

تهجين اندادار المتجه الداعم مع الخوارزمية الفوضوية للتنبؤ

بالحمل الكهربائي في المنطقة الجنوبية

م.م هدى عبد السادة هاشم أ.د. ساهره حسين زين

جامعة البصرة / كلية الإدارة والاقتصاد / قسم الاحصاء

Email: Aser33588@gmail.com

Email: sahera.zain@uobasrah.edu.iq

ORCID: <https://orcid.org/0009-0000-7319-3083>

ORCID: <https://orcid.org/0000-0002-4503-8075>

الملخص:

تعد الطاقة الكهربائية من أهم مصادر الطاقة الرئيسية التي تسهم مساهمة كبيرة في جميع القطاعات التي تدفع بعملية التنمية الى التقدم، وتؤدي دورا مهما في عملية التنمية والرفاهية الاقتصادية والحضارية لاستخدامها كمستلزمات مهمة في الاقتصاد. لذا تعد أحد أهم مظاهر الحضارة والتطور ومقياسا للرفاهية في أي مجتمع من المجتمعات لما تؤديه هذه الطاقة من خدمات. تطبق هذه الدراسة نمودجا للتنبؤ بالحمل الكهربائي من خلال تطبيق اندادار المتجه الداعم مع الخوارزميات الهجينة الفوضوية لتحسين أداء التنبؤ، والتي تعمل على حل مشكلات تحسين معلمات اندادار المتجه الداعم، فتم تهجين اندادار المتجه الداعم مع خوارزميات فوضوية ((CIA)، ((CPSO لتحديد المعلمات المثلى والمناسبة لنمودج اندادار المتجه الداعم ، ومقارنة النماذج بعضها مع بعض، لاختيار النموذج الأفضل واستخدامه في التنبؤ باستهلاك الطاقة الكهربائية للمدة (2020 – 2029) في المنطقة الجنوبية من العراق وقد توصلت النتائج ان نمودج (CIASVR) أكثر دقة وكفاءة من نماذج التنبؤ الأخرى استنادا الى معايير دقة التنبؤ الاحصائية.

الكلمات المفتاحية: اندادار المتجه الداعم، خوارزمية المناعة، خوارزمية المناعة الفوضوية، خوارزمية تحسين سرب الطيور، خوارزمية سرب الطيور الفوضوية.

Supporting Vector Regression Hybridization with chaotic Algorithm for Electric Load Prediction in Southern Region

Huda Abd El- Sadah

Sahera Hussein Zain Al-Thalabi

college of Administration and Economics

University of Basrah

Abstract:

Electric energy is one of the most important main sources of energy that contributes significantly to all sectors that push the development process to progress. It plays an important role in the process of development and economic and cultural well-being to be used as important requirements in the economy. Therefore, it is one of the most important manifestations of civilization and development and a measure of sophistication and well-being in any society because of the services provided by this energy.

This study applies a model for electric load prediction by applying support vector regression with chaotic hybrid algorithms to improve prediction performance, Which solves the problems of improving the support vector regression parameters, so the support vector regression was hybridized with chaotic algorithms (CIA), (CPSO) to determine the optimal and appropriate parameters for the support vector regression model, Comparing the models with each other, to choose the best model and use it to predict electrical energy consumption for the period (2020–2029) in the southern region of Iraq .The results found that the CIASVR model is more accurate and efficient than other forecasting models based on statistical forecasting accuracy criteria.

Keywords: support vector regression, immune algorithm.chaotic immunity algorithm, the partial swarm algorithm, chaotic the partial swarm algorithm.

مقدمة:

لقد حظي التنبؤ بالأحمال الكهربائية ودقتها باهتمام متزايد ويعتبر من المواضيع المهمة في الإحصاء نتيجة الحاجة اليه في مختلف مجالات الحياة. كانت هذه العملية محط اهتمام الاحصائيين لفترة طويلة من الزمن لان التنبؤ له أهمية واضحة ومؤثرة في دقة القرار، فمعظم الدول في برامجها التخطيطية تعتمد على أسس وطرائق علمية متقدمة للحصول على نتائج أكثر فعالية.

اقترح العديد من الباحثين عدة اساليب للتنبؤ بالحمل الكهربائي لزيادة دقة الأداء ، من هذه الطرائق الأساليب التقليدية التي تضمنت نماذج المتوسطات المتحركة (ARIMA)، ونماذج (Box – jenkis) ونماذج التمهيد الاسي، والانحدار المتعدد، ونماذج تقدير بايزي (Bayesian)، وكذلك الأساليب الذكية مثل تقنية الشبكة العصبية الاصطناعية (ANN) (حسين ، 2019 ، 5)، واتسمت هذه الأساليب بضعف القدرة الملائمة غير الخطية، لذا من الصعب التنبؤ بالحمل الكهربائي باستخدام هذه الأساليب. ويمكن أن تؤدي إعدادات المعلمات المختلفة الى اختلافات كبيرة في الأداء. لذا يعد اختيار المعلمات المثلى خطوة مهمة في تصميم (SVR). لذا يتم تطبيق (SVR) الهجين مع الخوارزمية الفوضوية بنجاح في التنبؤ بالحمل الكهربائي للحصول على نتائج أكثر دقة وكفاءة في التنبؤ بالحمل الكهربائي. (زين ، 2018 ، 14) .

ان الهدف من هذا البحث هو تكوين نموذج هجين من (SVR) مع الخوارزميات الفوضوية (خوارزمية سرب الطيور الفوضوية، خوارزمية المناعة الفوضوية) والمقارنة بين النموذجين لاختيار افضل نموذج وفق معايير إحصائية،

واستخدام النموذج المختار في التنبؤ باستهلاك الطاقة الكهربائية في المنطقة الجنوبية للمدة (2020 – 2028).

الدراسات السابقة

قامت دراسة (Malek Sarhani, 2015) باستخدام الأسلوب الهجين المقترح (SVR-FS-PSO) للتنبؤ بالحمولة الكهربائية وإجراء اختيار الميزة من أجل تحسين أداء ELF وتحسين معلمات (SVR)، واشتملت العينة على بيانات الاحمال الكهربائية التاريخية المستخدمة في مسابقة (THE EUNITE) للمدة (1 كانون الثاني لعام 1997 الى 31 كانون الأول 1998) في المغرب، واستنتجت الدراسة ان الاسلوب الهجين المقترح لاختيار النموذج يحقق قدرة تعميم أفضل بالمقارنة مع نموذج (SVR) الكلاسيكي في أثناء استخدام اختيار الميزة وبدون استخدامه. [Sarhani, 2019, 11]

تقترح دراسة (Guifen Gong, 2010) نهجاً جديداً يعرف باسم (chaotic particle swarm optimization algorithm) مع (SVR) للتنبؤ بالعوائد المالية. فشملت العينة بيانات العوائد المالية في الفترة من 5 يناير 2003 الى 28 ديسمبر 2005 في بورصة شنغهاي، وظهرت نتائج الدراسة أن النموذج المقترح يفوق النهج الأخرى في التنبؤ بالعائدات المالية. [Cheng, 2010, 2]


هدفت دراسة (Yucheng Dong, 2011) الى تقديم نموذج (SSVRCIA) انحدار المتجه الداعم (SVR) الذي يجمع بين آلية التكيف الموسمية وخوارزمية مناعية فوضوية (CIA) لإيجاد التنبؤ بالأحمال الكهربائية الشهرية. تم استخدام خوارزمية المناعة الفوضوية المقترحة (CIA) على أساس خوارزمية تحسين الفوضى وخوارزمية المناعة (IA)، للتغلب على المشكلة المحلية المثلى السابق لأوانه في تحديد ثلاث معلمات لنموذج انحدار المتجه الداعم (SVR). شملت العينة بيانات الحمل الكهربائي

الشهرية التاريخية من شمال شرق الصين وتوصلت الدراسة الى ان النموذج المقترح حقق نتائج تنبؤ أكثر دقة من نماذج (ARIMA) و (TF-ε-SVR-SA) لذا فهو يعد بديلا واعدا للتنبؤ بالحمولة الكهربائية. [Hong,2011,3]

وقد تناول هذا البحث جانبا نظريا وهي الأساليب الإحصائية المستخدمة للتنبؤ، وجانب تطبيقي اخر يتمثل في تحليل النتائج واختيار أفضل نموذج للتنبؤ بالحمل الكهربائي في المنطقة الجنوبية.

انحدار المتجه الداعم (support vector regression) [Yuan ,2012,13]

إن المفهوم الأساسي لنموذج (SVR) هو ان مجموعة البيانات الأصلية غير الخطية (x_i) يتم تعيينها الى فضاء مميزات عالية الابعاد (أي عدد كبير من الميزات)، يوضح الشكل (1) خريطة البيانات الى فضاء الميزة عالية الابعاد.



الشكل (1) مساحة ميزة انحدار المتجه الداعم (SVR) [Chen ,2016,1]

لتوضيح مفهوم (SVR) تمت صياغة مشكلة الانحدار على النحو التالي:

نفرض ان مجموعة بيانات تدريب معطاة:

$$s = \{(x_1, y_1), \dots, (x_n, y_n)\} \dots (1)$$

حيث أن: y_i هو قيمه الإخراج المرتبطة بـ x_i ، وان دالة الانحدار (SVR) وهي

$$f(x) = w \times \Phi(x) + b \dots (2)$$

حيث ان: $\Phi(x)$: يشير الى دالة التعيين غير الخطية ; b : يمثل مصطلح التحيز. [16] الهدف من (SVR) هو العثور على دالة $f(x)$ التي لديها أقصى انحراف (ε) عن الأهداف (y_i) لكل بيانات التدريب، إذ يتم تقديم دالة الخسارة لضمان تباين المتجه الداعم، وتعرف دالة الخسارة على وفق الاتي:

$$L_s(y_i, f(x)) = \begin{cases} |y_i - f(x_i)| - \varepsilon, & |y_i - f(x_i)| \geq \varepsilon \\ 0 & \text{otherwise} \end{cases} \quad \dots (3)$$

حيث ان: $L_s(y_i, f(x))$: تمثل دالة الخسارة التي يتم اختيارها بشكل مناسب، إذ تشير الى كيفية معاقبة الاختلافات بين y و $f(x)$ أي (القيم المتبقية).
يمكن إضافة متغيرات الركود غير سالبة (ξ_i, ξ_i^*) لتمثيل المسافة من القيم الحقيقية الى القيم المقابلة لـ ε لذا يمكن صياغة النموذج المقيد وعلى وفق الاتي:

$$\min \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i, \xi_i^*) \quad \dots (4)$$

$$\begin{aligned} \text{subject to} \quad & y_i - [w \times \Phi(x)] - b \leq \varepsilon + \xi_i \\ & [w \times \Phi(x)] + b - y_i \leq \varepsilon + \xi_i^* \\ & \xi_i, \xi_i^* \geq 0 \quad ; \quad i = 1, 2, 3, \dots, l \end{aligned}$$

حيث ان: $C \sum_{i=1}^m (\xi_i, \xi_i^*)$: يمثل المصطلح التجريبي الذي يقيس دالة الخسارة ; ε, C : تمثل دالة تكلفه قياس المخاطر التجريبية ; ξ_i, ξ_i^* : تمثل متغيرات الركود.
يتم حل مشكله التحسين المقيد باستخدام نموذج لاكرانج على وفق الاتي:

$$\begin{aligned} \text{Maximize} \quad & \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \\ & - \varepsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) \quad \dots (5) \end{aligned}$$

$$\text{subject to } \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \quad \alpha_i, \alpha_i^* \in [0, C] , i = 1, 2, \dots, l$$

حيث أن: α_i, α_i^* : تمثل مضاعفات لاكرانج ; $K(x_i, x_j)$: تمثل دوال النواة.

يتم تعريف (Kernall Function) على وفق الاتي: [Wang ,2012,12]


$$K(x_i, x_j) = \phi(x_i), \phi(x_j) \dots (6)$$

وتكتب دالة الانحدار الخطي على النحو الاتي:

$$f(x) = \sum_{i=1}^l (\alpha_i^* - \bar{\alpha}_i) K(x, x_i) + \bar{b} \dots (7)$$

إن الأسلوب المستخدم لحل المشكلة غير الخطية هو إسقاط مجموعة من البيانات إلى

مساحة الأبعاد العالية عن طريق إدخال دالة النواة. [Wang ,2012,12]



الشكل (2) تعيين مجموعات البيانات الى مساحة عالية الابعاد مع دالة النواة

[Kavzoglu ,2009,6](Kernel)

خوارزمية تحسين سرب الطيور (PSO)

تعد من الخوارزميات التي تحاكي سلوك المجموعات مثل مجموعات الطيور، الأسماك، الحشرات وما الى ذلك، تنتمي خوارزمية تحسين سرب الطيور (PSO) الى فئة تقنيات ذكاء السرب المستخدمة في حل مسائل الامثلية.

وقد طبقت هذه الخوارزمية عام 1995 من قبل الباحثين (Kennedy) و(Eberhard)، ان الهدف من خوارزمية تحسين سرب الطيور (PSO) الحصول على الحل الأفضل من خلال محاكاة سلوكيات الطيور عند البحث عن الطعام الأفضل لذلك فان أسلوب هذه الخوارزمية سيتم تشكيلة

في البداية بعملية تهيئة عشوائية لمجموعة من السكان وعدة حلول مرشحة في فضاء بحث

المشكلة ، ويتم البحث ضمن هذه المجموعة عن الحل الأمثل. (محمد ، 2018 ، 9)

خوارزمية تحسين سرب الطيور الفوضوية

تقوم خوارزمية تحسين سرب الطيور الفوضوية بتحسين خوارزمية سرب الطيور من خلال دمجها مع نظرية الفوضى. استنادا الى خوارزمية (PSO) المقترحة مع (AIWF) والبحث المحلي الفوضوي (CLS) يتم اقتراح نهج تكراري على مرحلتين يسمى (CPSO) ، اذ يتم استخدام (PSO) مع (AIWF) للاستكشاف العالمي من خلال تحديث سرب الجسيمات اذ يتم استخدام (CLS) للبحث الموجه محليا لحلول (PSO) ، كما يتم استخدام ديناميكيات الفوضى لتعديل افضل الجسيمات المولدة بواسطة (PSO) محليا.[Liu ,2005,8]

تحسين معلمات اندادار المتجه الداعم استنادا الى خوارزمية تحسين سرب الطيور الفوضوية

- تطبق خوارزمية تحسين السرب الفوضوي لاختيار امكانية البحث في ثلاث معلمات في نموذج (SVR) التي لها تأثير أكبر على أداء النموذج، يمكن تلخيص الخطوات الرئيسية لتحسين معلمات (SVR) باستخدام (CPSO) على وفق الاتي:
- 1- انشاء متجه ثلاثي الابعاد وفقا للنظام الفوضوي، ووزن القصور الذاتي، وتهيئه الحد الأقصى للتكرار، وحد الخطأ للياقة البدنية، وحد سرعة كل جسيم.
 - 2- تحديث أفضل حل مثالي للجسيم وأفضل للمجموعة بأكملها.
 - 3- اجراء تحسين فوضوي من خلال تعيين (50%) من الجسيمات الأفضل أداء الى الفترة [0,1].
 - 4- إذا كان الجسيم المحسن من قبل نظرية الفوضى يتميز بمستوى اعلى من اللياقة فيجب تحديث أفضل جسيم.
 - 5- يتم تكرار الخطوة (3) اذا لم يصل الى الحد الأقصى للتكرارات. [Li, 2014, 7]

خوارزمية المناعة (Immune algorithm)

تم اقتراح نظام خوارزمية المناعة (IA) من قبل الباحث (Mori) عام 1993 لحل مشكلات التحسين غير الخطي، الذي يقوم على محاكاة نظام المناعة البيولوجي. فتمتتع خوارزمية المناعة بالقدرة على إيجاد الحلول المثلى مع الحفاظ على درجة عالية من التنوع في مجال البحث. فخوارزمية المناعة (IA) خوارزمية بحث عشوائي استكشافية لوجود قدرة تطويرية تجمع بين الاختيار والتعرف العشوائي، وقد اتفق الباحثون على ان الخوارزمية هي محاكاة أساسية لجهاز المناعة في استجابة

مناعة تكيفية مع دراسة الاجسام المضادة لاستكمال العملية، حيث تم استخدامها على نطاق واسع لحل مشكلات التحسين، واتضح أنها توفر طريقة أكثر كفاءة لحل مشكلات التحسين، إلا أن هناك عيباً واضحاً في الخوارزمية (IA)، فسرعة تشغيلها بطيئة مما يؤثر سلباً في تطبيقها. [Prakash, 2008,10]

خوارزمية المناعة الفوضوية (CIA)

هي طريقة فعالة قابلة للتطبيق لتحسين اختيار المعلمات الثلاثة في (SVR)، وقد استخدم العديد من الباحثين ومنهم (Wang) عام 2009 خوارزمية المناعة الفوضوية لتقييم المعلمات الثلاثة (C, ϵ, σ) لنموذج (SVR)، إذ وجدوا أنها فعالة وتعطي أداء جيد في تخطي المستوى المحلي الأمثل. [Hong, 2013,4]

خوارزمية المناعة الفوضوية في اختيار معلمات نموذج انحدار المتجه الداعم

تتأثر دقة التنبؤات بقيم المعلمات الثلاثة (C, ϵ, σ) لنموذج (SVR) ومع ذلك لا توجد أساليب هيكلية للتحقق من كفاءه المعلمات. وفيما يلي خطوات عمل (CIA) على وفق الاتي:

الخطوة 1: تهيئة القيم الأولية: تمثيل قيم المعلمات الثلاثة في (SVR) باستخدام $X_k^{(i)}, k = \sigma, C, \epsilon$ واستخدام المعادلة في ادناه لتحويل المعلمات الثلاثة الى متغير فوضوي $x_k^{(i)}$:

$$x_k^{(i)} = \frac{X_k^{(i)} - Min_k}{Max_k - Min_k} \dots \dots (8)$$

حيث ان: (i): تشير الى عدد التكرار، $X_k^{(i)}$ تمثل المعلمات الثلاث في نموذج انحدار المتجه الداعم (SVR)، $k = C, \sigma, \epsilon$ ، $x_k^{(i)}$: تمثل المتغيرات الفوضوية بعد

التحويل $K = \text{Min}_k$: تمثل الحد الأدنى لقيم المعلمات $X_k^{(i)}, k = C, \sigma, \varepsilon$; C, σ, ε

Max_k : تمثل الحد الأقصى لقيم المعلمات $K = C, \sigma, \varepsilon$.

الخطوة 2: تعريف التوافق والتشابه. يتم تعريف التقارب بين القيم الأولية (الاجسام المضادة)

والمستند وفق المعادلة التالية:

$$Ag_k = 1/(1 + d_k) \dots \dots (9)$$

حيث ان: d_k : تمثل أخطاء التنبؤ في (SVR) والتي يتم الحصول عليها من خلال k_i .

كما يتم التعبير عن التشابه بين الاجسام المضادة وفق الاتي:

$$Ab_{ij} = 1/(1 + T_{ij}) \dots \dots (13)$$

حيث ان: T_{ij} : تمثل الفرق بين خطأ التنبؤ الحالي وخطأ التنبؤ السابق لنموذج (SVR) الذي تم الحصول عليه من القيم الأولية.

الخطوة 3: اختيار القيم الأولية في خلايا الذاكرة. الأجسام المضادة ذات القيم الأعلى لـ Ag_k لديها فرصة أفضل لدخول خلية الذاكرة.

الخطوة 4: عبور الاجسام المضادة. تستخدم إجراءات العبور والتطفير لإنتاج أجسام مضادة جديدة. يتم مطابقة السلاسل المضادة للأجسام بشكل ديناميكي لتنفيذ عملية العبور.

[Hong ,2013, 4]

الخطوة 5: الطفرة الفوضوية في الاجسام المضادة. يتم تعيين مجموعة الاجسام المضادة اثناء العبور من مساحة الحل الحالية (Min_k, Max_k) الى فترة المتغير الفوضوي $[0,1]$ لتكوين

فضاء متغير فوضوي $\hat{x}_k^{(i)}, k = C, \varepsilon, \sigma$ وفق المعادلة الاتية:

$$\hat{x}_k^{(i)} = \frac{\hat{X}_k^{(i)} - Min_k}{Max_k - Min_k} \dots \dots (14)$$

$\hat{x}_k^{(i)}$: تمثل المتغيرات الفوضوية بعد تطبيع $\hat{X}_k^{(i)}, k = C, \varepsilon, \sigma$ تمثل

المعاملات الثلاث لما بعد عملية التقاطع لنموذج انحدار المتجه الداعم (SVR)

باستخدام احتمال حدوث الطفرة (p_m) يتم تعيين متغير الطفرة الفوضوي الذي تم الحصول عليه في الفترة $[0,1]$ الى فترة الحل وفق المعادلة الاتية:

$$\tilde{X}_k^{(i)} = Min_k + \tilde{x}_k^{(i)} (Max_k - Min_k) \dots \dots (15)$$

حيث ان: p_m : تمثل احتمال الطفرة، $\tilde{x}_k^{(i)}$: تمثل متغيرات الطفرة الفوضوية $K = C, \varepsilon, \sigma$

الخطوة 6: معايير التوقف. عندما يكون عدد الأجيال يساوي مستوى معين فإن الاجسام المضادة الأفضل تمثل الحل، والا يتم العودة الى الخطوة الثانية. [Hong, 2011,3]

التحليل الاحصائي:


تم استخدام مجموعة بيانات حقيقة للحمل الكهربائي في المنطقة الجنوبية للفترة من (1980) الى (2019) والتي تتضمن المتغير التابع (الاستهلاك السنوي للطاقة الكهربائية في المنطقة الجنوبية (ميكاواط، ساعة) والمتغيرات المستقلة التي نقيس تأثير نموذج انحدار المتجه الداعم هي كلا من (الناتج المحلي

الإجمالي بالدينار العراقي، متوسط نصيب الفرد من الدخل بالدينار العراقي، عدد المشتركين في المنطقة الجنوبية ، سعر الكيلو واط بالدينار /kwh). ويتم التنبؤ من خلال النموذج الأفضل باستخدام (CPSO)، (CIA) ، باستخدام برنامج (Matlab 7.11)، اذ يتم ذلك عن طريق تقدير معلمات (SVR) وهي (C, ε, σ) ، واستخدام أسلوب (cross – Valinda) لتقسيم البيانات بصورة مختلفة ثم تقسيمها الى ثلاث فصول $(k = 3)$ حتى يتم تقديرها.

جدول (1) تقدير معلمات (SVR) مع (CIA)

نموذج التقلب	متوسط مربع الخطاء	المعلمات الأمثل
3.251	1.963	δ
6.952×10^5	4.263×10^3	C
0.47	0.21	ε
p=1, q=2	K=3	عدد المدخلات
3.842	1.89	الخطأ العشوائي الأصغر

يوضح الجدول (1) تقدير معلمات نموذج (SVR) باستخدام (CIA) بعد عملية تكرار اكثر من مره للحصول على تقنية افضل للنموذج (CIASVR) من خلال اقل خطأ معياري ، وقد اشارت النتائج الى ان متوسط الخطأ لـ δ (1.963)، وكذلك قيمته في النموذج (3.251). وقيمة متوسط الخطأ في C وفي النموذج (4.263×10^3) ، (6.952×10^5) . ومتوسط الخطأ في ε (0.21) وأيضا في النموذج (0.47)، حيث ان قيمة الخطأ المعياري انخفضت بعد تكرار العملية.



شكل (3) يوضح نتائج نموذج (SVR) مع (CIA)


يوضح الشكل البياني تأثير بناء نموذج انحدار المتجه الداعم (SVR) من قبل خوارزمية المناعة الفوضوية (CIA)، إذ نلاحظ ارتفاع استهلاك الطاقة الكهربائية بعد عام 2010 وحتى نهاية المدة لبيانات الدراسة 2019.

جدول (2) تقدير معلمات (SVR) مع (CPSO)

المعلمات الأمثل	متوسط مربع الخطاء	نموذج التقلب
δ	0.675	3.614
c	7.693×10^3	6.236×10^5
ε	0.74	0.67
عدد المدخلات	$K=3$	$p=1, q=2$
الخطأ العشوائي الأصغر	2.756	3.147

يوضح الجدول (2) أعلاه تقدير معالم نموذج (SVR) باستخدام (CPSO) والتي نسعى من خلالها الوصول الى القيم المثلى لهذه المعلمات. وبعد عملية تكرار أكثر من مره للحصول على تقنية أفضل لتقدير معلمات (SVR) من خلال اقل خطأ معياري. حيث اشارت النتائج الى ان متوسط الخطأ للمعلمة (δ) (0.675) وقيمتها في النموذج (3.614)، وهذا يدل على ان الارتباط بين متجهات الدعم ضعيفة ومن ثم تكون عملية التعلم الآلي معقدة نسبيا. وقيمة متوسط الخطأ لـ C (7.693×10^3) وفي النموذج (6.236×10^5)، وتشير هذه القيمة الى تحسين دقة التعلم. وان متوسط الخطأ المعياري لـ ϵ (0.74) وفي النموذج (0.67)، وتشير قيمة المعلمة (ϵ) الى ان المتجه الداعم يكون ضعيفا وهذا يؤدي الى ان نموذج التنبؤ بسيط وذو دقة منخفضة.

شكل (4) يوضح نتائج نموذج (SVR) مع خوارزمية (CPSO)



جدول (3) معايير المفاضلة بين النماذج

معايير لدقة التنبؤ	نموذج انحدار المتجه العام مع خوارزميه سرب الطيور	نموذج انحدار المتجه العام مع خوارزميه المناعة الفوضوية
MSE	6.007E11	215389577888
RMSE	245091.8195	29460.0
MAE	350830.0	28830.0
MAPE	1.000	7.415

يتضح من النماذج السابقة ان لكل نموذج قيم تدل على جودته ودقته في اختيار المعلومات المطلوبة وبالنظر للمعادلات والقوانين الإحصائية نجد ان النموذج (CIASVR) هو الأفضل من حيث الدقة المطلوبة في تحليل البيانات. لذا تم اختيار أسلوب (SVR) مع خوارزمية المناعة الفوضوية للتنبؤ لعشر سنوات مستقبلية لاستهلاك الطاقة الكهربائية.

الجدول (4) قيم التوقعات المستقبلية لاستهلاك الطاقة الكهربائية (2020-2029)

السنوات	CPSO+SVR قيم التنبؤ للاستهلاك باستخدام خوارزمية (جيجاوات/ساعة)
2020	17090370.91
2021	17518054.12
2022	17945737.34
2023	18373420.55
2024	18801103.76
2025	19228786.98
2026	19656470.19
2027	20084153.41
2028	20511836.62
2029	20939519.83

الاستنتاجات:

تم تقديم نموذج (SVR) مع خوارزميتين فوضوية تمثل: (CIA)، (CPSO) لدراسة بيانات الحمل الكهربائي للمدة من 1980 الى 2019 للتنبؤ سنويا باستهلاك الطاقة الكهربائية في المنطقة الجنوبية. وقد تم التوصل الى الاستنتاجات التالية:

1- تم تهجين انحدار المتجه الداعم مع الخوارزميات التطورية الفوضوية لتطوير وتصميم اختيار أفضل معلمات SVR.

2- أظهرت النتائج ان خوارزمية المناعة الفوضوية لها التفوق في التعامل مع عيوب خوارزمية المناعة (CIA) وهي إحدى التقنيات التي تمتاز بتقاربها السريع مقارنة مع الخوارزميات الأخرى بالإضافة الى كونها سهلة التطبيق والتنفيذ.

3- يساعد الدمج بين نموذج انحدار المتجه الداعم (SVR) والخوارزميات الفوضوية في تحسين دقة التنبؤ وقد اعطى هذا النموذج تنبؤات جيدة وقريبة من القيم الفعلية لسلسلة الاستهلاك السنوي للطاقة الكهربائية.

4- تحسين دقة النموذج بشكل كبير والتنبؤ بالحمل الكهربائي في المنطقة الجنوبية للمدة (2020 – 2029) باستخدام النموذج الهجين (CIASVR).

5- يعد تهجين تقنيات ذكية جديدة بمساعدة خوارزميات تطورية منفردة تكون أكثر ملائمة للحصول على مستويات تنبؤ أكثر دقة.

المصادر :

1. حسين ، جاسم ناصر وآخرون، "استخدام نموذج الانحدار الذاتي والإعلام المتحرك المتكامل للتنبؤ بإنتاج التمور في العراق"، جامعة البصرة، مجلة الاقتصادي الخليجي، العدد (42)، ديسمبر، 2019
2. حسين، ساهرة زين استخدام طريقة ARIMA في التنبؤ بعرض النقود في الاقتصاد العراقي، كلية الإدارة والاقتصاد جامعة البصرة مجلة الاقتصادي الخليجي ، العدد (35) ، مارس 2018
3. محمد، صالحة رائد وصالح، إبراهيم احمد (2018). "استخدام خوارزمية أمثليه عناصر السرب لقياس جودة البرمجيات"، مجلة الرافيدين لعلوم الحاسبات والرياضيات، المجلد (12)، العدد (1)
4. Chen, C. W. & Chang, Y. C. (2016). "Support Vector Regression and Genetic Algorithm for HVAC Optimal Operation", National Taipei University of Technology, Hindawi Publishing Corporation, Volume 2016, No. 1.
5. Cheng, Y., Fu, Y., & Gong, G. (2010). "A Hybrid Support Vector Regression Based on Chaotic Particle Swarm Optimization Algorithm in Forecasting Financial Returns", School of Computer Science & Technology, Soochow University, China.

Hong, W. C., Dong, Y., Lai, C. Y., Chen, L. Y. & Wei, S. .6

Y. (2011). "SVR with Hybrid Chaotic Immune Algorithm for Seasonal Load Demand Forecasting", *Energies*, 4(6),

Hong, W.-C. (2013). *Intelligent Energy Demand* .7

Forecasting. Department of Information Management
Oriental Institute of Technology New Taipei City Taiwan
R.O.C, Lecture Notes in Energy. doi:10.1007/978-1-
4471-4968-2.

Hussein, Jassim Nasser et al., "Using the Autoregressive .8

Model and Integrated Moving Media (ARMA) to Predict
Date Production in Iraq", University of Basra, Gulf
Economic Journal, Issue (42), December, 2019.

Kavzoglu, T., & Colkesen, I. (2009). "A kernel functions .9

analysis for support vector machines for land cover
classification". *International Journal of Applied Earth
Observation and Geoinformation*, vol.11, No. (5), Li, T.;

Yong.W.; Zhi, GZ.; Zhi, L.; Chen, YG. (2014). .10

Short-Term Wind Power Prediction Based on Support
Vector Regress Optimized by Chaos Particle Swarm
Optimization, School of Electrical Engineering, Anhui
Polytechnic University, Wuhu, China.

- Liu, B., Wang, L., Jin, Y.-H., Tang, F., & Huang, D.-X. (2005). Improved particle swarm optimization combined with chaos. *Chaos, Solitons & Fractals*, 25(5), 1261–1271. doi: 10.1016/j.chaos.2004.11.095. **.11**
- Mohammed, Salha Raed and Saleh, Ibrahim (2018). "Using Swarm Element Optimization Ahmed (2018). "Using Algorithm to Measure Software Quality", *Al-Rafidain Vol. Journal of Computer Science and Mathematics*, (12), No. (1), **.12**
- Prakash, A., Kiwanis, N., Tiwari, M.K.& Cohen, Y. (2008). "Modified immune algorithm for job selection and operation allocation problem in flexible manufacturing system", *Advances in Engineering Software*, M., El Afia, A. (2015). "Electric load forecasting using hybrid machine learning approach incorporating feature selection", Mohammed-V University Rabat, Morocco, **.14**
- Wang, Y., Wang, B. & Zhang, X. (2012). "A New Application of the Support Vector Regression on the Construction of Financial Conditions Index to CPI Prediction", *Procedia Computer Science*, vols. 9, **.15**

Yuan, F.C. (2012). "Parameters Optimization Using .16

Genetic Algorithms in Support Vector Regression for
Sales Volume Forecasting", Department of Information
Management, Yuan Ze University, 2012, vols. 3,

Using the ARIMA method in ،Sahara Hussein،Zain .17

University ،forecasting money Supply in the Iraqi economy
Journal, Issue (35), March, of Basrah Gulf Economic
2018

References

1. Hussein, Jassim Nasser et al., "using the self-regression model and integrated mobile media to predict the production of dates in Iraq", University of Basra, Gulf Economist magazine, issue (42), December, 2019
2. Hussein, Sahra Zain the use of the ARIMA method in predicting the money supply in the Iraqi economy, Faculty of management and Economics University of Basra Gulf economic Magazine, Issue (35), March 2018
3. Mohammed, Saleh Raed and Saleh, Ibrahim Ahmed (2018). "Using the swarm element optimization algorithm to measure software quality", al-Rafidain Journal of Computer Science and mathematics, Vol. (12), No. (1).

4. Chen, C. W. & Chang, Y. C. (2016). "Support Vector Regression and Genetic Algorithm for HVAC Optimal Operation", National Taipei University of Technology, Hindawi Publishing Corporation, Volume 2016, No. 1.
5. Cheng, Y., Fu, Y., & Gong, G. (2010). "A Hybrid Support Vector Regression Based on Chaotic Particle Swarm Optimization Algorithm in Forecasting Financial Returns", School of Computer Science & Technology, Soochow University, China.
6. Hong, W. C., Dong, Y., Lai, C. Y., Chen, L. Y. & Wei, S. Y. (2011). "SVR with Hybrid Chaotic Immune Algorithm for Seasonal Load Demand Forecasting", *Energies*, 4(6), pp (960–977).
7. Hong, W.-C. (2013). Intelligent Energy Demand Forecasting. Department of Information Management Oriental Institute of Technology New Taipei City Taiwan R.O.C, Lecture Notes in Energy. doi:10.1007/978-1-4471-4968-2.
8. Hussein, Jassim Nasser et al., "Using the Autoregressive Model and Integrated Moving Media (ARMA) to Predict Date Production in Iraq", *University of Basra, Gulf Economic Journal*, Issue (42), December, 2019.
9. Kavzoglu, T., & Colkesen, I. (2009). "A kernel functions analysis for support vector machines for land cover

- classification". International Journal of Applied Earth Observation and Geoinformation, vol.11, No. Li, T.
10. Yong.W.; Zhi, GZ.; Zhi, L.; Chen, YG. (2014). Short-Term Wind Power Prediction Based on Support Vector Regress Optimized by Chaos Particle Swarm Optimization, School of Electrical Engineering, Anhui Polytechnic University, Wuhu, China,
 11. Liu, B., Wang, L., Jin, Y.-H., Tang, F., & Huang, D.-X. (2005). Improved particle swarm optimization combined with chaos. Chaos, Solitons & Fractals, 25(5), 1261–1271. doi: 10.1016/j.chaos.2004.11.095.
 12. Mohammed, Salha Raed and Saleh, Ibrahim Ahmed (2018). "Using Swarm Element Optimization Algorithm to Measure SoftwareQuality", Al-Rafidain Journal of Computer Science and Mathematics, Vol. (12), No. (1), Prakash,
 13. A., Kiwanis, N., Tiwari, M.K.& Cohen, Y. (2008). "Modified immune algorithm for job selection and operation allocation problem in flexible manufacturing system", Advances in Engineering Software,
 14. Sarhani ,M., El Afia, A. (2015). "Electric load forecasting using hybrid machine learning approach incorporating feature selection", Mohammed-V University Rabat, Morocco,

15. Wang, Y., Wang, B. & Zhang, X. (2012). "A New Application of the Support Vector Regression on the Construction of Financial Conditions Index to CPI Prediction", Procedia Computer Science, vols. 9,
16. Yuan, F.C. (2012). "Parameters Optimization Using Genetic Algorithms in Support Vector Regression for Sales Volume Forecasting", Department of Information Management, Yuan Ze University, 2012, vols. 3,
17. Zain ،Sahara Hussein، Using the ARIMA method in forecasting money Supply in the Iraqi economy، University of Basrah Gulf Economic Journal, Issue (35), March, 2018