

UKJAES

University of Kirkuk Journal
For Administrative
and Economic Science

ISSN 2222-2995

University of Kirkuk Journal For Administrative
and Economic Science



Abdulhadi Dalia Mahfood & Rasheed Husam Abdulrazzak. Kernel semi-parametric model improvement based on Opposition - based Learning in Golden Jackal Optimization Algorithm (Comparative Study). *University of Kirkuk Journal For Administrative and Economic Science* (2024) 14 (4):337-349.

Kernel semi-parametric model improvement based on Opposition - based Learning in Golden Jackal Optimization Algorithm (Comparative Study)

Dalia Mahfood Abdulhadi ¹ , Husam Abdulrazzak Rasheed ²

^(1,2) Mustansiriyah University/Faculty of Administration and Economics, Baghdad, Iraq

dalia.abdulhadi@uomustansiriyah.edu.iq ¹
husamstat@uomustansiriyah.edu.iq ²

Abstract: Recent research and studies show widespread interest in the subject of semiparametric regression model analysis, which combines parametric and nonparametric components. This interest is because it gives accurate and effective statistical model estimates. This paper proposes to improve estimates of semiparametric regression models using opposition-based learning technology in the golden Jackal Optimization algorithm to increase the accuracy of these models, accelerate convergence, and expand the exploration area. The effectiveness of using this algorithm was evaluated by comparing it with the most commonly used methods for estimating the model statistically such as CV and GCV. Using economic data, the results showed that the OBL-GJO algorithm in terms of accuracy and convergence speed outperforms the traditional methods of calculating the semiparametric nucleus regression model. Based on that, we will use two types of economic data: the first was taken from local sources and the second was taken from global sources because of its great impact on the economy and to clarify the process of improvement using the algorithm proposed in the models.

Abbreviations:

CV : Cross-Validation

GCV : Generalized Cross-Validation

GJO : Golden Jackal Optimization Algorithm

OBL-GJO : Opposition-Based Learning in Golden Jackal Optimization Algorithm

Keywords: Semiparametric Regression Model, Golden Jackal Optimization Algorithm, Opposition-Based Learning Technology.

توظيف خوارزمية التعلم المعارض لابن أوى المحسنه في تحسين الأنموذج شبه المعلمي في الجانب الاقتصادي (دراسة مقارنة)

الباحثة: داليا محفوظ عبد الهادي ١، أ.م.د. حسام عبد الرزاق رشيد ٢

(١،٢) قسم الإحصاء-كلية الإدارة والاقتصاد/الجامعة المستنصرية، بغداد، العراق

المستخلص: تظهر الأبحاث والدراسات الحديثة اهتماما واسع النطاق بموضوع تحليل أنموذج الانحدار شبه المعلمي ، والذي يجمع بين المكونات المعلمية و اللامعلمية. ويعزى هذا الاهتمام إلى حقيقة أنه يعطي تقديرات دقيقة وفعالة للأنموذج الإحصائي. يقدم هذا البحث مقترحا لتحسين تقديرات نماذج الانحدار شبه المعلمية باستخدام تقنية التعلم القائم على المعارضه في خوارزمية ابن أوى لزيادة دقة هذه النماذج وتسريع عملية التقارب، وتوسيع مساحة الاستكشاف . تم تقييم فعالية استخدام هذه الخوارزمية من خلال مقارنتها بالطرائق الأكثر استخداما لتقدير الأنموذج إحصائيا مثل CV و GCV. وباستخدام بيانات اقتصادية حيث أظهرت النتائج أن خوارزمية OBL-GJO من حيث الدقة وسرعة التقارب تتفوق على الطرق التقليدية في حساب انحدار النواة شبه المعلمي. استناداً لذلك سنأتي على استخدام نوعين من البيانات الاقتصادية، الأولى اخذت من مصادر محلية والثانية اخذت من مصادر عالمية لما لها من الاثر الكبير في الاقتصاد ولتوضيح عملية التحسين باستخدام الخوارزمية المقترحة في النماذج .

المصطلحات:

CV : Cross-Validation

GCV : Generalized Cross-Validation

GJO : Golden Jackal Optimization Algorithm

OBL-GJO : Opposition - based Learning in Golden Jackal Optimization Algorithm

الكلمات المفتاحية: انموذج الانحدار شبه المعلمي، خوارزمية ابن أوى الذهبي، التعلم المعارض.

Corresponding Author: E-mail: dalia.abdulhadi@uomustansiriyah.edu.iq

المقدمة:

تعد ظاهرة النمذجة أحد الأهداف الرئيسية لدراسة المشكلات أو الظواهر المختلفة ، بما في ذلك الظواهر الاقتصادية والهندسية والطبية وغيرها وإيجاد انموذج رياضي تمثل المدخل الرئيسي لفهم أنماط وسلوك هذه الظواهر وتحليل بياناتها ، حيث أنه في بعض الظواهر ، وخاصة الظواهر الاقتصادية ، لا يحقق الأنموذج الذي يصف الظاهرة افتراضات الأنموذج المعلمي مما يجعله غير متسق ، بحيث لا يتم تحديد الشكل الدالي للظاهرة في ظل غياب المعرفة حول الظاهرة المدروسة ، هناك العديد من الأسباب ، مثل أن التجربة تجري لأول مرة ، أو أنه لا يمكن تحديد العلاقة السببية بين المتغيرات أو شرح العلاقة بين متغير الاستجابة والمتغيرات التفسيرية بشكل كامل. وبالنسبة للأنموذج اللامعلمي، فهو يتمتع بمرونة عالية ولكنه يعاني من مشكلة لعنة الأبعاد. ولعنة الأبعاد (Curse of Dimensionality) هي مشكلة شائعة في النماذج اللامعلمية، وتحدث عندما يزيد عدد الأبعاد (المتغيرات) في البيانات بشكل كبير، مما يؤدي إلى صعوبات في التحليل والتفسير، وبما ان التقديرات في النماذج اللامعلمية تعتمد على البيانات المتاحة دون فرض افتراضات قوية حول شكل العلاقة بين المتغيرات، مما يجعلها حساسة لزيادة الأبعاد. ويؤدي بذلك إلى مشاكل عدة في التحليل والنمذجة. مثال ذلك

١. **زيادة التعقيد الحسابي:** كلما زاد عدد الأبعاد، زادت كمية الحسابات المطلوبة، مما يجعل النماذج أكثر تعقيداً وأبطأ في التنفيذ.

٢. **تشبث البيانات:** في الأبعاد العالية، تصبح البيانات أكثر تشبثاً، مما يقلل من كثافة البيانات في الفضاء ويصعب عملية التقدير.

٣. **زيادة الحاجة إلى البيانات:** كلما زاد عدد الأبعاد، زادت الحاجة إلى كمية أكبر من البيانات لتقدير النموذج بدقة.

٤. **صعوبة التفسير:** النماذج في الأبعاد العالية تكون أكثر صعوبة في التفسير والفهم.

هنا، ظهرت نماذج الانحدار شبه المعلمية، والتي تجمع بين خصائص الانحدار المعلمي واللامعلمي. يعتبر هذا الأنموذج من النماذج الهجينة، حيث يجمع بين انموذجين، ويتمتع هذا الأنموذج بجميع السمات الإيجابية للأنموذجين السابقين. في هذا البحث، سنقترح دالة الانحدار للأنموذج شبه المعلمي من خلال تقدير الأنموذج المعلمي باستخدام طريقة المربعات الصغرى العادية وتقدير الأنموذج اللامعلمي باستخدام طريقة ممهد النواة (kernel)

وقد تم استخدام خوارزمية: التعلم المعارض في تحسين ابن أوى: وهي إحدى خوارزميات الذكاء الاصطناعي التي تستخدم مفهوم التعلم القائم على المعارضه في خوارزمية تحسين ابن أوى الذهبي لتحسين عملية اختيار معلمة النواة في الأنموذج شبه المعلمي وبالتالي حل المشكلات الإحصائية والحصول على الإمكانات المثلى ولتحسين النتائج في البيانات الاقتصادية (عرض النقد، تكوين راس المال)

حيث اننا سوف نستخدم أكثر من نوع واحد لنماذج انحدار النواة شبه المعلمي في تحسين تقدير المعروض النقدي في الاقتصاد العراقي وتحسين تقدير نموذج تكوين راس المال في الاقتصادات الاجنبية.

وسنعرض بعض من الباحثين الذين استخدموا الانموذج شبه المعلمي في أبحاثهم العلمية. في عام ٢٠٠٤، قدم الباحثون (Härdle, W., Müller, M., Sperlich, S., & Werwatz, A. (2004). كتابا يمثل أحد أهم المراجع التي تناولت نماذج الانحدار بانواعها المعلمية، اللامعلمية وشبه المعلمية وشرح مفصل لمقدرات تلك النماذج [9]،

(Yongsong & et at) في عام ٢٠٠٧ اقترح طريقة جديدة لايجاد نوع من البيانات المفقودة (البيانات شبه المعلمية). باستخدام الذكاء الاصطناعي لعرض النطاق لطريقة نواة وطبقوها على المحاكاة والبيانات الحقيقية. وأثبتت النتائج أن احتساب الانحدار شبه المعلمي العشوائي أفضل من حساب الانحدار شبه المعلمي الحتمي الحالي من حيث الكفاءة والفعالية [12]؛ اقترح (Chen and Zhou 2012) مقدرًا شبه معلميًا جديدًا لنموذج الانحدار المقطوع تحت قيود الاستقلال، والذي يستخدم التوزيع المقطوع بالكامل. تشير نتائج المحاكاة إلى أن المقدر يتفوق على العديد من التصميمات، وقد ثبت أن هذا المقدر متنسق وطبيعي دون تقارب [4]. اقترح (Lee et al. 2018) أنموذج الانحدار شبه المعلمي cumulative incidence function ذات القيم المفقودة والمتغيرة. قدموا فئة جديدة من نماذج الانحدار شبه المعلمية المعممة لـ CIF بناء على مقدر التوزيع المتغير المفقود ونموذج الانحدار الخطي. استخدموا المحاكاة لمقارنة النتائج ثم طبقوا النماذج. استنادًا إلى بيانات حقيقية للمرضى الذين يعانون من سرطان الدم النقوي [10]. استخدم الباحثون (Taavoni and Srahi، ٢٠٢١) نموذج التأثيرات المختلطة شبه المعلمية لتحليل البيانات الطولية. قاموا بتقدير الدالة اللامعلمية باستخدام طريقة kernel واستخدموا طريقة المربعات الصغرى المرجحة لتقدير معاملات الانحدار. ووجدوا أن backfitting method غالبًا ما ينتج عنه تحيز وتباين أكثر، لغرض تحسين الكفاءة، يتم تقدير دالة التباين باستخدام خوارزمية تكرارية [17]. استخدم (الجمال، ٢٠٢٤) خوارزمية الخفافيش في مساحة منفصلة لتحديد معامل التجانس المستخدم في نماذج الانحدار شبه المعلمية حيث وجد أن أسلوب القيم المثلثي لمعامل التجانس أكثر دقة من بقية الطرق المقارنة مثل CV و GCV [3].

أولاً: المشكلة

في ظل ثورة تحسين الكفاءة والاداء وتطوير المفاهيم في نمذجة البيانات وتحليلها للوصول الى افضل وادق النتائج التي تساهم في تحسين الجوده وتسهيل التكامل بين الانظمة لتقليل التكرار والبناء عليها في اتخاذ القرارات المستقبلية للمؤسسات والدول ولا سيما فيما يتعلق بالجوانب الاقتصادية والمالية منها، والتي تحتاج الى نتائج جيدة لكي تبني عليها قرارات استثمارية دقيقة وواضحة حيث ان التخطيط على المدى القريب والبعيد له اهمية كبرى من هنا برز الاهتمام بحل مشاكل نمذجة تلك البيانات وطرق معالجتها احصائيا وبالاخص لدى غياب المعرفة التامة بسلوك تلك المتغيرات في تلك البيانات بحيث لايمكن تحديد العلاقة السببية او السلوكية التي تربط بين جميع هذه المتغيرات، مما يؤدي الى مشاكل في اختيار الانموذج الملائم للظاهرة.

- تقديرات المعلمات غير الدقيقة كأفترض خطية العلاقة بين المتغيرات واهمال تأثير المتغيرات اللاخطية منها.

- التعقيد في المعالجة واستهلاك الوقت الكبير نتيجة تعدد المتغيرات وضخامة البيانات في مساحة بحث كبيره.

ومما سبق وغيره من التعقيدات الاخرى سيؤدي الى ظهور مشاكل واضحة في دقة الوصف والتنبؤ بالقيم المستقبلية. وهذا ما انعكس في تحليل البيانات المالية لدى استخدام طرق التقدير التقليدية.

ثانياً: هدف البحث

يهدف هذا البحث

- التغلب على الصعوبات التي يعاني منها انموذج الانحدار عندما لا تكون البيانات واضحة ولا توجد علاقة واضحة بين بعض من المتغيرات
- حساب تقدير معلمات أنموذج الانحدار شبه المعلمي باستخدام أكثر من انموذج لانحدار النواة شبه المعلمي وباكثر الطرق القياسية استخداما.
- استخدام نوعيه مطوره وجديده من خوارزميات التحسين في تسريع تحسين انموذج النواة شبه المعلمي .
- المقارنه بين نتائج الخوارزمية والطرق القياسية المستخدمة احصائيا.

المبحث الاول: الجانب النظري

اولاً: أنموذج الانحدار شبه المعلمي

اكتسبت نماذج الانحدار شبه المعلمية اهتماماً في التحليلات الإحصائية المتقدمة للحصول على مقدرات عالية الكفاءة [13]، لأنها تجمع بين نماذج الانحدار المعلمية الصارمة ونماذج الانحدار اللامعلمي عالية المرونة. نموذج الانحدار الخطي الجزئي (PLRM) هو أنموذجاً شائعاً لأنموذج الانحدار شبه البارامترية حيث يتم عرض العلاقة بين الأجزاء المعلمية واللامعلمية بوضوح. تم اقتراح نموذج PLRM من قبل روبنسون وسبيكمان في عام ١٩٨٨ كحالة خاصة من النماذج التجميعية. الشكل العام لنموذج الانحدار شبه المعلمي هو:

$$y_i = \sum_{j=1}^p \beta_j Z_{ij} + g(u_i) + \varepsilon_i, \quad i = 1, 2, 3, \dots, n. \quad (1)$$

حيث أن:

y : يمثل متجه متغير الاستجابة أو المتغير التابع وهو من الدرجة $n \times 1$.
 Z : يمثل مصفوفة من المتغيرات التفسيرية للدرجة $(n \times (p+1))$.
 β : يمثل متجه المعالم غير المعروفة المراد تقديرها بالدرجة $((p+1) \times 1)$.
 ε : هو متجه للأخطاء العشوائية من الدرجة $n \times 1$ وهو مستقل مع المتوسط $\cdot$ والتباين σ^2 .
 u_i : إنه متغير مستمر يعبر عن المتغير اللامعلمي بالأبعاد $(n \times 1)$.

الانموذج الموصوف في المعادلة السابقة في شكل مصفوفة هو:

$$y = Z\beta + g + \varepsilon \quad (2)$$

Where:

$Z\beta$: الجزء المعلمي للأنموذج قيد الدراسة.
 g : دالة أولية غير محددة للمتغير (u) من الدرجة $(n \times 1)$ ، والتي تمثل الجزء اللامعلمي من النموذج.
من أجل تقدير النموذج شبه البارامترية، يجب حساب معلمات الأنموذج المعلمي ودالة التمهيد غير المعروفة للأنموذج اللامعلمي.
نبدأ بتقدير معلمات الجزء المعلمي:

سنقوم بتقدير معلمات الأنموذج المعلمي باستخدام طريقة المربعات الصغرى، والتي تكون صيغتها الرياضية كما يلي: [1١].

$$Y_i = \beta_0 + \sum_{j=1}^p \beta_j Z_{ij} + \varepsilon_i, \quad i = 1, 2, 3, \dots, n. \quad (3)$$

يشيع استخدام نموذج الانحدار الخطي المتعدد لدراسة تأثير المتغيرات التفسيرية المتعددة على متغير الاستجابة، وصيغته الرياضية هي كما يلي: يتكون من (p) متغيرات تفسيرية، $(p+1)$ معلمات، و (n) مشاهدات. باستخدام طريقة المصفوفة، صيغتها هي [7].

$$Y = Z\beta + \varepsilon \quad (4)$$

يتم تقدير معلماته باستخدام طريقة المربعات الصغرى (OLS)، وصيغتها هي

$$\hat{\beta}_{OLS} = (Z^T Z)^{-1} Z^T y \quad (5)$$

بعد ذلك، نقوم بتقدير معلمات الأنموذج اللامعلمي باستخدام طريقة مصفوفة التمهيد. تم اقتراح هذه الطريقة (Green and Silverman، ١٩٩٤) لتقدير نموذج الانحدار الخطي الجزئي شبه البارامترية باستخدام مصفوفة التمهيد (S) ، والتي تعتمد على معلمة التمهيد (α) ، وتم اختيار المعلمة باستخدام طريقة التعاير الشرعي العام (GCV).
أنموذج الانحدار شبه المعلمي (Kernel) واحد من أهم الطرق لتقدير الجزء غير الخطي في النماذج شبه المعلمية هي باستخدام دوال kernel (ممهدة النواة) أو بعبارة أخرى، عن طريق تغيير تمثيل البيانات [13]. لتحويل البيانات غير الخطية المدخلة من p -dimension إلى مساحة عالية الأبعاد ومن ثم يمكن تقدير التحويل الجديد

$$\phi: X = (x_1, x_2, \dots, x_N) \rightarrow Z = (z_1 = \phi(x_1), z_2 = \phi(x_2), \dots, z_N = \phi(x_N)) \quad (6)$$

تم استخدام دالتين من دوال kernel [11]

1. Polynomial kernel functions

$$K(x, y) = [x^T y + 1]^m \quad (7)$$

2. Gaussian radial basis kernel functions

$$K(x, y) = \frac{\exp(-\|x - y\|^2)}{2\sigma^2} \quad (8)$$

يتم تعريف نموذج الانحدار شبه المعلمي على النحو التالي:

$$\text{Polynomial: } Y = Z\beta + [x^T y + 1]^m + e \quad (9)$$

$$\text{Gaussian radial basis: } Y = Z\beta + \exp(-\|x - y\|^2 / 2\sigma^2) + e \quad (10)$$

ثانياً: طريقة التحقق المتقاطع (العبور الشرعي) CV:

إنها تقنية تستخدم على نطاق واسع في التعلم الآلي والإحصاء لتقييم أداء الأنموذج التنبؤي. يساعد في تقدير مدى جودة أداء الأنموذج على البيانات غير المشاهدة (المرئية).

فيما يلي قواعد طريقة التعابر الشرعي CV :

١. تقسيم البيانات: تنقسم مجموعة البيانات إلى قسمين: مجموعة تدريب ومجموعة اختبار.
٢. التحقق المتبادل k-fold: تنقسم مجموعة البيانات إلى مجموعات فرعية (شرائح) من مجموعات K متساوية الحجم تقريباً.
٣. تكرارات التدريب والاختبار: تتكون عملية التعابر الشرعي من K من التكرارات
٤. مقاييس الأداء: لكل تكرار ، يتم حساب مقاييس الأداء مثل الدقة أو متوسط مربع الخطأ MSE
٥. إعادة التحقق (التعابر الشرعي) K-Fold : يتم تكرار الخطوتين ٣ و ٤ من المرات ، في كل مرة باستخدام مجموعة مختلفة كمجموعة اختبار
٦. التقييم: يتم حساب متوسط مقاييس الأداء التي تم الحصول عليها في كل تكرار للعثور على تقدير واحد لأداء النموذج.
٧. ضبط المعلمة: يستخدم التعابر الشرعي أيضاً لضبط المعلمات الفائقة.
٨. النموذج النهائي: بعد عملية التعابر الشرعي، يمكن تدريب الأنموذج النهائي على مجموعة البيانات بأكملها باستخدام أفضل المعلمات الفائقة أداء وتقييمه على مجموعة بيانات غير مرئية تماماً لتقدير أدائه في سيناريوهات العالم الحقيقي.

ثالثاً: طريقة التحقق المتقاطع العام (العبور الشرعي العام) GCV:

١. تقسيم البيانات: تنقسم مجموعة البيانات إلى قسمين: مجموعة تدريب ومجموعة اختبار.
٢. تدريب الأنموذج: يتم تدريب الأنموذج على مجموعة التدريب
٣. تقييم الأداء: تستخدم مجموعة الاختبار لتقييم أداء الأنموذج وحساب الأخطاء التنبؤية
٤. حساب العبور الشرعي العام: يتم حساب قيمة GCV والتي تعكس مدى دقة الأنموذج في التنبؤ بالبيانات الجديدة ،
٥. التقييم: توفر درجة GCV تقدير لأداء الأنموذج. وتشير درجة GCV المنخفضة إلى ملائمة أفضل للبيانات مع تعميم جيد للبيانات غير المرئية
٦. اختيار الأنموذج الأمثل: يتم اختيار الأنموذج الذي يقلل من درجة GCV حيث أن القيمة الأقل تشير إلى الأنموذج الأفضل
٧. ضبط المعلمة: يستخدم العبور الشرعي العام أيضاً لضبط المعلمات الفائقة.
٨. الأنموذج النهائي: بعد عملية العبور الشرعي العام ، يمكن تدريب الأنموذج النهائي على مجموعة البيانات بأكملها باستخدام أفضل المعلمات الفائقة أداء وتقييمه على مجموعة بيانات غير مرئية تماماً لتقدير أدائه في سيناريوهات العالم الحقيقي.

رابعاً: تحسين أنموذج النواة شبه المعلمي باستخدام التعلم المعارض في خوارزمية تحسين ابن أوى:

تهدف هذه الخوارزمية إلى استخدام مفهوم التعلم القائم على المعارض في توليد المجتمع الأولي لخوارزمية تحسين ابن أوى الذهبي لتحسين عملية اختيار معلمة النواة في الأنموذج شبه المعلمي. حيث تعاملت هذه الخوارزمية مع المفاهيم الأساسية التالية:

- خوارزمية تحسين ابن أوى الذهبي (Golden Jackal Optimization (GJO) .
- التعلم القائم على المعارض (Opposition-Based Learning (O-BL) .
- التحسين المستخدم

➤ خوارزمية تحسين ابن أوى الذهبي (GJO) Golden Jackal Optimization .

GJO مستوحاة من سلوك الصيد التعاوني لابن أوى الذهبي (Canis aureus) [2].. تم اقتراح طريقة تحسين ابن أوى الذهبي (GJO) من قبل نيتيش شوبرا ومحسن أنصاري في عام ٢٠٢٢. الخطوات الأساسية الثلاث للخوارزمية هي البحث عن الفريسة ، والإحاطة ، والانقضاض ، والتي يتم نمذجتها وتطبيقها رياضياً. يتم تقييم قدرة الخوارزمية المقترحة ، من خلال المقارنة مع أحدث ما في علم الاستدلال الحديث ، على وظائف معيارية. تبدأ (GJO) بتهيئة مجموعة من الحلول المرشحة لمشكلة التحسين التي يتم حلها. يتم تمثيل كل حل مرشح كمتجه للقيم التي تشفر معلماته أو متغيراته. في المرحلة الأولى من الخوارزمية ، والتي تسمى "مرحلة الاستكشاف" ، يتم تقييم الحلول المرشحة بناء على كفاءتها أو هدف الدالة. يتم الاحتفاظ بالحلول الأكثر ملائمة ، بينما يتم التخلص من الحلول الأقل ملائمة (، تلي مرحلة الاستكشاف "مرحلة الاستغلال" ، حيث يتم استخدام الحلول المحتفظ بها لتوجيه البحث نحو حلول أفضل. هذه المرحلة مستوحاة من تكتيك ابن أوى المتمثل في العمل معاً لصيد الفرائس . في هذه المرحلة ، تعمل الحلول المحتفظ بها كمرشدين أو قادة يجذبون الحلول المرشحة الأخرى نحوها. لقد ثبت أن (GJO) فعالة في حل مجموعة واسعة

من مشكلات التحسين ، بما في ذلك تلك التي تكون غير خطية ومتعددة الحدود. حيث انها تتميز بقدرتها على التكيف مع مشاكل التحسين المختلفة وقد تمت مقارنة أدائها بشكل إيجابي بخوارزميات التحسين الشائعة الأخرى مثل خوارزميات مستعمرة النمل وتحسين سرب الجسيمات. [6]

يمكن أن يوفر فهم سلوك واستراتيجيات الصيد التعاوني لابن آوى الذهبي في الطبيعة. حيث تعتمد هذه الخوارزمية على محاكاة سلوكيات البحث عن الطعام، التسلل، والإحاطة بالفريسة لالتقاطها، مما يساعد في تحديث موقع ابن آوى وتحسين الحلول. ويلهم حلولاً مبتكرة للمشاكل المعقدة. يمثل (GJO) أحد هذه الحلول المستوحاة من تكتيكات صيد ابن آوى التي لها تطبيقات في مختلف المجالات ، مثل الروبوتات والذكاء الاصطناعي.

١. في البداية ، يتم اختيار أفراد المجتمع عشوائياً وتهيئتهم وفقاً للحد الأدنى والحد الأعلى للمشكلة وفق المعادلة (١)

$$Z_0 = L + rand * (U - L) \quad (11)$$

حيث يمثل L و U الحد الأدنى والحد الأعلى لمنطقة البحث ، ويشير $rand$ إلى رقم عشوائي محدد بالفتره [٠,١]. في المعادلة ادناه ، يتم إنتاج مصفوفة الحلول الأولية $prey$ في هذه المرحلة ويتم اختيار اثنين من عناصرها هما الأصلح كزوج ابن آوى

$$prey = \begin{bmatrix} Z_{1,1} & Z_{1,2} & \dots & Z_{1,d} \\ Z_{2,1} & Z_{2,2} & \dots & Z_{2,d} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{n,1} & Z_{n,2} & \dots & Z_{n,d} \end{bmatrix} \quad (12)$$

حيث ، $Z_{i,j}$ هو عنصر الحل الاولوي ويمثل j^{th} البعد ، i^{th} يمثل الفريسة و n يشير الى العدد الإجمالي للفرائس ، d يمثل عدد المتغيرات. حيث يشير موضع الفريسة إلى معلومات حل معين.

٢. ننتقل الى مرحلة الاستكشاف أو البحث عن الفريسة في هذه المرحلة ، يتم اقتراح استراتيجية استكشاف GJO. كما هي طبيعة ابن آوى ، فهم يعرفون كيفية إدراك الفريسة ومتابعتها ، ولكن بشكل منقطع اذ لا يمكن القبض على الفريسة بسهولة والهروب. بعد التطويق ، يقفزون على فريستهم ويأكلونها. يتم التعبير عن سلوك الصيد هذا ، جنباً إلى جنب مع ابن آوى من الذكور والإناث ، رياضياً على النحو التالي:

$$Z_1(t) = Z_M(t) - E.[Z_M(t) - rl * prey(t)] \quad (13)$$

$$Z_2(t) = Z_{FM}(t) - E.[Z_{FM}(t) - rl * prey(t)] \quad (14)$$

الهدف من rl في المعادلة (13) و (14) هو إنتاج سلوك عشوائي في فترة الاستغلال ، مع التركيز على الاستكشاف وتجنب الحل الأمثل (المتوفر) المحلي.

حيث يشير (t) إلى التكرار الحالي ، و $prey(t)$ هو متجه موضع الفريسة ، ويشير $Z_M(t)$ و $Z_{FM}(t)$ إلى موضع ابن آوى الذكر والأنثى. $Z_1(t)$ و $Z_2(t)$ هي الموضع المحدث لذكر وأنثى ابن آوى المقابلة للفريسة. E هو التهرب من طاقة الفريسة أخيراً ، يتم تحديد موضع التحديث الجديد لابن آوى الذهبي على النحو التالي:

$$Z(t+1) = \frac{Z_1(t) + Z_2(t)}{2} \quad (15)$$

٣. مرحلة الاستغلال أو تطويق الفريسة والانقضاض عليها ، في هذه المرحلة يتم تقليل قدرة الفريسة على الهروب عندما تتعرض للمضايقة من قبل ابن آوى ، ثم تطوق أزواج ابن آوى الفريسة المكتشفة في المرحلة السابقة. بعد التطويق ، يقفزون على فريستهم ويأكلونها. يتم التعبير عن سلوك الصيد هذا رياضياً على النحو التالي:

$$Z_1(t) = Z_M(t) - E.[rl.Z_M(t) - prey(t)] \quad (16)$$

$$Z_2(t) = Z_{FM}(t) - E.[rl.Z_{FM}(t) - prey(t)] \quad (17)$$

➤ التعلم القائم على المعارضة (O-BL) Opposition-Based Learning

تم تقديم فكرة O-BL كتنقيية جديدة لتسريع تقارب الأساليب التطورية عند نشرها على المشكلات المعقدة ، لا سيما تلك المشاركة في البحث والتحسين. وهو مستوحى من التحولات غير المتوقعة والجزئية للتطورات الاجتماعية. المبدأ الحاسم هو أنه في التكرار الحالي ، يمكن إنشاء كل جسيم أو حل مرشح لمشكلة التحسين إما عن طريق دمج المعلومات التي تم الحصول عليها أثناء تطوير الخوارزمية أو عن طريق إنتاج تخمينات عشوائية بسيطة (Sutton, R. S. 2018) [16]، كما هو الحال في تهيئة المجتمع الاولوي للسكان. خلال المرحلة الثانية ، يمكن تعزيز سرعة التقارب بشكل احتمالي من خلال إنتاج نقطة معارضة لكل حل ممكن في بداية العملية وفي كل تكرار. يتوقع O-BL أن استكشاف اتجاه الحل المرشح الأولي وكذلك بالترتيب العكسي قد يكون مفيداً لتحديد القيمة المثلى بطريقة أكثر وضوحاً. نتيجة لذلك ، فإن الفكرة الأساسية هي رقم معاكس ، على سبيل المثال، يمكن أن يكون لدينا مجموعة

من الحلول في مسألة معينة، ونقوم بحساب حلاً معاكساً لكل حلاً من هذه المجموعة. هذا يمكن أن يساهم في تحسين الأداء وتسريع عملية البحث عن الحلول المثلى. حيث يمكن تحديد الرقم المعاكس لأي قيمة حقيقية عشوائية $Z \in [L, U]$ على النحو التالي:


$$\bar{Z} = L + U - Z \quad (18)$$

حيث $\bar{Z} \in R^n$ هو متجه الموضع المعاكس من متجه الموضع الحقيقي $Z \in R^n$. بالإضافة إلى ذلك، تتم مقارنة الحلين و أثناء عملية التحسين ويتم تخزين أفضل هذه الحلول، بينما يتم التخلص من أسوأ الحلول من خلال مقارنة دالة الكفاءة (the fitness functions). على سبيل المثال، إذا كانت $F(Z)$ أقل من $F(\bar{Z})$ (للتصغير)، يتم حفظ Z وإذا كانت $F(Z)$ أكبر من $F(\bar{Z})$ ، يتم حفظ $\bar{Z}$.

استخدام تقنية التعلم القائم على المعارضة بخوارزمية ابن اوى الذهبي (التحسين المستخدم) Incorporate OBL into GJO Algorithm (OGJO):

يوضح هذا الجزء OGJO المقترح كمزيج من قدرات خوارزمية GJO مع تقنية OBL لتعزيز استكشاف منطقة البحث، مما يؤدي إلى تحسين دقة الحل الأمثل. تم تحسين طريقة GJO بواسطة OBL نظراً لأن لها عدداً من الخصائص غير المرغوب فيها، مثل ضعف التقارب والوقوع في شرك الحلول المحلية (القريبه)، مما يحد من استكشاف منطقة البحث والاستخدام المناسب للوقت. يتضمن النهج المقترح القيمة المتعارضة أثناء تغطية منطقة البحث من خلال النظر في الاحتمالين للنقطة المحسوبة من أجل منع الحالات المذكورة أعلاه. يزيد هذا التحسن من احتمالية استخدام الحلول المثلى في وقت أقل بنسبة ٥٠٪. يتم تنفيذ الاستراتيجية المقترحة على مرحلتين.

تتضمن المرحلة الأولى تهيئة السكان (المجتمع الاولي) باستخدام O-BL، والتي تبدأ مع اختيار ابن اوى الذهبي NP الأقرب إلى الحل الأمثل. المرحلة الثانية تحديث الجيل الجديد من ابن اوى الذهبي.




شكل (١): المخطط الرئيسي لخوارزمية OGJO

تحسين المستخدم في نموذج النواة شبه المعلمي استناداً إلى خوارزمية التعلم المعارض لتحسين ابن اوى:

ان المعلمات الفائقة المرتبطة بنوع النواة لها تأثير مباشر على تحسين حل دالة الهدف. يعتمد أداء دالة kernel بشكل كبير على اختيار هذه المعلمات الفائقة، ولكن لا توجد طرق رياضية متاحة لتحديد قيمها الدقيقة. وبالتالي، فإن البحث في نموذج الانحدار شبه المعلمي للنواة يعتمد بشكل كبير على اختيار هذه المعلمات الفائقة. في حين أن طريقة CV و GCV حيث ان هذه التقنيات الأكثر شيوعاً والمستخدم في الأدبيات لتحديد هذه المعلمات، تستغرق وقتاً طويلاً. في الحوسبة، لذلك تستخدم الخوارزميات المحسنة، مما يؤدي إلى أداء أكثر ملاءمة من ذلك الذي تحققه أي خوارزمية وحدها [16]، إحدى هذه الخوارزميات هي OGJO، التي لديها القدرة على التغلب على الحلول المثلى المحلية ومشاركة الميزات إلى حل وسط بين الاستكشاف والاستغلال، وتأخير بداية تقارب كل خوارزمية، ومنع الوقوع في المستوى الأمثل المحلي. لتحسين خصائص أداء الخوارزمية المقترحة والحصول على تقارب أسرع من أجل الهروب من الأمثل المحلي، مما يعزز استكشاف واستغلال خوارزمية GJO، مما يجعلها أكثر فعالية. يساعد هذا بكفاءة في العثور على أهم قيم المعلمات الفائقة المتعلقة بأنموذج النواة شبه المعلمي مع أداء تنبؤ عالي. حيث يتم عرض مخطط انسيابي لتحسين الخوارزمية المستخدم لأنموذج النواة شبه المعلمي كمايلي:

وقد تمت الخطوات كما يلي:

1. تم تخصيص خمسة وعشرين ابن اوى، وتم التخطيط ل $t = 500$ تكرار كحد أقصى.
2. تم وضع ابن اوى المعارض من خلال مفهوم التعلم المعارض.
3. لكل من المجموعتين، في التكرار الأول، يتم حساب أفضل واحد وثاني (ذكر وانثى ابن اوى) بين مجموعة العنصر والعنصر المقابل.
4. يتم وضع (ذكر وانثى ابن اوى) في مواقعهم بشكل عشوائي. يتم تمثيل المعلمة الفائقة P (the parameter of kernel function) من خلال موقع ابن اوى. يتم اختيار مواقع انطلاق ابن اوى عشوائياً من التوزيع الطبيعي بين الفترة $[0, 0.12]$.
5. حساب $\bar{Z}$ لكل معلمة فائقة باستخدام المعادلة (18).
6. يتم تعريف دالة الكفاءة (fitness function) على النحو التالي:
7.
$$fitness = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (19)$$
8. يتم تحديث المواقع باستخدام المعادلات (13)، (14).
9. تكرر الخطوات 3, 4 و 5 للوصول إلى t_{max} .



شكل (٢): Semi-parametric kernel model using the OGJO

رابعاً: معيار المقارنه بين المقدرات المستخدمة:

يتم إجراء مقارنة بين طرق التقدير المذكورة سابقاً، ويتم اختيار أفضل مقدر باستخدام متوسط مربع الأخطاء (MSE) وصيغته الرياضية هي

$$MSE = \frac{\sum (y_i - \hat{y})^2}{n} \quad (20)$$

المبحث الثاني: الجانب العملي


في هذا الجانب، سيتم توضيح ما تم ذكره في الجانب النظري وتطبيقه على البيانات الحقيقية المتعلقة بالجانب الاقتصادي. وبناء على ذلك، سنقوم باختبار خطية البيانات لتحديد الانموذج الملائم لها (الانموذج شبه المعلمي) واستخدام نوعين من انموذج انحدار النواة شبه المعلمي (Gaussian Radial Basis, Polynomial) والذي سيوضح لنا المقارنة بين الطرق المستخدمة في الحساب باستخدام معيار المقارنة (متوسط مربع الخطأ) MSE

اولاً: عرض النقد والعوامل المؤثرة فيه (التطبيق الاول)


ان لعرض النقد اهمية كبيره في الاقتصاد وفي تحديد السياسة النقدية لاي دولة لعدة أسباب تتضمن التحكم بالتضخم , تحقيق الاستقرار الاقتصادي , تحديد السياسة النقدية المناسبه , وايضاً التنبؤ بالنشاط الاقتصادي والذي يقوم على تحليل عرض النقد بالدرجة الأساس مما يمكن الحكومات والبنوك المركزيه من تحقيق التوازن بين العرض والطلب على النقد , والذي يسهم بدوره في استقرار الأسعار والنمو الاقتصادي المستدام [1] حيث ان عرض النقد بمفهومه المبسط هو عبارة عن القدرة الشرائية لدى الأفراد، ويُشار له ايضاً بتوافر النقود أي أنَّ الأصول السائلة في القطاع الاقتصادي تعتمد على تبادل الخدمات والسلع، حيث يشير الى مقدار النقد والعملة والأصول السائلة الأخرى المتداولة في الاقتصاد وتؤخذ ايضاً المقاييس المختلفة للمعروض النقدي في الاعتبار (البنود غير النقدية) مثل الائتمان والقروض . البنوك المركزيه هي المعني الرئيسي بتحديد مستوى المعروض النقدي داخل الدولة من خلال الاجراءات التوسعية او الانكماشية اذ تتضمن السياسات التوسعية زيادة المعروض النقدي من خلال تدابير مثل السوق المفتوحة فيما تشمل السياسة الانكماشية بيع سندات الخزانه. يحلل الاقتصاديون المعروض النقدي ويطورون سياسات مرتبطة به، لذلك فهم بحاجة الى انموذج يرسم علاقه بشكل واضح بين متغير عرض النقد والعوامل المؤثرة فيه للوصول الى التحكم في اسعار الفائدة، وزيادة كمية الأموال المتدفقة في الاقتصاد او تقليلها، حيث تؤدي الزيادة في المعروض النقدي الى خفض في اسعار الفائدة وتوليد المزيد من الاستثمار وزيادة الاموال لدى المستهلكين وبالتالي تحفيز الانفاق، في هذه الحالة تزيد الشركات انتاجها ونشاطها التجاري وبالتالي الطلب على العماله ويمكن ان يحدث العكس اذا انخفض المعروض النقدي . ان الزيادة في عرض النقد من دون الاستناد الى العوامل المؤثرة سيؤدي إلى ظهور تضخم اقتصادي، أما انخفاض عرض النقد فينتج عنه ظهور البطالة، والانكماش، وخمول القدرة على الإنتاج. وقد تم الحصول على البيانات من الموقع الرسمي للجهاز المركزي للإحصاء في العراق. هي مجموعة من مؤشرات البيانات المالية التي تعكس المؤشرات النقدية والتطورات التي حدثت في القطاع الاقتصادي ممثلة بالقاعدة النقدية وعرض النقد ل ١٤ عام، وركزت البيانات على تحديد أهم وأبرز العوامل التي تؤثر على عرض النقد من عام ٢٠١٠ الى عام ٢٠٢٣. المتغيرات المؤثرة على عرض النقد هي العملة المتداولة خارج البنوك ، الودائع الجارية ، المطلوبات ، صافي الأصول الأجنبية ، ديون القطاع الخاص والقطاعات الأخرى ، القروض والسلف ، التحويلات والسندات ، رأس المال والاحتياطيات ، وصافي الأصول الأخرى.

ثانياً: اختبار خطية البيانات لعرض النقد والعوامل المؤثرة فيه


تتضمن الخطوة الأولى تحليل العلاقة بين المتغيرات المستقلة ومتغير الاستجابة التابع بيانياً. هذا التحليل ضروري لتحديد ما إذا كانت العلاقة بين المتغيرات خطية أو غير خطية ، وبناء على هذا التقسيم ، يتم تعريف المتغيرات لكل من مكونات النموذج المعلمي وغير المعلمي . تم الحصول على نتائج البيانات الحقيقية باستخدام البرنامج الإحصائي R ، وتوضح الرسوم البيانية التالية ما إذا كانت المتغيرات خطية أم لا. عند فحص مخطط التشتت ، تم تحديد أن العلاقة بين كل من المتغيرات التفسيرية (العملة خارج البنوك X1 ، الودائع الجارية X2 ، المطلوبات X3 ، صافي الأصول الأجنبية X4 ، ديون القطاع الخاص والقطاعات الأخرى X5 ، القروض والسلف X6 ، التحويلات والسندات X7 ، رأس المال والاحتياطيات X8 ومتغير الاستجابة التابع (عرض النقد Y) خطية. من ناحية أخرى ، فإن العلاقة بين متغير الاستجابة التابع (Y) والمتغير التفسيري التاسع (صافي الأصول الأخرى X9 غير خطي .



شكل (٣): يوضح طبيعة العلاقة بين متغير الاستجابة Y والمتغيرات التوضيحية x1,x2,x3 لبيانات عرض النقد



شكل (٤) : يوضح طبيعة العلاقة بين متغير الاستجابة Y والمتغيرات التوضيحية x4,x5,x6 لبيانات عرض النقد



شكل (٥): يوضح طبيعة العلاقة بين متغير الاستجابة Y والمتغيرات التوضيحية X7,X8,X9 لبيانات عرض النقد

بمجرد تحديد العلاقة بين متغير الاستجابة (التابع) والمتغيرات التفسيرية، يتم وصف الانموذج شبة المعلمي بمتغيراته التفسيرية (المعلمية الثمانية والمتغير اللامعلمي التاسع) والمتغير التابع وصياغته على النحو التالي

$$y_i = X_{i1}\beta_1 + X_{i2}\beta_2 + X_{i3}\beta_3 + X_{i4}\beta_4 + X_{i5}\beta_5 + X_{i6}\beta_6 + X_{i7}\beta_7 + X_{i8}\beta_8 + g(x_9) + \varepsilon_i \quad (21)$$

$i = 1, 2, 3, \dots, n.$

ثالثاً: مناقشة نتائج عرض النقد والعوامل المؤثرة فيه

تظهر النتائج في الجدول (١) أن خوارزمية OGJO أنتجت MSE أقل من الطرق الاحصائية التقليدية CV و GCV يمثل الجدول (٢) وقت التنفيذ (بالثواني) ، مما يشير إلى أن OGJO يستغرق وقتاً أقل للحصول على نتائج MSE

Table (1): MSE value for the methods used

Method ,N=14	Gaussian Radial Basis	Polynomial
CV	12.567	13.382
GCV	11.295	12.988
GJO	10.454	11.305
OGJO	9.012	9.873

Table (2): The execution time value of the methods used


Method	Gaussian Radial Basis	Polynomial
CV	141	148
GCV	135	145
GJO	117	129
OGJO	101	106

رابعاً: العوامل المؤثرة على نسبة إجمالي تكوين رأس المال إلى الناتج المحلي الإجمالي

يشار الى إجمالي تكوين رأس المال غالباً باسم الاستثمار حيث يمثل القيمة الإجمالية للأصول المادية الجديدة والتي تم إنشاؤها داخل الاقتصاد خلال فترة محددة. وتشمل هذه الأصول المباني والبنية التحتية والآلات والسلع المعمرة الأخرى التي تساهم في الإنتاج المستقبلي. ويعد مقياساً بالغ الأهمية لأنه يعكس قدرة الاقتصاد على توليد الثروة وتعزيز الإنتاجية. تم الحصول على بيانات هذه الدراسة من الموقع الرسمي للبنك الدولي (Bank Word, 2021) من مجموعة بيانات مؤشرات التنمية العالمية المحدثة حتى ٢٠٢١-٧-١، والتي تضمنت مجموعة من المعلومات المتعلقة باقتصاديات العديد من الدول حول العالم، حيث يتم النظر في ما يقرب من ٧٨ دولة لعام ٢٠٢٠. وركزت البيانات على تحديد أهم وأبرز العوامل التي تؤثر على نسبة إجمالي تكوين رأس المال إلى الناتج المحلي الإجمالي GDP. والذي يؤثر فيه كل من رصيد الحساب الجاري والاستثمار الأجنبي المباشر والتضخم.

١٣. اختبار خطية البيانات لإجمالي تكوين رأس المال والعوامل المؤثرة فيه.

تم تحليل العلاقة بين المتغيرات المستقلة ومتغير الاستجابة التابع بيانياً. في هذا البحث، باستخدام البرنامج الإحصائي R ، لإنشاء مخطط مبعر ، كما هو موضح في الشكل (٦). عند فحص مخطط التشتت، وجدنا أن العلاقة بين كل من المتغيرين التفسيريين (رصيد الحساب الجاري X_1 والاستثمار الأجنبي X_2 ومتغير الاستجابة التابع (إجمالي تكوين رأس المال Y) خطية، والعلاقة بين متغير الاستجابة التابع (Y) والمتغير التفسيري الثالث (التضخم X_3) غير خطية



الشكل (٦): يوضح طبيعة العلاقة بين متغير الاستجابة والمتغيرات التفسيرية للبيانات المتعلقة بتكوين رأس المال

تم تحديد العلاقة بين متغير الاستجابة والمتغيرات التفسيرية (رصيد الحساب الجاري والاستثمار الأجنبي المباشر والتضخم) إلى إجمالي تكوين رأس المال. في هذا النموذج، حيث تم وصف المتغيرات التفسيرية الثلاثة على النحو التالي: المتغير التفسيري الأول هو رصيد الحساب الجاري (X_1) ، والذي يعتبر معلمياً لأنه له علاقة خطية مع متغير الاستجابة (إجمالي تكوين رأس المال). المتغير التفسيري الثاني هو الاستثمار الأجنبي المباشر (X_2) ، وهو أيضاً معلمياً بسبب علاقته الخطية بتكوين رأس المال الكلي. لذلك فإن المكون المعلمي للنموذج مناسب لكل من X_1 و X_2 وأخيراً، المتغير التفسيري الثالث هو التضخم (X_3) ، وهو متغير لا معلمياً بسبب علاقته غير الخطية بتكوين رأس المال الكلي. نتيجة لذلك، سيتم تضمينه في المكون اللامعلمي للنموذج. بناءً على هذه المعلومات، تكون صيغة نموذج الانحدار كما يلي

$$y_i = X_{i1}\beta_1 + X_{i2}\beta_2 + g(x_3) + \varepsilon_i \quad , i = 1,2,3 \dots , n. \quad (22)$$

خامساً: مناقشة نتائج إجمالي تكوين رأس المال والعوامل المؤثرة فيه:

تظهر النتائج في الجدول (٣) أن خوارزمية OGJO أنتجت MSE أقل من CV و GCV ، بينما يمثل الجدول (٤) وقت التنفيذ (بالثواني) ، مما يشير إلى أن OGJO يستغرق وقتاً أقل للحصول على نتائج MSE

Table (3): MSE value for the methods used

Method ,N=78	Radial Basis	Polynomial
CV	11.361	12.176
GCV	10.089	11.782
GJO	9.055	10.054
OGJO	7.806	8.667

Table (4): The execution time value of the methods used

Method,N=78	Radial Basis	Polynomial
CV	124	131
GCV	118	128
GJO	96	109
OGJO	83	89

المبحث الثالث: الاستنتاجات والتوصيات

أولاً: الاستنتاجات:

- من خلال الجانب العملي، وجدنا ما يلي:
١. تعمل خوارزمية البحث عن الجاذبية الثنائية المقترحة (OGJO) بشكل أفضل من خوارزمية ابن اوى.
٢. تقلل خوارزمية التحسين (OGJO) من وقت الحساب المطلوب للتقدير مقارنة بالطرق الأخرى، مثل CV و GCV.
٣. تستكشف OGJO مساحة البحث بشكل أكثر فعالية من طرق القياس الأخرى.
٤. الخوارزمية المقترحة لديها القدرة على تعزيز قابلية تطبيق نماذج النواة شبه المعلمية في تطبيقات مختلفة، بما في ذلك التمويل والاقتصاد والهندسة والطب.

ثانياً: التوصيات

يمكن تلخيص التوصيات التالية:

١. نوصي بتطبيق الخوارزمية (GJO) في مجالات أخرى من التعلم الآلي ، مثل التعلم العميق والتعلم المعزز.
٢. نوصي باستخدام خوارزميات محسنة ومطورة لتحسين نماذج الانحدار شبه المعلمي.
٣. نوصي باستخدام نماذج شبه معلمية أخرى من Kernel استناداً إلى دوال kernel الأخرى.
٤. للتغلب على المشاكل التي تعاني منها أي خوارزمية في مساحة بحث كبيره نوصي بالبحث في تحسين اوالدمج بين الخوارزميات.

المصادر

أولاً: المصادر العربية

١- صالح، عدنان مناتي (٢٠١٧) " عرض النقود واثرة في التضخم دراسة تحليلية في الاقتصاد العراقي للمدة ١٩٩٠-٢٠١٣"، كلية بغداد للعلوم الاقتصادية الجامعة، مجلة دنائير، مجلد ٢٦، العدد ٧.

ثانياً: المصادر العربية المترجمة

- 1- Saleh, Adnan Manati (2017) "Money supply and its impact on inflation, an analytical study in the Iraqi economy for the period 1990-2013", Baghdad College of Economic Sciences, University of Baghdad, Dinars Journal, Volume 26, Issue 7.

ثالثاً: المصادر الاجنبية

- 1- Admasu, E., Thirgood, S. J., Bekele, A., & Karen Laurenson, M. (2004). Spatial ecology of golden jackal in farmland in the Ethiopian Highlands. *African Journal of Ecology*, 42(2), 144-152.
- 2- AL-Taie, F.A.Y., Qasim, O.S. and Algamal, Z.Y., 2024, March. Improving kernel semi-parametric regression model based on a bat optimization algorithm. In AIP Conference Proceedings (Vol. 3036, No. 1). AIP Publishing.
- 3- Chen, Songnian, and Xianbo Zhou 2012 Semiparametric estimation of a truncated regression model. *Journal of Econometrics* 167(2):297-304.
- 4- Chiou, Sy Han, 2019 Semiparametric regression analysis of panel count data: A practical review. *International Statistical Review* 87(1):24-43.
- 5- Chopra, N., & Ansari, M. M. (2022). Golden jackal optimization: A novel nature-inspired optimizer for engineering applications. *Expert Systems with Applications*, 198, 116924.
- 6- Ghysels, Eric, and Hang Qian 2019 Estimating MIDAS regressions via OLS with polynomial parameter profiling. *Econometrics and statistics* 9:1-16.
- 7- Guha, R., Ghosh, M., Chakrabarti, A., Sarkar, R., & Mirjalili, S. (2020). Introducing clustering based population in binary gravitational search algorithm for feature selection. *Applied Soft Computing*, 93, 106341.
- 8- Härdle, W., Müller, M., Sperlich, S., & Werwatz, A. (2004). *Nonparametric and semiparametric models* (Vol. 1). Berlin: Springer.
- 9- Lee, Unkyung, 2018 Analysis of generalized semiparametric regression models for cumulative incidence functions with missing covariates—computational statistics & data analysis 122:59-79.
- 10-Micchelli, Charles A, Massimiliano Pontil, and Peter Bartlett 2005 Learning the Kernel Function via Regularization. *Journal of machine learning research* 6(7).
- 11-Qin, Y., Zhang, S., Zhu, X., Zhang, J. and Zhang, C., 2007. Semi-parametric optimization for missing data imputation. *Applied Intelligence*, 27(1), pp.79-88.
- 12-Robinson, Peter M 1997 Large-sample inference for nonparametric regression with dependent errors. *The Annals of Statistics* 25(5):2054-2083.
- 13-Roozbeh, M., Hesamian, G., & Akbari, M. G. (2020). Ridge estimation in semi-parametric regression models under the stochastic restriction and correlated elliptically contoured errors. *Journal of Computational and Applied Mathematics*, 378, 112940.
- 14-Schramm, Catherine, 2020 KSPM: A Package For Kernel SemiParametric Models. *The R Journal* 12(2):82-106.
- 15-Sutton, R. S. (2018). Reinforcement learning: An introduction. *A Bradford Book*.
- 16-Taavoni, M. and Arashi, M., 2021. Kernel estimation in semiparametric mixed effect longitudinal modeling. *Statistical Papers*, 62(3), pp.1095-1116.
- 17-Zhang, Ting, 2015 Semiparametric model building for regression models with time-varying parameters. *Journal of Econometrics* 187(1):189-200.