



AL- Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

مجلة كلية الرافدين الجامعة للعلوم

Available online at: <https://www.jrucs.iq>

JRUCS

Journal of AL-Rafidain
University College for Sciences

تصنيف بيانات الأسهم المالية باستخدام تقنية آلة الموجه الداعم في التعليم الاحصائي

| | |
|--|--|
| محمد هشام ابراهيم | ا.م.د. اسماء غالب جابر |
| mohammed.ibrahim1201@coadec.uobaghdad.edu.iq | drasmaa.ghalib@coadec.uobaghdad.edu.iq |
| قسم الاحصاء - كلية الادارة والاقتصاد - جامعة بغداد، بغداد، العراق | |

| المستخلص | معلومات البحث |
|---|--|
| <p>تعد الاسواق المالية بانها ذات حركة مستمرة وديناميكية ومتسارعة مما يؤدي الحاجة الى طرائق ووسائل التقنية في التحليل واتخاذ القرارات وذلك يدفع المستثمرين والمحللين في الاسواق المالية الى استخدام اساليب التحليل المختلفة للوصول الى اساليب التنبؤ بحركة اتجاه السوق المالي لاتخاذ القرارات في الاستثمارات المختلفة لأجل تحديد اتجاه حركة الأسهم اذ تم استخدام طريقة آلة المتجه الداعم svm لتصنيف بيانات الأسهم المالية لتحديد اتجاه الأسهم فيما اذا كانت ذات اتجاه صاعد او هابط. ان الهدف من البحث هو تصنيف بيانات الأسهم المالية باستخدام خمسة متغيرات حيث تم استخدام بيانات المصرف العراقي الاسلامي للاستثمار والتنمية لتوضيح طريقة آلة المتجه الداعم حيث اظهرت النتائج دقة هذه التقنية وكان اداء تقنية آلة الموجه الداعم جيدا.</p> | <p>تواريخ البحث: تاريخ تقديم البحث: 2021/6/21 تاريخ قبول البحث: 2021/9/13 تاريخ رفع البحث على الموقع: 2022/6/25</p> <p>الكلمات المفتاحية: آلة المتجه الداعم، تصنيف، الأسهم المالية</p> <p>للمراسلة: محمد هشام ابراهيم mohammed.ibrahim1201@coadec.uobaghdad.edu.iq DOI: https://doi.org/10.55562/jrucs.v51i1.526</p> |

1. المقدمة

تعد الاسواق المالية بكونها ذات اهمية في الاقتصاد والمالية وذلك لما تمتلكه من امكانية في انعاش الاقتصاد وايضا تكون مصدر استثمارات للأموال وان الاسواق المالية تتميز بانها نظام ديناميكي وتحتوي على كميات كبيرة من البيانات وان عملية تصنيف اتجاه حركة الأسهم والتي تتصف بكثافة البيانات غير منظمة وتحتوي على العلاقات الخفية وان حركة اسعار السوق تكون غير عشوائية ديناميكية وغير خطية. ان تصنيف اتجاه حركة الأسهم تتصف بكونها غير خطية.

يهدف البحث الى استخدام طريقة Support vector machines (Svm) وان آلة المتجه الداعم وهي احدى خوارزميات تعلم الآلة machine learning حيث تتميز بقدرتها على التحكم بدالة القرار Decision function وامكانياتها على استخدام دالة اللب Kernel function.

تعد آلة المتجه الداعم Support vector machines بانها واسعة الانتشار وذلك لإمكانيتها على حل المسائل غير الخطية من خلال تحويل البرمجة التربيعية Quadratic programming وكذلك ان آلة المتجه الداعم يكون حلها فريد والافضل عالميا وتم استخدام طريقة العبور الشرعية Cross-validation وذلك لتجنب مشكله الافراط في المطابقة وكذلك عن طريق تحديد اكبر هامش maximum margin للحد الفصل plane

هنالك العديد من الدراسات السابقة التي تناولت موضوع آلة الموجه الداعم فيما يلي عرض بعض هذه الدراسات ومنها قام الباحثان (غيداء وسجي) سنة 2014 باكتشاف نسبة التصحر في منطقة الحضر بالاعتماد على محتويات الصور.

نشر الباحثان (رنا وغيداء) سنة 2018 دراسة مقارنة لخوارزميات التنقيب وتحليل العواطف وتطبيقاتها كما قدم (Rosillo & fuente) سنة 2014 محاكاة لسوق الأسهم باستخدام آلة المتجه الداعم.


2. الجانب النظري

2.1. آلة المتجه الداعم (Support vector machines)

وهي من تقنيات التصنيف في تنقيب البيانات و احدى خوارزميات التعليم المشرف او الموجه Supervised والتي تقوم بتصنيف البيانات وذلك عن طريق ايجاد افضل مستوى فاصل hyper plane حيث تم التوصل الى هذه الطريقة عام 1992 من قبل Vapnik وتعد من الأنظمة التي تستند الى نظرية التعليم الاحصائية Statistical learning theory وتقوم طريقة آلة المتجه الداعم svm بتصنيف البيانات الى فئات بواسطة المستوى الفاصل Hyper plane وكذلك تستخدم آلة المتجه الداعم بالإضافة الى التصنيف في حل مسائل الانحدار Regression. فيما يأتي انواع آلة الموجه الداعم

1. آلة المتجه الداعم الخطي Linear Support vector machines

حيث يتم فصل البيانات خطيا بواسطة الحد الفاصل Hyper plane اذا كانت البيانات ثنائية الابعاد $D=2$. الابعاد مقسومة قسمين وكالاتي (حيث D تمثل عدد الابعاد) اما اذا كانت متعددة الابعاد $D>2$ فان البيانات تنقسم الى ثلاثة خطوط من الحل الافضل كالاتي:



شكل(1): آلة المتجه الداعم svm الخطي


Source: Baraithiya, H., & Pateriya, R. K. (2019). Classifiers ensemble for fake review detection. Int. J. Innov. Technol. Explor. Eng, 8(4), 730-736.

x : تمثل متغير بيانات المشاهدات

b : تمثل متغير حد التحيز

2. آلة المتجه الداعم غير الخطي Nonlinear support vector machines

هنالك حالات لا يمكن فصل البيانات بصورة خطية لذلك تستخدم طريقة دالة اللب kernel والتي تقوم بتحويل الحالة الخطية الى حالة غير خطية وكالاتي:



شكل (2): يمثل آلة المتجه الداعم svm غير الخطي

Source: Hussain, L., Awan, I. A., Aziz, W., Saeed, S., Ali, A., Zeeshan, F., & Kwak, K. S. (2020). Detecting congestive heart failure by extracting multimodal features and employing machine learning techniques. BioMed research international, 2020.

φ: تمثل تعيين من مساحة الادخال الى مساحة المشاهدات

3. صيغة آلة المتجه الداعم (Formula Support Vector Machines)

ان طريقة آلة المتجه الداعم Svm تقوم بعملية التصنيف وذلك عن طريق وضع البيانات الى احدى جهتي الحد الفاصل وتهدف طريقة آلة المتجه الداعم الى بناء الحد الفاصل كسطح قرار وذلك ليكون الهامش الفاصل بين البيانات ذات الفئة الموجبة والسالبة لتكون اكبر ما يمكن (maximized). ان طريقة آلة المتجه الداعم تسعى الى ايجاد دالة القرار والغاية هي ان نجد دالة القرار التي تقلل من تعميم الخطأ.

تعتمد آلة المتجه الداعم على عدة معلمات التي تؤثر بشكل مباشر وغير مباشر في ايجاد الحل النهائي وكذلك تؤثر في دقة التصنيف والمستوى الفاصل hyper plane ومضاعفات لاكرانج Lagrange multipliers

Support Vector: وهي نقاط التي تقع في حدود الخط الفاصل بين الفئتين او صفتين classes و يمكن توضيح الحدود الفاصلة بالمعادلتين الاتيتين:


$$w^t x_i + b = +1 \quad \text{for } y_i = +1 \quad i = 1, 2 \dots N \quad (1)$$

$$w^t x_i + b = -1 \quad \text{for } y_i = -1 \quad i = 1, 2 \dots N \quad (2)$$

يمكن تمثيل معادلة المستوى الفاصل التي تقع في اقصى كل فئة كالآتي:

$$w^t x_i + b = 0 \quad (3)$$

كما هو موضح في الشكل الاتي:



شكل (3): مخطط الحدود الفاصلة في Svm

Source: Noyum, V. D., Mofenjou, Y. P., Feudjio, C., Göktug, A., & Fokoué, E. (2021). Boosting the Predictive Accuracy of Singer Identification Using Discrete Wavelet Transform For Feature Extraction.

يمكن تمثيل الحد الفاصل الثاني في آلة المتجه المساند Support vector machine كالآتي:

$$w^t x_i + b = +1 \quad (4)$$

وهي تمثل الحد الفاصل الثاني في آلة المتجه المساند وكالآتي:

$$w^t x_i + b = -1 \quad (5)$$

a. معادلة Primal بالصيغة الاتية:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|_2^2 - \sum_{i=1}^N \alpha_i (y_i (x_i^T w + b) - 1) \quad (6)$$

x_i^T : تمثل نقاط بيانات التدريب
 y_i : تمثل اشارة نقاط التدريب

و عند فتح المعادلة تكتب كالآتي

$$L(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i y_i x^{iT} w + b(\sum_{i=1}^n \alpha_i y_i) + \sum_{i=1}^n \alpha_i \quad (7)$$

ونطبق الشروط وكالآتي:

1.

$$\frac{\partial L}{\partial w} = 0 \rightarrow w^* = \sum_{i=1}^N \alpha_i y_i x^i \quad (8)$$

α_i : تمثل مضاعفات لاكرانج (Lagrange multipliers)

$$0 \leq \alpha_i \leq c$$

حيث ان

c: وتمثل معيار يقوم بالموازنة بين الخطأ التقديري ومقدار التباعد عن المحور الرئيسي استعمال قيمة 1

2.

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N y_i \alpha_i = 0 \quad (9)$$

وتكون معادلة Dual بالصيغة الآتية:

$$\max_{\alpha_1, \dots, \alpha_n} L(w^*, b^*, \alpha) \quad (10)$$

Subject to:

$$\alpha_i \geq 0, i \in 1, \dots, n \text{ and } \sum_{i=1}^N \alpha_i y_i = 0 \quad (11)$$

و عند تعويض المعادلة تكون بالصيغة الآتية

$$\max_{\alpha_1, \dots, \alpha_n} L(w^*, b^*, \alpha) = \max_{\alpha_1, \dots, \alpha_n} - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j x^{iT} x^j + \sum_{i=1}^N \alpha_i \quad (12)$$

Subject to

$$\alpha_i \geq 0, i \in 1, \dots, N \text{ and } \sum_{i=1}^N \alpha_i y_i = 0 \quad (13)$$

$$w^* = \sum_{i=1}^N \alpha_i y_i x^i \quad (14)$$

وتكون مسافة الحد الفاصل hyper plane كالآتي:

$$\frac{2}{\|w^*\|} \quad (15)$$

ولإيجاد حد التحيز وذلك من خلال ما يأتي:

ان نقطة البيانات التي تستوفي المعادلة (9) والتي تاخذ الصيغة الآتية :

$$y(w^T x + b) = 1$$

ثم يتم التعويض فيها بالمعادلة (14) لكي نحصل على المعادلة الآتية:

$$y \left(\sum_{i=1}^N \alpha_i y_i x_i x + b \right) = 1$$

ثم يتم بعد ذلك الضرب بالـ y في المعادلة لكي نحصل على المعادلة الآتية

$$y^2 \left(\sum_{i=1}^N \alpha_i y_i x_i x + b \right) = y$$

وذلك لان y^2 تمثل واحد 1 كما هو يمثل في المعادلتين الآتية

$$w^t x + b \geq 1 \quad \text{for } y_i = +1$$

$$w^t x + b \leq -1 \quad \text{for } y_i = -1$$

فإننا نحصل على المعادلة التالية

$$b = y - \sum_i^N \alpha_i y_i x_i \cdot x \quad (16)$$


ثم يأخذ المعدل لكل معادلة نحصل على الاتي

$$b = \frac{1}{N} \sum_{i=1}^N (y - \sum_i^n \alpha_i y_i x_i \cdot x) \quad (17)$$

وبذلك تكون معادلة التصنيف كالآتي:

$$y = (w * x_i + b) \quad (18)$$

فيما يأتي مخطط يوضح آلة المتجه المساند



شكل (4): مخطط يوضح آلة المتجه الداعم

Source: Papadonikolakis, M., & Bouganis, C. S. (2012). Novel cascade FPGA accelerator for support vector machines classification. IEEE transactions on neural networks and learning systems, 23(7), 1040-1052.

3. الجانب التطبيقي (Practical Part)

تم في الجانب التطبيقي استخدام آلة المتجه الداعم svm وكذلك استخدام الرسم لتوضيح كفاءة طريقة آلة المتجه الداعم في تصنيف اتجاهات الأسهم المالية فيما اذا كانت صاعدة او هابطة وتم استخدام بيانات الاوراق المالية للأعوام 2019-2020 للمصرف العراقي الاسلامي للاستثمار والتنمية حيث استخدمت المتغيرات المتعلقة بالأسهم وذلك للقيام بعملية التصنيف وتكون هذه المتغيرات كالآتي:

1. x_1 : ويمثل متغير قيمة السهم
2. x_2 : ويمثل متغير قيمة السهم الابتدائية
3. x_3 : ويمثل متغير قيمة السهم الاعلى
4. x_4 : ويمثل متغير قيمة السهم الاقل
5. x_5 : ويمثل متغير قيمة السهم الحقيقية
6. y : ويمثل متغير قيمة التغير في السهم

ان تطبيق آلة المتجه الداعم وذلك من خلال استخدام بيانات سوق العراق للأوراق المالية المصرف العراقي الاسلامي للاستثمار والتنمية وهذه البيانات تتكون من خمسة متغيرات وهي قيمة السهم وقيمة السهم الابتدائي وقيمة

السهم الاعلى وقيمة السهم الاقل وقيمة السهم الحقيقي و 105 قيود اذ تم تطبيق آلة المتجه الداعم على بيانات التدريب ثم اختبار الطريقة على بيانات الاختبار وذلك لاختبار دقة التصنيف لطريقة آلة المتجه الداعم وتم تطبيق طريقة آلة المتجه الداعم عن طريق كتابة برنامج باستخدام Matlab 2018b وكذلك تم حساب معايير دقة الطريقة بالاعتماد على مجموعة مؤشرات وهي كالآتي:

1. مؤشر تشخيص العينة غير المعالجة (TP - True Positive)
 2. مؤشر تشخيص الصحيح للعينة المعالجة (TN- True Negative)
 3. مؤشر عينة غير معالجة تم تشخيصها بشكل صحيح (FP- False Positive)
 4. مؤشر تشخيص العينة تم معالجتها بصورة غير صحيحة (FN- False Negative)
- وبالاعتماد على هذه المؤشرات نجد المعايير التالية:

1. الدقة: وهو المعيار الذي يمثل النسبة بين النتائج التي تم تشخيصها بشكل صحيح الى النتائج الكلية

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} * 100\% \quad (19)$$

2. النوعية: وهو المعيار الذي يمثل النسبة بين العينة التي تم تشخيصها ومعالجتها بشكل صحيح الى مجموع العينات التي تم تشخيصها بشكل صحيح و معالجتها مع العينات التي تم تشخيصها بشكل غير صحيح

$$SPE = \frac{TN}{TN+FP} * 100\% \quad (20)$$

3. الحساسية: وهو المعيار الذي يمثل النسبة بين العينات غير المعالجة والمشخصة بشكل صحيح الى جميع العينات غير المعالجة والمشخصة بشكل صحيح وبشكل غير صحيح

$$SEN = \frac{TP}{TP+FP} * 100\% \quad (21)$$

4. نسبة الخطاء الموجب: وهو المعيار الذي يمثل النسبة بين العينات غير المعالجة والمشخصة بشكل غير صحيح الى جميع العينات المشخصة بشكل صحيح

$$FPR = \frac{FP}{TN+FP} * 100\% \quad (22)$$

وهنا يتم تطبيق آلة الموجه الداعم وتم الحصول على النتائج وكالآتي:

جدول (1): نتائج Svm باستخدام دالة linear kernel

| n | نوع kernel | C | Acc |
|---|------------|-------|--------|
| 1 | linear | 0.001 | 69.524 |
| 2 | linear | 0.01 | 69.524 |
| 3 | linear | 0.1 | 67.619 |
| 4 | linear | 1 | 69.524 |
| 5 | linear | 10 | 71.429 |
| 6 | linear | 100 | 71.429 |
| 7 | linear | 1000 | 70.476 |

الجدول 1 يمثل نتائج التصنيف باستخدام Svm مع دالة النوى الخطية حيث تم استخدام عدة قيم للمعلمة c. ويظهر الجدول ان أعلى دقة (71.429%) تحققت عند القيمتين 10 و 100 للمعلمة c.

جدول (2): نتائج Svm باستخدام دالة rbf kernel

| n | نوع kernel | C | G | Acc |
|----|------------|-------|-------|--------|
| 1 | rbf | 0.001 | 0.001 | 86.667 |
| 2 | rbf | 0.001 | 0.01 | 86.667 |
| 3 | rbf | 0.001 | 0.1 | 86.667 |
| 4 | rbf | 0.001 | 1 | 86.667 |
| 5 | rbf | 0.001 | 10 | 86.667 |
| 6 | rbf | 0.001 | 100 | 86.667 |
| 7 | rbf | 0.001 | 1000 | 86.667 |
| 8 | rbf | 0.01 | 0.001 | 86.667 |
| 9 | rbf | 0.01 | 0.01 | 86.667 |
| 10 | rbf | 0.01 | 0.1 | 86.667 |

| | | | | |
|----|-----|------|-------|--------|
| 11 | rbf | 0.01 | 1 | 86.667 |
| 12 | rbf | 0.01 | 10 | 86.667 |
| 13 | rbf | 0.01 | 100 | 86.667 |
| 14 | rbf | 0.01 | 1000 | 86.667 |
| 15 | rbf | 0.1 | 0.001 | 86.667 |
| 16 | rbf | 0.1 | 0.01 | 86.667 |
| 17 | rbf | 0.1 | 0.1 | 86.667 |
| 18 | rbf | 0.1 | 1 | 86.667 |
| 19 | rbf | 0.1 | 10 | 86.667 |
| 20 | rbf | 0.1 | 100 | 86.667 |
| 21 | rbf | 0.1 | 1000 | 86.667 |
| 22 | rbf | 1 | 0.001 | 91.429 |
| 23 | rbf | 1 | 0.01 | 91.429 |
| 24 | rbf | 1 | 0.1 | 91.429 |
| 25 | rbf | 1 | 1 | 91.429 |
| 26 | rbf | 1 | 10 | 91.429 |
| 27 | rbf | 1 | 100 | 91.429 |
| 28 | rbf | 1 | 1000 | 91.429 |
| 29 | rbf | 10 | 0.001 | 91.429 |
| 30 | rbf | 10 | 0.01 | 91.429 |
| 31 | rbf | 10 | 0.1 | 91.429 |
| 32 | rbf | 10 | 1 | 91.429 |
| 33 | rbf | 10 | 10 | 91.429 |
| 34 | rbf | 10 | 100 | 91.429 |
| 35 | rbf | 10 | 1000 | 91.429 |
| 36 | rbf | 100 | 0.001 | 91.429 |
| 37 | rbf | 100 | 0.01 | 91.429 |
| 38 | rbf | 100 | 0.1 | 91.429 |
| 39 | rbf | 100 | 1 | 91.429 |
| 40 | rbf | 100 | 10 | 91.429 |
| 41 | rbf | 100 | 100 | 91.429 |
| 42 | rbf | 100 | 1000 | 91.429 |
| 43 | rbf | 1000 | 0.001 | 91.429 |
| 44 | rbf | 1000 | 0.01 | 91.429 |
| 45 | rbf | 1000 | 0.1 | 91.429 |
| 46 | rbf | 1000 | 1 | 91.429 |
| 47 | rbf | 1000 | 10 | 91.429 |
| 53 | rbf | 1000 | 100 | 91.429 |
| 59 | rbf | 1000 | 1000 | 91.429 |

جدول (2) يمثل نتائج التصنيف باستخدام Svm مع دالة النوى rbf حيث تم استخدام عدة قيم للمعلمة G و C ولوحظ انه نحصل على اعلى دقة 91.429%) عندما تكون قيمة c من 0.1 الى 1000.

جدول (3): نتائج Svm باستخدام دالة polynomial kernel

| n | نوع kernel | C | G | d | R | Acc |
|----|------------|-------|-------|---|---|--------|
| 1 | polynomial | 0.001 | 0.001 | 1 | 1 | 72.381 |
| 2 | polynomial | 0.001 | 0.01 | 1 | 1 | 71.429 |
| 3 | polynomial | 0.001 | 0.1 | 1 | 1 | 71.429 |
| 4 | polynomial | 0.001 | 1 | 1 | 1 | 69.524 |
| 5 | polynomial | 0.001 | 10 | 1 | 1 | 71.429 |
| 6 | polynomial | 0.001 | 100 | 1 | 1 | 69.524 |
| 7 | polynomial | 0.001 | 1000 | 1 | 1 | 70.476 |
| 8 | polynomial | 0.01 | 0.001 | 1 | 1 | 72.381 |
| 9 | polynomial | 0.01 | 0.01 | 1 | 1 | 71.429 |
| 10 | polynomial | 0.01 | 0.01 | 1 | 1 | 69.524 |

| | | | | | | |
|----|------------|-------|-------|---|---|--------|
| 11 | polynomial | 0.01 | 0.01 | 1 | 1 | 69.524 |
| 12 | polynomial | 0.01 | 10 | 1 | 1 | 69.524 |
| 13 | polynomial | 0.01 | 100 | 1 | 1 | 69.524 |
| 14 | polynomial | 0.01 | 1000 | 1 | 1 | 70.476 |
| 15 | polynomial | 0.1 | 0.001 | 1 | 1 | 74.286 |
| 16 | polynomial | 0.1 | 0.01 | 1 | 1 | 70.476 |
| 17 | polynomial | 0.1 | 0.1 | 1 | 1 | 66.667 |
| 18 | polynomial | 0.1 | 1 | 1 | 1 | 68.571 |
| 19 | polynomial | 0.1 | 10 | 1 | 1 | 69.524 |
| 20 | polynomial | 0.1 | 100 | 1 | 1 | 66.667 |
| 21 | polynomial | 0.1 | 1000 | 1 | 1 | 69.524 |
| 22 | polynomial | 1 | 0.001 | 1 | 1 | 71.429 |
| 23 | polynomial | 1 | 0.01 | 1 | 1 | 70.476 |
| 24 | polynomial | 1 | 0.1 | 1 | 1 | 66.667 |
| 25 | polynomial | 1 | 0.01 | 1 | 1 | 69.524 |
| 26 | polynomial | 1 | 10 | 1 | 1 | 68.571 |
| 27 | polynomial | 1 | 100 | 1 | 1 | 66.667 |
| 28 | polynomial | 1 | 100 | 1 | 1 | 69.524 |
| 29 | polynomial | 10 | 0.001 | 1 | 1 | 72.381 |
| 30 | polynomial | 10 | 0.01 | 1 | 1 | 70.476 |
| 31 | polynomial | 10 | 0.1 | 1 | 1 | 71.429 |
| 32 | polynomial | 10 | 1 | 1 | 1 | 71.429 |
| 33 | polynomial | 10 | 10 | 1 | 1 | 70.476 |
| 34 | polynomial | 10 | 100 | 1 | 1 | 68.571 |
| 35 | polynomial | 10 | 1000 | 1 | 1 | 69.524 |
| 36 | polynomial | 100 | 0.001 | 1 | 1 | 71.429 |
| 37 | polynomial | 100 | 0.01 | 1 | 1 | 66.667 |
| 38 | polynomial | 100 | 0.01 | 1 | 1 | 68.571 |
| 39 | polynomial | 100 | 0.1 | 1 | 1 | 65.714 |
| 40 | polynomial | 100 | 0.1 | 1 | 1 | 70.476 |
| 41 | polynomial | 100 | 10 | 1 | 1 | 68.571 |
| 42 | polynomial | 100 | 100 | 1 | 1 | 69.524 |
| 43 | polynomial | 100 | 1000 | 1 | 1 | 70.476 |
| 44 | polynomial | 1000 | 0.001 | 1 | 1 | 72.381 |
| 45 | polynomial | 1000 | 0.01 | 1 | 1 | 71.429 |
| 46 | polynomial | 1000 | 0.1 | 1 | 1 | 70.476 |
| 47 | polynomial | 1000 | 1 | 1 | 1 | 71.429 |
| 48 | polynomial | 1000 | 10 | 1 | 1 | 68.571 |
| 49 | polynomial | 1000 | 100 | 1 | 1 | 69.524 |
| 50 | polynomial | 1000 | 1000 | 1 | 1 | 69.524 |
| 51 | polynomial | 0.001 | 0.001 | 2 | 1 | 67.619 |
| 52 | polynomial | 0.001 | 0.01 | 2 | 1 | 73.333 |
| 53 | polynomial | 0.001 | 0.1 | 2 | 1 | 71.429 |
| 54 | polynomial | 0.001 | 10 | 2 | 1 | 47.619 |
| 55 | polynomial | 0.001 | 100 | 2 | 1 | 47.619 |
| 56 | polynomial | 0.001 | 1000 | 2 | 1 | 47.619 |
| 57 | polynomial | 0.01 | 0.001 | 2 | 1 | 44.762 |
| 58 | polynomial | 0.01 | 0.01 | 2 | 1 | 71.429 |
| 59 | polynomial | 0.01 | 0.1 | 2 | 1 | 71.429 |
| 60 | polynomial | 0.01 | 10 | 2 | 1 | 47.619 |
| 61 | polynomial | 0.01 | 100 | 2 | 1 | 47.619 |
| 62 | polynomial | 0.01 | 1000 | 2 | 1 | 47.619 |

| | | | | | | |
|-----|------------|-------|-------|---|---|--------|
| 63 | polynomial | 0.01 | 0.1 | 2 | 1 | 70.476 |
| 64 | polynomial | 0.1 | 0.01 | 2 | 1 | 72.381 |
| 65 | polynomial | 0.1 | 0.1 | 2 | 1 | 71.429 |
| 66 | polynomial | 0.1 | 10 | 2 | 1 | 47.619 |
| 67 | polynomial | 0.1 | 100 | 2 | 1 | 47.619 |
| 68 | polynomial | 0.1 | 1000 | 2 | 1 | 47.619 |
| 69 | polynomial | 1 | 0.001 | 2 | 1 | 66.667 |
| 70 | polynomial | 1 | 0.01 | 2 | 1 | 70.476 |
| 71 | polynomial | 1 | 0.1 | 2 | 1 | 71.429 |
| 72 | polynomial | 1 | 10 | 2 | 1 | 47.619 |
| 73 | polynomial | 1 | 100 | 2 | 1 | 47.619 |
| 74 | polynomial | 1 | 1000 | 2 | 1 | 47.619 |
| 75 | polynomial | 1 | 0.001 | 2 | 1 | 66.667 |
| 76 | polynomial | 10 | 0.01 | 2 | 1 | 70.476 |
| 77 | polynomial | 10 | 10 | 2 | 1 | 47.619 |
| 78 | polynomial | 10 | 100 | 2 | 1 | 47.619 |
| 79 | polynomial | 10 | 1000 | 2 | 1 | 47.619 |
| 80 | polynomial | 10 | 0.1 | 2 | 1 | 71.429 |
| 81 | polynomial | 100 | 0.001 | 2 | 1 | 68.571 |
| 82 | polynomial | 100 | 0.01 | 2 | 1 | 74.286 |
| 83 | polynomial | 100 | 0.1 | 2 | 1 | 71.429 |
| 84 | polynomial | 100 | 10 | 2 | 1 | 47.619 |
| 85 | polynomial | 100 | 100 | 2 | 1 | 47.619 |
| 86 | polynomial | 100 | 1000 | 2 | 1 | 47.619 |
| 87 | polynomial | 1000 | 0.001 | 2 | 1 | 71.429 |
| 88 | polynomial | 1000 | 0.01 | 2 | 1 | 70.476 |
| 89 | polynomial | 1000 | 0.1 | 2 | 1 | 71.429 |
| 90 | polynomial | 1000 | 10 | 2 | 1 | 47.619 |
| 91 | polynomial | 1000 | 100 | 2 | 1 | 47.619 |
| 92 | polynomial | 1000 | 1000 | 2 | 1 | 47.619 |
| 93 | polynomial | 0.001 | 0.001 | 3 | 1 | 47.619 |
| 94 | polynomial | 0.001 | 0.01 | 3 | 1 | 47.619 |
| 95 | polynomial | 0.001 | 0.1 | 3 | 1 | 47.619 |
| 96 | polynomial | 0.001 | 1 | 3 | 1 | 47.619 |
| 97 | polynomial | 0.001 | 10 | 3 | 1 | 47.619 |
| 98 | polynomial | 0.001 | 100 | 3 | 1 | 47.619 |
| 99 | polynomial | 0.001 | 1000 | 3 | 1 | 47.619 |
| 100 | polynomial | 0.01 | 0.001 | 3 | 1 | 47.619 |
| 101 | polynomial | 0.01 | 0.01 | 3 | 1 | 47.619 |
| 102 | polynomial | 0.01 | 0.01 | 3 | 1 | 47.619 |
| 103 | polynomial | 0.01 | 0.01 | 3 | 1 | 47.619 |
| 104 | polynomial | 0.01 | 10 | 3 | 1 | 47.619 |
| 105 | polynomial | 0.01 | 100 | 3 | 1 | 47.619 |
| 106 | polynomial | 0.01 | 1000 | 3 | 1 | 47.619 |
| 107 | polynomial | 0.1 | 0.001 | 3 | 1 | 47.619 |
| 108 | polynomial | 0.1 | 0.01 | 3 | 1 | 47.619 |
| 109 | polynomial | 0.1 | 0.1 | 3 | 1 | 47.619 |
| 110 | polynomial | 0.1 | 1 | 3 | 1 | 47.619 |
| 111 | polynomial | 0.1 | 10 | 3 | 1 | 47.619 |
| 112 | polynomial | 0.1 | 100 | 3 | 1 | 47.619 |
| 113 | polynomial | 0.1 | 1000 | 3 | 1 | 47.619 |
| 114 | polynomial | 1 | 0.001 | 3 | 1 | 47.619 |
| 115 | polynomial | 1 | 0.01 | 3 | 1 | 47.619 |
| 116 | polynomial | 1 | 0.1 | 3 | 1 | 47.619 |

| | | | | | | |
|-----|------------|-------|-------|---|---|--------|
| 117 | polynomial | 1 | 0.01 | 3 | 1 | 47.619 |
| 118 | polynomial | 1 | 10 | 3 | 1 | 47.619 |
| 119 | polynomial | 1 | 100 | 3 | 1 | 47.619 |
| 120 | polynomial | 1 | 100 | 3 | 1 | 47.619 |
| 121 | polynomial | 10 | 0.001 | 3 | 1 | 47.619 |
| 122 | polynomial | 10 | 0.01 | 3 | 1 | 47.619 |
| 123 | polynomial | 10 | 0.1 | 3 | 1 | 47.619 |
| 124 | polynomial | 10 | 1 | 3 | 1 | 47.619 |
| 125 | polynomial | 10 | 10 | 3 | 1 | 47.619 |
| 126 | polynomial | 10 | 100 | 3 | 1 | 47.619 |
| 127 | polynomial | 10 | 1000 | 3 | 1 | 47.619 |
| 128 | polynomial | 100 | 0.001 | 3 | 1 | 47.619 |
| 129 | polynomial | 100 | 0.01 | 3 | 1 | 47.619 |
| 130 | polynomial | 100 | 0.1 | 3 | 1 | 47.619 |
| 131 | polynomial | 100 | 0.1 | 3 | 1 | 47.619 |
| 132 | polynomial | 100 | 10 | 3 | 1 | 47.619 |
| 133 | polynomial | 100 | 100 | 3 | 1 | 47.619 |
| 134 | polynomial | 100 | 1000 | 3 | 1 | 47.619 |
| 135 | polynomial | 1000 | 0.001 | 3 | 1 | 47.619 |
| 136 | polynomial | 1000 | 0.01 | 3 | 1 | 47.619 |
| 137 | polynomial | 1000 | 0.1 | 3 | 1 | 47.619 |
| 138 | polynomial | 1000 | 1 | 3 | 1 | 47.619 |
| 139 | polynomial | 1000 | 10 | 3 | 1 | 47.619 |
| 140 | polynomial | 1000 | 100 | 3 | 1 | 47.619 |
| 141 | polynomial | 1000 | 1000 | 3 | 1 | 47.619 |
| 142 | polynomial | 0.001 | 0.001 | 4 | 1 | 47.619 |
| 143 | polynomial | 0.001 | 0.01 | 4 | 1 | 47.619 |
| 144 | polynomial | 0.001 | 0.1 | 4 | 1 | 47.619 |
| 145 | polynomial | 0.001 | 1 | 4 | 1 | 47.619 |
| 146 | polynomial | 0.001 | 10 | 4 | 1 | 47.619 |
| 147 | polynomial | 0.001 | 100 | 4 | 1 | 47.619 |
| 148 | polynomial | 0.001 | 1000 | 4 | 1 | 47.619 |
| 149 | polynomial | 0.01 | 0.001 | 4 | 1 | 47.619 |
| 150 | polynomial | 0.01 | 0.01 | 4 | 1 | 47.619 |
| 151 | polynomial | 0.01 | 0.01 | 4 | 1 | 47.619 |
| 152 | polynomial | 0.01 | 0.01 | 4 | 1 | 47.619 |
| 153 | polynomial | 0.01 | 10 | 4 | 1 | 47.619 |
| 154 | polynomial | 0.01 | 100 | 4 | 1 | 47.619 |
| 155 | polynomial | 0.01 | 1000 | 4 | 1 | 47.619 |
| 156 | polynomial | 0.1 | 0.001 | 4 | 1 | 47.619 |
| 157 | polynomial | 0.1 | 0.01 | 4 | 1 | 47.619 |
| 158 | polynomial | 0.1 | 0.1 | 4 | 1 | 47.619 |
| 159 | polynomial | 0.1 | 1 | 4 | 1 | 47.619 |
| 160 | polynomial | 0.1 | 10 | 4 | 1 | 47.619 |
| 161 | polynomial | 0.1 | 100 | 4 | 1 | 47.619 |
| 162 | polynomial | 0.1 | 1000 | 4 | 1 | 47.619 |
| 163 | polynomial | 1 | 0.001 | 4 | 1 | 47.619 |
| 164 | polynomial | 1 | 0.01 | 4 | 1 | 47.619 |
| 165 | polynomial | 1 | 0.1 | 4 | 1 | 47.619 |
| 166 | polynomial | 1 | 0.01 | 4 | 1 | 47.619 |
| 167 | polynomial | 1 | 10 | 4 | 1 | 47.619 |
| 168 | polynomial | 1 | 100 | 4 | 1 | 47.619 |
| 169 | polynomial | 1 | 100 | 4 | 1 | 47.619 |
| 170 | polynomial | 10 | 0.001 | 4 | 1 | 47.619 |

| | | | | | | |
|-----|------------|-------|-------|---|---|--------|
| 171 | polynomial | 10 | 0.01 | 4 | 1 | 47.619 |
| 172 | polynomial | 10 | 0.1 | 4 | 1 | 47.619 |
| 173 | polynomial | 10 | 1 | 4 | 1 | 47.619 |
| 174 | polynomial | 10 | 10 | 4 | 1 | 47.619 |
| 175 | polynomial | 10 | 100 | 4 | 1 | 47.619 |
| 176 | polynomial | 10 | 1000 | 4 | 1 | 47.619 |
| 177 | polynomial | 100 | 0.001 | 4 | 1 | 47.619 |
| 178 | polynomial | 100 | 0.01 | 4 | 1 | 47.619 |
| 179 | polynomial | 100 | 0.1 | 4 | 1 | 47.619 |
| 180 | polynomial | 100 | 0.1 | 4 | 1 | 47.619 |
| 181 | polynomial | 100 | 10 | 4 | 1 | 47.619 |
| 182 | polynomial | 100 | 100 | 4 | 1 | 47.619 |
| 183 | polynomial | 100 | 1000 | 4 | 1 | 47.619 |
| 184 | polynomial | 1000 | 0.001 | 4 | 1 | 47.619 |
| 185 | polynomial | 1000 | 0.01 | 4 | 1 | 47.619 |
| 186 | polynomial | 1000 | 0.1 | 4 | 1 | 47.619 |
| 187 | polynomial | 1000 | 1 | 4 | 1 | 47.619 |
| 188 | polynomial | 1000 | 10 | 4 | 1 | 47.619 |
| 189 | polynomial | 1000 | 100 | 4 | 1 | 47.619 |
| 190 | polynomial | 1000 | 1000 | 4 | 1 | 47.619 |
| 191 | polynomial | 0.001 | 0.001 | 5 | 1 | 47.619 |
| 192 | polynomial | 0.001 | 0.01 | 5 | 1 | 47.619 |
| 193 | polynomial | 0.001 | 0.1 | 5 | 1 | 47.619 |
| 194 | polynomial | 0.001 | 1 | 5 | 1 | 47.619 |
| 195 | polynomial | 0.001 | 10 | 5 | 1 | 47.619 |
| 196 | polynomial | 0.001 | 100 | 5 | 1 | 47.619 |
| 197 | polynomial | 0.001 | 1000 | 5 | 1 | 47.619 |
| 198 | polynomial | 0.01 | 0.001 | 5 | 1 | 47.619 |
| 199 | polynomial | 0.01 | 0.01 | 5 | 1 | 47.619 |
| 200 | polynomial | 0.01 | 0.01 | 5 | 1 | 47.619 |
| 201 | polynomial | 0.01 | 0.01 | 5 | 1 | 47.619 |
| 202 | polynomial | 0.01 | 10 | 5 | 1 | 47.619 |
| 203 | polynomial | 0.01 | 100 | 5 | 1 | 47.619 |
| 204 | polynomial | 0.01 | 1000 | 5 | 1 | 47.619 |
| 205 | polynomial | 0.1 | 0.001 | 5 | 1 | 47.619 |
| 206 | polynomial | 0.1 | 0.01 | 5 | 1 | 47.619 |
| 207 | polynomial | 0.1 | 0.1 | 5 | 1 | 47.619 |
| 208 | polynomial | 0.1 | 1 | 5 | 1 | 47.619 |
| 209 | polynomial | 0.1 | 10 | 5 | 1 | 47.619 |
| 210 | polynomial | 0.1 | 100 | 5 | 1 | 47.619 |
| 211 | polynomial | 0.1 | 1000 | 5 | 1 | 47.619 |
| 212 | polynomial | 1 | 0.001 | 5 | 1 | 47.619 |
| 213 | polynomial | 1 | 0.01 | 5 | 1 | 47.619 |
| 214 | polynomial | 1 | 0.1 | 5 | 1 | 47.619 |
| 215 | polynomial | 1 | 0.01 | 5 | 1 | 47.619 |
| 216 | polynomial | 1 | 10 | 5 | 1 | 47.619 |
| 217 | polynomial | 1 | 100 | 5 | 1 | 47.619 |
| 218 | polynomial | 1 | 100 | 5 | 1 | 47.619 |
| 219 | polynomial | 10 | 0.001 | 5 | 1 | 47.619 |
| 220 | polynomial | 10 | 0.01 | 5 | 1 | 47.619 |
| 221 | polynomial | 10 | 0.1 | 5 | 1 | 47.619 |
| 222 | polynomial | 10 | 1 | 5 | 1 | 47.619 |
| 223 | polynomial | 10 | 10 | 5 | 1 | 47.619 |
| 224 | polynomial | 10 | 100 | 5 | 1 | 47.619 |

| | | | | | | |
|-----|------------|------|-------|---|---|--------|
| 225 | polynomial | 10 | 1000 | 5 | 1 | 47.619 |
| 226 | polynomial | 100 | 0.001 | 5 | 1 | 47.619 |
| 227 | polynomial | 100 | 0.01 | 5 | 1 | 47.619 |
| 228 | polynomial | 100 | 0.1 | 5 | 1 | 47.619 |
| 229 | polynomial | 100 | 0.1 | 5 | 1 | 47.619 |
| 230 | polynomial | 100 | 10 | 5 | 1 | 47.619 |
| 231 | polynomial | 100 | 100 | 5 | 1 | 47.619 |
| 232 | polynomial | 100 | 1000 | 5 | 1 | 47.619 |
| 233 | polynomial | 1000 | 0.001 | 5 | 1 | 47.619 |
| 234 | polynomial | 1000 | 0.01 | 5 | 1 | 47.619 |
| 235 | polynomial | 1000 | 0.1 | 5 | 1 | 47.619 |
| 236 | polynomial | 1000 | 1 | 5 | 1 | 47.619 |
| 237 | polynomial | 1000 | 10 | 5 | 1 | 47.619 |
| 238 | polynomial | 1000 | 100 | 5 | 1 | 47.619 |
| 239 | polynomial | 1000 | 1000 | 5 | 1 | 47.619 |

جدول (3) يمثل نتائج التصنيف باستخدام Svm مع دالة النوى polynomial حيث تم استخدام عدة قيم للمعلمات r و d و G و C و علما ان اعلى دقة (74.286%) قد تحققت عند قيمة C (0.1) و (100) وقيمة G (0.001) و (0.01) وقيمة d (1) و (2).

جدول (4): يمثل اعلى قيم نتائج الدقة في Svm باستخدام دوال kernel

| N | Kernel | Acc |
|---|------------|--------|
| 1 | Linear | 71.429 |
| 2 | Rbf | 91.429 |
| 3 | Polynomial | 74.286 |

من خلال الجداول 1 و 2 و 3 و 4 نلاحظ ان هنالك زيادة كبيرة في الدقة عند استخدام دالة النوى rbf والتي تصل الى (91.429%). وعند التطبيق دالة النوى rbf تم الحصول على نتائج المؤشرات وكالاتي:

جدول (5): مؤشرات Svm باستخدام دالة النوى rbf

| TN | TP | FN | FP |
|----|----|----|----|
| 41 | 55 | 0 | 9 |

من هذه المؤشرات يتم حساب اداء آلة المتجه الداعم باستخدام دالة النوى rbf باستخدام المعايير وهي كالاتي

جدول (6): يمثل معايير Svm باستخدام دالة النوى rbf

| ACC | SPE | SEN | FPR |
|--------|-----|---------|-----|
| 91.429 | 82 | 85.9375 | 18 |

من خلال المعايير المذكورة في جدول (6) نلاحظ أنه تم تصنيف البيانات الى اسهم صاعدة واسهم هابطة وذلك يدل على ان طريقة svm تعمل بشكل جيد جدا.

اظهرت النتائج svm باستخدام دالة النوى rbf kernel ما يلي:

1. ان قيمة المعلمة c لها تأثير في svm عند استخدام دالة النوى rbf kernel
 - a. عندما تكون قيمة c من 0.1 الى 1000 نحصل على أعلى دقة
 - b. عندما تكون قيمة c من 0.01 الى 0.001 نحصل على أعلى دقة
2. ان قيمة المعلمة g ليس لها تأثير يذكر في svm عند استخدام دالة النوى rbf kernel.

4. الاستنتاجات والتوصيات Conclusions and Recommendation

4.1 الاستنتاجات

1. اظهرت النتائج ان دقة آلة المتجه الداعم كانت جيدة جدا والنتائج كانت فعالة في تصنيف فئات الاسهم الصاعدة والاسهم الهابطة
2. تم استخدام دالة اللب rbf وكانت نتائج الدقة 71.429 وتم استخدام دالة اللب Linear وكانت نتائج الدقة % 91.429 وتم استخدام دالة اللب Polynomial وكانت نتائج الدقة 74.286 وذلك يدل على ان دالة اللب rbf قد حققت اعلى نتائج للدقة.
3. تم الحصول على اعلى قيمة للدقة في دالة اللب rbf وذلك عندما تكون قيمة المعلمة c من 0.1 الى 1000.

4.2. التوصيات

نوصي باستخدام خوارزميات الذكاء الاصطناعي لطرق المقارنة مثل الخوارزمية الجينية، شجرة القرار وغيرها.

5. المصادر

- [1] Ma, Y., & Guo, G., (2014). (Eds.). Support vector machines applications (Vol. 649). New York, NY, USA: Springer.
- [2] Xydas, E. S., Marmaras, C. E., Cipcigan, L. M., Hassan, A. S., & Jenkins, N. (2013, September). "Forecasting electric vehicle charging demand using support vector machines". 48th International Universities Power Engineering Conference (UPEC) (pp. 1-6). IEEE.
- [3] Pham, H. (Ed.). (2006), Springer handbook of engineering statistics. Springer Science & Business Media.
- [4] Deng, N., Tian, Y., & Zhang, C., (2012), Support vector machines: optimization based theory, algorithms, and extensions. CRC press.
- [5] Steinwart, I., & Christmann, A., (2008), Support vector machines. Springer Science & Business Media.
- [6] Wang, L. (Ed.). (2005), Support vector machines: theory and applications (Vol. 177). Springer Science & Business Media.
- [7] Stanevski, N., & Tsvetkov, D. (2005), Using support vector machine as a binary classifier. In International Conference on Computer Systems and Technologies–CompSys Tech.
- [8] Kecman, V., (2001), Learning and soft computing: support vector machines, neural networks, and fuzzy logic models. MIT press.
- [9] Suykens, J., (2003), A (short) introduction to Support Vector Machines and kernel based learning. Katholieke University Leuven ESANN. -SCD-SISTA, Belgium.
- [10] Hastie, T., Tibshirani, R., & Friedman, J., (2009), The elements of statistical learning: data mining, inference, and prediction. Springer Science & Business Media.
- [11] Maronna, R. Alan julian izenman. (2008), Modern multivariate statistical techniques: regression, classification and manifold learning. Statistical Papers, 52(3), 733.
- [12] Ren, R., Wu, D. D., & Liu, T., (2018) Forecasting stock market movement direction using sentiment analysis and support vector machine. IEEE Systems Journal, 13(1), 760-770.



AL- Rafidain
University College

PISSN: (1681-6870); EISSN: (2790-2293)

**Journal of AL-Rafidain
University College for Sciences**

Available online at: <https://www.jrucs.iq>

JRUCS

Journal of AL-Rafidain
University College for
Sciences

Classification of Financial Stock Data Using the Vector Technology in Statistical Learning

| | |
|--|--|
| Mohamed H. Ibrahim | Assist. Prof. Dr. Asmaa G. Jaber |
| mohammed.ibrahim1201@coadec.uobaghdad.edu.iq | drasmaa.ghalib@coadec.uobaghdad.edu.iq |
| Department of Statistics - College of Administration and Economics - University of Baghdad, Baghdad - Iraq. | |

Article Information

Article History:

Received: June, 21, 2021

Accepted: September, 13, 2021

Available Online: June, 25, 2022

Keywords:

Support vector machine, classification, financial stock

Correspondence:

Mohamed H. Ibrahim

mohammed.ibrahim1201@coadec.uobaghdad.edu.iq

DOI: <https://doi.org/10.55562/jrucs.v51i1.526>

Abstract

The financial markets are considered to be of continuous, dynamic and accelerating movement, which leads to the need for techniques methods and means for analysis and decision-making, which push investors and analysts in the financial markets to use various analysis methods and forecasting approaches for the direction of the financial market movement to make decisions for different investments in order to determine the direction of the stock movement, thus the Support Vector Machine method (SVM) is used to classify financial stock data to determine the direction of the stock, whether it is in an upward or downward trend. The aim of the research is to classify the financial stock data using five variables, where data from The Iraqi Islamic Bank for Investment and Development is used to clarify the method of the Support Vector Machine. The results showed accuracy of this technique and the performance of the Support Vector Machine is good.