

التنبؤ للحمل الكهربائي باستخدام المنحنى الافضل والخوارزمية الجينية

م. نوال علاء الدين الجراح

الجامعة المستنصرية كلية الادارة والاقتصاد قسم الاحصاء

د. ندى الحكاك

كلية بغداد للعلوم الاقتصادية الجامعة قسم علوم الحاسبات

**Electricity Load Forecasting Using Fitting and
Genetic Algorithm**

ادارة تجهيز الطاقة الكهربائية هي مهمة صعبة واهم جزء فيها هو التنبؤ للطلب على الحمل الكهربائي للشبكة الوطنية. من خلال هذا البحث تم استخدام منحنى متعدد الحدود والخوارزمية الجينية للتنبؤ بالحمل الكهربائي. عملية توفير المنحنى المناسب لعينة من البيانات هي عملية مهمة وتعرف عادة باسم توفير المنحنى المناسب (curve fitting) والذي يحتاج الى مقاييس لقياس كفاءة هذا المنحنى ومنها مجموع مربعات الخطا SSE والجذر التربيعي لمتوسط مربعات الخطا RMSE ومعدل الانحرافات المطلقة MAE وبعد اختيار المنحنى المناسب تم استخدام الخوارزمية الجينية Genetic Programming للحصول على القيمة المثلى لهذه المعلمات Optimal Parameters وباستخدام الاسلوب المقترح تم الحصول على نتائج افضل بمقارنتها مع طرق التنبؤ الاخرى.

الكلمات المفتاحية

Curve fitting ,Genetic programming ,optimal parameters ,Fitness Function.

Abstract

In this paper Genetic Algorithm have been used to optimize the parameter of the 4th degree polynomial; which was selected as a best curve fit for the load of electricity of Iraq then use this new model to predict the electricity model . The proposed idea gave better results than the original model.

Keywords: Curve fit, Genetic Algorithm, optimize, parameters, polynomial.

المقدمة

المقصود بادارة الحمل الكهربائي هو القابلية على الموازنة ما بين التجهيز والطلب على الطاقة الكهربائية [1] وكيفية تجهيز المواطن بالطاقة الكهربائية الاكثر استقرارا ولحاجة المختصين المعنيين ببناء أنظمة الطاقة الكهربائية الخاصة بالانتاج والتوزيع الى احدث اساليب التنبؤ للوصول الى النموذج الاكثر استقرارية والى التقدير الدقيق للطلب على الحمل الكهربائي. طرق التنبؤ يمكن تصنيفها الى ثلاثة انواع وهي التنبؤ قصير المدى والتنبؤ متوسط المدى والتنبؤ بعيد المدى. النوع الاول يمثل الطلب على الحمل الكهربائي خلال الساعات القادمة اما النوع الثاني يمثل التنبؤ خلال الايام او الاسابيع القادمة والنوع الثالث يمثل التنبؤ خلال الاشهر او السنوات القادمة. وعليه فان عملية التخطيط لانتاج الطاقة الكهربائية تحتاج الى التنبؤ المتوسط والتنبؤ بعيد المدى. لاجل اتخاذ القرار المناسب حول جدولة الاستثمارات الخاصة بالانتاج وكذلك جدولة الفترات المناسبة لصيانة الشبكة الوطنية [1] وطرق التنبؤ بصورة عامة تعتمد على الطرق الاحصائية والسلاسل الزمنية المبنية على العمليات العشوائية ونماذج الانحدار الذاتي ونماذج الانحدار اللامعلمية. وكذلك تعتمد على نماذج الانظمة الخبيرة على سبيل المثال الشبكات العصبية والشبكات العصبية الدائناميكية وعليه يمكن تقسيمها الى صنفين هما الطرق الكلاسيكية مثل نماذج التمهيد الاسي ونماذج بوكس جنكز والانحدار المتعدد والمتوسطات المتحركة (ARIMA) [5] [8] والصنف الثاني هو الانظمة الخبيرة التي تعتمد على تقنية الحاسبات الالكترونية مثل الانحدار المضطرب والشبكات العصبية والخوارزمية الجينية. خلال هذا البحث تم تطبيق طريقة جديدة للتنبؤ من خلال توفير المنحنى المناسب curve fitting لبيانات الحمل الكهربائي ثم الاعتماد على الخوارزمية الجينية لتحسين معلمات المنحنى المقترح والتوصل الى القيم المثلى لهذه المعلمات Optimum estimation والمنحنى متعدد الحدود من الدرجة الرابعة 4th degree polonomial هو المنحنى الذي تم الاعتماد عليه في هذا البحث. توفير المنحنى المناسب وتحسين معلماته تم تنفيذه عن طريق استخدام برنامج ماثلاب عن طرق كتابة برنامج لتنفيذ متطلبات النموذج المقترح. تم مقارنة نتائج النموذج المقترح بنتائج نماذج التمهيد الاسي عن طريق استخدام نظام statgraph وكانت نتائج النظام المقترح افضل من نتائج تطبيق نماذج التمهيد الاسي بالاعتماد على مقياس الكفاءة RMSE .

١- نموذج التمهيد الاسي البسيط [8][5] Exponential Smoothing Method (EXP)

$$F_t = \alpha X_t + (1 - \alpha) F_{t-1} \dots\dots\dots(1)$$

حيث :

F_t : التنبؤ

X_t : الحمل الفعلي للفترة الحالية t .

F_t : التنبؤ للحمل للفترة $t-1$.

α : ثابت التسرح الاسي للبيانات.

٢- نموذج التمهيد الاسي الخطي [8][5] Holt's linear exponential method

$$F_t = \alpha X_t + (1 - \alpha)(F_{t-1} + T_{t-1}) \dots\dots\dots(2)$$

$$T_t = \beta(F_t - F_{t-1}) + (1 - \beta)T_{t-1} \dots\dots\dots(3)$$

$$F_{t+h} = F_t + hT_t \dots\dots\dots(4)$$

حيث:

α : ثابت التسرح الاسي للبيانات

β : ثابت التسريح للاتجاه العام

T_t : معلمة الاتجاه العام الخطي

٣- نموذج التمهيد الاسي الخطي [8][5] Brown's Linear Exponential Smoothing (LES)

$$F_t = \alpha X_t + (1 - \alpha) F_{t-1} \dots\dots\dots(6)$$

$$Ft_t^* = \alpha F_t + (1 - \alpha) Ft_{t-1}^* \dots\dots\dots(7)$$

حيث

Ft_t^* : التنبؤ للحمل الكهربائي

٤ - دالة خطية متعددة الحدود من الدرجة الرابعة [4][9] Linear model Poly4

$$f(x) = p1 * x^4 + p2 * x^3 + p3 * x^2 + p4 * x + p5$$

حيث :

P : ثوابت

X : الوقت

F : قيمة الدالة او التنبؤ للحمل الكهربائي

الخوارزمية الجينية (Genetic Algorithms)

الخوارزمية الجينية تم اختراعها عن طريق John Holland عام ١٩٦٠ في ولاية مشكان الامريكية وهذه الخوارزمية مبنية على نظرية التطور لدارون وكان هدفه تصميم نظم صناعية لها مميزات مشابهة للنظم الطبيعية [11][10]. كل الكائنات الحية تتألف من خلايا يوجد في كل خلية نفس مجموعة الكروموسومات chromosomes ويتألف كل كروموسوم من عدد من الجينات gene وان كل جين يرمز لصفة معينة من الكائن الحي على سبيل المثال لون العينين. ولكل جين ضمن الكروموسوم موقعه الخاص locus. اول مرحلة في عملية التكاثر ومرحلة الاختيار (selection) وهي عملية اختيار الافراد الاكثر كفاءة على اساس دالة الكفاءة (fitness function) والمرحلة الثانية هي مرحلة التصلب او التقاطع وهي عملية توليد جيل جديد من خلال تزاوج الافراد الافضل (الكروموسومات) والاجيال الجديدة احيانا تخضع للطفرة mutation وهي عملية تغيير بعض صفات الجيل الناتج من عملية التصلب بهدف تحسينه. والمرحلة الثالثة هي انتهاء الخوارزمية بالاعتماد على شرط معين. وعليه يمكن تعريف الخوارزمية الجينية على انها مجموعة من الاوامر للبحث عن الخيار الامثل لمجموعة من الحلول وقد يكون الحل الامثل يعتمد على مكاملة احد الحلول مع حل اخر. لتنفيذ الخوارزمية الجينية نحتاج: [2][10]

١- اسلوب التمثيل Encoding

٢- دالة التطابق او الكفاءة Fitness function

٣- الاختيار Selection

٤- التصلب والطفرة crossover and mutation

اسلوب التمثيل Encoding

ويتم استخدام عدة طرق لتمثيل البيانات ومنها :

• اسلوب Binary حيث يستخدم (0,1) في تمثيل الكروموسوم

chrom A = 1011001011
Chrom B = 1111110000

• اسلوب الارقام

chrom A = 1532647899
chrom B = 857723149

• التمثيل بواسطة قيم معينة مثل ارقام ، كلمات ، سلسلة من الحروف

chrom A = 1.2323
chrom B=abcdejeif

دالة التطابق او الطفرة fitness function: هي دالة تعرف مسبقا لقياس كفاءة الحل في كل محاولة .

التصلب crossover: اي اختيار موقع عشوائي من الكروموسوم الاول وتبديله مع نفس الموقع من الكروموسوم الثاني للحصول على كروموسوم حديث


Parent A= 011011
Parent B = 101100
New A = 011100
New B =101011

اذا كان النسل الجديد افضل من الاباء فيتم اهمال الاباء وجعل النسل الجديد هم الاباء .

الطفرة Mutation

هو حصول تغيير للقيمة في مواقع معينة من الكروموسوم مثلا 1 يصبح 0 وبالعكس

يمكن تمثيل خطوات الخوارزمية بالمخطط التالي: [6]



١- التنفيذ يبدأ بتوليد عينة من الحلول initial population وتكون هذه الحلول عشوائية ومن خلال تمثيل البيانات ستتولد عدة حلول .

٢- دالة الكفاءة fitness function ستقوم بقياس كفاءة الحلول لكل محاولة توليد.

٣- الاختيار selection في كل محاولة سيتم اختيار نسبة من الحلول الكفاءة لتغذية النسل القادم.

٤- التصلب crossover سيتم توليد الجيل الثاني بالاعتماد على الحلول التي تم اختيارها وسيولد منها كروموسومات افضل من الجيل السابق .

٥- عمليات التوليد اعلاه ستتكرر الى ان تنتهي او تتوقف بالاعتماد على شرط التوقف مثلا الوصول الى الحل الامثل المساوي الى دالة الهدف او قد يكون عدد مرات المحاولات generation number قد تحقق.

النموذج المقترح :

١- تم اختيار نموذج منحنى متعدد الحدود من الدرجة الرابعة والذي كان افضل نموذج بعد مقارنته مع نماذج انحدار خطية ولاخطية وكذلك بعد مقارنته ببعض نماذج السلاسل الزمنية (نماذج التمهيد الاسي) بالاعتماد على مقياس Rmse واستخدام نظام statgraph وبرنامج الماثلاب والدوال polyfit والدالة polyval

٢- تم تحسين معاملات هذ المنحنى باستخدام الخوارزمية الجينية عن طريق كتابة دالة الكفاءة fitness function باستخدام برنامج ماثلاب و كتابة العبارة التالية: [3]

$$[x \ f \ val]=ga@Load-fitness$$

حيث :

ga @Load_fitness: برنامج دالة الكفاءة المكتوب بلغة ماثلاب .

x = قيمة المتغيرات

Fval = قيمة دالة الملائمة

٣- تم استخدام المنحنى النهائي بعد تحسينه في التنبؤ للحمل الكهربائي عن طريق استخدام الدوال التالية feval, fittestype

F=fittestype(' ');

Y=feval(f, , , ,x)

والجدول (1) يبين قيمة rmse لجميع الطرق السابقة وبضمنها الطريقة المقترحة .

التطبيق العملي

١- تم التوصل الى ان نموذج الانحدار الخطي متعدد الحدود ومن الدرجة الرابعة هو الافضل بعد مقارنته مع نماذج الانحدار الخطية المتعددة الحدود من الدرجة الثانية والثالثة والخامسة بالاعتماد على مقياس RMSE (الجذر التربيعي لمعدل مربعات الخطأ) وكذلك بعد مقارنته مع نماذج التنبؤ للسلاسل الزمنية وبالاخص نماذج التمهيد الاسي كما هو مبين في جدول (٢) حيث كان مقياس RMSE لهذا النموذج يساوي 569.3 ، $R^2=0.94$ كما هو مبين في الشكل (١) والشكل (٢) والشكل (٣) وكما هو مبين في الجدول (٢) .

٢- تم تحسين معاملات النموذج الافضل باستخدام الخوارزمية الجينية كما هو مبين في الشكل (٤) والشكل (٥) والشكل (٦) والشكل (٧) وكان معامل RMSE يساوي 563.35 وبعد محاولات عديدة تتضمن تغيير بعض المعاملات للخوارزمية حيث كان مايلي:

Population = 500

Scaling function = shift linear


Selection = Reminder Function

Crossover Fraction =0.7


Crossover Function = Single Point

Generation =100

Best=563.3578=RMSE




شكل (١) : اختبار نموذج متعدد الحدود من الدرجة الرابعة




شكل (٢) : النموذج الافضل قبل تحسين معالم النموذج

جدول (١) : جدول يمثل المشاهدات الحقيقية والتنبؤ بالمنحنى الافضل والمنحنى المحسن



شكل (٣) : القيم الاصلية للحمل مع القيم المتنبأ بها باستخدام نموذج متعدد الحدود



شكل (٤) : استخدام الخوارزمية الجينية لتحسين معالم النموذج

File Help

Prob: Show Quick Reference
Solv: Optimization Tool Help
Prob: About Optimization Toolbox

Fitness function: @load_fitness
Number of variables: 5

Constraints:
Linear inequalities: A: b:
Linear equalities: Aeq: beq:
Bounds: Lower: 0.1086,-17.2468,-1500.0,4000 Upper: 0.3702,-3.3,264.73,24.7000
Nonlinear constraint function:

Run solver and view results
☒ Use random states from previous run
Start Pause Stop

Current iteration: 51 Clear Results

Objective function value: 839.2982691153562
Optimization terminated: average change in the fitness value less than options.TolFun.
Optimization running.
Optimization terminated.
Objective function value: 562.0495437511136
Optimization terminated: average change in the fitness value less than options.TolFun.

Final point:

1	2	3	4	5
0.109	3.301	27.214	3.705	4.595.448

Options

Population
Population type: Double Vector
Population size: Use default: 20
Specify:
Creation function: Use constraint dependent default


Initial population: Use default: []
Specify:
Initial scores: Use default: []
Specify:
Initial range: Use default: [0,1]
Specify:

Fitness scaling
Scaling function: Rank


Selection
Selection function: Stochastic uniform

Reproduction
File count: Use default: ?

شكل (٥) : كيفية استخدام الخوارزمية الجينية لتحسين معلمات نموذج متعدد الحدود



شكل (٦) : القيم الحقيقية والقيم المتنبأ بها باستخدام النموذج المقترح



شكل (٧) : القيم الحقيقية والقيم المتنبأ بها باستخدام نموذج متعدد الحدود قبل وبعد التحسين

RMSE	Model
898.305	ponential smoothing with alpha = 0.9999
849.31	linear exp. smoothing with alpha = 0.5679
854.034	ar exp. smoothing with alpha = 0.9999 and beta = 0.1407
1490	
1011	
730.5	
569	al4
563.35	nomial

جدول (٢) : جدول مقارنة ما بين النماذج المستخدمة بالاعتماد على مقياس RMSE

النتائج: تم اجراء تحسين بسيط على نموذج متعدد الحدود ولكن في التنبؤ فان مثل هذا التحسين يؤثر على القرارات المتخذة بشأن أنتاج الطاقة الكهربائية.

التوصيات: نوصي باجراء تجارب على نماذج اخرى ثم تحسينها باستخدام الخوارزمية الجينية مع اجراء عدة محاولات تتضمن تغيير فيما يخص نسب التصلاب او التقاطع والطفرة وحجم المجتمع والكروموسومات الابتدائية لبدأ التجربة للحصول على نتائج افضل

المصادر

- [1] Karabulut, K., Alkan, A. and Yilmaz, A.S., 2008. Long term energy consumption forecasting using genetic programming. Mathematical and Computational Applications, 13(2), pp.71-80.
- [2] Farahat, M.A. and Talaat, M., 2012. Short-Term Load Forecasting Using Curve Fitting Prediction Optimized by Genetic Algorithms. International Journal of Energy Engineering, 2(2),
- [3] Samanta, S., 2014. Genetic algorithm: an approach for optimization (using MATLAB). International Journal of Latest Trends in Engineering and Technology (IJLTET), 1(3), pp.261-267.
- [4] Behera, R., Pati, B.B., Panigrahi, B.P. and Misra, S., 2012. An application of genetic programming for power system planning and operation. Int. J. Control Syst. Instrum, 3(2).
- [5] Feng, G., Chen-Yu, L., Bin, Z. and Su-Qin, Z., 2012, October. Spares Consumption Combination Forecasting Based on Genetic Algorithm and Exponential Smoothing Method. In Computational Intelligence and Design (ISCID), 2012 Fifth International Symposium on (Vol. 2, pp. 198-201). IEEE.
- [6] Xue, B., Geng, J., Zheng, Y. and Li, J., 2013, October. Application of genetic algorithm to middle-long term optimal combination power load forecast. In TENCON 2013-2013 IEEE Region 10 Conference (31194) (pp. 1-4). IEEE.
- [7] Jakarta. Ismail, Z., (2008). A decision support system for improving forecast using genetic algorithm and tabu search, ARPN Journal of Engineering and Applied Sciences, vol.3, no.3.
- [8] Makridakis, S., Wheelwright, S.C. and Hyndman, R.J., 2008. Forecasting methods and applications. John Wiley & Sons.
- [9] Ya-lun Chou, 1975, Statistical Analysis, Second Edition, Holt Rinehart Winstor.

[10] الحمادي علاء حسين ، ٢٠٠٨ ، تنقيب البيانات Data Mining ، مكتبة الجامعة ، اثناء للنشر والتوزيع.

[11] جهاد عفيفي ، ٢٠١٥ ، الذكاء الاصطناعي والانتظمة الخبيرة ، الطبعة العربية ، دار امجد للنشر والتوزيع.