

Investigating The Impact Of The K-Means Clustering Algorithm On SVM Model Performance In The Task Of Predicting The Exchange Rate Of The Syrian Pound

Dr. Taleb ahmad^{*}
Dr. Mjed ali^{**}
Hozaifa ehab kasso^{***}

(Received 12 / 10 / 2024. Accepted 18 / 12 / 2024)

□ ABSTRACT □

This research investigates the impact of the K-means clustering algorithm on the performance of a Support Vector Machine (SVM) model in predicting the exchange rate of the Syrian Pound against the US dollar. This study holds significant relevance given the substantial fluctuations observed in the Syrian Pound's exchange rate and its direct impact on the Syrian economy. The study utilizes daily time-series data for the exchange rate, spanning from the beginning of 2015 to mid-February 2024, comprising 3333 observations. SPSS26, RStudio, and Orange Data Mining were employed for data analysis and algorithm implementation.

The K-means algorithm was initially applied to cluster the data. Results indicated the algorithm's success in classifying the data into two statistically distinct clusters, suggesting underlying patterns within the exchange rate data. Subsequently, the SVM algorithm was applied to predict the exchange rate, first without utilizing K-means as a preprocessing step and then with its inclusion. The findings demonstrated a notable improvement in the SVM model's performance when K-means was employed as a preprocessing step. Specifically, the Mean Squared Error (MSE) decreased by 47.23%, the Root Mean Squared Error (RMSE) decreased by 27.28%, and the Mean Absolute Error (MAE) decreased by 18.21%. Conversely, the Mean Absolute Percentage Error (MAPE) increased by 31.81%. However, a substantial increase in the coefficient of determination (R^2) by 52.32% indicates a significant improvement in the model's ability to explain the variance in the data. Based on these results, the study recommends incorporating K-means as a preprocessing step to enhance SVM performance in exchange rate prediction. Furthermore, it recommends future research encompassing longer time periods and employing advanced analytical techniques such as deep learning.

Keywords: Data mining, k-means algorithm, SVM algorithm, prediction.

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

^{*}Professor, Department of Business Administration, Faculty of Economics, Tishreen University, Latakia, Syria.

^{**}Associate Professor, Department of Artificial Intelligence, Faculty of Informatics Engineering, Tishreen University, Latakia, Syria.

^{***}Postgraduate Student (Master), Department of Business Administration, Faculty of Economics, Tishreen University, Latakia, Syria Hozaifa.kasso@tishreen.edu.sy

دراسة تأثير خوارزمية العنقدة K-means على أداء النموذج SVM في مهمة التنبؤ بسعر الصرف لليرة السورية

د. طالب أحمد*

د. مجد علي**

حزيفه ايهاب كاسو***

(تاريخ الإيداع 2024 / 10 / 12. قُبل للنشر في 2024 / 12 / 18)

□ ملخص □

هدف البحث إلى دراسة تأثير خوارزمية التجميع K-means على أداء نموذج دعم آلات المتجهات (SVM) في مهمة التنبؤ بسعر صرف الليرة السورية مقابل الدولار الأمريكي. تُعتبر هذه الدراسة ذات أهمية بالغة في ظل التقلبات الحادة التي يشهدها سعر صرف الليرة السورية وتأثيره المباشر على الاقتصاد السوري. استخدمت الدراسة بيانات سلاسل زمنية يومية لسعر الصرف للفترة الممتدة من بداية عام 2015 حتى منتصف فبراير 2024، بواقع 3333 مشاهدة. تم الاعتماد على برامج SPSS26 و RStudio و Orange Data Mining لتحليل البيانات وتطبيق الخوارزميات. تم تطبيق خوارزمية K-means لتجميع البيانات. أظهرت النتائج نجاح الخوارزمية في تصنيف البيانات إلى مجموعتين متميزتين إحصائياً، مما يُشير إلى وجود أنماط كامنة ضمن بيانات سعر الصرف. بعد ذلك، تم تطبيق خوارزمية SVM للتنبؤ بسعر الصرف، أولاً بدون استخدام K-means كخطوة سابقة، ثم مع استخدامها. أظهرت النتائج تحسناً ملحوظاً في أداء نموذج SVM باستخدام K-means كخطوة مسبقة. انخفض متوسط الخطأ التربيعي (MSE) بنسبة 47.23%، وانخفض جذر متوسط الخطأ التربيعي (RMSE) بنسبة 27.28%، وانخفض متوسط الخطأ المطلق (MAE) بنسبة 18.21%. في المقابل، ارتفع متوسط الخطأ المطلق النسبي (MAPE) بنسبة 31.81%، ومع ذلك، ارتفع معامل التحديد (R^2) بنسبة 52.32%، مما يشير إلى تحسن كبير في قدرة النموذج على تفسير التباين في البيانات. بناءً على هذه النتائج، يُوصي البحث باستخدام K-means كخطوة معالجة مسبقة لتحسين أداء SVM في التنبؤ بسعر الصرف، كما يُوصي بإجراء دراسات مستقبلية تتضمن فترات زمنية أطول، وتطبيق تقنيات تحليل متقدمة مثل التعلم العميق.

الكلمات المفتاحية: التنبؤ في البيانات، خوارزمية k-means، خوارزمية SVM، التنبؤ.



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* أستاذ ، قسم الإحصاء والبرمجة، كلية الاقتصاد، جامعة تشرين، اللاذقية، سورية.

** أستاذ مساعد، قسم الذكاء الصناعي، كلية الهندسة المعلوماتية، جامعة تشرين، اللاذقية، سورية.

*** طالب دراسات عليا (ماجستير)، قسم الإحصاء والبرمجة، كلية الاقتصاد، جامعة تشرين، اللاذقية، سورية.

Hozaifa.kasso@tishreen.edu.sy

مقدمة:

تشكل العملة ركناً رئيسياً في النظام الاقتصادي لأي دولة، وهي أساسية لبناء علاقات تجارية، لذلك فهي بحاجة تحديد سعر الصرف حيث يعد من أهم المؤشرات الاقتصادية التي تؤثر في اقتصاد البلد والعالم بشكل عام، فيحدد قيمة العملة المحلية مقارنةً بالعملة الأجنبية، وله تأثير مباشر في التجارة العالمية، والاستثمارات الدولية، وفي تكاليف الاستيراد والتصدير وفي أسعار السلع المحلية والخارجية، مما ينعكس على التضخم والنمو الاقتصادي.

وفي ظل التطورات العلمية والتكنولوجية الحاصلة تعد خوارزمية العنقدة مفيدة جداً في فهم وتحليل التغيرات في سعر الصرف والعوامل التي تؤثر فيها، وذلك من خلال تحليل الأنماط البيانية أو تحليل العوامل المؤثرة أو استخدام نماذج التنبؤ وتحليل كمية كبيرة من البيانات واستخلاص المعلومات المهمة منها، حيث تم نمذجة تقلبات سعر الصرف في سورية باستخدام تلك الخوارزمية والتي تعد أداة قوية تستخدم في مجال التقيب في البيانات لتحليل الأنماط والتوجهات، والتنبؤ بالأحداث المستقبلية وذلك من عام 2015 - 2024.

• الدراسات السابقة:

قام الباحث بإجراء مراجعة أدبية لمجموعة من الدراسات السابقة العربية منها والأجنبية، وذلك بغرض تقديم ملخص موجز عن تلك الدراسات التي تناولت هذه العلاقة بغية الإفادة منها في دعم هذا البحث:

الدراسات العربية:

1. دراسة (أحمد، 2019) بعنوان:

نمذجة تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي باستخدام نماذج GARCH.

هدفت الدراسة لنمذجة تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي من خلال استخدام نموذج الانحدار الذاتي المعمم المشروط بعدم تجانس تباينات الأخطاء (GARCH) خلال الفترة من يناير 2007 إلى ديسمبر 2018. كما هدفت للتعرف على أثر الصدمة في تذبذب سعر صرف الليرة السورية، ومدى فعالية نماذج GARCH في نمذجة تقلبات سعر الصرف، واعتمدت الدراسة على استخدام المنهج الوصفي التحليلي الذي يعتمد على وصف البيانات وتحليلها. وتم الاعتماد على أسلوب GARCH في تحليل السلاسل الزمنية. وتم الحصول على بيانات السلسلة الزمنية لسعر الصرف الرسمي لليرة السورية مقابل الدولار الأمريكي من بيانات مصرف سورية المركزي. واستخدام برنامج E-Views 9 لتحليل البيانات. وتوصلت الدراسة إلى نموذج قياسي هو $GARCH(1,1)$ يمكن استخدامه في نمذجة تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي، بالإضافة إلى وجود أثر الصدمة على تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي هو كبير ويستمر إلى ما لانهاية، وأن التباين المستقبلي لأسعار الصرف سيظل مشروطاً بالصدمة الحالية إلى ما لانهاية، وقدمت الدراسة مجموعة من التوصيات أهمها متابعة التطورات التي تعرفها النمذجة القياسية للظواهر الاقتصادية والاستفادة من مختلف الصيغ غير الخطية المستحدثة عن نماذج الانحدار الذاتي المشروط بعدم تجانس تباين الأخطاء في نمذجة الظواهر المالية، اتباع سياسات واستراتيجيات محددة لتحسين سعر صرف الليرة السورية مقابل الدولار الأمريكي، وضرورة الابتعاد عن ربط سعر صرف الليرة السورية بعملة واحدة

كالدولار مثلاً، وذلك لتجنب الصدمات المتوقعة واتباع سياسة صرف أكثر مرونة من خلال ربط سعر صرف العملة المحلية بسلة من العملات الأجنبية.

2. دراسة (الموسى ويارا، 2020) بعنوان:

تحسين أداء خوارزمية التجميع K-Means باستخدام التجميع الفرعي: دراسة تطبيقية على سوق الأسهم.

هدفت الدراسة إلى تطوير خوارزمية جديدة للتجميع تسمى Subtractive K-Means لتحسين خوارزمية K-Means من خلال إيجاد طريقة أفضل لاختيار المراكز الأولية للعناقيد، وقد اعتمدت الدراسة على استخدام مخرجات خوارزمية التجميع الفرعي كمدخلات لخوارزمية K-Means بدلاً من اختيارها عشوائياً. ولتقييم الخوارزمية الجديدة، تم تطبيقها على عدة قواعد بيانات وتمت مقارنة نتائجها مع نتائج K-Means من حيث عدد التكرارات، زمن التنفيذ، مجموع مربعات الأخطاء (SSE)، ومتوسط مقياس Silhouette بعد ذلك، تم تطبيق الخوارزمية الجديدة على بيانات أسهم سوق عمان المالي لتجميع الأسهم في مجموعات، وقد أظهرت النتائج تحسناً في نتائج التجميع وسرعة تنفيذ أعلى عند استخدام الخوارزمية الجديدة مقارنة مع K-Means. ففي معظم قواعد البيانات، قل عدد التكرارات وزمن التنفيذ، مع تحسن قيم SSE و Silhouette وفي حالة أسهم سوق عمان، تم تجميع الأسهم بشكل فعال، مما ساعد المستثمرين على اختيار الأسهم واتخاذ القرارات الاستثمارية، وقدمت الدراسة مجموعة من التوصيات أهمها تنصح الدراسة باستخدام خوارزمية Subtractive K-Means لتحسين أداء التجميع في حالات تواجد عدد كبير من البيانات أو في التطبيقات التي تتطلب سرعة تنفيذ عالية. كما يمكن تطبيق الخوارزمية على مجالات أخرى مثل تحليل الصور الطبية وتصنيف العملاء. ويوصى بإجراء المزيد من الأبحاث لتقييم أداء الخوارزمية على أنواع مختلفة من البيانات وللتحقيق في طرق أخرى لتحسينها.

الدراسات الأجنبية:

1. دراسة (Garg, 2012) بعنوان:

Forecasting Exchange Rate Using Machine-Learning Models with Time-Varying Volatility.

النتبؤ بأسعار صرف العملات باستخدام نماذج التعلم الآلي مع الأخذ بعين الاعتبار طبيعة تقلبات السوق المتغيرة باستمرار.

هدفت الدراسة إلى استقصاء القدرة على التنبؤ بعوائد أسعار الصرف على الترددات الشهرية واليومية باستخدام نماذج مرنة للتعلم الآلي. تم توسيع نماذج التعلم الآلي بنموذج GARCH لالتقاط التجميع المتقلب في سلسلة عوائد العائدات المالية. تم تحليل ثلاثة أسعار صرف مختلفة: EUR/SEK و EUR/USD و USD/SEK، وتم تطبيق نماذج التعلم الآلي الموسعة لـ GARCH لإجراء تنبؤات لمدة خطوة واحدة مسبقاً عن طريق التقدير التكراري. وأظهرت النتائج أن نموذج SVR الموسع لـ GARCH يظهر القدرة على تحسين تنبؤ عوائد أسعار الصرف على الترددات الشهرية واليومية. كانت المتغيرات المهمة المحددة هي الفائدة طويلة الأجل (5 سنوات) وسعر الصرف المتأخر لخطوة واحدة. كانت النتائج مختلطة مع ذلك، حيث تفوق GARCH-extended SVR النماذج الأخرى في بعض الحالات. وقد أوصت الدراسة أنه يمكن إجراء مقارنات إضافية باستخدام نموذج GARCH بدلاً من GARCH(0,1) يمكن أيضاً

استكشاف توسيعات مختلفة لنموذج ARCH/GARCH يمكن أن يشمل ذلك النماذج من نوع GARCH، بالإضافة إلى ذلك، يمكن تطبيق نماذج التعلم الآلي الموسعة لـ GARCH على عائدات مالية أخرى، مثل عائدات سوق الأسهم.

دراسة (Rout et al, 2014) بعنوان:

Forecasting of Currency Exchange Rates Using an Adaptive ARMA Model with Differential Evolution Based Training.

التنبؤ بأسعار سعر صرف العملات باستخدام نماذج ARMA التكيفي مع التدريب القائم على التطور التفاضلي.

هدفت الدراسة إلى التغلب على قيود الأساليب الإحصائية للتنبؤ بأسعار الصرف. ولتحقيق ذلك، اقترح الباحثون نموذجاً تنبئاً هجيناً يجمع بين بنية ذاتية الانحدار ومتوسط متحرك تكيفي (ARMA) وتدريب قائم على التطور التفاضلي (DE) لمعايير الأمامية والخلفية. تم استخراج سمات إحصائية بسيطة لكل سعر صرف باستخدام نافذة منزلقة من البيانات السابقة واستخدمت كمدخلات لنموذج التنبؤ لتدريب معاملاته الداخلية باستخدام إستراتيجية تحسين DE، تم التحقق من صحة كفاءة التنبؤ باستخدام أسعار صرف سابقة غير مستخدمة لأغراض التدريب. تم تقديم نتائج المحاكاة باستخدام بيانات من الحياة الواقعية لثلاثة أسعار صرف مختلفة لمدة 1-15 شهراً من التنبؤات المستقبلية. تمت مقارنة نتائج النموذج المطور بأربع طرق تنافسية أخرى ARMA-PSO، ARMA-CSO، ARMA-BFO، و-ARMA، FBLMS. أظهر نموذج التنبؤ ARMA-FBLMS القائم على المشتق أسوأ أداء للتنبؤ بأسعار الصرف. أظهرت مقارنات مقاييس أداء مختلفة، بما في ذلك وقت تدريب جميع نماذج الحوسبة التطورية الثلاثة، أن نموذج التنبؤ بأسعار الصرف ARMA-DE يمتلك قدرة تنبؤ فائقة قصيرة وطويلة المدى مقارنة بالآخرين. للتنبؤ طويل المدى، أوصت الدراسة باستخدام ميزات إضافية مخفية من السلاسل الزمنية المالية كمدخلات للنموذج، وكذلك استكشاف استخدام نماذج تكيفية أخرى واعدة. للتحسينات المستقبلية، يجب مراعاة العوامل السياسية، والكوارث الطبيعية، والأحداث غير المتوقعة الأخرى التي يمكن أن تؤثر على تقلبات أسعار الصرف.

تعقيب على الدراسات السابقة:

تعد الدراسة الحالية مساهمة علمية لما تتناوله من متغيرات، حيث تختلف الدراسة الحالية عن الدراسات السابقة بأن بعض الدراسات تناولت متغير سعر الصرف على حدة لبناء نموذج للتنبؤ وأخرى تناولت متغير سعر الصرف مع العديد من المتغيرات المستقلة لبناء النموذج، حيث تتميز الدراسة باستخدام خوارزمية العنقدة التي تشكل إحدى الركائز الفاعلة في الذكاء الصناعي التي من شأنها اكتشاف قاعدة المعرفة وبشكل خاص في ظل فترة الدراسة المأخوذة التي تتضمن فترة هدوء وأزمة ووباء، لذلك يمكن أن تسهم هذه الدراسة بما تمثله من إضافة للتراكم المعرفي في مجال التنبؤ بالمتغيرات المالية واكتشاف أنماط مخفية تساعد في إيجاد نموذج فعال.

مشكلة البحث:

تكمن مشكلة البحث في أنّ الاقتصاد السوري في الفترة الأخيرة ظل يعاني من مشاكل كبيرة، ولعلّ من أهم هذه المشاكل هو التدني في سعر صرف الليرة السورية مقابل العملات الأخرى وخاصة الدولار الأميركي، إذ أنّ سعر الصرف هو

الذي يربط الاقتصاد المحلي بالاقتصاد الخارجي من خلال معدلات التبادل التجاري مع الدول الأخرى والمتمثل بالصادرات والواردات وأثرها في الميزان التجاري ومن ثم ميزان المدفوعات سلباً وإيجاباً.

وبما أنه من الصعب التنبؤ بأسعار الصرف وخاصة أن معظم النماذج الإحصائية والاقتصادية بما فيها النماذج الكلاسيكية والحديثة المستخدمة لتحليل السلاسل الزمنية والتنبؤ بسلوك المتغيرات الاقتصادية لم تكن دقيقة في عملية التنبؤ بالتالي صعوبة الاعتماد عليها في هذا المجال، فكان لا بد استخدام خوارزمية العنقدة التي تساعد على فهم التركيب الطبيعي لمجموعات من البيانات، ويمكن تلخيص مشكلة البحث ضمن التساؤلات التالية:

- ما هي أهم العوامل الاقتصادية التي تؤثر في تذبذب سعر صرف الليرة السورية مقابل الدولار الأمريكي؟
- هل يمكن لخوارزمية التجميع K-means تحديد أنماط أو مجموعات متميزة في البيانات التاريخية لسعر صرف الليرة السورية مقابل الدولار الأمريكي؟
- هل يمكن لخوارزمية دعم آلات المتجهات SVM، التنبؤ بتغيرات سعر صرف الليرة السورية مقابل الدولار الأمريكي؟
- هل تسهم خوارزمية K-means في تحسين دقة التنبؤ عند دمجها مع خوارزمية SVM؟

أهمية البحث و أهدافه:

تتمثل أهمية البحث في ناحيتين: نظرية وعملية:

الأهمية العلمية: تعتبر هذه النماذج حديثة في تحليل سلوك المتغيرات الاقتصادية المالية واكتشاف الجانب المخفي لتلك المتغيرات، حيث أن معظم الدراسات التي تناولت سعر الصرف لم تستخدم أي من تقنيات خوارزمية التصنيف أو العنقدة.

الأهمية العملية: تتبع الأهمية العملية في استنتاج نموذج يستخدم للتنبؤ بسعر الصرف اليومي في سورية للفترة القادمة، مما يساهم في عملية التخطيط السليم واتخاذ القرارات الاقتصادية، وحاجة الاقتصاد السوري اليوم ككل والعديد من فئات المجتمع للنتائج التي ستمتخض عنها.

أهداف البحث:

تتمثل أهمية البحث بمجموعة من النقاط:

- تحديد على أهم العوامل الاقتصادية وغير الاقتصادية المؤثرة على تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي.
- استخدام خوارزمية التجميع K-means لتحديد الأنماط والتشابهات الموجودة في البيانات التاريخية لسعر الصرف، وتجميعها في مجموعات متميزة.
- التنبؤ بسعر الصرف باستخدام خوارزمية دعم آلات المتجهات (SVM).

فرضيات البحث:

- لا يمكن لخوارزمية التصنيف K-means تحديد أنماط أو مجموعات متميزة في البيانات التاريخية لسعر صرف الليرة السورية.
- لا يمكن لخوارزمية دعم آلات المتجهات SVM للتنبؤ بسعر صرف الليرة السورية.
- لا تؤدي إضافة خوارزمية K-means كخطوة معالجة مسبقة إلى تحسين دقة خوارزمية SVM في التنبؤ بسعر صرف الليرة السورية.

منهجية البحث:

تم استخدام المنهج الوصفي الذي يعتمد على وصف الظاهرة وتحليلها، وتم الحصول على بيانات سعر الصرف الرسمي لليرة السورية مقابل الدولار الأمريكي من بيانات مصرف سورية المركزي للفترة من 1/1/2015 حتى 15/2/2024، وتم استخدام برنامج SPSS26 و R وبرنامج Orang Data Mining لتحليل البيانات.

الحدود الزمانية والمكانية للبحث:

- الحدود المكانية: سورية
- الحدود الزمانية: امتدت فترة البحث من عام 1/1/2015 إلى عام 15/2/2024 وبشكل يومي وذلك لتوفر سلسلة تاريخية من متغيرات البحث.

الإطار النظري للبحث:**أولاً: مفهوم سعر الصرف:**

يُعد سعر الصرف من العوامل الحيوية في الاقتصاد، حيث يتم تحديده كقيمة نسبية لعملة دولة ما مقارنة بعملة أخرى أو سلة من العملات الأجنبية. يُعبر هذا السعر عادةً بعدد الوحدات من العملة الأجنبية التي يمكن شراؤها بوحدة واحدة من العملة المحلية. تقع أهمية سعر الصرف في دوره الحاسم في التجارة الدولية والتمويل، حيث يؤثر في تكاليف السلع والخدمات عند تداولها بين الدول، ويسهم في تحديد ربحية الصادرات والواردات واستقرار الاقتصاد بشكل عام.

يعرفه (Leung et al,2020) بأنه السعر الذي يمكن فيه استبدال عملة بأخرى في سوق الصرف الأجنبي، والعامل الحاسم في التجارة الدولية والتمويل، لأنه يقوم على تحديد تكلفة أسعار السلع والخدمات عند تداوله بين البلدان.

كما يعرفه (محفوظ وآخرون، 2022) بأنه المرآة التي ينعكس من خلالها مركز الدولة التجاري مع العالم الخارجي، حيث ينظر له من زاويتين، الأولى هي عدد وحدات النقد المحلي التي تتم مبادلتها مقابل وحدة واحدة من النقد الأجنبي، والثانية هي عدد وحدات العملة الأجنبية التي تدفع ثمناً لوحدة من العملة المحلية.

من وجهة نظر الباحث: سعر الصرف هو القيمة التي يمكن بها تبادل عملة مع أخرى في سوق الصرف الأجنبي، ويعتبر العامل الحاسم في التجارة الدولية والتمويل، إذ يحدد تكلفة السلع والخدمات عند تداولها بين البلدان.

ثانياً: أشكال سعر الصرف: يمكن تصنيف اشكال سعر الصرف في أربعة أنواع رئيسية:

1. سعر الصرف الإسمي: هو سعر تحويل عملة أجنبية إلى عملة محلية والعكس، يتأثر بالعوامل الاقتصادية والسياسية، حيث يمكن أن يرتفع أو ينخفض حسب نظرية العرض والطلب في سوق الصرف ويعبر عنه بالمعادلة (Ha et al, 2019):

$$e = \epsilon * \frac{p^{foreign}}{p^{domestic}} \quad (1)$$

أي محددات سعر الصرف e تتمثل في الأسعار العالمية $p^{foreign}$ والأسعار المحلية $p^{domestic}$ وسعر الصرف الحقيقي ϵ .

عند ارتفاع مستوى الأسعار المحلية، ينخفض سعر الصرف الإسمي للعملة المحلية، وعند ارتفاع مستوى الأسعار العالمية يرتفع سعر الصرف الإسمي، وهذا يوضح العلاقة العكسية بين الأسعار المحلية وسعر الصرف الإسمي، والتبادلية بين الأسعار العالمية وسعر الصرف الإسمي. حيث أنه يخلق ذلك سوقين للعملة كآتي: **سعر الصرف الرسمي** هو سعر العملة المحدد من قبل السلطات النقدية للمعاملات الرسمية وهو ثابت عادةً ومعلن، بينما **سعر الصرف الموازي** هو الذي يتشكل في الأسواق غير الرسمية بناءً على العرض والطلب ويتغير باستمرار، وغير معلن رسمياً (صلحة، 2022).

2. سعر الصرف الحقيقي: يعكس القوة الشرائية بين العملات بعد تعديلها وفقاً لمعدلات التضخم في البلدان المعنية؛ حيث تؤثر التغيرات في مستويات الأسعار على تنافسية الصادرات وجاذبية الواردات ويعبر عنه بالمعادلة:

$$R_e = e \left(\frac{p_f}{p_d} \right) \quad (2)$$

حيث أن:

← R_e : سعر الصرف الحقيقي، e : سعر الصرف الإسمي، p_f : مستوى الأسعار في الدولة الأجنبية، p_d : مستوى الأسعار المحلية.

أي لو زادت قيمة عملة محلية مع ثبات الأسعار، تقل تنافسية البضائع المحلية، لكن إذا ارتفعت أسعار البضائع الأجنبية، تصبح الصادرات المحلية أكثر تنافسية والمستوردات أكثر جاذبية إذا كان التضخم المحلي أعلى من الأجنبي (Hamilton, 2018).

3. سعر الصرف الإسمي الفعال: يعبر عن العلاقة الناشئة بين سعر الصرف الفعلي لعملة محلية معبر عنها بالقيمة المجمعة لسلة عملات أجنبية في فترة زمنية ما، أي عدد وحدات العملة المحلية المدفوعة فعلياً أو المقبوضة لقاء معاملة دولية قيمتها وحدة واحدة من العملة الأجنبية، وبالمقارنة بينه وبين الإسمي الذي ذكر سابقاً فإن الإسمي الفعال يكون مقابل المتوسط المرجح لمجموعة من العملات الأجنبية والإسمي الذي ذكر سابقاً يكون مقابل عملة أجنبية واحدة. ويعرف صندوق النقد الدولي سعر الصرف الإسمي الفعال (NEER) بأنه مقياس لقيمة العملة مقابل متوسط مرجح لعدد من العملات الأجنبية حيث تشير الزيادة فيه إلى ارتفاع سعر صرف العملة المحلية مقابل سلة العملات المرجحة لشركاتها التجاريين، ويمكن التعبير عن ذلك من خلال القانون التالي: (IMF, 2022) هذه ويعبر عنه بالمعادلة:

$$NEER = \sum_{i=1}^n \left(\frac{S_i}{S_i^*} \right)^{w_i} \quad (3)$$

حيث تشير n إلى عدد عملات الدول المضمنة في السلة و S_i إلى سعر صرف العملة الوطنية مقابل عملة الدولة (i)، و S_i^* سعر صرف العملة الوطنية مقابل عملة الدولة i المضمنة في السلة خلال سنة الأساس، و w_i فتشير إلى الوزن المرجح لعملة الشريك التجاري المضمنة في السلة، إذا كان NEER أكبر من واحد تكون العملة المحلية أقوى نسبياً من العملات المرجحة.

4. سعر الصرف الحقيقي الفعال: ويعبر عنه بأنه متوسط أوزان أسعار الصرف الاسمية الفعالة بعد تعديلها بنسبة التضخم في البلد المحلي والتضخم في مجموعة بلدان الشركاء التجاريين أي يستخدم كمؤشر لقياس تنافسية الدولة من حيث أسعار الصرف، حيث في هذه الحالة يتم إعطاء الدول التي يتم التبادل التجاري معها وزناً كبيراً في المؤشر مقارنة مع الدول الأخرى (ازهر، 2022) ويعبر عنه بالمعادلة:

$$REER = \sum_{i=1}^n \left(\frac{S_i}{S_i^*} * \frac{P_i}{P(md)} \right)^{w_i} \quad (4)$$

n : تشير إلى عدد عملات الدول المضمنة في السلة.

S_i : سعر صرف العملة الوطنية مقابل عملة الدولة i .

S_i^* : سعر صرف العملة الوطنية مقابل عملة الدولة i المضمنة في السلة خلال سنة الأساس.

w_i : الوزن المرجح لعملة الشريك التجاري المضمنة في السلة.

p_{md} : الأسعار المحلية السائدة.

p_i : الأسعار العالمية السائدة عند الشركاء التجاريين.

ثالثاً: العوامل المؤثرة في سعر الصرف:

يتأثر سعر الصرف بمجموعة من العوامل تحدد قيمته مقابل العملات الأخرى، حيث يعرف بأن سعر الصرف في أغلب الأوقات يكون غير مستقر وذلك ارتفاعاً وانخفاضاً، حيث أن عدم الاستقرار هذا يعود إلى مجموعة من العوامل الاقتصادية وغير الاقتصادية بما تتضمنهم من متغيرات، فإن أي تغير في هذه العوامل سينعكس على سعر الصرف سواء بالارتفاع أو الانخفاض ومحصلة تأثير مجموعة من هذه المتغيرات ستؤثر أيضاً في سعر الصرف.

وتتضمن العوامل الاقتصادية ما يلي:

(1 عرض النقود: هو مجموع الأموال المتاحة في الاقتصاد، يشمل العملة المتداولة وأنواع مختلفة من الودائع، ويؤثر على الأسعار والقوة الشرائية للعملة المحلية، وبالتالي في سعر الصرف، حيث أن زيادة عرض النقود قد تخفض قيمة العملة إذا لم يتبعها نمو اقتصادي مماثل، كما أن أسعار الفائدة تؤثر في تدفقات رأس المال، الأمر الذي يؤثر بدوره في قيمة العملة (Chasanh et al, 2022).

(2) **الناتج المحلي الإجمالي:** هو القيمة الإجمالية لكل السلع والخدمات المنتجة داخل بلد في سنة واحدة ويقاس قوة اقتصاده، حيث إن زيادة الناتج تدل على النمو الاقتصادي وتجذب الاستثمارات الأجنبية، مما قد يحسن قيمة العملة الوطنية (pareshkumar et al, 2014).

(3) **معدل التضخم:** يقيس الزيادة المستمرة في الأسعار ويؤدي إلى انخفاض القيمة الشرائية للعملة، وإن ارتفاع التضخم في بلد معين يسبب انخفاض قيمة العملة المحلية أي يتسبب ذلك في ارتفاع أسعار السلع والخدمات مقارنةً بالدول الأخرى، الأمر الذي يسبب اختلال في ميزان المدفوعات، حيث ستكون لدينا واردات أكبر من الصادرات، لأن السلع المحلية ستكون ذات أسعار مرتفعة، بينما الأجنبية ستكون ذات أسعار منخفضة ويزيادة الطلب على السلع الأجنبية سيزداد الطلب على العملة الأجنبية يقابله زيادة عرض العملة في البلدان الأخرى، الأمر الذي يسبب انخفاض قيمة العملة مقارنةً بالعملة الأجنبية (Odionye et al, 2023).

(4) **التغيرات في معدل الفائدة الحقيقية:** تغيرات معدل الفائدة لها تأثير مباشر في أسعار الصرف، حيث أن الزيادة في معدل الفائدة تجذب الاستثمارات الأجنبية، مما يرفع من قيمة العملة، بينما الانخفاض في معدل الفائدة يجعل العملة أقل جاذبية، مما يخفض من قيمتها، كما أن التغيرات في سياسات الفائدة تؤثر في الناتج المحلي ومستويات التضخم، ويمكن أن تؤدي إلى ركود اقتصادي إذا لم تدار بشكل فعال (أحمد، 2019).

(5) **الدين العام:** البلدان التي لديها ديون عامة أكثر تدفع معظم أرباحها في سداد الديون، حيث إن الأجانب لا يحبون هذا النوع من البلدان. ونتيجة لذلك، يصبحون غير متشجعين على القيام بأي نوع من الأعمال التجارية مع هذه البلدان، مما يجعل الواردات باهظة الثمن والتصدير أرخص، وهذا يجعل سعر صرف تلك البلدان منخفض مقابل سعر الصرف للدول الأجنبية. ويؤدي التغيير في معدل الضريبة إلى جذب الأموال إلى داخل وخارج البلاد (Eiteman et al, 2004).

(6) **التدخلات الحكومية:** تهدف التدخلات الحكومية عبر البنك المركزي للتحكم في سعر صرف العملة لتوفير الاستقرار الاقتصادي ومواجهة مشكلات مثل تهريب العملة والاحتكار والمضاربة في سورية، حيث لم تستطع هذه التدخلات أن ترسخ الاستقرار المنشود بسعر الصرف، ورغم محاولات الحفاظ على الوضع الاقتصادي، فقد اتسمت بعدم الكفاءة وترافقت مع زيادة في التضخم، واستهلاك الاحتياطي النقدي دون تحقيق تأثير ملموس (فضيلة، 2015).

أما العوامل غير الاقتصادية فإنها تتضمن الآتي:

1. **العوامل السياسية والعسكرية:** تؤثر الاضطرابات، والأخبار الاقتصادية، والتصريحات الرسمية، والنزاعات سلباً في المجالات الاقتصادية مثل التجارة، والصناعة، والزراعة، مما يؤدي إلى تقلبات في سعر الصرف وضعف الثقة في العملة المحلية، خاصةً مع زيادة الإنفاق العسكري وتراجع الاستثمارات نتيجة تضرر البنية التحتية (Eun et al, 2022).

2. **الإشاعات والأخبار:** يمكن أن تسبب تقلبات سريعة في سعر الصرف سواء كانت صحيحة أم لا، ولأن سعر الصرف يعتمد على أساسيات مثل سعر الفائدة وسياسات السلطة النقدية، إلى جانب الأحداث السياسية والأزمات مثل جائحة COVID-19، لها تأثير ملحوظ في العملة، حيث التغيرات في بيانات الحالات الجديدة للفيروس أظهرت تأثيراً على قيمة العملات، مما يدل على الاستجابة السريعة لأسعار الصرف لتغير الظروف الاقتصادية (النحال، 2016).

3. **الكوارث الطبيعية أو الأحداث غير المتوقعة:** تسبب الزلازل والأوبئة تداعيات سلبية على الاقتصاد وأسواق الصرف، لأن تلك الأحداث تقلل الثقة في العملة المحلية، وتزيد الطلب على العملات الأجنبية، وتؤدي لضغوطات على الاقتصاد (Ahmed, 2021). الأزمة السورية وفيروس كوفيد-19 مثالان على كيفية تأثير هذه الأحداث في العملة

والتجارة الدولية. وبحسب البنك الدولي في 2023، تسبب الزلزال في سورية خسائر بالغة ويحتاج إلى مبالغ كبيرة لإعادة الإعمار، مما يؤدي إلى انخفاض الإنتاج وارتفاع التضخم.

مفهوم التنقيب في البيانات وطرقه:

التنقيب في البيانات هو عملية تهدف إلى فحص وتحليل كميات ضخمة من البيانات وتحليلها لاستخراج المعلومات المفيدة واكتشاف الأنماط المجهولة، حيث تشكل الأساليب الإحصائية الكلاسيكية جزءاً أساسياً من هذه العملية، إلا أن التنقيب في البيانات يستفيد أيضاً من تقنيات الذكاء الاصطناعي والتعلم الآلي ويشمل تقنيات مختلفة مثل الانحدار (سواء كان للتنبؤ أو للتصنيف)، الشبكات العصبية، وأشجار القرار وحيث أنه أيضاً يركز على تقنيات أقل شيوعاً مثل قواعد الارتباط للاستكشاف الأولي للبيانات، التقنيات الضبابية والمجموعات التقريبية لوصف عدم اليقين المرتبط بالمفاهيم، آلات دعم المتجهات لفصل البيانات بشكل أكثر موثوقية، والخوارزميات الجينية لتحسين الحلول حيث تعالج هذه التقنيات تحديات عند التعامل مع كميات البيانات الضخمة، وتتعامل مع أنواع أكثر تعقيداً من البيانات. يسعى التنقيب في البيانات إلى تحديد العلاقات والأنماط عند التعامل مع هذه المجموعات البياناتية الضخمة، ما يوفر إمكانيات قوية لاستخراج رؤى ومعارف مفيدة من خلال التحليل الاستكشافي والمنهجي للبيانات (Unpingco, 2019).

ويرى الباحث أن عملية التنقيب في البيانات تتضمن تقنيات تحليلية من (علوم الإحصاء، التعلم الآلي، والذكاء الاصطناعي) لاكتشاف الأنماط والتوجهات في قواعد البيانات الكبيرة، وتهدف هذه العملية إلى تقديم معرفة عميقة ورؤى استراتيجية، مما يساعد في تحسين قرارات الأعمال وتحقيق الابتكار، حيث إن التنقيب يشمل تجميع البيانات، تحليلها، ومعالجتها لتحويل البيانات الخام إلى معلومات مهمة ومن خلال هذه العملية يمكن للمؤسسات صياغة استراتيجيات فعالة وتخفيض التكلفة وزيادة الإيرادات وتحقيق ميزة تنافسية.

خوارزمية K-means:

تعتبر خوارزمية K-Means من خوارزميات التعلم غير الخاضع للإشراف والتي تستخدم لحل مهام التصنيف على شكل عناقيد، حيث إن مبدأ عمل هذه الخوارزمية تتبع طريقة بسيطة وسهلة لتصنيف مجموعة بيانات معينة من خلال عدد معين من العناقيد مع افتراض أن k عدد العناقيد، مجموعة البيانات داخل العنقدة الواحدة متجانسة لكنها غير متجانسة مع مجموعة البيانات داخل العناقيد الأخرى، أي يمكن القول بأن خوارزمية k-mean هي تصنيف البيانات إلى مجموعات من الأشياء تبنى على صفات في K عدد من المجموعات، حيث تؤسس على المركز والذي يعرف (Center Based)، والتي تقوم بحل مشاكل العنقدة على عدة مراحل، ويمكن القول بأنها معدل النقاط في المجموعات (Unpingco, 2019).

وتعتبر خوارزمية العنقدة (K-means) إحدى الخوارزميات الفعالة في مجال العنقدة، حيث تبدأ باختيار مراكز عشوائية للسمات المتاحة لدينا، من أجل تحديد معدل التشابه بين السمات المختلفة المدروسة، حيث تم الاعتماد على حساب المسافة الاقليدية وهو عبارة عن معيار إحصائي يقوم بحساب المسافة بين العينات المختلفة بحيث يتم تجميع العينات ذات المسافة الأقل من قيمة محددة ثابتة فيما بينها بعنقود مستقل يمثل مجموعة متشابهة في الصفات، بعد ذلك يتم تحديد مركز كل عنقود بأخذ المتوسط الحسابي لعيناته وحساب المسافة بين جميع عينات الأصناف ومن ثم تحديد معدل التقارب، حيث يمكن في البداية أخذ هذه المراكز عشوائياً وحساب متوسط السمات بعد إضافة العينة المدروسة

إلى الصنف لإيجاد مركز جديد حيث يستمر التكرار حتى الوصول إلى ثبات في المراكز وعندما يتم الانتهاء من التصنيف، وعطى علاقة المسافة الإقليدية التي تستخدم في خوارزمية K-means لإيجاد درجة الترابط بين العناصر بالعلاقة (أيوب ونايف، 2016):

$$dist(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

خطوات بناء خوارزمية K-means:

تتمثل خطوات بناء خوارزمية K-means في الآتي (Ahmad and Dey, 2007):

- (1) تحديد قيمة K المطلوبة حيث تمثل عدد العناقيد المرغوبة.
- (2) تحديد المراكز الرئيسية، حيث يكون عدد المراكز الأولية مساوي لعدد العناقيد ويتم تحديده بشكل عشوائي من البيانات الموجودة لدينا.
- (3) العمل على إيجاد النقاط الأقرب إلى كل مركز عنقود من خلال حساب المسافة الإقليدية.
- (4) ترتيب البيانات من خلال المسافة الدنيا، حيث تصبح البيانات تابعة للعنقود إذا كانت أقرب لمركز العنقود.
- (5) إيجاد المراكز الجديدة اعتماداً على متوسط البيانات في كل عنقود
- (6) العمل على اختبار النموذج في حال حدوث أي تغيير يتم العودة للخطوة 3 أو المتابعة في حال حدوث أي تغييرات في الاسناد إلى العناقيد.

خوارزمية آلة المتجه الداعم SVM:

هي خوارزمية تعلم آلي خاضعة للإشراف تُستخدم في كل من التصنيف والانحدار. حيث يتمثل الهدف الرئيسي لخوارزمية آلة المتجه الداعم في إيجاد المستوى التشعبي الأمثل في فضاء ذي أبعاد N الذي يمكنه فصل نقاط البيانات في فئات مختلفة في فضاء السمات، ويحاول المستوى التشعبي أن يكون الهامش بين أقرب النقاط للفئات المختلفة أكبر قدر ممكن ويعتمد بُعد المستوى الفائق على عدد الميزات. حيث إذا كان عدد ميزات الإدخال اثنين فإن المستوى التشعبي يكون مجرد خط، أما إذا كان عدد ميزات المدخلات ثلاثة يصبح المستوى الفائق مستوى ثنائي الأبعاد، وكلما زاد عدد السمات كلما أصبح من الصعب تخيله، حيث إنّ البيانات الأساسية تصنف وفق النموذج الرياضي الآتي (Arabiat and ALTAYEB, 2024):

$$W^T x_i + b \geq +1 \text{ for } d_i = +1, i = 1, 2, \dots, N \quad (6)$$

$$W^T x_i + b \geq +1 \text{ for } d_i = -1, i = 1, 2, \dots, N$$

حيث W : متجه الأوزان، x : متجه الإدخال، b : تمثل قيمة التحيز، d : تمثل قيمة الإخراج.

ويمكن ملاحظة معاملات الحدود في المستوى من خلال الشكل الآتي:

نقول أنّ معادلة المستوى الفاصل (*Hyper plan*) تكتب بالشكل

$$W^T x_i + b = 0 \quad (7)$$

كما أنّ البيانات القريبة أو التي تقع على حدود الحد الفاصل تسمى متجهات الدعم أو المساندة، ويمكن حساب المسافة

$$d(W, b, x_i) = \frac{|W^T x_i + b|}{\|W\|} \quad (8) \quad \text{بين النقاط في المستوى الفاصل من العلاقة:}$$

أنواع خوارزمية آلة المتجه الداعم SVM:

من أنواع خوارزمية آلة المتجه الداعم SVM الآتي (Torgo,2011):

(1) آلة المتجه الداعم الخطي: تستخدم لفصل البيانات خطياً بواسطة الحد الفاصل Hyper plane إذا كانت البيانات ثنائية الأبعاد، أما إذا كانت متعددة الأبعاد فإن البيانات تنقسم إلى ثلاث خطوط، عندما يمكن فصل البيانات بشكل خطي بدقة تكون آلة المتجه الداعم الخطية مناسبة جداً، مما يعني أن خطأ مستقيماً واحداً (في البعد الثاني) أو (في أبعاد أعلى) والذي يمكن أن يقسم تماماً نقاط البيانات إلى فئاتها المعنية حيث أن الحد القراري هو الذي يزيد من الهامش بين الفئات

(2) آلة المتجه الداعم غير الخطي: عندما لا يمكن تقسيم البيانات بصورة خطية يتم استخدام وظائف النواة Kernel والتي تحول الحالة الخطية إلى حالة غير خطية. أي يتم تحويل البيانات الأصلية إلى فضاء سمات ذو أبعاد أعلى، حيث يمكن فصل نقاط البيانات بشكل خطي ويستخدم الـ SVM الخطي لتحديد حدود القرار الغير خطي في هذا الفضاء المعدل ويمكن توضيح وظائف النواة Kernel في الجدول الآتي :

Linear	$K(w, b) = w^T x + b \quad (8)$ هذه المعادلة تمثل الحدود القرارية الخطية في خوارزمية SVM حيث يتم استخدام vector الوزن وقيمة الإزاحة لفصل البيانات إلى فئتين مختلفتين.
Polynomial	$K(w, x) = (\gamma w^T x + b)^N \quad (9)$ تم استخدام تحويل Polynomial لتحويل المساحة الإدخالية من أبعاد منخفضة إلى أبعاد أعلى حيث: γ يمثل عامل التوازن الذي يؤثر على تأثير تحويل البيانات N يمثل درجة الـ Polynomial ويحدد مدى تعقيد التحويل الدرجة. باستخدام هذه المعادلة، يتم رفع ناتج الضرب الداخلي بين الوزن والبيانات إلى قوة N وإضافة قيمة الإزاحة b. هذا التحويل الدرجة يساعد في خلق حدود قرارية أكثر تعقيداً بحيث يتمكن النموذج من فصل البيانات بشكل أفضل في حالات الفصل غير الخطي.
Gaussian RBF	$K(w, x) = \exp(-\gamma \ x_i - x_j\ ^n) \quad (10)$ تخدم وظيفة الـ Gaussian لقياس التشابه بين نقطتين بابينيتين. يتم تحويل البيانات إلى أبعاد أعلى γ هو عامل يتحكم في شدة التأثير لدوار النقطتين: x_i و x_j: يمثلان نقطتين من بيانات الإدخال عند استخدام هذه النواة، تكون الحدود بين الفئات غير الخطية وتتميز بالقدرة على فصل البيانات في فضاء ذو أبعاد عالية. يعتبر استخدام Gaussian RBF من الطرق الشائعة للتعامل مع مجموعات البيانات التي غالباً ما تكون غير خطية وغير قابلة للفصل باستخدام حدود خطية.

Sigmoid	$K(x_i, x_j) = \tanh(ax_i^T x_j + b) \quad (11)$ يتم استخدام وظيفة Sigmoid لقياس التشابه بين نقطتين من بيانات الإدخال. α: يمثل عامل النمو الذي يحدد مقدار التغير في الميل لوظيفة Sigmoid حيث قيمة α تحدد كمية التأثير الذي تمارسه Sigmoid على البيانات عند استخدام نواة Sigmoid، يتم إنشاء حدود غير خطية بين الفئات، مما يسمح بفصل البيانات بشكل فعال في حالات البيانات الغير قابلة للفصل بواسطة حدود خطية. حيث أن هذه النواة تُستخدم بشكل شائع لتعزيز أداء النماذج الخاصة بتصنيف البيانات غير الخطية.
---------	---


النتائج والمناقشة:

اعتمد البحث والتحليل على بيانات سعر صرف يومية للفترة الزمنية الممتدة من عام 2015 وحتى عام 2024 بواقع 3333 مشاهدة، وتم تحليل بيانات البحث باستخدام البرامج R studio, SPSS26, orang data mining.

أولاً: البحث عن العدد الأمثل للعناقيد:

(1) عدد المجموعات مقابل الإجمالي ضمن مجموع المربعات

الشكل (1): عدد المجموعات مقابل الإجمالي ضمن مجموع المربعات



المصدر: من إعداد الباحث بالاعتماد على Rstudio


يوضح الشكل رقم (1) خوارزمية Elbow Point وهي تقنية تساعد في إيجاد العدد الأمثل للعناقيد حيث يعمل من خلال تشغيل خوارزمية k-means عدة مرات، مع تغيير قيمة k في كل مرة (مثلاً من 1 إلى 10) ثم حساب مجموع مربعات المسافات (WCSS) بين كل نقطة بيانات ومركز عنقودها، لكل قيمة k، ثم يتم رسم قيم WCSS على المحور الرأسي وقيم k على المحور الأفقي وبعدها يتم البحث عن نقطة الانحناء (الانكسار) أو عادةً ما تسمى الكوع في الرسم البياني، والتي تمثل نقطة التغير الملحوظ في انحدار الخط، بالنسبة للبيانات التي لدينا نلاحظ أنه يوجد انحناء عند $k = 2$ عنقود، فيمكن القول مبدئياً أن عدد العناقيد هي 2 وقد تم التأكد من عدد العناقيد من الاختبارات اللاحقة .

(2) عدد المجموعات مقابل إحصائية الفجوة واختبار silhouett للتأكد من عدد العناقيد:


تُعدّ إحصائية الفجوة أداة قيمة لتحديد العدد الأمثل للمجموعات عند تجميع البيانات. تُقارن هذه الإحصائية التباين داخل المجموعات بقيمتها المتوقعة للتوزيع بدون تجميع، مما يُتيح تقييم تأثير التجميع على تباين البيانات، حيث تستخدم هذه

الطريقة لقياس مدى التباين داخل المجموعة ومقارنة القيم المتوقعة لتوزيع بدون تجميع بقيم مختلفة من عدد المجموعات المختلفة (k) عندما يكون هناك تداخل أقل بين القيم المتوقعة والقيم الفعلية للتباين داخل المجموعة، فإن ذلك يشير إلى وجود تجميع فعال، يتم استخدام طريقة إحصائية الفجوة بالاعتماد على طريقة الـ k-means clustering لتقدير توزيع البيانات. يتم حساب قيم الفجوة لمجموعة من القيم المختلفة لـ k واختيار القيمة لـ k التي تعطي فجوة قيمة منخفضة نسبياً.

الشكل (3): اختبار Silhouette



المصدر: من إعداد الباحث بالاعتماد على Rstudio

الشكل (2): إحصائية الفجوة
uster = km
K.max = 7, B = 100, nstart = 50)

المصدر: من إعداد الباحث بالاعتماد على Rstudio

وبناءً عليه ومن الشكل (2) يلاحظ الباحث أن المحور الأفقي (x) يمثل عدد المجموعات (k) والمحور الرأسي (y) يمثل قيمة إحصائية الفجوة (Gap statistic) ويمثل الخط الأسود متوسط قيمة إحصائية الفجوة لكل عدد من المجموعات والخطوط الحمراء الرأسية تمثل الخطأ المعياري لكل قيمة والهدف هو العثور على أكبر قيمة للإحصائية، حيث تكون قيم إحصائية الفجوة أكبر بكثير من قيم الخطأ المعياري، بالتالي في هذه الحالة يمكن القول أن $k=2$ هو أفضل عدد للمجموعات لأن إحصائية الفجوة أكبر من قيم الخطأ المعياري عند $k=2$ مقارنةً بالعدد من المجموعات الأخرى.

ومن الشكل (3) يلاحظ الباحث أن هذا الرسم البياني يوضح نتيجة اختبار (Silhouette) لكشف أفضل عدد للمجموعات في تحليل العناقيد، وهو مقياس لمدى تناسب كل نقطة مع مجموعة معينة، ويعتمد على مفهوم "المسافة" بين النقطة ومركز مجموعة النقطة ذاتها وأقرب مجموعة أخرى والهدف هو العثور على أعلى قيمة (Silhouette)، مما يعني أفضل تناسب بين النقط ومجموعة معينة بناءً عليه يجد الباحث أن أعلى قيمة (Silhouette) هي عند $K=2$. بالتالي يستنتج الباحث وبناءً على الاختبارات التي أجراها للحساب عدد العناقيد الأنسب يتبين للباحث أن العدد الأنسب للعناقيد هو 2.

ثانياً: إجراء تجميع K-Means باستخدام K الأمثل

الجدول (1): مراكز المجموعات الأولية، تاريخ التكرارات ومراكز المجموعات النهائية في خوارزمية K-Means

Initial Cluster Centers			Iteration History ^a			Final Cluster Centers		
	Cluster		Iteration	Change in Cluster Centers				
	1	2		1	2		1	2
exchang rate	-.54876	4.25464	1	.310	.634	exchang rate	-.23855	3.62111
			2	.000	.000			

المصدر: من إعداد الباحث بالاعتماد على spss26

يتكون الجدول رقم (1) من ثلاثة أجزاء حيث الجزء الأول (Initial Cluster Centers) يُظهر مراكز المجموعات الأولية التي تم اختيارها عشوائياً للبدء بعملية K-means حيث في التكرار الأول تم اختيار (-.54876) كمركز للمجموعة "1" و (4.25464) كمركز للمجموعة "2"، والجزء الثاني (Iteration History) يُظهر تاريخ التغيرات في مراكز المجموعات (Change in Cluster Centers) خلال التكرارات التي تُجرى في خوارزمية K-Means حيث في التكرار الأول تغير مركز المجموعة الأولى بمقدار (0.310) وتغير مركز المجموعة الثانية بمقدار (0.634)، أما في التكرار الثاني لم تحدث أي تغيرات في مراكز المجموعات وهذا يشير إلى أن الخوارزمية حققت التقارب. الجزء الثالث (Final Cluster Centers) يُظهر مراكز المجموعات النهائية التي وصلت إليها الخوارزمية بعد التقارب، حيث أصبح مركز المجموعة الأولى هو -0.23855 ومركز المجموعة الثانية هو 3.62111

الجدول (2): المسافات بين مراكز المجموعات النهائية والحالات التي تم تصنيفها

Distances between Final Cluster Centers			Number of Cases in each Cluster		
Cluster	1	2	Cluster	1	3127.000
1		3.860		2	206.000
2	3.860		Valid		3333.000
			Missing		1.000

المصدر: من إعداد الباحث بالاعتماد على spss26

من الجدول رقم (2) يُظهر القسم الأول (Distances between Final Cluster Centers) المسافات بين مراكز المجموعات النهائية بعد وصول خوارزمية K-Means إلى التقارب، حيث يُشير رقم المجموعة في الصف إلى المجموعة التي نقارنها بالمجموعات الأخرى بالعمود والمسافة تُشير إلى قيمة البيانات في الجدول رقم (2) إلى المسافة بين مركز المجموعة الموضحة في الصف ومركز المجموعة الموضحة في العمود. يوضح هذا الجدول رقم (2) أن المسافة بين مركز المجموعة "1" ومركز المجموعة "2" هي 3.860 هذا يعني أن المجموعتان معزولتان عن بعضهما بعضاً، وأن النقاط الموجودة في كل مجموعة أقرب إلى مركزها من أقربها إلى مركز المجموعة الأخرى. ويُظهر القسم الآخر من الجدول رقم (2) (Number of Cases in each Cluster) عدد الحالات التي تم تصنيفها إلى كل مجموعة بعد انتهاء عمل خوارزمية K-Means، عدد الحالات التي تم تصنيفها إلى المجموعة "1" هو

3127 وعدد الحالات التي تم تصنيفها إلى المجموعة "2" هو 206، أي أن البيانات في المجموعة "1" تُعد أكثر تشابهاً مع بعضها البعض من البيانات في المجموعة "2".

الجدول (3): اختبار الفروق بين المجموعات

ANOVA						
	Cluster		Error		F	Sig.
	Mean Square	df	Mean Square	df		
exchang rate	2879.105	1	.136	3331	21175.559	.000


المصدر: من إعداد الباحث بالاعتماد على spss26

يُظهر الجدول رقم (3) نتائج تحليل التباين ANOVA التي تُستخدم لمقارنة متوسطات المجموعات (Clusters) في خوارزمية K-Means وعليه يلاحظ الباحث أن $sig < 0.05$ بالتالي يرفض الفرضية العدم ويقبل الفرضية البديلة التي تنص على أنه يمكن لخوارزمية التصنيف K-means تحديد أنماط أو مجموعات متميزة في البيانات التاريخية لسعر صرف الليرة السورية، أي أن الخوارزمية K-Means نجحت في تصنيف البيانات إلى مجموعتين ذوات متوسطات سعر صرف مختلفة بشكل ذو دلالة إحصائية.

ثانياً: التنبؤ باستخدام خوارزمية SVM

من أجل التنبؤ بسعر الصرف حتى نهاية عام 2024 قام الباحث باستخدام برنامج Orang Data Mining، حيث قام الباحث بتطبيق الخوارزمية قبل وبعد عملية العنقدة للتأكد هل سيتحسن النموذج بإضافة عملية العنقدة كخطوة سابقة قبل تطبيق SVM.

الشكل (4): خوارزمية SVM قبل تطبيق العنقدة كخطوة سابقة



المصدر: من إعداد الباحث بالاعتماد على orange

يوضح الشكل (4) الخطوات التي تم اتباعها في برنامج Orang Data Mining من أجل تطبيق خوارزمية SVM حيث تم في البداية تم تحميل ملف البيانات إلى برنامج Orane حيث يتضمن الملف المشاهدات اليومية من 1/1/2015 حتى 15/2/2024 مشاهدة، وكخطوة أولية تم معالجة البيانات من خلال استخدام

"Continuize" لتحويل البيانات قيم معيارية، وبعدها اختيار العمود الهدف من خلال "Select Columns" التي سُتستخدم في النموذج، ثم تقسيم البيانات إلى بيانات تدريب بنسبة 70% واختبار بنسبة 30% من خلال "data sample" وبعدها يتم تطبيق خوارزمية SVM وتم اختيار وظيفة نواة خوارزمية SVM هي RBF والتي تم توضيحها في العلاقة رقم (10)، وتم توضيح مؤشرات أداء النموذج المستخدم في الجدول (4)


الجدول(4): مؤشرات دقة النموذج المتنبأ قبل تطبيق العنقدة

Model	MSE	RMSE	MAE	MAPE	R^2
SVM model	0.506	0.711	0.247	0.220	0.495

المصدر: من إعداد الباحث بالاعتماد على orange

- حيث R^2 يشير إلى "معامل التحديد" وهو مقياس لمدى تناسب النموذج مع البيانات. يتراوح من 0 إلى 1، حيث يشير 1 إلى تناسب مثالي، بينما يشير 0 إلى عدم تناسب.
 - **MAPE**: يشير إلى "متوسط الخطأ المطلق النسبي" وهو مقياس للخطأ النسبي المتوسط بين التنبؤات والقيم الفعلية. يُعبر عن MAPE كنسبة مئوية، وتُعتبر قيمة أقل أفضل.
 - **MAE** : يشير إلى "متوسط الخطأ المطلق" وهو مقياس للخطأ المطلق المتوسط بين التنبؤات والقيم الفعلية.
 - **RMSE**: يشير إلى "جذر متوسط الخطأ التربيعي" وهو مقياس للخطأ المتوسط التربيعي بين التنبؤات والقيم الفعلية. يُفضل أن يكون RMSE صغيراً، حيث يُشير إلى دقة تنبؤية أفضل.
 - **MSE**: يشير إلى "متوسط الخطأ التربيعي" وهو مقياس للخطأ التربيعي المتوسط بين التنبؤات والقيم الفعلية. يُفضل أن يكون MSE صغيراً، حيث يُشير إلى دقة تنبؤية أفضل.
- ← وبناءً عليه يرفض الفرضية العدم ويقبل الفرضية البديلة التي تنص على أنه يمكن لخوارزمية دعم آلات المتجهات SVM التنبؤ بسعر صرف الليرة السورية.

الشكل(5): خوارزمية SVM بعد تطبيق العنقدة (K-means) كخطوة سابقة



المصدر: من إعداد الباحث بالاعتماد على orange

يوضح الشكل (5) الخطوات التي تم اتباعها في برنامج Orang Data Mining من أجل تطبيق خوارزمية SVM بعد تطبيق خوارزمية k-means كخطوة سابقة، حيث تم تطبيق الخطوات نفسها التي تم تطبيقها وشرحها في الجدول (4)، باختلاف تطبيق خوارزمية K-means كخطوة سابقة قبل تطبيق خوارزمية SVM وعليه كانت مؤشرات دقة النموذج المنتبأ به موضحة بالجدول (5).

الجدول (5): مؤشرات دقة النموذج المنتبأ به بعد تطبيق العنقدة

Model	MSE	RMSE	MAE	MAPE	R^2
SVM model	0.267	0.517	0.202	0.290	0.754

المصدر: من إعداد الباحث بالاعتماد على orange

من الجدول (5) يلاحظ الباحث أنّ مؤشرات دقة النموذج المنتبأ به قد تحسنت، وبناءً عليه يرفض الفرضية العدم ويقبل الفرضية البديلة التي تنص على أنه تؤدي إضافة خوارزمية K-means كخطوة معالجة مسبقة إلى تحسين دقة خوارزمية SVM في التنبؤ بسعر صرف الليرة السورية، وقد تم الاعتماد على هذا النموذج للتنبؤ بسعر الصرف حتى نهاية عام 2024.

الجدول (6): جدول المقارنة قبل وبعد تطبيق K-means

المؤشر	قبل K-means	بعد K-means	نسبة التغيير
MSE	0.506	0.267	-47.23%
RMSE	0.711	0.517	-27.28%
MAE	0.247	0.202	-18.21%
MAPE	0.220	0.290	+31.81%
R^2	0.495	0.754	+52.32%


المصدر: من إعداد الباحث

يُلاحظ تحسن واضح في أداء نموذج SVM للتنبؤ بسعر صرف الليرة السورية بعد تطبيق خوارزمية (K-means) كخطوة سابقة حيث لاحظ الباحث:

- انخفاض قيمة الخطأ (MSE): انخفضت قيمة متوسط الخطأ التربيعي (MSE) من 0.506 إلى 0.267، بنسبة انخفاض بلغت 47.23%. وهذا يشير إلى انخفاض كبير في التباين بين القيم المتوقعة والقيم الفعلية.
- انخفاض قيمة جذر متوسط الخطأ التربيعي (RMSE): انخفضت قيمة (RMSE) من 0.711 إلى 0.517، بنسبة انخفاض بلغت 27.28%. وهذا يعني أن النموذج أصبح أكثر دقة في التنبؤ بالقيم القريبة من القيم الفعلية.

- انخفاض قيمة متوسط الخطأ المطلق (MAE): انخفضت قيمة (MAE) من 0.247 إلى 0.202، بنسبة انخفاض بلغت 18.21%. وهذا يدل على أن النموذج أصبح أقل عرضة للأخطاء الكبيرة في التنبؤ.
 - انخفاض قيمة متوسط الخطأ المطلق النسبي (MAPE): على الرغم من أن قيمة (MAPE) قد ارتفعت من 0.220 إلى 0.290، بنسبة زيادة بلغت 31.81%، إلا أن هذا لا يقلل من أهمية التحسن الذي طرأ على المؤشرات الأخرى.
 - ارتفاع قيمة معامل التحديد (R^2): ارتفعت قيمة (R^2) من 0.495 إلى 0.754، بنسبة زيادة بلغت 52.32%. وهذا يشير إلى تحسن ملحوظ في قدرة النموذج على تفسير التباين في البيانات.
- أي أن استخدام خوارزمية (K-means) كخطوة سابقة لتحضير البيانات قد ساهم بشكل كبير في تحسين أداء نموذج SVM للتنبؤ بسعر صرف الليرة السورية. انخفاض قيم الخطأ (MSE, RMSE, MAE) وارتفاع قيمة (R^2) تشير إلى أن النموذج أصبح أكثر دقة في التنبؤ وأكثر قدرة على تفسير التباين في البيانات. رغم ارتفاع قيم (MAPE)، إلا أن التحسن الكبير في باقي المؤشرات يؤكد فاعلية استخدام (K-means) كخطوة سابقة.

الشكل (6): النموذج المتنبأ به من تطبيق خوارزمية SVM



المصدر: من إعداد الباحث بالاعتماد على orange

يظهر الشكل رقم (6) "سعر الصرف" (مُشار إليه باللون الأزرق) ونموذج "SVM" (مُشار إليه باللون الأحمر) و"خطأ نموذج SVM" (مُشار إليه باللون الأزرق في القسم السفلي من الشكل 6)، حيث يبين تطور سعر الصرف مع مرور الوقت، حيث يُمكن ملاحظة تغييرات كبيرة في السنوات الأخيرة، خاصةً في 2023، نموذج SVM يُمثل نموذج التنبؤ بسعر الصرف باستخدام خوارزمية SVM، حيث يُظهر قدرة النموذج على التنبؤ بالاتجاهات العامة لسعر الصرف،

ولكن مع بعض الأخطاء في التنبؤ بالتقلبات المفاجئة، خطأ نموذج SVM يُبين الفرق بين النموذج والبيانات الفعلية لسعر الصرف، حيث يُظهر خطأ كبيراً في بعض الفترات، خاصةً في 2023، بينما يُظهر خطأ أقل في فترات أخرى.

الاستنتاجات والتوصيات:

(1) يتحدد سعر صرف الليرة السورية مقابل الدولار الأمريكي بتفاعل معقد بين عدة عوامل اقتصادية رئيسية. يلعب عرض النقود دوراً محورياً، حيث أن زيادته دون نمو اقتصادي متناسب تساهم في انخفاض قيمة العملة. يُضاف إلى ذلك تأثير معدل التضخم، الذي يُضعف القوة الشرائية لليرة السورية مع ارتفاعه. كذلك، يُعتبر الناتج المحلي الإجمالي مؤشراً هاماً، إذ يعكس قوة الاقتصاد وقدرته على جذب الاستثمارات الأجنبية، مما يؤثر إيجاباً على سعر الصرف. وتُظهر التغيرات في أسعار الفائدة الحقيقية تأثيراً مباشراً على جاذبية العملة للاستثمارات، وبالتالي على قيمتها. أخيراً، يُمثل مستوى الدين العام عبئاً على الاقتصاد ويُقلل من ثقة المستثمرين الأجانب، مما يسهم في انخفاض سعر صرف الليرة.

(2) أظهرت الدراسة فعالية نموذج هجين يجمع بين خوارزمية K-means و SVM للتنبؤ بسعر صرف الليرة السورية مقابل الدولار الأمريكي. نجاح K-means في تصنيف البيانات إلى مجموعات متجانسة ساهم في تحسين أداء SVM وقدرتها على التنبؤ بالتغيرات في سعر الصرف. يُشير هذا إلى أن النموذج الهجين المقترح يُمكن استخدامه كأداة فعالة للتنبؤ بسعر الصرف اليومي في سورية للفترات القادمة، مما يُساعد في اتخاذ القرارات الاقتصادية السليمة والتخطيط للمستقبل في ظل تقلبات السوق. مع ذلك، يجب الأخذ بعين الاعتبار أن النموذج ليس مثالياً وقد يحتاج إلى تطوير مستمر من خلال دمج بيانات إضافية وعوامل أخرى مؤثرة، بالإضافة إلى تحسين تقنيات التحليل المستخدمة.

(3) يستنتج من نجاح خوارزمية K-means في تحديد أنماط متميزة في بيانات سعر الصرف، وجود مجموعات أو فئات مختلفة ضمن البيانات المدروسة تتبع سلوكيات متميزة فيما يتعلق بسعر الصرف. هذا يشير إلى إمكانية وجود عوامل كامنة أو متغيرات غير مدرجة في التحليل تؤثر على سعر الصرف وتساهم في تكوين هذه المجموعات. بمعنى آخر، سعر الصرف لا يتحرك عشوائياً، بل يتأثر بعوامل تؤدي إلى سلوكيات مميزة يمكن للخوارزمية التقاطها.

(4) تحسين دقة التنبؤ باستخدام خوارزمية SVM بعد تطبيق K-means، يشير إلى أن عملية تجميع البيانات وتصنيفها إلى مجموعات متجانسة قبل تطبيق SVM يُحسن من قدرة النموذج على التنبؤ بالتغيرات المستقبلية في سعر الصرف. هذا يشير إلى أن K-means تُساعد في تبسيط البيانات وتقليل التشويش فيها، مما يسمح لـ SVM بالتقاط العلاقات بين المتغيرات بشكل أكثر فعالية. بمعنى آخر، وجود مجموعات متجانسة يُسهل على SVM مهمة التنبؤ.

(5) فاعلية خوارزمية SVM في التنبؤ بسعر الصرف تُشير إلى أن هذه الخوارزمية تُمثل أداة فعالة لتحليل بيانات سعر الصرف والتنبؤ بتغيراته المستقبلية، ولو بشكل تقريبي. هذا يفتح الباب أمام استخدام هذه الخوارزمية في بناء نماذج تنبؤية أكثر تعقيداً ودقة، ودمجها مع أدوات أخرى لتحليل البيانات المالية والاقتصادية.

التوصيات:

بناءً على نتائج البحث، يُمكن تقديم مجموعة من التوصيات الأكاديمية:

(1) يوصى الباحث بمزيد من البحث والتحليل لفهم التفاعلات المعقدة بين العوامل الاقتصادية وغير الاقتصادية وتأثيرها على سعر صرف الليرة السورية، من خلال التركيز على دراسة السياسات النقدية والمالية التي تؤثر على عرض النقود ومعدل التضخم، بالإضافة إلى السياسات الاقتصادية التي تحفز النمو الاقتصادي وتجذب الاستثمارات الأجنبية. كما يُوصى بتحليل دور الدين العام في التأثير على ثقة المستثمرين والبحث عن سبل لتخفيفه وإدارته بشكل فعال. يُشدد أيضاً على أهمية مراقبة وتحليل التغيرات في أسعار الفائدة الحقيقية وتأثيرها على جاذبية الليرة السورية للاستثمارات. من شأن هذه الدراسات المُعمقة أن تُساهم في وضع استراتيجيات فعّالة للحفاظ على استقرار سعر صرف الليرة السورية.

(2) توسيع نطاق الدراسة: وذلك من خلال:

- نطاق زمني أكبر: إجراء دراسة باستخدام سلسلة زمنية أطول لفترة زمنية تُشمل فترات تاريخية أكثر استقراراً أو أزمات اقتصادية مختلفة، لإثراء نتائج البحث وتحسين دقة التنبؤ.
- مجموعة دول: تطبيق النموذج على مجموعة من الدول ذات ظروف اقتصادية مختلفة، للمقارنة بين سلوك سعر الصرف في ظروف اقتصادية متنوعة.

(3) تحسين تقنيات التحليل: وذلك من خلال:

- التعلم العميق: تطبيق تقنيات التعلم العميق في تحليل البيانات، كالتحليل النصي الذي يُمكنه معالجة الكثير من البيانات المنشورة المتعلقة بالاقتصاد السوري وتحليل المعلومات من الكتب والتقارير المتعلقة بالاقتصاد السوري.
- طرق إحصائية متقدمة: استخدام طرق إحصائية متقدمة للتنبؤ بسعر الصرف، مثل "ARIMA" و "GARCH" مع التكامل مع تقنيات الذكاء الاصطناعي.
- التحليل المتعدد: دمج تقنيات تحليلية مختلفة مثل "K-means" و "SVM" و "ARIMA" و "GARCH" في نموذج واحد للوصول إلى نموذج تنبؤي بمؤشرات خطأ منخفضة ودقة تنبؤية مرتفعة.

References:

Arabic references:

- AHMAD, T. Modeling the fluctuations of the Syrian pound exchange rate against the US dollar using GARCH models, Tishreen University Journal. Volume (41), Issue (5), 2019, p. 55-71.
- AZHAR, A. The impact of exchange rate fluctuations on Turkish economic growth. TADAMSA D-UNEGMU. Volume (2), 2022, p. 141-152.
- AYOUB, M; NAYEF, Q. Using K-Means clustering algorithm in Data Mining with an applied reality. Journal of Economic and Administrative Sciences, Vol. 22, No. 91, 2016, p. 389-406.
- SALHA, A. Exchange rate liberalization policies in Arab countries between theory and practice. Arab Monetary Fund, 2022.
- FADILA, A; ABED, S. The Impact of Monetary Policies on the Purchasing Power of the Syrian Pound (2001-2013). Tishreen University Journal of Research and Scientific Studies. Volume (37), Issue (5), 2015, p. 249-270.
- MAHFOUZ, A; Ahmed, M. The impact of exchange rate changes on the balance of payments: An applied study on the Libyan economy during the period (1990-2018). Ustaz Journal. Volume (59), 2022, p. 22-87.
- ALMOUSA, Y; HASSANA, Y. Improving the performance of K-Means clustering algorithm using sub-clustering: An applied study on the stock market. Aleppo University Research Journal, Economic Sciences Series, Issue (41), 2020, p.1-21.
- AL-NAHAL, M. The impact of exchange rate fluctuations on the financial performance of banks listed on the Palestine Stock Exchange. Published Master's Thesis, Gaza, Islamic University, 2016.
- WORLD BANK. Syria Earthquake Rapid Assessment of Damage and Needs Report 2023. <https://short-link.me/Cyuz>
- أحمد، طالب. نمذجة تقلبات سعر صرف الليرة السورية مقابل الدولار الأمريكي باستخدام نماذج GARCH مجلة جامعة تشرين. المجلد (41)، العدد (5)، 2019، ص 55-71.
- أزهر، علي. أثر تقلبات سعر الصرف على النمو الاقتصادي التركي. TADAMSA D- UNEGMU. المجلد (2)، 2022، ص 141-152.
- أيوب، محي الدين؛ نايف، القزاز. استخدام خوارزمية (K-Means) للعنقدة في تنقيب البيانات (Data Mining) مع واقع تطبيقي. مجلة العلوم الاقتصادية والإدارية، المجلد (22)، العدد (91)، 2016، ص 389-406.
- صلحة، الوليد أحمد . سياسات تحرير الصرف في الدول العربية بين النظرية والتطبيق. صندوق النقد العربي، 2022.
- فضيلة، عابد؛ عابد، سنان. أثر السياسات النقدية على القيمة الشرائية لليرة السورية (2001-2013). مجلة جامعة تشرين للبحوث والدراسات العلمية. المجلد (37)، العدد (5)، 2015، ص 249-270.
- محفوظ، عبد الرحمن؛ أحمد، محمد. أثر تغير سعر الصرف على ميزان المدفوعات: دراسة تطبيقية على الاقتصاد الليبي خلال الفترة (1990-2018). مجلة الأستاذ. المجلد (59)، 2022، ص 22-87.

- الموسى، ياسر؛ حسنه، يارا. تحسين أداء خوارزمية التجميع K-Means باستخدام التجميع الفرعي: دراسة تطبيقية على سوق الأسهم. مجلة بحوث جامعة حلب، سلسلة العلوم الاقتصادية، العدد(41)، 2020، 1-21.
- النحال، محمد. أثر تقلبات أسعار الصرف على الأداء المالي للبنوك المدرجة ببورصة فلسطين للأوراق المالية. رسالة ماجستير منشورة، غزة، الجامعة الإسلامية، 2016.
- البنك الدولي. تقرير التقييم السريع للأضرار والاحتياجات الناتجة عن الزلزال في سورية لعام 2023.

<https://short-link.me/Cyuz>

Foreign references:

- AHAMED, F. Macroeconomic Impact of Covid-19: A case study on Bangladesh. Journal of Economics and Finance, Vol(12), No(1), 2021, P 24-29.
- AHMAD, A; DEY, L. A k-mean clustering algorithm for mixed numeric and categorical data. Data & Knowledge Engineering, Vol(63), 2007, p 503-527.
- ARABIAT, A, ALTAYEB, M. Assessing the effectiveness of data mining tools in classifying and predicting road traffic congestion. J Electrical Engineering Comput Sci. Vol(34), No(2), 2024, p 295-303.
- CHASANH, A, RISTANTO, H. Factors Affecting the Aupiah Exchange Rate During the Covid 19 Pandemic. Journal of Economics and Public Health. Vol(1),No(2),2022,P 8-80.
- EITEMAN, K, STONEHILL, I, MOFFETT, H. Multinational Business Finance. 10th ed. USA: Pearson Addison Wesley. 2004.
- EUN, C; RESNICK, B. International financial management. McGraw-Hill Education, 2022
- HA, J; STOCKER, M; YILMAZKUDAY, H. Inflation and Exchange Rate Pass-Through. Policy Research Working Paper 8780, 2019.
- HAMILTON, A. Understanding Exchange Rates and Why They Are Important. RESERVE BANK OF AUSTRALIA, 2018.
- IMF. International Financial Statistics (IFS) Dataset Portal ,Washington Dc, 2022.
- LEUNG, M; CHEN, A; DAOUK, H. Forecasting Exchange Rate Using General Regression Neural Networks, 2020.
- ODIONYE, J; OJIAKU, E; UBA, C. Impact of Interest Rate Differential Exchange Rate Changes and Political Stability on Foreign Capital Inflow in Nigeria: Discrete Threshold Regression Model. FINANCIAL ECONOMICS | RESEARCH ARTICLE, 2023.
- PARESHKUMAR, J; NARENDAR, J; ASHOK, R. Factors Affecting Currency Exchange Rate Economical Formulas and Prediction Models. International Journal of Application or Innovation in Engineering & Management (IJAIEEM),Vol(3), No(3), 2014, P 6-53.
- ROUT, M; MAJHI, B. Forecasting of Currency Exchange Rates Using an Adaptive ARMA Model with Differential Evolution Based Training. Journal of King Saud University Computer and Information Sciences,Vol(26),No(1), 2014, P 7-18.
- TORGO, L. Data Mining with R Learning with Case Studies. Taylor & Francis Group, 2011.
- UNPINGCO, J. Python for Probability Statistics and Machine Learning. Springer Nature Switzerland, 2019.
- GARG, A. Forecasting exchange rates using machine learning models with time-varying volatility. Master Thesis in Statistics and Data Mining, Linköping University, 2012. <http://urn.kb.se/resolve?urn=urn:nbn:se:liu:diva-79053>