



USING THE BEST CHAOTIC ALGORITHM MODEL WITH SUPPORT VECTOR REGRESSION TO PREDICT ELECTRICAL LOAD IN THE REGION TO THE SOUTH

Researcher Huda Abd Al- Sadah Hashem

College of Administration and Economics, University of Basra, Basra, Iraq

Email: Aser33588@gmail.com

Prof. Dr. Sahera Hussein Zain

College of Administration and Economics, University of Basra, Basra, Iraq

Email: saherazain@gmail.com

Article history:	Abstract:
<p>Received: June 4th 2024 Accepted: July 3rd 2024</p>	<p>The prediction and accuracy of electrical load has received increasing attention, and is one of the important topics in statistics due to the need for it in various areas of life. This process has been the focus of attention of statisticians for a long period of time because prediction has a clear and influential importance in the accuracy of the decision. Most countries in their planning programmers rely on advanced scientific foundations and methods to obtain more effective results. This paper examines a novel and inventive approach for electrical load prediction that enhances prediction performance by combining chaotic hybrid algorithms with super-resolution (SVR) technology. It fixes problems with parameter optimization (SVR). The stability of the support vector regression model (SVR) depends on the selection of ideal parameters. To achieve this, hybridization (SVR) with two chaotic algorithms (CGA, CIA) was conducted. The optimal parameter values in the SVRCIA and SVRCGA models were then compared. The objective was to determine which model was the best and apply it to the estimation of the amount of electrical energy that will be consumed in southern Iraq between 2020 and 2028. The study concluded that the (CGASVR) model is distinguished and superior to other predictive predictions in terms of statistical prediction criteria.</p>

Keywords: SVR, GA, CGA, IA, CIA .

استخدام أفضل خوارزمية فوضوية مع انحدار المتجه الداعم للتنبؤ بالحمل الكهربائي في المنطقة الجنوبية

الباحثة: هدى عبد السادة هاشم

كلية الإدارة والاقتصاد، جامعة البصرة، البصرة، العراق

Email: Aser33588@gmail.com

أ.د. ساهرة حسين زين

كلية الإدارة والاقتصاد، جامعة البصرة، البصرة، العراق

Email: saherazain@gmail.com

المخلص

نال التنبؤ بالحمل الكهربائي ودقته اهتماماً متزايداً، وهو أحد الوسائل الاحصائية المهمة بسبب الحاجة إليه في مختلف المجالات. وكانت هذه العملية محط اهتمام الإحصائيين لفترة طويلة من الزمن لأن التنبؤ له مكانة وأهمية واضحة ومؤثرة في اتخاذ القرارات، واعتمدت معظم البلدان في مبرمجي التخطيط على أسس وأساليب علمية متقدمة للحصول على نتائج أكثر فعالية. بحثت هذه الورقة نهج جديد ومبتكر للتنبؤ بالحمل الكهربائي الذي يعزز كفاءة أداء التنبؤ من خلال الجمع بين الخوارزميات (الهجينة) الفوضوية ونموذج (SVR). فإنه يحدد مشاكل مع المعلمة الأمثل (SVR)، يعتمد اختيار المعلمات المثالية على اساس استقرار أنموذج انحدار المتجه الداعم. ولغرض تحقيق ذلك يتم عن طريق إجراء التهجين (SVR) مع اثنين من الخوارزميات الفوضوية (CGA, CIA). ثم تمت مقارنة قيم المعلمات المثلى في نماذج SVRCIA وSVRCGA. ان الهدف هو اختيار وتحديد النموذج الأفضل لتقدير كمية الطاقة الكهربائية التي سيتم استهلاكها في المنطقة الجنوبية من العراق للفترة من (2020- 2028). واطهرت النتائج أن نموذج (CGASVR) متميز ومتفوق على التنبؤات الأخرى من حيث معايير التنبؤ الإحصائي. **الكلمات المفتاحية:** SVR, GA, CGA, IA, CIA .

يمكن أن توفر تنبؤات الحمل الكهربائي السنوية اتجاهها جديراً بالثقة لتخطيط وإدارة البنية التحتية للطاقة. يعد التنبؤ بحمل الكهرباء أكثر أهمية في إدارة استراتيجية نظام الطاقة الوطنية، لأنه نظراً لعدم وجود أسلاك كهربائية غير خطية فإن التنبؤ السنوي بالكهرباء يمثل مشكلة غير محددة.

العديد من الباحثين اقترحوا طرق عدة للتنبؤ بالحمل الكهربائي لزيادة دقة الأداء، ومن أهم هذه الطرق التقليدية التي تضمنت نماذج (ARIMA)، ونماذج (Box-jenkis)، ونماذج التمهيد الآسي، ونماذج الانحدار المتعدد، ونماذج (Bayesian)، وكذلك الأساليب الذكية مثل تقنية الشبكة العصبية الاصطناعية، ونظراً لضعف الطرق التقليدية للتنبؤ بالحمل الكهربائي عند استخدامها، تنشأ مشكلة هذه الدراسة ونتيجة لذلك تم تطبيق التنبؤات باستخدام انحدار المتجه الداعم. يعتمد توقع نموذج الانحدار المتجه بشكل كبير على المعلمات (C, E) التي يتم اختيارها لذلك، يعد اختيار المعلمات المثالية مرحلة حاسمة في تصميم انحدار متجه الدعم. من أجل تقدير الحمل الكهربائي بشكل أكثر فعالية، تم تطبيق نموذج انحدار المتجه الداعم الهجين مع خوارزمية فوضوية بنجاح. هدفت هذا الدراسة إلى تطوير نماذج هجينة من انحدار متجه الدعم باستخدام خوارزميات فوضوية مثل خوارزمية المناعة الفوضوية، الخوارزمية الجينية الفوضوية بعد مقارنة النموذج يتم اختيار أفضل نموذج لتوقع بكمية الطاقة الكهربائية في المنطقة الجنوبية للفترة (2020-2028) باستخدام النموذج التجريبي الأفضل.

2. الدراسات السابقة

(Yucheng Dong's، 2011) هدفت الدراسة إلى تقديم نموذج (SSVRCA) لانحدار المتجه الداعم الذي جمع بين آلية التكيف الموسمية مع خوارزمية المناعة الفوضوية للعثور على التنبؤ الأحكام الكهربائية الشهرية. يتم تحديد ثلاث معلمات نموذج انحدار المتجه الداعم من خلال حل مشكلة الأمثل المحلية المبكرة باستخدام خوارزمية المناعة الفوضوية، والتي تعتمد على تقنية تحسين الفوضى (IA). تم إنشاء العينة باستخدام بيانات الحمل الكهربائي الشهرية التاريخية من شمال شرق الصين. وأظهرت نتائج التحقيق أن النموذج المقترح تفوق في الأداء على نموذجي TF-ε-SVR-SA و ARIMA من حيث دقة التنبؤ. نتيجة لذلك، يعتقد أن هذا النموذج بديل قابل للتطبيق لتقدير المتطلبات الكهربائية. [Hong,2011]

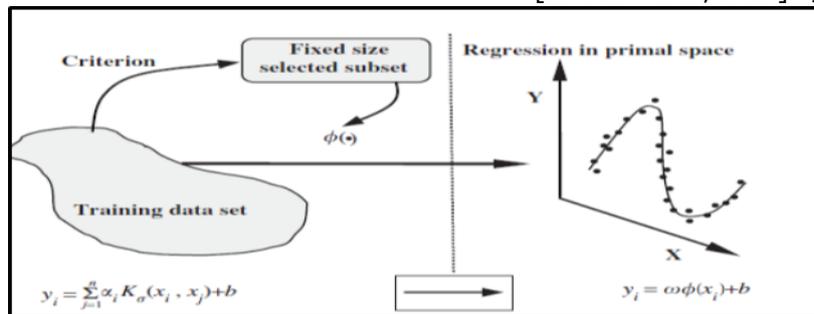
(Yanfang Deng، 2012) استخدم التنبؤ بتدفق حركة المرور في المناطق الحضرية على المدى القصير، تم استخدام تقنية التعلم الإحصائي لانحدار المتجهات القائمة على الخوارزمية الجينية العشوائية. لمعالجة مسألة التحسين المحلي المبكر، وتم استخدام النهج المقترح لزيادة دقة التنبؤ من خلال المعلمات الأساسية الثلاثة لنموذج انحدار المتجه الداعم. وأظهرت العينة بيانات عن تدفق حركة المرور في الصين عبر نهر ووهان-اليانغتسي (Wuhan-Yangtze) بعد دراسة أن النموذج المقترح بالإمكان تطبيقه بفعالية في التخطيط لتدفق حركة المرور لفترة قصيرة من الزمن. [Deng,2012]

(Peyman Yousef، 2020) تم اقتراح نهج جديد لتحسين دقة النماذج المستخدمة للتنبؤ من خلال استخدام نظرية الفوضى بتقديرات استهلاك المياه اليومية في المناطق الحضرية. الهدف من هذا النهج هو تحسين إدارة النظام وزيادة الموثوقية. تم الاعتماد على بيانات استهلاك المياه في منطقة كيلونا في كندا كعينة للتنبؤ بقيم الاستهلاك المستقبلية، باستخدام فترات زمنية مختلفة على جداول زمنية مختلفة. الهدف الرئيسي لهذه الدراسة هو العثور على نماذج يمكن أن تساعد في تحسين أداء التنبؤ. وعززت النتائج أداء التنبؤ، إذ يتضح أن هناك حاجة إلى المزيد من التحقيق لفهم الطبيعة الفوضوية للبيانات المتعلقة باستخدام المياه على فترات زمنية مختلفة. [Yousefi,2020]

تناولت هذه الدراسة الجوانب النظرية لتقنيات التنبؤ الإحصائي وكذلك الجوانب العملية لتحليل البيانات واختيار أفضل نموذج لتوقع الحمل الكهربائي في المنطقة الجنوبية.

SVR 2.1

يتم اتباع مفهوم الحد من المخاطر الهيكلية، الذي يحاول تقليل الحد الأقصى لخطأ التعميم بدلاً من التركيز على خطأ التنبؤ في مجموعة التدريب (مبدأ الحد من المخاطر التجريبية)، في بناء الانحدار المتجه الداعم (SVR). من أجل تحقيق ذلك، يتم وضع قيود على انحناء أو بنية مجموعة من الوظائف المستخدمة في التقدير. ومن أجل إنشاء تنبؤات دقيقة حول البيانات الجديدة، يحسن انحدار المتجه الداعم القدرة على تعميم الصلة بين المدخلات والمخرجات التي تم تعلمها خلال مرحلة التدريب. ولتسهيل حل مشكلة الانحدار الخطي في منطقة ميزة (F-dimension) فإن انحدار المتجه الداعم (SVR) يخطط بيانات الإدخال x من خلال رسم خرائط غير خطية. [Abd El-Sadah، 2023]



الشكل (1) في منطقة ذات سمات عالية الأبعاد، مع تحديد مساحة المدخلات x [Wang, 2006]

حساب دالة الانحدار باستخدام مجموعة البيانات المقدمة كأساس.

$$G = (x_i, d_i)_i^n \dots (1)$$

العثور على دالة الانحدار $y = f(x)$ التي يمكنها التنبؤ بشكل صحيح بالنتيجة $\{d_i\}$ لمجموعة جديدة من حالات الإدخال والإخراج $\{(x_i, d_i)\}$ هو هدف النمذجة. تستخدم المعادلة التالية لتقريب دالة الانحدار الخطي:

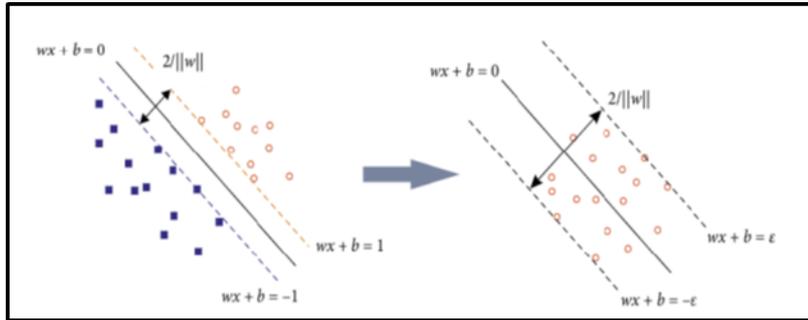
$$f(x) = \omega \phi(x) + b \dots (2)$$

وعلى فإن الانحدار غير الخطي في فضاء مدخلات منخفض الأبعاد (low-dimensional) يتفاعل مع الانحدار الخطي في مساحة ميزة عالية الأبعاد high-dimensional أي عندما يكون هناك العديد من الميزات، والناتج الداخلي بين ω و $\phi(x)$ في فضاء الميزة عالية الأبعاد لا يتم حسابها، وهذا يقلل من وظيفة المخاطر المنهجية ويسمح بتقدير البارامترات ω و b .

$$R_{SVR}(C) = R_{emp} + \frac{1}{2} \|\omega\|^2 = C \frac{1}{n} \sum_{i=1}^n L_S(d_i, y_i) + \frac{1}{2} \|\omega\|^2 \dots (3)$$

$$L_S(d, y) = \begin{cases} |d - y| - \varepsilon & ; \quad |d - y| \geq \varepsilon, \\ 0 & \text{otherwise} \end{cases} \dots (4)$$

تعمل نظرية (SVR) كأساس لتقنية الانحدار المعروفة باسم (انحدار المتجه الداعم) والتي تدعم الانحدار الخطي وغير الخطي (SVM) مصنف يستخدم للتنبؤ تسميات فئوية متميزة، وهذا يختلف عن دعم ناقلات الانحدار. يستخدم انحدار المتجه الداعم للتنبؤ بالمتغيرات بترتيب مستمر.



الشكل (3) تمييز SVM (يسار) و SVR (يمين). [Li, 2014]

إن تقليل حدود الخطأ في التعميم هو المفهوم الأساسي لانحدار ناقل الدعم مما يعكس المخاطر الحقيقية المرتبطة بتنفيذ التعلم الآلي، وفي عام (1995) طور Vapnik انحدار المتجه الداعم من خلال التفاعل بين دالة الخسارة ε-Essential والمتجه الداعم لمعالجة مشاكل تقدير الانحدار غير الخطي.

وعليه فإن تحديد الدالة يقع خروجها عن البيانات الفعلية ضمن نطاق محدد مسبقاً هو المبدأ الأساسي للانحدار. ويمكن التعبير عن صيغته الهيكلية على النحو التالي: [Wenjun, 2016]

$$R(w) \leq Re mp(w) + \phi(n/h) \dots (5)$$

GA 2.2

تم تطبيق الخوارزمية الجينية بنجاح لإيجاد حلول مقبولة (قريبة من المثالية) للمشاكل المتعلقة بالعلوم لأنها تقلل الكثير من الوقت والجهد لمصممي البرامج والأنظمة الحاسوبية للحصول على خوارزمية عامة موثوقة عند حل أنواع مختلفة من المشكلات، بدلاً من بناء خوارزمية خاصة لكل مشكلة. وضع في اعتبارك حجم ونوع البيانات المستخدمة وطبيعة الوظيفة المستهدفة وقيود كل مشكلة مع مراعاة التغييرات اللازمة التي تناسب خصوصية كل مشكلة. تستخدم الخوارزمية الجينية لتحسين المعلمات في دعم نمذجة انحدار المتجه الداعم على نطاق واسع لإيجاد الحل الأمثل. [البدراني، 2007]

CGA 2.3

لتحسين فوائد البحث لكلا النموذجين، يتم دمج محرك رسم الخرائط الفوضوي (CMO) والخوارزمية الجينية (GA) لإنشاء الخوارزمية الجينية الفوضوية (CGA)، من أجل توزيع الأشخاص بعناية بين الأجيال الفرعية ومنع الاختيار المبكر للأفراد في الأجيال اللاحقة، تستفيد هذه الطريقة من الخصائص الثلاث للمتغيرات الفوضوية، فضلاً عن تزايد الخوارزمية الجينية الفوضوية من احتمالية إنتاج أفراد متفوقين وتساعد في البحث عن الحل الأمثل العالمي من خلال تطبيق جانب القرب البطيء للخوارزمية الجينية لمواجهة عدم القدرة على التنبؤ الكامن في العملية الفوضوية. [Yan, 2003]

2.4 استخدام (CGA) في بارامترات نموذج (SVR)

وفيما يلي وصف لخطوات الخوارزمية المقترحة:

الخطوة 1. قم بإنشاء رقم أولي باستخدام محرك الخرائط الفوضوي: هناك ثلاث معلمات ممكنة لنموذج انحدار المتجه الداعم، ويتم الإشارة إليها على أنها $X_k^{(i)}$ حيث $K = C, \sigma, \varepsilon$.

حيث: (i) يشير إلى عدد من التكرار، $X_k^{(i)}$ المعلمات الثلاثة في (SVR)، $k = C, \sigma, \varepsilon$ تمثل رسم خرائط $i = 0$ ، يتم استخدام الصيغة التالية لضبط المعلمات الثلاثة (C, σ, ε) بين الفاصل الزمني (Max_k, Min_k) للمتغيرات الفوضوية $X_k^{(i)}$ التي تتراوح قيمها بين 0 و 1. [Hong, 2013]

$$x_k^{(i)} = \frac{X_k^{(i)} - \text{Min}_k}{\text{Max}_k - \text{Min}_k}, K = C, \sigma, \varepsilon \dots (10)$$

الخطوة 2: يتم تقييم لياقة الدالة المستهدفة في كل حل باستخدام خطأ متوسط الجذر المربع (MAPE-) لتحديد كفاءة مجموعة المعلمات (C, ε, σ).

الخطوة 3: بناءً على دوال اللياقة البدنية من المتوقع أن تنتج الحلول ذات قيم اللياقة البدنية الأعلى ذرية في الجيل القادم، ويستخدم مبدأ اختيار عجلة الروليت لاختيار الحل المناسب. [Jingjing, 2014]

الخطوة 4: عمليات الانتقال: يتم استخدام التحديد العشوائي لإيجاد حلول متوافقة مع بعضها البعض بمجرد تحديد اهم نقاط التوقف، يتم تبادل سلاسل الحلول المرتبطة وفقاً لمبدأ نقطة التقاطع المفردة. [Deep, 2012]

الخطوة 5: عملية الطفرة الفوضوية: يتم تطبيق المعلمات الثلاثة بعد عملية التقاطع $\hat{X}_k^{(i)}$ كمتغيرات فوضوية $k = C, \sigma, \varepsilon$ وفقاً $\hat{x}_k^{(i)}$ للمعادلة التالية:

$$\hat{x}_k^{(i)} = \frac{\hat{X}_k^{(i)} - \text{Min}_k}{\text{Max}_k - \text{Min}_k} \dots (11), k = C, \sigma, \varepsilon, 1, 2, \dots, q_{\text{max}}$$

الخطوة 6: إيقاف الحالة: سيتم عرض الحل المثالي إذا كان عدد الحلول يفي بالعتبة المحددة مسبقاً؛ إذا لم يكن كذلك فيجب عليك العودة إلى الخطوة (2). [Zhang, 2012]

IA 2.5

ولغرض معالجة مشكلات التحسين سنستخدم خوارزميات مناعة الذكاء الاصطناعي على نطاق واسع ووفقاً للطريقة التي تمت بها مقارنة خوارزمية المناعة بالخوارزمية الجينية، وجد أن خوارزمية المناعة توفر طريقة أكثر كفاءة لحل مشاكل التحسين. ومع ذلك ان

هناك خلل واضح في الخوارزمية إذ أن سرعة تشغيلها بطيئة مما سيؤثر سلباً على تطبيقها. هدفت خوارزمية المناعية إلى تعظيم وظيفة اللياقة البدنية مع الأخذ بنظر الاعتبار أن (IA) قادر على إيجاد الحل الأمثل لمشاكل تحسين الأداء. [Taher,2012]

CIA 2.6

في عام (2009) طبق Hong خوارزمية المناعية الفوضوية لتحديد معايير نموذج (SVR)، ووجد أن هذا النموذج يفوق طرق التنبؤ الأخرى مثل نماذج الشبكة العصبية ونماذج الانحدار التقليدية، فضلاً عن ذلك ان استخدام التسلسلات الفوضوية في إجراءات التحسين العشوائي مثل التعديلات الطفيفة في إعدادات المعلمة أو القيم الأولية للنموذج وهي طريقة فعالة لتنويع نطاق الوصف. [Hong,2014]

2.7 خطوات خوارزمية المناعية الفوضوية الموجهة مع (SVR)

تشمل خطوات تنفيذ خوارزمية المناعية الفوضوية (CIA) ما يلي:

1. تحديد القيم الأولية: $X_k^{(i)}$ يستخدم للإشارة إلى قيم البارامترات الثلاثة في انحدار متجه الدعم عن طريق التكرار (i)، حيث $k = \sigma$ ، ϵ ، C . نبدأ بتعيين $i = 0$ ، ثم يتم تحويل المعلمة الثلاثة من النطاقات (Min_k, Max_k) إلى متغيرات عشوائية $x_k^{(i)}$ يقع داخل النطاق $[0,1]$ باستخدام المعادلة (12).

$$x_k^{(i)} = \frac{X_k^{(i)} - Min_k}{Max_k - Min_k} \dots (12)$$

2. تعريف التقارب والتشابه: تظهر القيم الأولية ذات قيمة تقارب أعلى لديها تنشيط مستعد أعلى، للحفاظ على تنوع القيم الأولية الموجودة في خلايا الذاكرة، من المحتمل تضمين القيم الأولية ذات التشابه المنخفض. وتحدد المعادلة التالية التقارب والتشابه بين القيم الأولية:

$$Ag_k = 1/(1 + d_k) \dots (13)$$

$$Ab_{ij} = 1/(1 + T_{ij}) \dots (14)$$

3. اختيار القيمة الأولية في خلايا الذاكرة: القيم الأولية ذات القيم الأعلى (Ag_k) لديها افضل فرصة لدخول خلية الذاكرة، من جهة أخرى لا يمكن للمرشحين المحتملين الذين تتجاوز قيمهم (Ab_{ij}) بالانضمام إلى خلية الذاكرة.
4. التقاطع بين القيم الرئيسية: لتوليد قيم أولية جديدة يتم تنفيذ إجراءات التقاطع والطفرة، وإجراء التقاطع ينفذ بشكل ديناميكي عن طريق مطابقة سلاسل قيم البداية. [Hong,2014]
5. الطفرة العشوائية للقيم الأولية: يتم تحديد مجموعة القيم الأولية أثناء عملية الانتقال $(k = C, \epsilon, \sigma)$ من مجال الحل الحالي (Min_k, Max_k) إلى مجال المتغير العشوائي $[0,1]$ ، لتشكيل فضاء متغير عشوائي $(x_k^{(i)}, k = C, \epsilon, \sigma)$ وفقاً للمعادلة التالية:

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

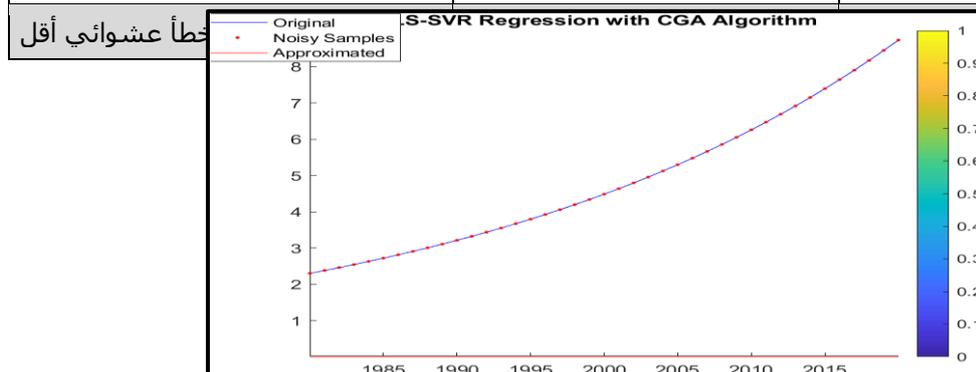
6. معايير التوقف: تشير أفضل القيم الأولية إلى الإجابة عندما يصل عدد الحلول إلى مستوى محدد مسبقاً وفي هذه الحالة لا يتم إرجاع الخطوة الثانية. [Hong,2011]

2.8 التحليل الإحصائي

للتغور على معلمة نموذج تراجع ناقل الدعم الأمثل سنعمل على تقديم نهج (هجين) يدمج الخوارزميات الفوضوية وأنموذج SVR. بعد إجراء عدة خطوات وتكرارات متعددة ثم نختار الخوارزمية الفوضوية المثلى للمعلمة (δ ، ϵ ، C). إذ طبقت الخوارزمية الجينية الفوضوية وخوارزمية المناعية الفوضوية لتقدير معلمة (SVR) لتحديد النموذج الأكثر ملاءمة وكفاءة للتنبؤ باستهلاك الحمل الكهربائي. استخدمت الدراسة البيانات الفعلية حول الطلب الكهربائي في المنطقة الجنوبية للمدة من (1980 – 2019). والتي يمكن التنبؤ بها بشكل أكثر دقة من خلال تقدير معاملات الانحدار وتطبيق نهج (cross Valinda)، وكذلك باستخدام نماذج (CGA) و (CIA) في (Matlab) (7.11). بعد تقسيم البيانات إلى ثلاث مجموعات ($k = 3$) للتقدير، قسّم البيانات بطريقة مختلفة

الجدول 1: استخدام نهج الخوارزمية الجينية الفوضوية لتقدير معلمة انحدار المتجه الداعم

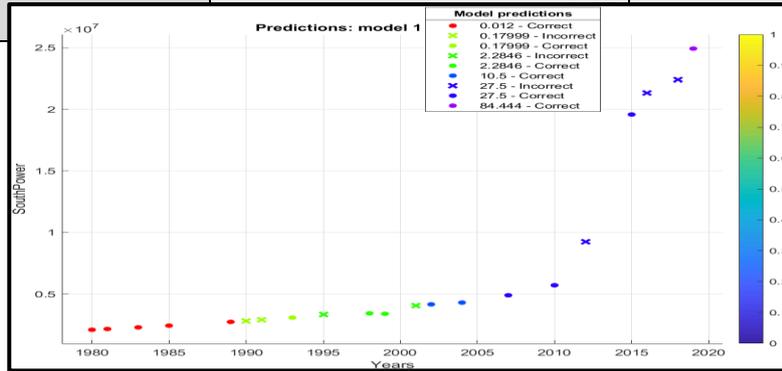
المعلمة الأمثل	متوسط مربع الخطأ	تغييرات النموذج
δ	0.532	1.967
C	6.374×10^3	6.312×10^5
ϵ	0.56	0.78
عدد الإدخالات	K=3	p=1, q=2



الشكل 4: مستخلص النتائج من تهجين CGA مع انحدار المتجه الداعم.

جدول 2: المعلمات المقدرة لانحدار المتجه الداعم بواسطة خوارزمية المناعة الفوضوية.

المعلمت الأمثل	متوسط مربع الخطأ	تغييرات النموذج
δ	1.963	3.251
C	4.263×10^3	6.952×10^5
ε	0.21	0.47
عدد الإدخالات	K=3	p=1, q=2
خطأ عشوائي أقل		3.842



الشكل (5) مخرجات نموذج SVR باستخدام (CIA) .

جدول (3): معايير المقارنة بين النماذج

معايير دقة التنبؤ	نموذج خوارزمية المناعة الفوضوية مع انحدار المتجه الداعم	نموذج الخوارزمية الجينية الفوضوية مع انحدار المتجه الداعم
MSE	215389577888	1400000
RMSE	29460.0	1183.216
MAE	28830.0	33.911
MAPE	7.415	0.12
SBC	4.6689	2.0578

يوضح الجدول (3) أن الخوارزمية الجينية الفوضوية (CGA) أكثر فعالية في تحسين معايير انحدار المتجه الداعم (SVR)، إذ حققت دقة تنبؤية أعلى مقارنة بالخوارزميات الأخرى.

تم اختيار النموذج (الهجين) المعروف باسم (SVRCGA)، والذي جمع بين الخوارزمية الجينية الفوضوية وتراجع ناقل الدعم بسبب فعالية التنبؤ الفائقة. وسيستخدم هذا النموذج للتنبؤ بالبيانات المتعلقة باختبار استهلاك الأحمال الكهربائية في المنطقة الجنوبية.

جدول (4) القيم المتوقعة في المستقبل لاستهلاك الطاقة الكهربائية (2020-2028) .

السنة	قيم التنبؤ استهلاك الحمل الكهربائي باستخدام SVR+CGA
2020	9236057

12790829	2021
16353621	2022
19568089	2023
21317833	2024
22847328	2025
22389174	2026
24915560	2027
9236057	2028

الاستنتاجات:

- تم تقديم نموذج (SVR) مع خوارزميتين فوضويتين (CIA) و (CGA) لدراسة بيانات الحمل الكهربائي للفترة من 1980 إلى 2019 للتنبؤ سنويًا باستهلاك الكهرباء في المنطقة الجنوبية. وتم التوصل إلى الاستنتاجات التالية:
- 1- تم تهجين تراجع ناقلات الدعم بخوارزميات تطويرية فوضوية لتطوير وتصميم اختيار أفضل لمعلمات SVR .
 2. أظهرت الدراسات أن الخوارزمية الوراثية الفوضوية تتفوق في التعامل مع عيوب الخوارزمية الجينية (GA)، وهي تقنية تتميز بتقاربها السريع مقارنة بالخوارزميات الأخرى، بالإضافة إلى سهولة تطبيقها وتنفيذها.
 3. نظرًا لأن نموذج (SVR) أنتج تنبؤات دقيقة كانت قريبة إلى حد ما من القيم الفعلية للاستهلاك السنوي لسلسلة الطاقة الكهربائية، فقد تمت زيادة دقة التنبؤ من خلال دمجها مع خوارزميات فوضوية.
 4. تحسين دقة النموذج بشكل كبير والتنبؤ بالحمل الكهربائي في المنطقة الجنوبية للفترة (2020-2029) باستخدام النموذج الهجين (CGASVR) .
 5. يعد تهجين التقنيات الذكية الجديدة المختلفة بمساعدة خوارزميات تطويرية واحدة أكثر ملاءمة للحصول على مستويات تنبؤ أكثر دقة.

المصادر:

- 1) Abd El-Sadah, Huda and Al-Thalabi, Sahera Hussein. (2023), Modeling and forecasting using support vector regression and chaotic algorithms/ applied study, University of Basra, Faculty of Administration and Economics, Department of Statistics, Iraq.
- 2) Badrani, Maha Abdelilah Mohamed (2007). The use of the genetic algorithm in matching the patterns of the English letter, Journal of Education and Science - Volume (19) Issue (4).
- 3) Deep, K., Nagar, A., Pant, M. & Bansal, J.C. (2012). **Advances in Intelligent and Soft Computing**, Proceedings of the International Conference on Soft Computing for Problem Solving, Volume 1, pp (933-941) , Springer New Delhi Heidelberg New York Dordrecht London.
- 4) Deng, Y., Xiang, J. & Ou, Z. (2012). **SVR with hybrid chaotic genetic algorithm for short-term traffic flow forecasting**, Mathematical department, School of science, Wuhan University of Technology, pp (708-712).
- 5) 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, vol. 4, No. 6, pp (960-977).
- 6) Hong, W. C., Dong, Y., Zhang, W. Y., Chen, L. Y. & Panigrahi, B. k. (2013). Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm, International Journal of Electrical Power & Energy Systems, vol. 44, No. 1, pp (604-614).
- 7) Hong, W.C. (2013). **Intelligent Energy Demand Forecasting**, Department of Information Management, Oriental Institute of Technology, City Taiwan.
- 8) Jingjing, W., Zheng, Y., Qi, W. & Shan, F. (2014). Application of Chaotic Genetic Algorithm and Elman to Assess Flight Performance Under Multiple Physiological Signals, The Open Automation and Control Systems Journal, vol. 6, pp (975-983).
- 9) Li, T., 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, pp (195-200).
- 10) Taher, S. A. & Amooshahi, M. K. (2012). New approach for optimal UPFC placement using hybrid immune algorithm in electric power systems, International Journal of Electrical Power & Energy Systems, vol. 43, No. 1, pp (899-909).
- 11) Wang, K., Kovacs, G., Wozny, M. & Fang, M. (2006). **Intelligent Strategies in Product Design**, International Federation for Information Processing (IFIP), Volume 207, (Boston: Springer), pp (840-846), Shanghai, China.
- 12) Wenjun, W., Jiang, F. (2016). Hybrid Genetic Algorithm and Support Vector Regression Performance in CNY Exchange Rate Prediction, School of Statistics and Mathematics, Zhongnan University of Economics and Law ,China, pp (0136-0139).

- 13) Yan, X. F., Chen, D. Z. & Hu, S. X. (2003). Chaos-genetic algorithms for optimizing the operating conditions based on RBF-PLS model, Computers & Chemical Engineering, vol. 27, No. 10, pp (1393–1404).
- 14) Yousefi, P., Courtice, G., Naser, G. & Mohammadi, H. (2020). Nonlinear Dynamic Modeling of Urban Water Consumption Using Chaotic Approach Case Study: City of Kelowna, Water, vol. 12, No. 3, pp (2-22).
- 15) Zhang, W. Y., Hong, W. C., Dong, Y., Tsai, G., Sung, J. T. & Fan, G. (2012). Application of SVR with chaotic GASA algorithm in cyclic electric load forecasting, Energy, vol. 45, No. 1, pp (850–858).
- 16) Zhang, Z. & Ye, S. (2011). **Long Term Load Forecasting and Recommendations for China Based on Support Vector Regression**, International Conference on Information Management, pp (597-602).