

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

USING THE SVR MODEL WITH THE HYBRID ALGORITHM TO PREDICT THE ELECTRICAL LOAD

Assistant Lecturer. Huda Abdulsadah hashim
College of Administration and Economics,
Department of Economics University of Basra, Basra, Iraq
Email: huda.hashim@uobasrah.edu.iq

Prof. Dr. Sahera Hussein Zain
College of Administration and Economics,
Department of Statistics University of Basra, Basra, Iraq
Email: saherazain@gmail.com

Abstract

Electrical load forecasting is an important topic in the planning and operation of power systems. It contributes to improving the efficiency of energy system management and future decision-making. Due to the nonlinear nature of the electrical load data, this study aimed to develop a prediction model based on the support vector regression (SVR) with two hybrid chaotic algorithms to optimize the selection of optimal parameters. The proposed models were compared using statistical accuracy criteria for predicting electrical load in the southern region of Iraq. The results showed that the supporting vector regression model with the chaotic genetic algorithm was superior in terms of accuracy and efficiency compared to other models.

Keywords: Support vector regression, Chaotic genetic algorithm, Chaotic particle swarm optimization algorithm.

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

استخدام نموذج (SVR) مع الخوارزمية الهجينة للتنبؤ بالحمل الكهربائي

مدرس مساعد: هدى عبد السادة هاشم
كلية الإدارة والاقتصاد، قسم الاقتصاد
، جامعة البصرة، البصرة، العراق
Email: huda.hashim@uobasrah.edu.iq

أ.د. ساهرة حسين زين
كلية الإدارة والاقتصاد، قسم الإحصاء
، جامعة البصرة، البصرة، العراق
Email: saherazain@gmail.com

ملخص: يعد التنبؤ بالحمل الكهربائي من الموضوعات المهمة في تخطيط وتشغيل انظمه الطاقة، اذ يسهم في تحسين كفاءة إدارة نظام الطاقة واتخاذ القرارات المستقبلية. ونظرا للطبيعة غير الخطية لبيانات الحمل الكهربائي هدفت هذه الدراسة الى تطوير نموذج تنبؤ يعتمد على انحدار المتجه الداعم (SVR) مع خوارزميتين فوضوية هجينة لتحسين اختيار المعلمات المثلى. وتمت مقارنة النماذج المقترحة باستخدام معايير الدقة الإحصائية للتنبؤ بالحمل الكهربائي في المنطقة الجنوبية من العراق، واطهرت النتائج تفوق نموذج انحدار المتجه الداعم مع الخوارزمية الجينية الفوضوية من حيث الدقة والكفاءة مقارنة بالنماذج الأخرى.

كلمات مفتاحية: انحدار المتجه الداعم، الخوارزمية الجينية الفوضوية، خوارزمية سرب الطيور الفوضوية.

مقدمة: تعد الطاقة الكهربائية من اهم مصادر الطاقة التي تسهم بصورة أساسية في دعم مختلف القطاعات الاقتصادية والاجتماعية، لما لها من دور في تحقيق التنمية فضلا عن كونها مؤشر ا على مستوي التقدم والتطور في المجتمعات. ونظرا للتزايد المستمر في الطلب على الطاقة الكهربائية، أصبحت عملية التنبؤ بالأحمال الكهربائية أصبحت عملية التنبؤ بالحمل الكهربائي من الموضوعات الحيوية التي تحظى باهتمام كبير لما لها من اثر مباشر في تخطيط وتشغيل انظمه الطاقة واتخاذ القرارات المتعلقة بإدارة مواردها بكفاءة. وقد شهدت أساليب التنبؤ بالحمل الكهربائي تطورا ملحوظا بدءًا من النماذج الإحصائية التقليدية مثل المتوسطات المتحركة والتمهيد الاسي والانحدار المتعدد، الأساليب البايزية، الا ان محدودية قدرتها على تمثيل العلاقات غير الخطية دفعت الباحثين الى تطوير نماذج أكثر كفاءة ومن أبرز هذه النماذج انحدار المتجه الداعم (support vector regression) والذي اثبت فعالية عالية في معالجة مشكلات التنبؤ غير

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

خطي الا ان اداءه يعتمد بدرجة كبيرة على الاختيار الأمثل للمعلمات. ولتحسين كفاءة النموذج اتجهت الدراسات الحديثة الى دمجها مع الخوارزميات التطورية بهدف تحسين اختيار المعلمات الا ان هذه الخوارزميات قد تواجه مشكلات تتمثل في بطء التقارب واحتمالية الوقوع في الحلول المحلية لذلك برزت الخوارزميات الفوضوية الهجينة بوصفها أسلوبا واعدًا لتعزيز البحث عن القيم المثلى وتحسين دقة التنبؤ. تهدف هذه الدراسة الى بناء نماذج هجينة تعتمد على دمج انحدار المنتج الداعم مع عدد من الخوارزميات الفوضوية وهي الخوارزمية الجينية الفوضوية، خوارزمية سرب الطيور الفوضوية. كما تهدف الى اجراء مقارنة بين هذه النماذج باستخدام مجموعة من المعايير الإحصائية لتحديد النموذج الأكثر كفاءة ومن ثم استخدامه في التنبؤ باستهلاك الطاقة الكهربائية في المنطقة الجنوبية خلال المدة (2020-2028). ولتحقيق هذا الهدف قسمت الدراسة الى أربعة فصول تناولت الإطار النظري للطاقة الكهربائية والتنبؤ، ومفاهيم انحدار المنتج الداعم والخوارزميات الفوضوية الهجينة، والجانب التطبيقي الذي تناول تحليل البيانات ونتائج التنبؤ.

دراسات سابقة:

- قدمت دراسة (Gong Guifen, 2010) نموذجا قائما على دمج خوارزمية تحسين سرب الطيور الفوضوية مع انحدار المنتج الداعم (SVR) بهدف التنبؤ بالعوائد المالية. واعتمدت الدراسة على بيانات العوائد المالية لبورصة شنغهاي للفترة من 5 كانون الثاني 2003 الى 28 كانون الأول 2005. وبينت النتائج تفوق النموذج المقترح على النماذج الأخرى من حيث دقة التنبؤ بالعوائد المالية. [8]
- اقترحت دراسة (رقم المصدر) نموذج (SVRCGA) للتنبؤ بالطلب على الهواتف النقالة بهدف تقييم كفاءة الخوارزمية الجينية الفوضوية (CGA) في تحديد المعلمات المثلى وتحسين دقة التنبؤ من خلال دمجها مع نموذج انحدار المنتج الداعم (SVR). وأشارت الدراسة الى أهمية استخدام التسلسل الفوضوي في تعزيز دقة التنبؤ من خلال الحد من الوقوع في الحلول المثلى المحلية، مقارنة بنموذج (SVRCGA). واعتمدت الدراسة على بيانات الطلب الشهري التاريخية على الهواتف النقالة للفترة (2006-2008)، وظهرت النتائج تفوق النموذج المقترح على ثلاثة نماذج أخرى هي نموذج المتوسط المتحرك المتكامل الذاتي (ARIMA)، ونموذج الانحدار العام للشبكات العصبية (GRNN)، ونموذج (SVRGASA). [7]
- قدمت دراسة (Hong, 2013) نموذجا للتنبؤ بالحمل الكهربائي يعتمد على انحدار المنتج الداعم (SVR) بالاقتران مع الخوارزمية الجينية الفوضوية (CGA) بهدف تحسين أداء التنبؤ. وقد طورت الخوارزمية المقترحة بالاستناد الى دمج خوارزمية التحسين الفوضوي مع الخوارزمية الجينية (GA)، اذ استخدمت العشوائية المتولدة من التكرارات الفوضوية لتفادي الوقوع المبكر في الحلول المثلى المحلية عند تحديد المعلمات الثلاث لنموذج (SVR)، واعتمدت الدراسة على بيانات الحمل الكهربائي الشهرية التاريخية لمنطقة شمال شرق الصين وأشارت نتائجها الى ان التهجين بين التعديل الموسمي والتسلسل

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026




This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

الفوضوي يسهم في تحسين دقة التنبؤ. كما أظهرت النتائج ان نموذج (SSVRCGA) حقق دقة تنبؤية اعلى مقارنة بنموذج (ARIMA) والنماذج الأخرى مما يجعله بديلا واعدا للتنبؤ بالحمل الكهربائي. [9]

انحدار المتجه الداعم (SVR):

يعتمد انحدار المتجه الداعم على المبادئ الأساسية نفسها التي تقوم عليها إله المتجه الداعم (support vector machine) مع وجود اختلافات طفيفة بينهما. اذ يهدف (SVR) الى إيجاد منحنى او دالة تحقق أفضل تمثيل للعلاقة بين البيانات بحيث يقلل مقدار الخطأ في التنبؤ. وتؤدي متجهات الدعم دورا أساسيا في تحديد النموذج الأفضل اذ تمثل أقرب نقاط البيانات الى دالة الانحدار وبذلك تسهم في تحديد موضع المنحنى وتحقيق أفضل توافق مع البيانات.



الشكل (1) يسار (SVM) ويمين (SVR)

يعد انحدار المتجه الداعم (support vector regression) أحد أساليب التعلم الآلي المستخدمة في مسائل الانحدار، اذ يمتلك القدرة على نمذجة العلاقات الخطية وغير الخطية بين المتغيرات، ويختلف هذا الأسلوب عن إله المتجه الداعم (support vector machine)، حيث تستخدم إله المتجه الداعم (SVM) في مشكلات التصنيف للتنبؤ بالتسميات او الفئات المنفصلة، بينما يستخدم انحدار المتجه الداعم (SVR) في مشكلات الانحدار للتنبؤ بالمتغيرات المستمرة ذات الترتيب المستمر. [13]

يعتمد أداء ودقة نموذج انحدار المتجه الداعم (SVR) بدرجة كبيرة على الاختيار المناسب لمعلماته مثل نوع دالة النواة (Kernel)، ونوع دالة الخسارة ومعلمات النواة، ونظرا الى ان تعقيد النموذج وقدرته على التعميم يتأثر بجميع هذه المعلمات فأن عملية اختيار القيم المثلى لها تعد مهمة معقدة عند بناء نموذج انحدار المتجه الداعم لما لها من تأثير جوهري في تحسين دقة النموذج وقدرته على التنبؤ.

تُستخدم المعلمة (ϵ) لضبط ملائمة نموذج انحدار المتجه الداعم (SVR) لبيانات التدريب، اذ تؤثر في عدد متجهات الدعم فزيادة قيمتها تقلل عدد متجهات الدعم وتنتج تقديرات أكثر ثباتاً واقل تعقيداً، اما المعلمة (c) فتمثل المفاضلة بين تعقيد النموذج وتقليل أخطاء التدريب، حيث يؤدي ارتفاع قيمتها الى التركيز على تقليل المخاطر التجريبية. [6]

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

ويعتمد اختيار معلمات دالة النواة (kernel) على طبيعة التطبيق وتوزيع قيم بيانات الإدخال لذا فإن الضبط الأمثل لهذه المعلمات يُعد ضرورياً لتقليل خطأ التعميم وتحسين أداء النموذج، وقد اقترح Cherkassky و Ma عام (2004) أسلوباً لتقدير قيمة (c) بالاعتماد مباشرة على بيانات التدريب دون الحاجة إلى إعادة أخذ العينات، وذلك باستخدام طريقة التقدير الآتية:

$$C = \text{Max} (|\bar{y} + 3\sigma_y|, |\bar{y} - 3\sigma_y|) \dots (1)$$

يتميز هذا النهج بالاستقرار في التعامل مع القيم المتطرفة المحتملة. وأوضح Cherkassky و Ma أن قيمة المعلمة (ε) يجب أن تتناسب مع الانحراف المعياري لضوضاء بيانات الإدخال ويمكن تقديرها بالاعتماد على نظرية الحد المركزي وفق المعادلة الآتية:

$$\varepsilon = 3\sigma \sqrt{\frac{\ln n}{n}} \dots (2)$$

ونظراً إلى أن قيمة σ غير معلومة، فيتم تقديرها وفقاً للمعادلة الآتية: [12]

$$\hat{\sigma} = \sqrt{\frac{n^{1/5}K}{n^{1/5}K - 1} \cdot \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \dots (3)$$

الخوارزمية الجينية (genetic algorithm)

تستند الخوارزمية الجينية (GA) في مبدأ عملها إلى مفاهيم الهندسة الوراثية التي تهدف إلى إنتاج أجيال تمتلك خصائص وراثية محسنة، وبناءً على هذا المفهوم تقوم الخوارزمية باختيار الحلول الأكثر كفاءة من بين مجموعة كبيرة من الحلول المتاحة، ثم إجراء عمليات التهجين والتعديل عليها لإنتاج حلول جديدة تتمتع بكفاءة أعلى مع تكرار هذه العمليات حتى الوصول إلى حل يقترب من الحل الأمثل. [14]

استخدمت الخوارزمية الجينية بنجاح في إيجاد حلول مقبولة وقريبة من الحلول المثلى للعديد من المشكلات في المجالات العلمية بما في ذلك في العلوم الطبية والهندسية، إذ تسهم في تقليل الجهد والوقت من قبل مصممي الأنظمة والبرامج من خلال توفير خوارزمية عامة يمكن الاعتماد عليها في معالجة أنواع مختلفة من المشكلات بدلاً من تطوير خوارزمية مستقلة لكل مشكلة مع النظر في حجم البيانات المستخدمة ونوعها وطبيعة دالة الهدف والقيود الخاصة بكل مشكلة مع إجراء التعديلات اللازمة بما يتلائم مع خصائص كل منها. [1]

وتعد الخوارزمية الجينية من الخوارزميات الملائمة لمعالجة المشكلات المعقدة وغير الخطية التي يصعب حلها باستخدام أساليب البحث التقليدية، إذ تمتاز بقدرتها العالية على إجراء البحث العالمي مقارنة بالطرائق

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

التقليدية. ومع ذلك، فإن كفاءتها قد تنخفض عند الاقتراب من الحل الأمثل مما يزيد من احتمالية وقوعها في الحد الأدنى المحلي (Local minimum) وهو ما قد يحول دون الوصول الى الحل الأمثل العالمي. وللتغلب على هذه المشكلة يتم دمج تسلسل الفوضى (chaos sequence) مع الخوارزمية الجينية بحيث تُستخدم المتغيرات الفوضوية لتعزيز عملية البحث واستكشاف الحلول بكفاءة أكبر مما يسهم في تحسين القدرة على الوصول الى الحل الأمثل ويعرف هذا الأسلوب المطور باسم الخوارزمية الجينية الفوضوية [16].

الخوارزمية الجينية الفوضوية (chaotic genetic algorithm)

أظهرت الدراسات الحديثة التي اجراها العديد من الباحثين ان توظيف أساليب التهجين في مسائل الإمثالية يسهم في تحسين جودة الحلول التي يمكن التوصل اليها وعلى الرغم من وجود اختلافات جوهرية بين هذه الخوارزميات فإنها تتشارك في مجموعة العناصر المشتركة التي لم تحظ بالاهتمام الكافي مما أدى الى عدم الاستفادة منها بالشكل الأمثل. [3]

تعد الخوارزمية الجينية الفوضوية من الأساليب الفعالة في معالجة مسائل التحسين المعقدة وغير الخطية اذ تتشابه اليه عملها مع الخوارزمية الجينية الا انها تختلف في طول سلاسل الحلول (string length) اذ لا يكون طول السلسلة ثابتاً وانما يتغير بصورة تدريجية وفقاً لمراحل تنفيذ الخوارزمية.

وتتميز الخوارزمية الجينية الفوضوية بقدرتها على التعامل مع المسائل ذات الطبيعة المعقدة من خلال اعتمادها على تمثيل مرّن للحلول مما يسهم في تحسين كفاءة عملية البحث والوصول الى الحلول المثلى. وتمثل كل سلسلة حل مجموعة من الجينات، وقد يختلف عدد الجينات بين سلسلة وأخرى.

في المراحل الأولى من تنفيذ الخوارزمية يتم توليد سلاسل قصيرة تمثل حلولاً جزئية للمشكلة قيد الدراسة ثم تُقيم هذه الحلول باستخدام دالة اللياقة (fitness function) لتحديد مدى ملاءمتها للمشكلة وبعد اجراء عملية التقييم يتم اختيار الجينات التي تحقق قيم لياقة تفوق متوسط اللياقة والاحتفاظ بها.

بعد ذلك، تستمر الخوارزمية في تنفيذ العمليات الجينية والانتقال من جيل الى اخر اذ يزداد طول سلاسل الحلول تدريجياً مع تقدم الأجيال وتستمر هذه العملية حتى تصل سلاسل الحلول الى الطول الكامل المطلوب. [4]

تقوم الخوارزمية الجينية الفوضوية (CGA) على دمج الخوارزمية الجينية (GA) مع مشغل الخرائط الفوضوية بهدف الاستفادة من خصائص البحث التي يتميز بها كل منهما وتعزيز كفاءة عملية البحث عن الحلول المثلى. اذ توظف الخوارزمية الخصائص الثلاث للمتغيرات الفوضوية في عملية توزيع افراد الأجيال الفرعية ضمن فضاء الحل مما يساعد على الحد من حدوث الاختيار المبكر لأفراد الأجيال اللاحقة. كما تستفيد الخوارزمية الجينية الفوضوية من خاصية التقارب البطيء التي تتميز بها الخوارزمية الجينية في الحد من التأثير العشوائي الناتج عن العملية الفوضوية، الامر الذي يعزز قدرة الخوارزمية على

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)


ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

استكشاف فضاء الحلول بصورة أكثر كفاءة مما يسهم في تحسين أداء الخوارزمية وزيادة إمكانية الوصول الى الحل الأمثل العالمي. [17]



مخطط (1) مراحل تنفيذ الخوارزمية الجينية الفوضوية

تحسين معلمات (SVR) باستخدام (CGA):

يعد تحديد القيم الملائمة لمعلمات نموذج انحدار المتجه الداعم من العوامل الأساسية التي تؤثر في أداء النموذج وكفاءته إذ تمثل عملية اختيار هذه المعلمات إحدى المشكلات المهمة في تطبيقات المتجه الداعم. وقد يؤدي الاختيار غير المناسب لقيم المعلمات إلى انخفاض دقة النموذج نظرًا لاعتماد كفاءة نموذج انحدار المتجه الداعم بدرجة كبيرة على تحديد القيم المثلى لمعلمات النموذج. ولغرض الوصول إلى التركيبة المناسبة للمعلمات الثلاث يتم اختبار مجموعة من التركيبات المختلفة من خلال أخذ عينات من فضاء البحث على فترات متباعدة ثم تحدي التركيبة التي تحقق أقل قيمة للخطأ التربيعة ثم تجري عملية بحث أكثر دقة من خلال تقليل الفترة الزمنية بين نقاط أخذ العينات حول التركيبة المحددة وتكرر هذه العملية بصورة تدريجية إلى أن لا يطرأ تحسن ملحوظ في دقة التحقق من الصحة. وبناءً على ذلك يُقترح استخدام الخوارزمية الجينية الفوضوية لتحسين قيم معلمات المتجه الداعم والوصول إلى التركيبة الأكثر ملائمة التي تسهم في تحسين أداء النموذج. [16]

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

خوارزمية تحسين سرب الطيور (particle swarm optimization algorithm)

تتتمي خوارزمية تحسين سرب الطيور الى تقنيات ذكاء السرب وتستخدم في حل مسائل التحسين. وقد طورت هذه الخوارزمية عام 1995 من قبل الباحثين (Kennedy and Eberhart) وتعتمد الخوارزمية على مجموعة من الحلول العشوائية التي تعرف بالجسيمات، اذ يمتلك كل جسيم موقعًا وسرعة محددين ويمكن تحديثهما بصورة مستمرة اثناء عملية البحث. وتتحرك الجسيمات ضمن فضاء البحث بهدف الوصول الى الحل الأمثل ولذلك تعرف هذه التقنية باسم خوارزمية سرب الجسيمات. [5]

يتمثل الهدف من الخوارزمية في الوصول الى الحل الأمثل من خلال محاكاة السلوك الجماعي للطيور اثناء بحثها عن أفضل مصادر الغذاء. وتعتمد الخوارزمية في بدايتها على تهيئة عشوائية لمجموعة من الافراد تمثل عددًا من الحلول المرشحة ضمن فضاء البحث الخاص بالمشكلة ثم تجري عملية البحث بين هذه الحلول بهدف الوصول الى الحل الأمثل. [2]

تعد خوارزمية (PSO) أحد تقنيات التحسين القائمة على السكان، وقد اقترحت في الأصل لمعالجة مسائل التحسين غير المقيدة بهدف الوصول الى القيمة الدنيا لدالة الهدف. ويمكن صياغة العديد من مسائل التحسين باستخدام دالة التحسين الوظيفية على النحو الاتي: [15]

$$\min_{S, t} f(X), X = \{x_1, x_2, \dots, x_n\} \dots (4)$$

$$x_i \in [a_i, b_i], i = 1, 2, \dots, n$$

خوارزمية تحسين سرب الطيور الفوضوية (Chaotic particle swarm optimization algorithm)

استنادا الى الخوارزمية المقترحة والبحث المحلي الفوضوي تم اقتراح نهج تكراري مكون من مرحلتين، اذ تستخدم الخوارزمية المقترحة مع خوارزمية (PSO) لتحقيق الاستكشاف العالمي من خلال تحديث مواقع الجسيمات في حين تستخدم اليه البحث المحلي لأجراء بحث موجه حول الحلول الواعدة، كما توظف ديناميكيات الفوضى لتعديل أفضل الجسيمات الناتجة عن عملية البحث المحلي. بما يسهم في تحسين جودة الحلول. علاوة على ذلك تولد جسيمات جديدة بصورة عشوائية وتدمج مع افراد المجتمع الجديد بهدف الحفاظ على التنوع السكاني وتجنب الوقوع في الحلول المثلى المحلية. ولتسريع عملية التقارب نحو الحل الأمثل يتم توليد الجسيمات الجديدة بصورة ديناميكية وفقا لألية البحث المعتمدة.

تعمل خوارزمية (CPSO) على تطوير خوارزمية تحسين سرب الطيور من خلال دمجها مع نظرية الفوضى بما يسهم في تحسين قدرتها على البحث والوصول الى الحلول المثلى. ولتوليد المتغيرات الفوضوية تُستخدم المعادلة اللوجستية الاتية: [11]

$$x_{n+1} = \mu x_n (1 - x_n) \dots (5)$$

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

تحسين معلمات (SVR) استنادا الى خوارزمية (CPSO):

تتمثل الخطوات الأساسية لتحسين معلمات انحدار المتجه الداعم (SVR) باستخدام خوارزمية تحسين سرب الطيور الفوضوية (CPSO) في مجموعة من المراحل الرئيسية، ويمكن تلخيصها على النحو الاتي:

1. تهيئة متجه ثلاثي الابعاد (three – dimensional) وفقا للنظام الفوضوي مع تحديد وزن القصور الذاتي والعدد الأقصى للتكرارات وحد الخطأ الخاص بدالة اللياقة بالإضافة الى تحديد الحد الأقصى لسرعة كل جسيم.
2. تحديث أفضل حل فردي لكل جسيم، الى جانب ذلك تحديث أفضل حل أمثل تم التوصل اليه على مستوى المجموعة بأكملها.
3. اجراء عملية التحسين الفوضوي من خلال إعادة تعيين نسبة ٥٠٪ من الجسيمات ذات الأداء الأفضل الى قيم ضمن المجال [٠.١]
4. إذا اظهر الجسيم المحسن باستخدام نظرية الفوضى قيمة اعلى لدالة اللياقة فيتم اعتماد هذا الجسيم وتحديث أفضل جسيم وفقا لذلك.
5. تُعاد الخطوة (3) بصورة تكرارية ما لم يتم بلوغ الحد الأقصى المحدد لعدد التكرارات. [10]

التحليل الاحصائي:

تم الاعتماد على مجموعة بيانات حقيقية تمثل الحمل الكهربائي في المنطقة الجنوبية للفترة من (1980-2019)، اذ تتضمن المجموعة متغيرا تابعاً يتمثل في الاستهلاك السنوي للطاقة الكهربائية في المنطقة الجنوبية (ميكاواط، ساعة) الى جانب مجموعة من المتغيرات المستقلة التي يُراد قياس تأثيرها في نموذج انحدار المتجه الداعم وهي: الناتج المحلي الإجمالي بالدينار العراقي، متوسط نصيب الفرد من الدخل بالدينار العراقي، عدد المشتركين في المنطقة الجنوبية، سعر الكيلو واط / ساعة بالدينار العراقي. (kwh) ويتم اجراء التنبؤ بالاعتماد على النموذج الأفضل الناتج عن استخدام (CIA, CPSO) وذلك باستخدام برنامج (MATLAB 11.7) من خلال تقدير نموذج انحدار المتجه الداعم (SVR) والمتمثلة في (C, ϵ, σ) كما تم استخدام أسلوب (cross – Valinda) لتقسيم البيانات الى مجموعات واعتماد ثلاث طبقات ($k=3$) بهدف تقدير المعلمات واختيار النموذج الأفضل.

النموذج الأول: دمج (support vector regression) مع (chaotic genetic algorithm).

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026




This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

جدول (1) تقديرات معاملات (SVR) باستخدام خوارزمية (CGA)

المعاملات الأمثل	متوسط مربع الخطأ	نموذج التقلب
δ	0.751	2.362
C	8.321×10^3	6.236×10^5
ε	0.66	0.82
عدد المدخلات	K=3	p=1, q=2
الخطأ العشوائي الأصغر	2.951	3.362

مع



جدول (2) تقديرات معاملات (SVR) باستخدام خوارزمية (CPSO)

المعاملات الأمثل	متوسط مربع الخطأ	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


Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>



شكل (3) النتائج البيانية لنموذج انحدار المتجه الداعم مع خوارزمية تحسين سرب الطيور الفوضوية يتضح من النماذج السابقة وجود اختلاف في نتائج كل نموذج عن الآخر من حيث أسلوب تحليل البيانات وأداء النموذج، لذا يتطلب الأمر إجراء مقارنة دقيقة بين النموذجين بهدف تحديد النموذج الأفضل من حيث مستوى الدقة والكفاءة في تحليل البيانات فضلا عن تحديد المعلمات التي تحقق الأهداف المرجوة من الدراسة. وبالنظر الى النماذج المعتمدة في الدراسة يتبين ان لكل نموذج مجموعة من القيم والمؤشرات التي تعكس مدى دقته وكفاءته في تحديد المعلمات المثلى لنموذج (SVR).

معايير لدقة التنبؤ	نموذج انحدار المتجه الداعم مع خوارزمية سرب الطيور الفوضوية	نموذج انحدار المتجه الداعم مع الخوارزمية الجينية الفوضوية
MSE	6.007E11	1400000
RMSE	245091.8195	1183.216
MAE	350830.0	33.911
MAPE	1.000	0.12
SBC	2.5339	2.0578

جدول (3) معايير تقييم ومقارنة النموذجين للمفاضلة بينها

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

شكل (4) النتائج البيانية للمفاضلة بين النموذجين. تشير نتائج الجدول الى ان الخوارزمية الجينية الفوضوية تتمتع بفاعلية أكبر في تحسين معلمات نموذج انحدار المتجه الداعم، اذ حققت مستوى اعلى من دقة التنبؤ مقارنة بالطرائق الأخرى. وبناء على ذلك تم اختيار النموذج الهجين المتمثل في (SVRCGA) لما اظهره من كفاءة عالية في تحسين المعلمات ودقة التنبؤ واعتماده في التنبؤ بقيم البيانات الخاصة باستهلاك الحمل الكهربائي في المنطقة الجنوبية من العراق.

جدول (4) القيم التنبؤية المستقبلية لاستهلاك الطاقة الكهربائية للفترة (2020-2028)

السنوات	قيم التنبؤ باستهلاك الحمل الكهربائي باستخدام النموذج (CGA+SVR) بوحدة (جيجا واط/ساعة)
2020	9236057
2021	12790829
2022	16353621
2023	19568089
2024	21317833
2025	22847328
2026	22389174
2027	24915560
2028	9236057

تم اجراء التنبؤ بكميات الاستهلاك السنوي للطاقة الكهربائية في المنطقة الجنوبية للمدة من 2020 الى 2028 باستخدام النموذج الذي تم التوصل اليه (CGASVR). واطهرت النتائج تفوق النموذج على النماذج الأخرى المعتمدة في الدراسة، اذ يتضح من الجدول (3) ان نموذج انحدار المتجه الداعم (SVR) باستخدام الخوارزمية (CGA) حقق أدنى قيم لمعايير الأداء (MSE,MAPE,MAE,RMSE) مقارنة بالنماذج الأخرى. كما يوضح الجدول (4) القيم التنبؤية للحمل الكهربائي في المنطقة الجنوبية للفترة (2020-2028) والتي تشمل (البصرة، ذي قار، ميسان، المثنى).

الاستنتاجات:

1. تم دمج نموذج انحدار المتجه الداعم مع الخوارزميات التطورية الفوضوية بهدف تطوير منهجية فعالة لاختيار أفضل المعلمات وتحسين أداء نموذج انحدار المتجه الداعم.

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

2. أظهرت النتائج ان الخوارزمية الجينية الفوضوية (CGA) تتفوق في معالجة بعض أوجه القصور في الخوارزمية الجينية (GA) ولا سيما مشكلة الوقوع في الحلول المثلى المحلية (local optima) مما يعزز قدرتها على الوصول الى حلول أكثر كفاءة.
 3. استنادا الى تحقيق ادني قيمة لمعيار (SBC) الى جانب الحصول على اقل القيم وفق معايير تقييم الأداء (MSE,MAPE,MAE,RMSE) تم اجراء المفاضلة بين النموذجين واظهرت النتائج ان نموذج (CGASVR) المتمثل في دمج انحدار المتجه الداعم مع الخوارزمية الجينية الفوضوية يُعد النموذج الأفضل والأكثر كفاءة في النمذجة والتنبؤ بالحمل الكهربائي السنوي.
 4. تحسين دقة النموذج ورفع كفاءته التنبؤية بصورة ملحوظة في تقدير الحمل الكهربائي بالمنطقة الجنوبية للمدة (2020-2028) بالاعتماد على النموذج الهجين (CGASVR).
- التوصيات:**

1. اجراء دراسات مستقبلية مماثلة على مستوى المحافظات بهدف تطوير أساليب اختيار المعلمات المثلى بالاعتماد على الخوارزميات الفوضوية بما يسهم في رفع دقة النماذج وتحسين كفاءتها مع اجراء مقارنات بين المحافظات المختلفة، كما يمكن مستقبلا دراسة قوة المعايير المعتمدة وتأثيرها في اداد النماذج التنبؤية.
 2. يمكن اعتماد النموذج (CGASVR) الذي تم التوصل اليه في هذه الدراسة من قبل الجهات المعنية في التنبؤ باستهلاك الطاقة الكهربائية وإدارته، فضلا عن توظيفه في تحليل هذه الظاهرة ودراسة اتجاهاتها المستقبلية لما يتمتع به النموذج من كفاءة تنبؤية تجعله نهجا واعدا للدراسات المستقبلية في مجال استهلاك الطاقة الكهربائية.
 3. الاستفادة من نتائج هذه الدراسة في التنبؤ باستهلاك الطاقة الكهربائية في المنطقة الجنوبية للمدة (2020-2028) من قبل الجهات المعنية والمسؤولين بما يسهم في دعم عملية اعداد الخطط والسياسات المستقبلية لإدارة الطاقة وتلبية الطلب المتوقع عليها.
- المصادر العربية:**

4. البدراني، مها عبد الاله محمد (2007). "استخدام الخوارزمية الجينية في تطابق أنماط الحرف الإنكليزي"، مجلة التربية والعلم - المجلد (19) العدد (4).
5. بشير، غالبية توفيق (2018). "تقدير معممات نموذج الانحدار المبتور باستخدام خوارزميتي سرب الطيور وأشبه نيوتن"، المجلة العراقية للعلوم الإحصائية، مج. 15، ع. 27، ص. 83-106.
1. بلال، وسيم حبيب (2014). "استخدام الطرق الهجينة للمساهمة في حل مسألة توجيه المركبة"، جامعة تشرين، مجلة جامعة تشرين للبحوث والدراسات العلمية - سلسلة العلوم.

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaopenaccess.com/index.php/6>

2. عبد الجليل، إبراهيم وشاكر، أمجد (2018). "دراسة تأثير تغيير بارامترات الخوارزمية الجينية الفوضوية على الحلول الأمثلية في تصميم شبكات مياه الشرب"، مجلة جامعه حماة، المجلد الأول، العدد الثاني.
 3. محمد، صالحة رائد وصالح، إبراهيم احمد (2018). "استخدام خوارزمية أمثلية عناصر السرب لقياس جودة البرمجيات"، مجلة الراافدين لعلوم الحاسبات والرياضيات، المجلد (12)، العدد (1)، ص 26-36.
- المصادر الأجنبية:
4. akkula, V. (2003). "Tutorial on Support Vector Machine (SVM)", School of EECS, Washington State University.
 5. Chen, L.Y.; Hong, W.C.; Panigrahi, B. K.; and Wei, S.Y. (2011). SVR with Chaotic Genetic Algorithm in Taiwanese 3G Phone Demand Forecasting, Part I, pp. (248– 256), Springer-Verlag Berlin Heidelberg.
 6. 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.
 7. 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,
 8. 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, China, pp (195-200).
 9. Liu, B., Wang, L., Jin, Y. H., Tang, F. & Huang, D. X. (2005). "Improved particle swarm optimization combined with chaos", Chaos, Solitons & Fractals, vol.25, No. 5, pp (1261–1271).
 10. Liu, Y., Qiao, N., Zhao, C., Zhuang, J. & Tian, G. (2018). "Using the AR–SVR–CPSO hybrid model to forecast vibration signals in a high-speed train

Eureka Journal of Business, Economics & Innovation Studies (EJBEIS)

ISSN 2760-4950 (Online) Volume 2, Issue 9, September 2026



This article/work is licensed under CC by 4.0 Attribution

<https://eurekaoa.com/index.php/6>

transmission system", College of Engineering and Technology, Jilin Agricultural University, China, pp (2-14), Part F: Journal of Rail and Rapid Transit.

11. Manurung, A.H., Suhartono, D., Hutahayan, B. & Halimawan, N. (2016). "Probability Bankruptcy Using Support Vector Regression", Management Department, Binus Business School, Bina Nusantara University.

12. Mishra, S. & Patra, S. K. (2008). "Short Term Load Forecasting Using Neural Network Trained with Genetic Algorithm & Particle Swarm Optimization", National Institute of Technology, First International Conference on Emerging Trends in Engineering and Technology, pp (606-611).

13. Perea, P. R., Ruiz, J. C., Chaparro, D.G., Venzor, J. A. P., Carreón, A.Q. & Rosiles J.G. (2013). "Support Vector Machines for Regression: A Succinct Review of Large-Scale and Linear Programming Formulations", International Journal of Intelligence Science, Vol. 3 No. 1, pp. (5-14).

14. Wang, Y. M., Zhang, Z., Zheng, J. B., & Tong, L. L. (2014). "Chaotic Genetic Algorithm for Mixed Integer Programming Problem", Applied Mechanics and Materials ,China ,vols. 651-653, pp(2273–2277).

15. 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).