تأثير المؤشرات المالية المدعمة بخوارزمية آلة المتجهات الداعمة (SVM) في دقة وسرعة التنبؤ بالتحليل المالي \ دراسة حالة في شركة المنصور للصناعات الدوائية

الباحثة زينب زهير نجم و أ.م.د. انوار مصطفى حسن
جامعة بغداد - كلية الإدارة والاقتصاد، بغداد \ العراق

The Effect of Financial Indicators Supported by the Support Vector Machine (SVM) Algorithm on the Accuracy and Speed of Financial Analysis Forecasting: A Case Study in Al-Mansour Pharmaceutical Industries Company

Researcher Zainab Zuhair Najm
and Assist. Prof. Dr. Anwar Mustafa Hassan
University of Baghdad, College of Administration and Economics, Baghdad / Iraq
zainab.najm2205@coadec.uobaghdad.edu.iq
dr.anwar-m@coadec.uobaghdad.edu.iq

المستخلص

يهدف هذا البحث إلى تحليل تأثير الذكاء الاصطناعي (Artificial Intelligence) في تحسين الأداء المالي للشركة الصناعة (شركة المنصور للصناعات الدوائية) المدرجة في سوق العراق للأوراق المالية، تم استخدام خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) كأداة تحليل وتصنيف، اعتمادًا على مجموعة من المؤشرات المالية شملت: العائد على الاستثمار (ROI–Return on Investment)، العائد على حقوق الملكية (ROE–Return on Equity)، المخاطرة النظامية (Systematic Risk)، المخاطرة غير النظامية (Un Systematic Risk)، والمخاطرة الكلية (Total Risk)، وتم جمع البيانات المالية من التقارير الربع سنوية للشركة، وتمت معالجتها وتحليلها بشكل مفصل، عبر بناء نموذج خاص بها باستخدام خوارزمية (SVM)، بهدف تقييم أدائها المالي والتنبؤ بنتائجها. أظهرت النتائج فعالية الذكاء الاصطناعي في تقديم مؤشرات دقيقة تعزز القدرة على التنبؤ وتحسين اتخاذ القرار المالي. يوصي البحث بضرورة اعتماد تقنيات الذكاء الاصطناعي في تحليل البيانات المالية داخل سوق العراق للأوراق المالية، لما لها من دور فعال في رفع كفاءة الأداء وتحقيق قيمة مضافة للشركات.

الكلمات المفتاحية:- الأداء المالي، المؤشرات المالية، الذكاء الاصطناعي، خوارزمية آلة المتجهات الداعمة (SVM).

Abstract

This research aims to analyze the impact of Artificial Intelligence (AI) on improving the financial performance of an industrial company Al-Mansour Pharmaceutical Industrial Company, which is listed on the Iraq Stock Exchange, The Support Vector Machine (SVM) algorithm was used as an analytical and classification tool based on a set of financial indicators, including Return on Investment (ROI), Return on Equity (ROE), Systematic Risk, Unsystematic Risk, and Total Risk. Financial data were collected from the companies' quarterly reports, and were processed and analyzed in detail by constructing a specialized model using the (SVM) algorithm, to evaluate the company's financial performance forecast its results. The findings demonstrated the effectiveness of Artificial Intelligence in providing accurate indicators that enhance predictive capability and support improved financial decision-making. The study recommends adopting Artificial Intelligence techniques in financial data analysis within the Iraq Stock Exchange, as they play an essential role in enhancing performance efficiency and creating added value for companies.

Keywords: Financial performance, Financial indicators, Artificial intelligence, Support Vector Machine (SVM).

المقدمة

أسواق الأوراق المالية تحظى بأهمية بالغة في كل من الدول المتقدمة والنامية، لما لها من دور أساسي في تجميع المدخرات وتوجيهها نحو قنوات استثمارية أكثر فاعلية، إذ تمثل حلقة وصل بين الوحدات المدخرة من أفراد وبنوك ومؤسسات، والوحدات المستثمرة من أفراد ومشروعات استثمارية. وفي هذا الإطار يُعد **سوق العراق للأوراق المالية** من الأسواق الحيوية التي تسهم في تنظيم حركة رؤوس الأموال واستثمارها بكفاءة ضمن مختلف الأنشطة الاستثمارية، بما يعزز بيئة الاستثمار ويرفع من كفاءة الأداء المالي للشركات.

كما تُعد المؤشرات المالية التقليدية من الأدوات الرئيسة في تقييم أداء الشركات وقياس قدرتها على الوفاء بالتزاماتها المالية، كونها تمثل وسيلة أساسية يعتمد عليها في التحليل المالي واتخاذ القرارات الاستثمارية. ومع التطور التقني الكبير الذي يشهده العالم في الوقت الراهن، لم يعد التحليل المالي محصورًا بالأساليب التقليدية فحسب، بل اتجه إلى توظيف تقنيات الذكاء الاصطناعي بما تتضمنه من خوارزميات متقدمة وشبكات عصبية وتقنيات تعلم الآلة في جمع البيانات ومعالجتها وتحليلها. وقد أسهم هذا التحول الرقمي في تطوير الأنظمة المالية وتعزيز كفاءة عمليات التحليل المالي ودعم عملية اتخاذ القرار الاستثماري، مما زاد من الاعتماد على الحلول الذكية والتطبيقات الرقمية في إدارة العمليات المالية وتحليل البيانات الضخمة، وهو ما يساعد على رفع دقة التنبؤات المالية وتقليل المخاطر المرتبطة بالاستثمار.

المبحث الاول \ منهجية البحث

1.1 مشكلة البحث

يواجه القطاع الصناعي ومنه (شركة المنصور للصناعات الدوائية) تحديات جديدة تتعلق بقدرة الشركة على تحليل الأداء المالي بدقة وسرعة وكفاءة. إذ تعد عملية التحليل المالي مسألة أساسية تعتمد عليها الشركة في تقييم كفاءتها التشغيلية وتقليل نسبة الخطأ في أدائها المالي، ولا سيما فيما يتعلق بالعائد والمخاطرة، مما يساعدها في اتخاذ قرارات استثمارية مدروسة. وأن الأساليب التقليدية في التحليل المالي قد لا تكون كافية في ظل التعقيد المتزايد للأسواق المالية وتغير الظروف الاقتصادية والتكنولوجية. وفي هذا السياق، أصبح تحسين دقة التنبؤات المالية من خلال تقنيات الذكاء الاصطناعي أمرًا ضروريًا لتعزيز قدرة الشركة على مواجهة التحديات السوقية. وتعتمد الشركات عادةً على المؤشرات المالية لاتخاذ قراراتها الاستثمارية، إلا أن هذه المؤشرات قد لا توفر دقة كافية شاملة للتغيرات المالية المستقبلية، مما يبرز الحاجة إلى توظيف أدوات تحليل متقدمة تعتمد على الذكاء الاصطناعي.

من هنا تنبع مشكلة البحث من الحاجة إلى تطوير نموذج تحليلي يستند إلى تقنيات الذكاء الاصطناعي، وبوجه خاص خوارزمية **آلة المتجهات الداعمة** (Support Vector Machine – SVM)، بهدف تحليل المؤشرات المالية للشركة الصناعية (المنصور للصناعات الدوائية) المدرجة في **سوق العراق للأوراق المالية**. وعلى الرغم من تزايد الاهتمام العالمي بتطبيقات الذكاء الاصطناعي في المجالات المالية، فإن السوق العراقي، ولا سيما في القطاع الصناعي، ما زال يعتمد بدرجة كبيرة على الأساليب التقليدية في تحليل البيانات المالية. كما أن الدراسات المحلية لم تتناول بصورة كافية تطبيق خوارزمية (SVM)ضمن هذا الإطار. ومن ثم، يهدف هذا البحث إلى معالجة هذه الفجوة من خلال توظيف خوارزمية(SVM) لتحليل المؤشرات المالية بدقة أعلى وشمولية أكبر، بما يعزز من كفاءة الأداء المالي للشركة الصناعية (شركة المنصور للصناعات الدوائية).

1. 2 أهمية البحث

برزت أهمية البحث في تسليط الضوء على دور خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) في تحسين عملية التحليل المالي لشركة المنصور للصناعات الدوائية الصناعية المدرجة في سوق العراق للأوراق المالية. وذلك من خلال اسناد المؤشرات المالية بتقنيات الذكاء الاصطناعي وبشكل خاصة خوارزمية (SVM). بهدف تحسين القرارات الاستثمارية.

1. 3 أهداف البحث

تتمثل اهداف البحث كالاتي:

- دراسة تأثير استخدام المؤشرات المالية المدعمة بتقنيات الذكاء الاصطناعي على الأداء المالي لشركة المنصور للصناعات الدوائية الصناعية المدرجة في سوق العراق للأوراق المالية.
- بيان تأثير المؤشرات المالية المدعمة بخوارزمية آلة المتجهات الداعمة (SVM) في تحسين دقة وسرعة التنبؤ بالتحليل المالي في شركة المنصور للصناعات الدوائية الصناعية المدرجة في سوق العراق للأوراق المالية، بهدف تعزيز كفاءة الأداء المالي واتخاذ القرارات الاستثمارية.

1. 4 فرضية البحث

يستند البحث على الفرضية الرئيسية التالية:

" أن تأثير المؤشرات المالية المدعمة بخوارزمية آلة المتجهات الداعمة (SVM) تبين دقة وسرعة التنبؤ بالتحليل المالي للشركة الصناعية عينة البحث المدرجة في سوق العراق للأوراق المالية"

والتي تنقسم إلى فرضيتين فرعيتين:

H0: استعمال المؤشرات المالية المدعمة بخوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) لا تؤثر بدقة وسرعة مؤشرات التحليل المالي ولا تقلل من معدلات الخطأ.

H1: استعمال المؤشرات المالية المدعمة بخوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) تؤثر بدقة وسرعة مؤشرات التحليل المالي وتقلل من معدلات الخطأ.

1. 5 منهج البحث

يعتمد البحث على منهجين متكاملين:

- الأول وصفي تحليلي لمراجعة الأدبيات النظرية المتعلقة بالعلاقة بين المؤشرات المالية والذكاء الاصطناعي.
- الثاني تطبيقي كمي يقوم على تحليل بيانات فعلية لشركة المنصور للصناعات الدوائية المدرجة ضمن القطاع الصناعي في سوق العراق للأوراق المالية، ومقارنتها بين نتائج المؤشرات التقليدية وتلك المدعومة بالذكاء الاصطناعي.

1. 6 حدود البحث

- الحدود المكانية: تتمثل الحدود المكانية للبحث في سوق العراق للأوراق المالية، حيث ركز البحث الحالي على القطاع الصناعي، وقد تم اختيار (شركة المنصور للصناعات الدوائية) عينة للبحث لغرض التحليل والتطبيق العملي، وذلك نظرًا لتوافر بياناتها المالية بشكل كامل واستمراريتها خلال مدة البحث، بما يضمن دقة النتائج وواقعية التحليل.
- الحدود الزمانية: الفترة الممتدة من عام (2012-2023).

1. 7 المخطط الفرضي للبحث

تم توضيح الترابط بين متغيرات البحث استنادًا إلى إشكالية البحث وأهدافه، إذ يقوم المخطط الفرضي على متغيرين رئيسين: المتغير المستقل (X)، والمتمثل بالمؤشرات المالية المدعومة بتقنيات الذكاء الاصطناعي، والمتغير التابع (Y)، الذي يُعبر عن تحسين الأداء المالي. وقد تم توظيف خوارزمية آلة المتجهات الداعمة (Support Vector Machine – SVM) لتحليل نتائج هذه المؤشرات المالية وتقييم مدى فعاليتها في تعزيز الأداء المالي

للشركة الصناعية عينة البحث المدرجة في سوق العراق للأوراق المالية. ويوضح الشكل رقم (1) العلاقة الفرضية بين متغيرات البحث.

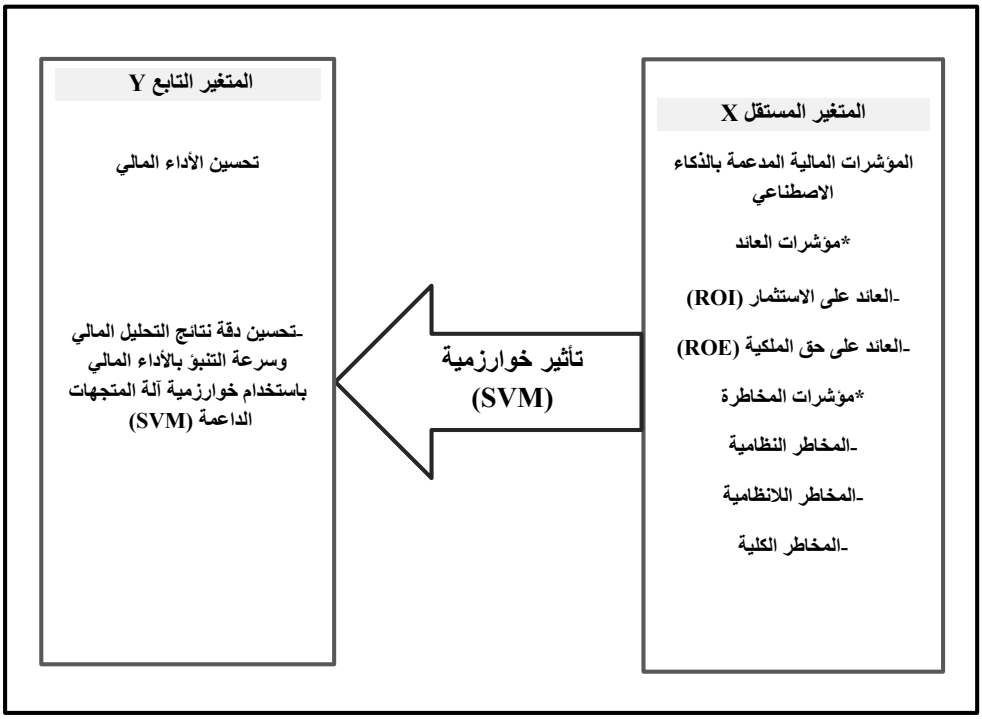

الشكل (1) المخطط الفرضي للبحث، المصدر اعداد الباحثة

المبحث الثاني \ الإطار النظري للبحث

اولا: مفاهيم عامة عن الأداء المالي ومؤشرات البحث

1.2 مفهوم الأداء المالي

يُعد الأداء المالي أحد المؤشرات الرئيسة المستخدمة في قياس مدى نجاح المؤسسات من حيث تحقيق العوائد المالية وإدارة المخاطر، كما يُعد أداة يعتمد عليها المستثمرون في تقييم عملية العناية الواجبة وتحليل حالة الاستثمار، ووسيلة للمراقبين الحكوميين لتقدير مستوى الامتثال للتنظيمات ومتابعة استقرار القطاع المالي (بن حمي & دادة، 2022: 3). ويركز الأداء المالي على قدرة الشركة في تحقيق أهدافها المالية بأقل التكاليف الممكنة، مع الحفاظ على توازنها المالي من خلال توفير السيولة اللازمة للوفاء بالتزاماتها، وفي الوقت ذاته تحقيق أرباح مرتفعة بأدنى تكلفة. وبذلك يعكس الأداء المالي مدى كفاءة وفاعلية النشاط المالي داخل الشركة في تحقيق نتائج منسجمة مع الأهداف والخطط المرسومة مسبقًا، مع الاستخدام الأمثل للموارد المتاحة. وتبرز أهمية تقييم الأداء المالي في كونه يوفر معلومات أساسية تسهم في عمليات التخطيط والرقابة واتخاذ القرارات (الخمايسة، 2024: 809).

2.2 أهمية الأداء المالي

يمكن تلخيص أهمية الأداء المالي في النقاط التالية:

- تقييم ربحية الشركة والعمل على تحسينها بهدف زيادة قيمتها وتعزيز ثروة المساهمين.
- تقييم سيولة الشركة لتحسين قدرتها على الوفاء بالالتزامات المالية المستحقة عليها.
- تقييم تطور نشاط الشركة لمعرفة كيفية توزيعها للموارد المالية وتوجيه استثماراتها بصورة فعالة.

- تقييم مستوى المديونية للشركة.
- تقييم تطور توزيعات الأرباح الصادرة عن الشركة.
- تقييم نمو حجم الشركة. (الخطيب، 2010: 4748-) (صالح و حياهم، 44:2022).
- الحفاظ على حقوق حملة الأسهم وضمان تحقيق عائد عادل لهم. (بوخاري و بن عوالي، 2021: 321).

3.2 مؤشرات قياس الأداء المالي

تشكل المؤشرات المالية ركيزة أساسية في توفير المعلومات اللازمة عن سير النشاط المالي للشركات، إذ تساعد المديرين في اتخاذ القرارات الإدارية الملائمة. كما تُعد من أهم الوسائل التي تُستخدم في تفسير الأرقام الواردة في قائمتي الدخل والمركز المالي للشركات (الحتو، 2015: 46). ويمكن شرح أهم هذه المؤشرات على النحو التالي:

- **العائد على الاستثمار:**(Return on Investment – ROI) تُعبر هذه النسبة عن مدى كفاءة الشركة في استخدام وإدارة الأموال المتاحة لها من حقوق المساهمين والأموال المقترضة طويلة الأجل، بهدف تحقيق العائد على تلك الموارد المالية. ويتم احتسابها وفق المعادلة الآتية: (صافي الربح بعد الضرائب / رأس المال المستثمر) × 100 وذلك بناءاً على (حجاج، 2016: 6).

- **العائد على حقوق الملكية:**(Return on Equity – ROE) تمثل هذه النسبة معدل العائد المحقق من استثمار أموال المساهمين، وتُظهر مدى كفاءة الإدارة في استخدام رأس المال المملوك لتحقيق الأرباح. ويُعد ارتفاع العائد على حقوق الملكية مؤشرًا إيجابيًا على كفاءة الأداء الإداري، إلا أنه قد يعكس في الوقت نفسه مستوى أعلى من المخاطر المالية. في المقابل، يشير انخفاض هذه النسبة إلى اعتماد الشركة على هيكل تمويلي محافظ يعتمد بدرجة أكبر على القروض. ويتم احتساب هذه النسبة وفق المعادلة الآتية: ويتم احتساب هذه النسبة وفق المعادلة الآتية: (صافي الربح / حق الملكية) ×100 وذلك قياساً على (ماهر، 2024: 67).

تعتبر مؤشرات **العائد على حقوق الملكية** (ROE) **والعائد على الاستثمار** (ROI) من أهم المؤشرات الجوهرية التي تعكس استدامة ربحية الشركة لكلٍ من المستثمرين والمديرين. ويُسهم التنبؤ الدقيق بهذه المؤشرات في تكوين أساس لاتخاذ القرارات الاستثمارية من قبل إدارة الشركة. كما يُعد تقدير هذه المؤشرات عاملاً أساسياً في دعم القرارات وتزويد المستثمرين المحتملين بالمعلومات الحديثة (Kayakus, 2023: 1).

- **المخاطر النظامية:**(Systematic Risk) تعد هذه المخاطر من أنواع المخاطر التي لا يمكن تجنبها بالتنويع، إذ ترتبط بالسوق المالي ككل، وتشمل احتمالية حدوث اضطرابات واسعة النطاق مثل انهيار النظام المالي أو الأزمات الاقتصادية الشاملة التي تؤثر في جميع القطاعات. وتتمثل خطورتها في تأثيرها المباشر على الترابط بين المستثمرين والأدوات المالية داخل السوق) العمراوي، 2023: 64(.

- **المخاطر اللانظامية:**(Unsystematic Risk) تُشير هذه المخاطر إلى العوامل الخاصة بالشركة أو القطاع التي يمكن أن تؤثر في أداء سهم معين، مثل ضعف الإدارة، أو انخفاض الطلب على منتجات الشركة، أو اشتداد المنافسة في السوق. وبما أن هذه المخاطر ترتبط بكيانات محددة، فهي تُعرف أحيانًا بالمخاطر الخاصة أو الفريدة بالشركة، كما تُعد من المخاطر القابلة للتنويع من خلال توزيع الاستثمارات على أكثر من شركة أو قطاع (البُلك، 2020: 56).

- **المخاطر الكلية** (Total Risk) بناءاً على ما جاء في (جاسم، 2019: 43): يتم احتساب المخاطرة الكلية من خلال جمع كل من المخاطرة النظامية والمخاطرة غير النظامية، ويمكن التعبير عنها بالمعادلة الآتية:

المخاطرة الكلية = المخاطرة النظامية + المخاطرة غير النظامية

4.2 مقاييس الخطر

يقدر مستوى الخطر المرتبط بالعوائد باستخدام مجموعة من الأدوات الإحصائية التي تبين مدى تذبذب العوائد حول متوسطها، ومن أبرز هذه الأدوات (خيرة،2020: 67-68) (قوتال، 2023: 28-29) (عباس، 2024: 12):

– التباين (Variance): يرمز له بـ (σ^2) (sigma square) ويعد أحد المقاييس المهمة للتشتت، ويحُسب من خلال المعادلة:

$$\boldsymbol{\acute{o}}^2 = \frac{1}{\boldsymbol{n}-1}\sum_{t=1}^{\boldsymbol{n}}\left(\boldsymbol{R}_t - \boldsymbol{R}^-\right) \wedge 2$$

حيث:

$\bar{R}$: متوسط العائد.

R_t: العائد الفعلي في السنة t.

n: عدد السنوات.

– **الانحراف المعياري** (Standard Deviation): ويرمز له بالرمز (σ) وهو الجذر التربيعي للتباين وهو من أكثر المقاييس دقة في تمثيل أو وصف درجة المخاطر، ويحسب بالمعادلة:

$$\sigma = \sqrt{\frac{1}{n-1}\sum_{=1}^{n}\left(R_t - R^-\right) \wedge 2}$$

– **معامل الاختلاف** (Coefficient of Variation): يتم إيجاده بقسمه الانحراف المعياري على متوسط العائد، كما في المعادلة:

$$CV = \sigma / R^-$$

– **معامل بيتا** (Beta Coefficient): يعبر هذا المقياس عن درجة التغير المنتظم في عائد سهم معين بالنسبة الى التغيرات التي تطرأ على السوق بشكل عام. وتستخرج قيمته من البيانات التاريخية للعوائد الخاصة بالشركة أو بالمجموعة الأستثمارية، مع مقارنة تلك البيانات بعوائد السوق لنفس الفترة الزمنية وتحسب وفق المعادلة التالية:

$$b = \frac{\Sigma\left(xy - n\overline{xy}\right)}{\Sigma\left(x^2 - n\overline{x}^2\right)}$$

$$\beta = \frac{COV\left(Ri\ Rm\right)}{\sigma^2 Rm}$$

Cov: التباين المشترك لعوائد السهم مع عوائد السوق.

σ^2Rm: التباين في عوائد محفظة السوق.

Rm: العائد الخاص بمحفظة السوق.

Ri: العائد المتوقع للسهم.

5.2 مفهوم الذكاء الاصطناعي

أشار **نيلسون** (2010) إلى أن الذكاء الاصطناعي يمثل *نشاطًا موجهًا نحو تمكين الآلات من اكتساب السلوك الذكي، حيث يُقصد بالذكاء قدرة الكيان على التصرف بطريقة ملائمة واستشرافية ضمن بيئته* (Cockburn *et al.*, 2018: 122). أما كابلان وهاينلاين فقد قدما تعريفًا آخر للذكاء الاصطناعي باعتباره *قدرة النظام على تحليل البيانات الخارجية بدقة، واستخلاص المعرفة منها، ثم توظيف تلك المعرفة بمرونة من أجل تحقيق أهداف ومهام محددة* (Kaplan & Haenlein, 2019: 17)..

ويتكون مصطلح **الذكاء الاصطناعي** (Artificial Intelligence) من كلمتين رئيسيتين هما: *الذكاء (Intelligence) والاصطناعي (Artificial)*، ولكلٍ منهما دلالته الخاصة التي تُسهم في تحديد المفهوم العام لهذا المصطلح. فمصطلح **الذكاء** (Intelligence) يشير إلى القدرة على استيعاب الظروف الجديدة والمتغيرة، ويشمل مهارات متعددة مثل التخطيط، والتحليل، والتمثيل العقلي السريع، وحل المشكلات، إضافةً إلى التفكير المجرد، والتواصل اللغوي، وتنظيم الأفكاء، وسرعة اكتساب المعرفة. أما مصطلح **الاصطناع** (Artificial) فيُعبر عن كل ما يتم إنتاجه أو تصميمه من قِبل الإنسان، في مقابل ما يوجد بصورة طبيعية أو ينشأ تلقائيًا دون تدخل بشري. (القرعان و بابوق، 2024: 1020).

6.2 تقنيات الذكاء الاصطناعي

تتضمن تقنيات الذكاء الاصطناعي مجموعة من الأساليب التي يمكن أن تخدم مجالات مختلفة، منها المجال المالي. ومن بين هذه التقنيات: النظم الخبيرة، الشبكة العصبية، التعلم العميق، وتقنيات التعلم الآلي. والتي تستخدم لتحليل البيانات المالية ودعم اتخاذ القرارات وتحسين دقة التنبؤات المالية.

– النظم الخبيرة:(Expert Systems)

هي نوع من **أنظمة المعلومات** المصممة للمساعدة في حل المشكلات عبر الاستفادة من المعرفة المتخصصة في مجال معين، بناءً على خبرة الإنسان في هذا المجال. ويعمل هذا النظام على **دعم عملية اتخاذ القرار** من خلال طرح أسئلة محددة وتقديم التبريرات التي تفسر اختيار الإجراءات المتخذة (حمد و نصيب، 2017: 189.)

– الشبكة العصبية:(Neural Network)

تعرف بأنها منظومة لمعالجة البيانات بطريقة مشابهة للشبكة العصبية الحقيقية في الإنسان، حيث تتكوَّن من مجموعة من الخلايا المخصصة لمعالجة المعلومات. وتتميز الشبكة العصبية بعدة خصائص، منها اعتمادها على أسس رياضية، وتصنيفها كأحد تطبيقات تقنيات المعالجة الذكية للمعلومات التي تحاكي عمل العقل البشري. كما تتعامل مع مختلف أنواع البيانات، سواء كانت كمية أو نوعية، وتمتلك القدرة على تخزين المعرفة الضمنية بالاستناد إلى الخبرات السابقة، ويمكن تطبيقها في شتى المجالات العلمية. (المالكي، 2023: 96).

– التعلم العميق:(Deep Learning)

تمثل بنية التعلم العميق مجموعة من الطبقات المتعددة المكوّنة من وحدات بسيطة، تخضع جميعها أو معظمها لعمليات التعلم، حيث تقوم كل وحدة بحساب التحويلات غير الخطية بين المدخلات والمخرجات. تعمل كل وحدة على تحويل مدخلاتها بهدف تعزيز الانتقائية وثبات التمثيل، من خلال الطبقات غير الخطية المتعددة. وعندما يصل عمق الشبكة إلى ما بين 5 و20 طبقة، يصبح النظام قادرًا على أداء مهام معقدة على مدخلاته مع الحفاظ على الحساسية للتفاصيل الدقيقة. وتعتمد العديد من تطبيقات التعلم العميق على هياكل الشبكات العصبية ذات التغذية الأمامية، التي تتعلم ربط مدخلات بحجم ثابت بمخرجات ذات حجم ثابت عبر الانتقال من طبقة إلى التالية لها (LeCun *et al.*, 2015: 3).

–التعلم الآلي:(Machine Learning) تم تعريفه من قبل (شقفة، 2021: 23) على أنه مجموعة من الأساليب الحسابية التي تُستخدم للاستفادة من الخبرة في تحسين الأداء أو لإجراء تنبؤات دقيقة. وتشير الخبرة هنا إلى المعلومات السابقة المتاحة للتعلم، والتي

غالبًا ما تكون على شكل بيانات إلكترونية يتم جمعها وتوفيرها لأغراض التحليل. وتمثل خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) أحدى اهم خوارزميات التعلم الآلي الخاضعة للأشراف.

7.2 مفهوم خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM)

تمثل خوارزمية تعلم آلي خاضعة للإشراف، وأصبحت من أكثر التقنيات شيوعًا في مجال التصنيف نظرًا لقدرتها العالية على رفع دقة النتائج.(Ali *et al.*, 2016: 501) وتُعتبر من أفضل وأحدث خوارزميات التعلم الخاضع للإشراف، إذ تم اقتراحها للمرة الأولى عام 1964، ثم شهدت تطويرًا مهمًا في تسعينيات القرن الماضي على يد الباحث فايبنك. تبحث هذه الخوارزمية عن أفضل مستوى فاصل (Hyperplane) قادر على تصنيف البيانات بدقة، بحيث تقل نسبة أخطاء التصنيف كلما اتسعت المسافة بين نقاط البيانات ومستوى الفاصل. تُعد خوارزمية (SVM) فعالة للغاية في التعامل مع مشكلات تصنيف الصور والنصوص المكتوبة يدويًا، كما تُستخدم في مهام التصنيف والانحدار استنادًا إلى نظرية التعلم الإحصائي. ويمكن كذلك توظيفها في تحليل العلاقات بين المجموعات الكبيرة من البيانات الإحصائية (الفريجي و عبد القادر، 2025: 5).

8.2 آلية عمل خوارزمية (SVM)

تعتمد آلية عملها على استكشاف البيانات، وهي عملية تهدف إلى فحص البيانات بهدف استخراج الأنماط والقواعد التي تُمثلها، والتي يصعب الوصول إليها بوسائل التحليل التقليدية. ويتم ذلك من خلال تصنيف البيانات المتشابهة وإنشاء نموذج أو عدة نماذج تعكسها باستخدام تحليل الانحدار لتلك البيانات.

تتضمن عملية التصنيف مرحلتين أساسيتين، هما مرحلة التدريب ومرحلة الاختبار:

- **المرحلة الأولى:** تُعرف بمرحلة التدريب، حيث يُزوّد النظام بمجموعة من البيانات تُسمى بيانات التدريب (Training Dataset)، وتعمل خوارزمية الدعم الآلي اعتمادًا على هذه البيانات في بناء نموذج قادر على تحديد التصنيفات، وذلك عبر إيجاد فاصل يميز خصائص كل فئة من الفئات أو أكثر.

– **المرحلة الثانية:** وهي مرحلة الاختبار (Validation)، وتأتي بعد إتمام مرحلة التدريب، حيث يتم بالاعتماد على ما تم تعلمه مسبقًا تصنيف مجموعة جديدة من البيانات، من خلال تحديد موقع كل عنصر بالنسبة للحد الفاصل. وتتمثل مهمة خوارزمية الدعم الآلي في هذه المرحلة في إيجاد **المستوى الفائق**. (قرنداش وآخرون، 2022: 101).

*المستوى الفائق: هو الخط الذي يقوم بالفصل الخطي بين مجموعات البيانات لتصنيفها. وبشكل منطقي، كلما ازدادت المسافة بين النقاط والمستوى الفائق، ارتفعت درجة الثقة في أن التصنيف تم بدقة. لذلك يُفضّل أن تكون النقاط بعيدة قدر الإمكان عن هذا المستوى مع بقائها ضمن الجهة الصحيحة من الحد الفاصل. وبناءً على ذلك، عند إدخال بيانات جديدة للاختبار، تُصنّف استنادًا إلى الجهة التي تقع فيها بالنسبة للمستوى الفائق. (Bambrick, 2016).

9.2 دور الذكاء الاصطناعي في دعم التحليل التنبؤي واتخاذ القرار المالي

شهدت الأسواق المالية تغيرات جوهرية نتيجة دمج تقنيات الذكاء الاصطناعي في مجالات التحليل وصنع القرار. ففي حين كان المستثمرون في السابق يعتمدون على أدوات تقليدية تتطلب وقتًا وجهدًا كبيرين لمعالجة البيانات، أصبح من الممكن اليوم استخدام أنظمة ذكية قادرة على معالجة ملايين البيانات خلال ثوانٍ معدود (FreeTech, 2025)، وتعتمد تقنيات الذكاء الاصطناعي في أدائها على استيعاب كميات ضخمة من بيانات التدريب المصنفة، ثم تحليلها بهدف اكتشاف الأنماط والعلاقات والارتباطات، وتوظيف تلك الأنماط في التنبؤ بالعمليات المستقبلية (رؤوف، 2025). فالذكاء الاصطناعي لم يعد مجرد أداة، بل أصبح محفزًا لتغيير غير مسبوق داخل المؤسسات. وتشمل هذه التحولات تأثيرات واضحة في رضا العملاء، وبروتوكولات الحماية، وإدارة المخاطر، والكفاءة التشغيلية، والعائد على الاستثمار، والالتزام بالأنظمة التنظيمية. كما يشهد استخدام الذكاء الاصطناعي وتقنيات التعلم الآلي (ML) تزايدًا في المؤسسات المالية، وتشمل تطبيقاته التداول الخوارزمي، وإدارة المخاطر، والكشف عن الاحتيال، وتقييم الجدارة الائتمانية، وخدمة العملاء (Hidayat, 2024:2).

وفي هذا الإطار، أتاحت خوارزميات الذكاء الاصطناعي للمؤسسات التعامل مع مجموعات ضخمة من البيانات واستخلاص الأنماط والعلاقات المعقدة التي يصعب اكتشافها بالوسائل التقليدية (FasterCapital, 2025). وفي ضوء ما تقدم، وبصورة أشمل، يُحدث التحليل التنبؤي باستخدام الذكاء الاصطناعي تحولًا جذريًا في أساليب تقديم الخدمات المالية وإدارة المخاطر والاستثمار، إذ يمنح المؤسسات المالية ميزة تنافسية وفرصًا أوسع لتحقيق قيمة مضافة لعملائها. ومع استمرار تطور الذكاء الاصطناعي، تتوسع إمكانيات التحليل التنبؤي في بيئة التكنولوجيا المالية المتغيرة، مع ضرورة تحقيق تـوازن بيـن التقنيـة والرقابـة البشريـة لضمـان سلامة القرارات أخلاقيًا وقانونيًا. (Dattana *et al.*, 2023: 79) ويُعد القرار الاستثماري من أكثر القرارات تعقيدًا لارتباطه الوثيق بالجانب المالي، إذ يهدف إلى تحديد الهيكل المالي الأمثل الذي يضمن تحقيق استثمارات قادرة على توليد عوائد مستقبلية. وتؤثر هذه القرارات بشكل مباشر في نمو الشركة واستمرارها، مما يجعل صياغة سياسة استثمارية دقيقة ومنسجمة مع أهدافها أمرًا ضروريًا (المسعودي، 2023: 62).

المبحث الثالث \ الجانب العملي

1.3 تحليل المؤشرات المالية للشركة الصناعية (المنصور للصناعات الدوائية) المدرجة في سوق العراق للأوراق المالية

تعد المؤشرات المالية من الركائز الأساسية في تحليل الأداء المالي، إذ تُستخدم لتقييم كفاءة الشركة من ناحية، ودرجة المخاطرة المرتبطة بها من ناحية أخرى، مما يعزز من عملية اتخاذ القرار الاستثماري على أسس علمية دقيقة. وبناءً على ذلك، ركز هذا البحث على مجموعة من المؤشرات المتعلقة بالعائد والمخاطرة، وهي:العائد على الاستثمار (Return on Investment – ROI)، والعائد على حقوق الملكية (Return on Equity – ROE)، والمخاطرة النظامية (Systematic Risk)، والمخاطرة اللانظامية (Unsystematic Risk)، والمخاطرة الكلية (Total Risk) وتعتبر هذه المؤشرات من أهم الأدوات الجوهرية التي تعكس استدامة ربحية الشركة لكل من المستثمرين والمديرين، كما تسهم في تقييم الأداء المالي العام للشركات.

– حساب العائد على الاستثمار ((ROI والعائد على حق الملكية (ROE):

تم جمع بيانات الموجودات وحقوق الملكية والأرباح من التقارير الرسمية الصادرة عن شركة المنصور للصناعات الدوائية، والمنشورة في سوق العراق للأوراق المالية. واستنادًا إلى هذه البيانات، تم حساب كل من العائد على الاستثمار (ROI) والعائد على حقوق الملكية (ROE)، تم الاعتماد على البيانات الربع سنوية لسنة 2023 من شركة المنصور للصناعات الدوائية، وذلك بهدف تقديم صورة دقيقة لتطورات أداء الشركة خلال هذا العام. كما يبيّن الجدول (1) القيم التفصيلية لهذه المؤشرات.

الجدول (1) حساب العائد على الاستثمار والعائد على حق الملكية

السنة	الربع	الموجودات	حق الملكية	صافي الربح	ROI	ROE
2023	الأول	16845156463	15691576488	-263690755	-0.015653803	-0.016804606
	الثاني	16661553631	15600942909	-412391990	-0.024751113	-0.026433786
	الثالث	17149608175	15675365101	-357659756	-0.020855273	-0.022816678
	الرابع	18997668339	16002505057	311228213	0.016382442	0.019448718

المصدر: من إعداد الباحثة بالاعتماد على البيانات المالية الربع سنوية للشركة الصناعية (عينة البحث) المنشورة في سوق العراق للأوراق المالية.

يوضح الجدول (1) تطورات الموجودات وحقوق الملكية والأرباح لشركة المنصور للصناعات الدوائية خلال الأرباع الأربعة لسنة 2023، مع حساب العائد على الاستثمار (ROI) والعائد على حقوق الملكية (ROE). تظهر البيانات تقلبات الأرباح خلال السنة، حيث سجلت الشركة خسائر في الثلاثة أرباع الأولى، بينما حققت ربحًا في الربع الرابع، مما انعكس على تحسن نسب العائد على الاستثمار والعائد على حقوق الملكية بنهاية العام.

- حساب المخاطرة النظامية (Systematic Risk) والمخاطرة اللانظامية (Unsystematic Risk):

تعتمد المخاطرة النظامية على درجة ارتباط عوائد الشركة بحركة السوق ككل، ويتم قياس هذا الارتباط باستخدام معامل بيتا(β)، الذي يحسب من خلال مقارنة العائد الفعلي للسهم (Ri) بعائد السوق (Rm) استنادًا إلى البيانات الربع سنوية لعام 2023. وتعد القيمة المرجعية لمعامل بيتا (β) هي (1)، إذ تشير إلى أن السهم يتحرك في الاتجاه نفسه للسوق وبمستوى تقلب مماثل، في حين تدل القيمة الأكبر من (1) على أن السهم أكثر تقلبًا من السوق، أما القيمة الأقل من (1) فتعني أن السهم أقل تقلبًا. كما تُحسب المخاطرة اللانظامية من خلال قسمة متوسط العائد للسهم على الانحراف المعياري للعائد الفعلي، وذلك بالاعتماد على البيانات الربع سنوية للسنة الواحدة، كما يبين الجدول (2) نتائج احتساب المخاطرتين النظامية واللانظامية.

الجدول (2) قياس قيمة المخاطرة النظامية والمخاطرة اللانظامية

سعر الاغلاق	العائد الفعلي (Ri)	مؤشر السوق	عائد السوق (Rm)	السنة	معامل بيتا (β) (النظامية)	الانحراف المعياري	المتوسط	المخاطرة اللانظامية
2.170	0.41830	611.830	103.230	2023	0.0041427	0.246888256	0.13327	1.8525749
2.140	-0.0138	637.070	0.041					
2.130	-0.0046	641.460	0.007					
2.120	-0.0046	809.800	0.262		0.1010653	0.042548857	-0.04871	-0.8735081
1.930	-0.0896	835.530	0.032					
1.830	-0.0518	667.170	-0.202					
1.800	-0.0163	717.060	0.075		0.0035853	0.005388076	-0.01104	-0.4880131
1.780	-0.0111	858.33	0.197					
1.770	-0.0056	929.19	0.083					
1.790	0.01130	808.550	-0.130		-0.055065	0.006523732	0.00377	1.7320508
1.790	0.00000	880.950	0.090					
1.790	0.00000	893.150	0.014					

المصدر: من إعداد الباحثة بالاعتماد على البيانات المالية الربع سنوية للشركة الصناعية (عينة البحث) المنشورة في سوق العراق للأوراق المالية.

يوضح الجدول (2) أن معامل بيتا (β) خلال سنة 2023 لم يكن ثابتًا، بل تغير عبر الأرباع، حيث كانت القيمة منخفضة جدًا في الربع الأول 0.0041، مما يشير إلى تحرك ضعيف للسهم بنفس اتجاه السوق تقريبًا في الربع الثاني ارتفعت القيمة إلى 0.101، مما يعكس زيادة طفيفة في حساسية السهم لتقلبات السوق. أما في الربع الثالث فقد انخفضت إلى 0.0036، وهو ما يشير إلى أن السهم كان يتحرك بشكل شبه مستقل عن السوق، بينما في الربع الرابع سجلت قيمة سالبة -0.055، مما يدل على تحرك السهم في اتجاه معاكس للسوق بدرجة محدودة. وهو ما يعكس تقلبات متفاوتة وزيادة طفيفة في المخاطرة النظامية. كما توضح قيم المخاطرة اللانظامية مدى تشتت العوائد الفعلية للسهم بعيدًا عن تأثير السوق، وهو مؤشر على المخاطر الخاصة بالشركة نفسها..

- حساب المخاطرة الكلية (Total Risk):

تمثل المخاطر الكلية مجموع المخاطرة النظامية واللانظامية، وهي تعكس القيمة النهائية لحساب المخاطرة في الأسواق المالية. ويعتمد بعض المحللين على المخاطر

الكلية باعتبارها مؤشرًا لتلاقي كلا النوعين من المخاطر، إذ يمكن أن يؤثر أحدهما على الآخر. ومع ذلك، فإن الاعتماد على المخاطر الكلية وحدها يُعد مخاطرة عند اتخاذ القرار الاستثماري بشأن قطاع معين أو شركة محددة، نظرًا لاعتمادها على التأثير المتبادل بين المخاطرتين النظامية واللانظامية، لاحظ جدول 3.

الجدول (3) المخاطرة الكلية

السنة	الربع	المخاطرة النظامية	المخاطرة اللانظامية	المخاطرة الكلية
2023	الأول	0.004	1.853	1.857
	الثاني	0.101	-0.874	-0.772
	الثالث	0.004	-0.488	-0.484
	الرابع	-0.055	1.732	1.677

المصدر: من إعداد الباحثة بالاعتماد على بيانات الجدولين (1) و (2).

2.3 استعمال الذكاء الاصطناعي تحديداً خوارزمية (SVM) في تدعيم وتحسين دقة المؤشرات المالية للشركة الصناعية (شركة المنصور للصناعات الدوائية) المدرجة في سوق العراق للأوراق المالية

- تجهيز البيانات ومعالجتها (Data Preprocessing):

لضمان جودة المدخلات للنماذج، تم اتباع بروتوكول دقيق لمعالجة البيانات الأولية المستخرجة، والذي شمل الخطوات التالية:

- استيراد البيانات: تم تحميل البيانات ومعالجتها باستخدام مكتبة pandas ضمن بيئة Python.

- معالجة القيم الناقصة: تم التعامل مع أي قيم مفقودة بواسطة استراتيجية التعبئة الأمامية (forward fill)، التي تقوم بملء الفجوات بآخر قيمة صالحة، وهو أسلوب مناسب للبيانات الزمنية.

- إعادة أخذ العينات:(Resampling) لضمان بناء نماذج خالية من التحيز، تم توحيد عدد العينات لكل شركة عند 200 عينة. تعمل هذه الخطوة على معالجة مشكلة عدم توازن البيانات، وتضمن أن يتعلم النموذج من عدد متساوٍ من الأمثلة لكل فئة تصنيفية ("أشجع" / "لا أشجع").

- معالجة البيانات وبناء النموذج: تم تقسيم بيانات الشركة عينة البحث إلى مجموعتين رئيسيتين: **تعرف المجموعة الأولى بمجموعة التدريب** (Training Set) تمثل 80% من إجمالي البيانات، وتُستخدم لتدريب النموذج وتعليمه الأنماط الموجودة ضمن البيانات. **والمجموعة الثانية يطلق عليها مجموعة الاختبار** (Test Set) تمثل الـ20% المتبقية من البيانات، وتُستخدم لتقييم أداء النموذج النهائي، بما يوفر مقياسًا غير متحيز لقدرة النموذج على التعامل مع بيانات مستقبلية.

تم اختيار هذه النسبة (20/80) لأنها تعد من الممارسات القياسية في مجال تعلم الآلة، حيث توازن بين توفير حجم بيانات كافٍ للتدريب الفعال والاحتفاظ بمجموعة اختبار قوية لضمان تقييم دقيق لأداء النموذج.

- مقاييس تقييم الأداء: لتقييم أداء النماذج بشكل موسع وشامل في كل تجربة، تم الاعتماد على مجموعة متكاملة من المقاييس المستخلصة من مصفوفة الارتباك (Confusion Matrix)، وهي: (الدقة الإجمالية (Accuracy)، الدقة النوعية (Precision)، الاستدعاء (Recall)، مقياس F1-Score (F1-Score)).

3.3 تحليل نتائج شركة المنصور للصناعات الدوائية (IMAP)

أوضح النموذج المخصص للشركة وجود **اختلاف واضح في الأداء تبعًا لعدد الخصائص المستخدمة.** وسُجل أفضل أداء عند الاعتماد على خاصيتين فقط (Features = 2)، حيث وصلت **دقة التصنيف إلى** 75%. ويكشف تحليل **مصفوفة الارتباك** لأداء النموذج على عينة الاختبار المكونة من 40 مشاهدة عن النقاط التالية:

- **التصنيفات الصحيحة** (عند Features=2): صنف النموذج 30 مشاهدة بشكل صحيح، حيث تضمنت 22 مشاهدة ضمن الفئة السالبة الصحيحة (True Negatives – TN) و8 مشاهدات ضمن الفئة الموجبة الصحيحة.(True Positives – TP)

- التصنيفات الخاطئة (عند Features=2): وقع النموذج في خطأ تصنيف 10 مشاهدات، موزعة بالتساوي بين 5 مشاهدات كـ (False Positives – FP) و5 مشاهدات كـ (False Negatives – FN), كما موضح في الشكلين 2 و 3 أدناه.

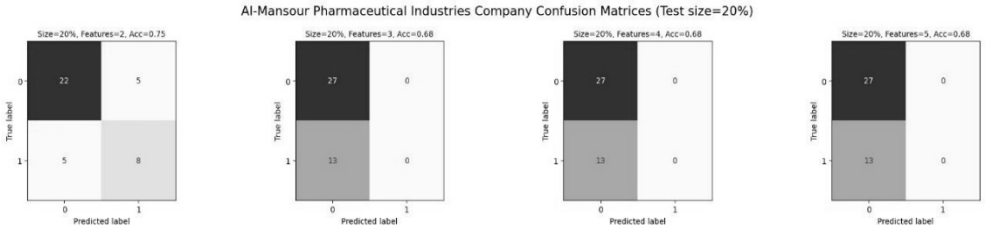

الشكل (2): مصفوفة الارتباك لشركة المنصور للصناعات الدوائية

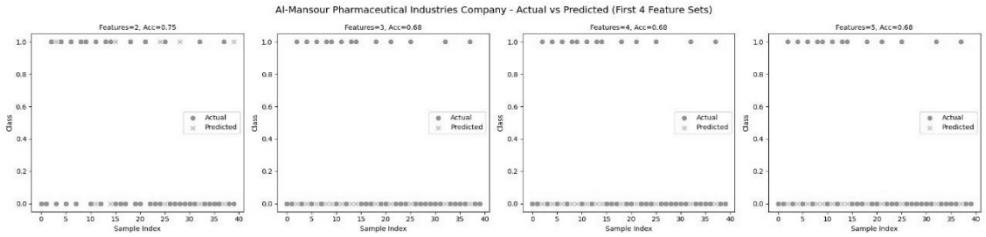

الشكل (3): التنبؤات الفعلية مقابل المتوقعة لشركة المنصور للصناعات الدوائية

- **التحليل والاستنتاج:** عند استخدام خاصيتين فقط (ROI, ROE) أظهر النموذج أداءً متوازنًا نسبيًا. إلا أن الملاحظة الأبرز تكمن في **تدهور الأداء بشكل كبير عند زيادة عدد الخصائص إلى ثلاث أو أكثر**، حيث انخفضت الدقة إلى 68%، وأصبح النموذج غير قادر على تصنيف أي حالة موجبة.(TP = 0) ويشير هذا إلى أن الخصائص الإضافية أدخلت **ضوضاء** (Noise)، مما أدى إلى **تحيز النموذج الكامل نحو التصنيف السلبي**، وجعل أدائه غير مستقر، وغير موثوق إلا عند استخدام تكوينه الأبسط.

- تحليل مقارن مفصل لأداء النماذج على مستوى الشركة

من أجل **تكوين صورة واضحة ومتكاملة** حول أداء النماذج المختلفة، تم **تجميع نتائج مقاييس الأداء لشركة المنصور للصناعات الدوائية** المدرجة في سوق العراق للأوراق المالية في الجدول (4)، بالاعتماد على **أعلى دقة سجلها كل نموذج.**

الجدول (4) النتائج التفصيلية والمقارنة لمقاييس أداء نماذج SVM (تقسيم 80/20)

ت	اسم الشركة	الدقة (Accuracy)	الدقة النوعية (Precision)	الاستدعاء (Recall)	مقياس F1 (F1 – Score)
1	المنصور للصناعات الدوائية	75%	75%	75%	75%

المصدر: إعداد الباحثة.

يوضح الجدول (4) بأن نموذج شركة المنصور للصناعات الدوائية حقق أداءً متوازنًا بنسبة 75% في جميع المقاييس، مما يعكس استقرار النموذج وقدرته على التمييز بين الفئات الإيجابية والسلبية بشكل متساوٍ ضمن نطاق البيانات المستخدمة، ويؤكد فعالية خوارزمية SVM والمؤشرات المالية المختارة في التنبؤ بالأداء المالي للشركة. وتعكس الدقة النوعية البالغة 75% قدرة النموذج على التعرف بدقة على الأنماط المالية وتقليل الأخطاء في التنبؤ بالفئات المختلفة، مما يوضح فعالية النموذج في تحليل الأداء المالي للشركة بشكل متوازن وواضح.

– اختبار فرضية البحث في ضوء النتائج التجريبية المفصلة

تم اختبار هذه الفرضية باستخدام خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) لتصنيف نتائج مؤشرات الأداء المالي (العائد على الاستثمار، العائد على حق الملكية، المخاطرة النظامية، والمخاطرة اللانظامية، والمخاطر الكلية). واستنادًا إلى نتائج نموذج شركة المنصور للصناعات الدوائية، يظهر أن استخدام المؤشرات المالية المدعمة بخوارزمية (SVM) أسفر عن تحقيق دقة متوازنة بنسبة 75% في جميع مقاييس الأداء (الدقة، الدقة النوعية، الاستدعاء، ومقياس F1)، مما يعكس قدرة النموذج على التنبؤ بالأداء المالي للشركة بشكل متناسق وفعال وتقليل احتمالات الأخطاء في التصنيف. ويشير هذا الأداء إلى أن استخدام خوارزمية SVM مع المؤشرات المالية ساهم في تحسين سرعة ودقة التنبؤ مقارنة بالأساليب التقليدية، حيث تمكن النموذج من التعرف على الأنماط الأساسية والمخفية في البيانات المالية للشركة بدقة ملحوظة.

بناءً على ذلك، يمكن رفض الفرضية (H0) التي تنص على أن استعمال المؤشرات المالية المدعمة بخوارزمية SVM لا يؤثر في دقة وسرعة التحليل المالي ولا يقلل من

معدلات الخطأ، وقبول الفرضية البديلة (H1) التي تؤكد أن استخدام هذه المؤشرات المدعمة بالخوارزمية يسهم في تحسين دقة وسرعة التنبؤ وتقليل معدلات الخطأ في التحليل المالي لشركة المنصور ضمن نطاق البيانات المستخدمة.

المبحث الرابع \ الاستنتاجات والتوصيات

1.4 الاستنتاجات

1) أظهرت نتائج البحث أن استخدام المؤشرات المالية الأساسية المُدعمة بخوارزمية آلة المتجهات الداعمة (SVM) ساهم في تقديم تنبؤات أكثر دقة للأداء المالي للشركة الصناعية عينة البحث المدرجة في سوق العراق للأوراق المالية.
2) ساعد النموذج في الكشف المبكر عن المخاطر المالية المحتملة، مما يعكس فعالية خوارزمية (SVM) في تحليل البيانات، مما يتيح للمستثمرين والشركة اتخاذ قرارات أكثر وعياً وأكثر دقة.
3) بينت النتائج أن الاعتماد على المؤشرات المالية الأساسية فقط أسهم في استقرار أداء النموذج، بينما إضافة متغيرات أخرى قد تقلل من الدقة بسبب ضوضاء البيانات.
4) أظهرت التجربة مرونة النموذج في التكيف مع طبيعة البيانات الفريدة لشركة المنصور للصناعات الدوائية، مؤكدة على قدرة خوارزمية (SVM) على التنبؤ بالأنماط المالية المهمة.
5) تؤكد النتائج صحة فرضية البحث، إذ أثبتت التجارب أن دمج المؤشرات المالية مع تقنيات الذكاء الاصطناعي أدى إلى تحسين دقة تقييم الأداء المالي وزيادة موثوقية التنبؤات.
6) توفر النتائج أساسًا متينًا لتطوير النماذج المستقبلية وإمكانية إدخال مؤشرات مالية إضافية أو تحسين آليات التحليل لتعزيز الدقة والكفاءة.

2.4 التوصيات

1) تعزيز جودة البيانات المالية للشركة، مع التركيز على المؤشرات الأساسية لتقليل الأخطاء وتحسين دقة النماذج المدعمة بالذكاء الاصطناعي.

2) تطوير البنية التحتية الرقمية والأنظمة المحاسبية لدعم تحليل البيانات المالية بشكل أفضل.
3) تدريب الكوادر المالية والتقنية على استخدام خوارزميات الذكاء الاصطناعي لضمان استيعاب النموذج وتطبيقه بكفاءة.
4) توسيع نطاق التحليل مستقبلاً بإضافة مؤشرات مالية جديدة ومقارنة نتائجها بالنموذج الحالي للوصول لأفضل أداء ممكن.
5) استخدام النموذج كأساس لتحليل اتجاهات الأداء المالي للشركة على المدى الطويل، مع متابعة التحديث الدوري للبيانات لضمان موثوقية النتائج واستقرارها.

المصادر

1. بايوق، لبنى سمير و القرعان، دعاء محمود (2024)، تقنيات الذكاء الاصطناعي وأثرها على المجتمعات الإنسانية، الجامعة الاردنية، كلية الأمير حسين بن عبدالله الثاني للدراسات الدولية، مجلة جامعة الزيتونة الاردنية للدراسات القانونية، المجلد 5، ص (1016–1038).
2. الـبُـلك، وليد خالد (2020)، تقييم وتسعير الأصول المالية، جامعة القاهرة، كلية التجارة، ص (1–225).
3. بن حمي، عبد القادر و دادة، مراد (2022)، مؤشرات قياس الأداء ودورها في تحسين الأداء المالي لشركات التامين، دراسة الصندوق الجهوي للتعاون ألفلاحي أدرار، رسالة مقدمة لنيل شهادة الماجستير في علوم مالية ومحاسبة، جامعة احمد دراية–ادرار، ص (1–35).
4. بوخاري، عبد الحميد و بن عوالي، إيمان (2021)، أثر تطبيق قواعد الحوكمة على الأداء المالي: دراسة ميدانية لعينة من المؤسسات الاقتصادية بالولايات المنتدبة تقرت، التنمية الإدارية والارتقاء بالمؤسسات الاقتصادية بولاية غرداية، جامعة غرداية، الجزائر، المجلد 7، العدد 1، ص (316–330).
5. جاسم، ماجد جودة (2019)، اثر المخاطرة الكلية في العائد على الموجودات والعائد على حق الملكية: دراسة تطبيقية في عينة من المصارف العراقية الخاصة، المجلة العراقية للعلوم الاقتصادية، المجلد 3، العدد 62، ص (40–55).
6. الحتو، عمر محمد هاشم (2015)، أثر المؤشرات المالية على المسؤولية الاجتماعية للشركات: دراسة تطبيقية على المصارف التجارية الأردنية للفترة 2003–2012، رسالة ماجستير غير منشورة، جامعة البلقاء التطبيقية، كلية الدراسات العليا، السلط، الاردن، ص (2–112).
7. حجاج، صليحة (2016)، دراسة قدرة مؤشرات الأداء المالي التقليدية والحديثة في تفسير عوائد الأسهم" دراسة حالة الشركات المدرجة في بورصة قطر للفترة (2010–2015)، رسالة ماستر اكاديمي في علوم اقتصادية والتسيير وعلوم تجارية، جامعة قاصدي مرباح، ورقلة – الجزائر، ص (2–75).
8. الخطيب، محمود محمد (2010)، الأداء المالي وأثره على عوائد أسهم الشركات الطبعة الأولى، دار الحامد للنشر والتوزيع، الأردن، ص (5–188).
9. الخمايسة، سجى طلال، صالح، رضا إبراهيم و صبري، أيمن محمد (2024)، أثر هيكل الملكية على الأداء المالي: دراسة تطبيقية على الشركات الصناعية المدرجة في سوق عمان المالي، مجلة الدراسات التجارية المعاصرة، المجلد10، العدد 18، ص (789–841).
10. خيرة، مجدوب (2020)، محاضرات في مقياس إدارة المخاطر المالية، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة ابن خلدون تيارت، قسم إدارة مالية، ص (1–101).

11. رؤوف، شيماء (2025)، كيفية الاستثمار بالذكاء الاصطناعي AI وما هي أفضل الأسهم. Arincen https://www.arinenc.com

12. شفاء، حمد و رجم، نصيب (2017)، دور الأنظمة الخبيرة في صناعة القرارات الإستراتيجية في منظمات الأعمال، مجلة العلوم الاجتماعية والإنسانية، العدد 13، ص (185-204).

13. صالح، ذكرى صالح و حياهم، يسرى (2022)، أثر التدقيق الداخلي على تحسين الاداء المالي، رسالة ماجستير، كلية العلم الاقتصادية والتجارية وعلوم التسيير، جامعة 8 ماي 1945 قالمة، ص (2-112).

14. عباس، غدير جاسم (2024)، تأثير قيمة رأس المال الفكري في كفاءة أداء أسهم الشركات الصناعية العراقية المساهمة -بحث تحليلي-، جامعة بغداد، كلية الإدارة والاقتصاد، رسالة ماجستير، ص (1-122).

15. العمراوي، زوبير (2023)، الادارة المالية المعمقة، جامعة محمد البشير الإبراهيمي برج بوعريريج، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، ص (1_157).

16. الفريجي، حيدر نعمة و عبد القادر، دعاء ذيب (2024)، أختيار المحفظة الاستثمارية المثلى لسوق العراق للأوراق المالية دراسة تطبيقية باستخدام خوارزمية الاسد للمدة (2010/1/1 - 2010/12/31)، مجلة كلية بغداد للعلوم الاقتصادية الجامعة، العدد 78، ص (1-15).

17. قرنداش، محمود، درويش، حنان كامل و محمد، عدنان احمد (2022)، تقييم خوارزميات التعلم الآلي لإنشاء خرائط الغطاء الأرضي من صور القمر الصناعيSentinel-2 س، مجلة جامعة البعث، كلية الهندسة المدنية، المجلد 44، العدد 13، ص (95-128).

18. قوتال، ابتسام (2023)، دروس في مقياس تسيير المخاطر المالية، كلية العلوم الاقتصادية والعلوم التجارية وعلوم التسيير، جامعة الجزائر3، قسم مالية ومحاسبة، ص (1-103).

19. المالكي، وفاء فواز (2023)، دور تطبيقات الذكاء الاصطناعي في تعزيز الاستراتيجيات التعليمية في التعليم العالي (مراجعة الأدبيات)، مجلة العلوم التربوية والنفسية، 7(5)، ص (93-107).

20. ماهر، أسعد حمدي محمد (2024)، أثر مؤشرات الاداء المالي في القيمة السوقية لأسهم عينة من المصارف التجارية في العراق للمدة (2010-2021)، مجلة جامعة التنمية البشرية، المجلد 10، العدد 2، ص (65-72).

21. FreeTech (2025)، الذكاء الاصطناعي في التنبؤ بالأسواق المالية: بين الفرص والمخاطر. تم الاسترجاع من https://freetech.tech

22. Ali, I., Saad, S., & Ahmed, S. (2016), Using One-Class SVM with Spam Classification, Iraqi Journal of Science, Vol.57, NO.1B, pp (501-506).

23. Bambrick, N. (2016), Support Vector Machines: A simple explanation, KDnuggets. https://www.kdnuggets.com/2016/07/support-vector-machines-simple-explanation.html.

24. Cockburn, I. M., Henderson, R., & Stern, S. (2018), The impact of artificial intelligence on innovation (Vol. 24449), Cambridge, MA, USA: National bureau of economic research, pp (115-146).

25. Hidayat, M., Defitri, S. Y., & Hilman, H. (2024), The Impact of Artificial Intelligence (AI) on Financial Management, Management Studies and Business Journal (PRODUCTIVITY), 1(1), PP (123-129).

26. Kaplan, A., & Haenlein, M. (2019), Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence, Business horizons, 62(1), pp (15-25).

27. Kayakus, M., Tucu, B., Terzioglu, M., Talaş, H., & ünal Uyar, G. F. (2023), ROA and ROE forcasting in iron and steel industry using machine learning techniques for sustainable profitability, Sustainability ,15, 7389, pp (1-14).

28. LeCun, Y., Bengio, Y., & Hinton, G. (2015), Deep learning, nature, 521(7553), pp (436-444).