Martin McGinnity , Ammar Belatreche, Sonya Coleman.(2016). Evaluating Machine Learning Classification for

Financial Trading: An Empirical Approach, **Expert Systems with Applications**, 54, 193-207.

10. Etemadi, H., Ahmadpour, A., & Moshashaei, S.M. (2015). Earnings per share forecast using extracted rules from trained neural network by genetic algorithm. **Computational Economics**, 46(1), 55–63.
11. Farshadfar, S., and Monem, R. (2013). Further evidence on the usefulness of direct method cash-flow components for forecasting future cash-flows. **The International Journal of Accounting**, 48, 111-133.
12. Financial Dictionary, Expected Future Cash Flows, (2019), accessed on November 19, 1019, at: <https://financial-dictionary.com/Expected+future+cash+flows>.
13. Fintechnews Singapore. (2018).the Potential of AI in Banking. Retrieved from: <http://fintechnews.sg/27160/ai/thepotential>.
14. Gepp, A., Linnenluecke, M. K., O'Neill, T., & Smith, T. (2017). Big data techniques in auditing research and practice: Current trends and future opportunities. **Journal of Accounting Literature**, 40, 102-115.
15. Guang Yih Sheu.(2019). Classification of the Priority of Auditing XBRL Instance Documents with Fuzzy Support Vector Machines Algorithm, **Journal of Autonomous Intelligence**, 2(2).
16. Horita, F. E., de Albuquerque, J. P., Marchezini, V., & Mendiondo, E. M. (2017). 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**, 97, 12-22.
17. Hua-Cheng Yin.(2014). A Novel Machine Learning Model for Risk Management. Proceedings of the First Asia Pacific **Conference on Global Business, Economics, Finance and Social Sciences** (AP14Singapore Conference).

18. Isaac Kofi Nti*, Adebayo Felix Adekoya, and Benjamin Asubam Weyori.(2020). Efficient Stock-Market Prediction Using Ensemble Support Vector Machine, **published by De Gruyter**,10, 153-163.
19. Liu Hongjiu .(2010). An Application Of Support Vector Machine For Evaluating Credit Risk Of Bank. Proceedings Of The 7th **International Conference On Innovation And Management** ,December 4-5, , Wuhan, China.
20. Min-Yuan Cheng, Andreas F.V. Roy.(2011). Evolutionary fuzzy decision model for cash flow prediction using time-dependent support vector machines. **International Journal of Project Management** 29 ,pp. 56–65.
21. Nagano, M., and Moraes, M.(2013).Accounting Information Systems: An Intelligent Agent Approach. **African Journal of Business Management**, 7(4), 273-284.
22. Paulius Danenas, Gintautas Garsva,(2011)," Svm And Xbrl Based Decision Support System For Credit Risk Evaluation", publication at: <https://www.researchgate.net/publication/266557312>.
23. Paulius Danenas, Gintautas Garsva,(2011)," Svm And Xbrl Based Decision Support System For Credit Risk Evaluation", publication at: <https://www.researchgate.net/publication/266557312>.
24. Rosillo, R.; Giner, J. & and De la Fuente, D. (2014).Stock Market simulation using support vector machines. **Journal of Forecasting**, 33(6), 488–500.
25. Saif, S., et al.(2012).Finding rules for audit opinions prediction through data mining methods. **European online Journal of Natural and Social Sciences**, 1(2), 28-36.
26. Shadi M. Basal.(2015). Comparison between Support Vector Machine & Box-Jenkins Methodology for Forecasting PALTEL'S Stock Market Prices. **Al-Azhar University-Gaza**.

27. Shan Suthaharan.(2016). **Machine Learning Models and Algorithms for Big Data.**
28. Shuo Han, Rung-Ching Chen.(2007). Using SVM with Financial Statement Analysis for Prediction of Stocks. Retrieved from <http://scholarworks.lib.csusb.edu/ciima/vol7/iss4/8>.
29. Spacey, J. (2016).Branches of Artificial Intelligence (AI). Simplicable. Retrieved from <https://simplicable.com>.
30. Trigo, A., Belfo, F., & Estébanez, R. P. (2014). Accounting information systems: The challenge of the real-time reporting. **Procedia Technology**, 16, 118-127.
31. Umesh, U. N., & Kagan, M. (2015). Data Visualization in Marketing. **Journal of Marketing Management**, 3(2), 39-46.
32. Vikramaditya Jakkula.(2010). Tutorial on Support Vector Machine (SVM). School of EECS, **Washington State ,University**, Pullman.
33. Yoo, C., & Pae, J.(2013). Estimation and Prediction Tests of Cash Flow Forecast Accuracy. **Journal of Forecasting**, Vol.32.
34. Yunqian Ma & Guodong Guo.(2014). **Support Vector Machines Applications**. Springer International Publishing Switzerland.
35. Zhang ,D. & Zhou ,L .(2004).Discovering Golden Nuggets :Data mining in Financial Application. IEEE Transactions on systems MAN, AND cybernetics-partc:**applications and Reviews**, 34(4).