

استخدام الخوارزميات الجينية المتوازية للكشف عن البيانات المتطرفة حسب مقياس BIC

شهيلة عبدالوهاب عبدالقادر

قسم أنظمة الحاسوب، المعهد التقني، الموصل، العراق

(تاريخ الاستلام: 8 / 6 / 2011 ---- تاريخ القبول: 2 / 4 / 2012)

المخلص

الخوارزمية الجينية هي إحدى تقنيات البحث الذكي التي تستخدم لإيجاد حلول تقريبية للمسائل التي تتطلب حلولاً أمثلية. الهدف من هذا البحث استخدام الخوارزميات الجينية المتوازية بتقنية المدير/العامل (Manager/Worker) في حاسبات متوازية وبدالة معيار المعلومات بايزي (Bayesian Information Criterion (BIC)) للكشف عن البيانات المتطرفة في نماذج الانحدار الخطي المتعدد. تم استخدام بيانات الأرصاد الجوية من درجات الحرارة اليومية والإشعاع الشمسي وسرعة الرياح واليوم من السنة لغرض تهيئتها لبناء نموذج تنبؤي لنسبة التبخر اليومي للأراضي المزروعة في مدينة الموصل للأعوام 1999-2001. أظهرت النتائج أن دالة معيار المعلومات بايزي BIC كدالة لياقة في الخوارزمية الجينية المتوازية ذات كفاءة عالية في الكشف عن البيانات المتطرفة وبأقل أخطاء ممكنة حيث وصلت نسبة تقليل الأخطاء ما يقارب 98%. كما أظهرت الدراسة أن لعوامل الخوارزمية الجينية (الانتخاب، الطفرة، العبور، الأجيال) تأثيراً واضحاً في تقليل تلك الأخطاء، وأن تقنية المدير /العامل في حاسبات متوازية التي تعمل بخوادم الحاسبات الموزعة ذات كفاءة في زيادة السرعة في هذا النوع من الخوارزميات الجينية الذكية. تم استخدام نموذج الانحدار الخطي المتعدد لتقييم النتائج واستخدم مقياس معامل التحديد المعدل Adjusted R Square في الحكم على النتائج، حيث كانت قيمة معامل التحديد المعدل 0.732 قبل اكتشاف البيانات المتطرفة وازدادت إلى 0.974 بعد اكتشاف البيانات المتطرفة.

الكلمات المفتاحية: الخوارزمية الجينية المتوازية، البيانات المتطرفة، معيار المعلومات بايزي، المدير/العامل.

1- المقدمة

الوراثة Inheritance والتزاوج Crossover والطفرات Mutations والاختيار الطبيعي Natural Selection، وبالتالي فهي شبيهة بعملية تطورا لأجيال واختيار أفضل الأفراد من كل جيل التي تحدث بشكل طبيعي عند الكائنات الحية، حيث من المعلوم أن مبدأ البقاء للأفضل (هو المبدأ طبعياً) وهو المبدأ الذي تعتمد عليه الخوارزمية الجينية في حل المسائل التي تتطلب حلاً أمثلياً [1] Ishibuchi وآخرون [10] اقترحوا خوارزمية جينية للكشف عن البيانات المتطرفة لمجاميع بيانية في تصنيف الأنماط. باستخدام معيار المعلومات بايزي (BIC) [11].

الهدف من هذه الدراسة سرعة الكشف عن البيانات المتطرفة في نماذج الانحدار الخطي المتعدد باستخدام الخوارزميات الجينية المتوازية بدالة معيار المعلومات بايزي BIC في حاسبات متوازية باستخدام بيانات الأرصاد الجوية لأيام السنة من درجات الحرارة والإشعاع الشمسي وسرعة الرياح ونسبة التبخر في مدينة الموصل /العراق. مابقى من البحث هو كما يلي: القسم الثاني يتضمن تفاصيل عن الطريقة المستخدمة في البحث. القسم الثالث يشرح المواد ومنهجية البحث المقترحة. القسم الرابع النتائج ومناقشتها. القسم الخامس الاستنتاجات.

2- الخوارزمية الجينية المتوازية للكشف عن البيانات المتطرفة

لتوضيح اكتشاف البيانات المتطرفة في نماذج الانحدار الخطي المتعدد باستخدام الخوارزميات الجينية المتوازية وبدالة معيار المعلومات بايزي في هذا القسم تكون كالآتي:-

الانحدار الخطي المتعدد هو واحد من الطرق الإحصائية الشائعة لتحليل البيانات وفهم الصفات الأساسية للبيانات. مع ذلك، هناك صعوبات كثيرة تواجه تحليل البيانات منها اكتشافها وإلغاء البيانات المتطرفة من البيانات الحقيقية. والبيانات المتطرفة هي بيانات خارجة عن نطاق البيانات الحقيقية لاي دراسة [1][4]. تحليل الانحدار الخطي المتعدد يواجه مشكلة البيانات المتطرفة التي تؤثر بشدة على نموذج الانحدار، وخاصة عند استخدام معيار تقدير المربعات الأقل (Ordinary Least Square) OLS. لذا عند تحليل البيانات وبناء النماذج يتم أولاً معالجة البيانات للكشف عن البيانات المتطرفة، وإزالتها ثم إعادة صياغة النماذج من البيانات الجديدة [2][7]. لاحظ الباحثين أن البيانات المتطرفة تؤثر بصورة مباشرة على نتائج التحليل الإحصائي وتجعله أقل فائدة لذلك استخدم العديد من الطرق الإحصائية التقليدية مثل studentized residual, Cook's distance, Dffits, diagonal elements في تعريف البيانات المتطرفة من خلال اكتشافها ومعالجتها [6][11][12][13]. لكن تلك الطرق الإحصائية لا تستطيع دائماً إيجاد القيم المتطرفة. لذلك قام آخرون بحل مشكلة البيانات المتطرفة في نماذج الانحدار الخطي المتعدد وزاتها باستخدام الخوارزمية الجينية [3][1][15]. الخوارزمية الجينية هي إحدى تقنيات البحث الذكي التي تستخدم لإيجاد حلول تقريبية للمسائل التي تتطلب حلولاً أمثلية، والتي يتطلب إيجادها وقتاً طويلاً وفق تقنيات البرمجة التقليدية تعتمد الخوارزميات الجينية على تقنيات مستوحاة من التطور الطبيعي للأجيال في الكائنات الحية Evolutionary Biology، حيث تستخدم تقنيات

المكونة من عدد ثابت، k عدد المتغيرات المستقلة، m_d عدد المتغيرات الزائفة المتطرفة (outlier dummy). عموماً النموذج الجيد يمتلك أخطاء قليلة بأقل معلمات، وبأفضل قيمة صغرى للدالة (BIC) [2]. إن مشكلة استخدام BIC لاكتشاف البيانات المتطرفة تميل في بعض الأحيان إلى تضمين بيانات زائفة متطرفة غير ضرورية ولحل هذه المشكلة يمكن أخذ معيار إضافي في هذه الطريقة باستخدام κ ($\kappa > 1$) للبيانات الزائفة. وحسب المعادلة (6):

$$BIC' = \log(\sigma^2) + (1+k) \log(N) / N + \kappa m_d \log(N) / N \dots\dots(6)$$

2-2 الخوارزميات الجينية لاكتشاف البيانات المتطرفة

الخوارزمية الجينية هي تقنيات بحث تستخدم لإيجاد الحلول الحقيقية والتقريبية في مشاكل البحث. حيث يتم فيها توصيف المشكلة لتمثيل الصبغيات Chromosomes الممثلة للحلول بوحدة من طرق الترميز. بعد ذلك تطبق مجموعة من العمليات الرياضية المستنبطة من العمليات البيولوجية كالعنبر، التوارث، الاختيار، التزاوج والطفرة للحصول في نهاية المطاف على مجموعة من الصبغيات التي تمثل الجيل النهائي وكل صبغى هو فرد من افراد الجيل، وأفضل صبغى هو الحل الأمثل الذي تبحث عنه المشكلة المطروحة. اذا، تبدأ عملية البحث انطلاقاً من مجموعة حلول وليس حل واحد [9][1]. الحلول ممثلة بصيغة ثنائية (1,0) لكل الاحتمالات الممكنة للمسألة، والجيل الأول يبدأ بتوليد جيل عشوائي لكل الصبغيات لتمثيل مساحة الحل، اما الجيل الجديد يتكون من تقييم كل فرد في الجيل القديم حسب دالة اللياقة استخدمت هذه الطريقة في اكتشاف البيانات المتطرفة في نموذج الانحدار الخطي المتعدد، والخوارزمية الجينية مكونة من الآتي:

• تشفير المعلمات Parameter Encoding: تشفير المعلمات (الصبغيات) على شكل متجه ثنائي (d) ، $(d_1, d_2, \dots, d_N)$ ، حيث ان $d_i = 0$ تشير الى ان البيان غير متطرف، $d_i = 1$ تشير الى ان البيان متطرف، لكل $i=1, \dots, N$. وهيكلية الصبغيات المتطرفة في الجيل تكون مكونة من الصبغيات P ، حيث ان عدد البيانات المتطرفة $P=1, \dots, N$ (O_p)، على سبيل المثال: عدد البيانات المتطرفة $p=3$: الاول، الثاني، $N-1$ كما في الشكل (1) الذي يوضح هيكلية الصبغيات في الخوارزمية الجينية:

	d_1	d_2	d_3	...	d_{N-1}	d_N
$d =$	1	1	0	...	1	0
	O_1	O_2	...		O_p	

الشكل رقم (1): هيكلية الصبغيات في الخوارزمية الجينية

1-2 البيانات المتطرفة في نماذج الانحدار المتعدد :

ان نموذج لانحدار الخطي المتعدد يهتم بتقدير العلاقة بين متغير كمي وهو المتغير التابع والعديد من المتغيرات الكمية هي المتغيرات المستقلة [7] وحسب المعادلة (1):

$$Y = B_0 + B_1X_1 + B_2X_2 + \dots + B_kX_k + U \dots\dots(1)$$

حيث ان Y المتغير التابع، X المتغيرات المستقلة للنموذج، B_0 حد ثابت، B المعالم المطلوب تقديرها في النموذج، U الأخطاء العشوائية. وبما ان المعادلة رقم (1) هي العلاقة الحقيقية المجهولة والمراد تقديرها باستخدام الإحصاءات المتوفرة عن المتغير التابع والمتغيرات المستقلة فانه يستوجب تحقق الفروض الأساسية التالية الخاصة بـ U وحسب المعادلة (2):

$$U \sim N(0, \sigma^2 Ln) \dots\dots\dots(2)$$

والتي تعني ان U يتوزع توزيعاً طبيعياً لمتجه وسطه الحسابي μ صغرى (0) ومصروفة تباين هي $\sigma^2 Ln$ ، ويمكن استخدام طريقة معيار تقدير المربعات الاقل OLS في تقدير معلمات النموذج الخطي المتعدد لذلك يمكن كتابة المعادلة (1) بصيغة المعادلة (3):

$$\hat{Y} = B'_0 + B'_1X_1 + B'_2X_2 + \dots + B'_kX_k + U \dots\dots(3)$$

ولما كان هدفنا الحصول على قيم (B') التي تجعل مجموع مربعات الانحرافات اقل ما يمكن، يمكن تصغير القيمة مبدا (المربعات الصغرى) الى اقل قيمة ممكنة، حسب المعادلة (4):

$$\text{Min } \sum e_i^2 = \sum (Y - \hat{Y})^2 \dots\dots(4)$$

ان الضرر الأساسي لطريقة OLS على الأداء وجود أخطاء (e) لاترضى بالفرضيات التقليدية. وواحدة من اهم الأخطاء الشائعة في التوزيع الطبيعي للبيانات هو احتوائها على واحدة او اكثر من البيانات المتطرفة [7][8].

فرضت البيانات المتطرفة على شكل متغيرات زائفة Dummy variables. المتغيرات الزائفة هي جزء من المتجه $(N*1)$ حيث ان N عدد بيانات نموذج لاختبار الكلية للمعادلة (1). البيانات الكلية تم تشفيرها باستخدام $(1, 0)$ ، حيث تكون قيمتها (1) في حالة البيانات الزائفة، وقيمتها (0) في حالة البيانات الحقيقية غير الزائفة، والمتغير الزائف يكافئ اكتشاف القيمة المتطرفة. والطريقة المقترحة من قبل Schwarz [14]، والتي تعرف بمعيار المعلمات بايزيا (BIC) تستخدم لاكتشاف البيانات المتطرفة في نماذج الانحدار الخطي المتعدد والتي يمكن حسابها من المعادلة (5):

$$BIC = \log(\sigma^2) + m \log(N) / N \dots\dots(5)$$

حيث ان $\sigma^2 = (e'e) / (N-K-1)$ ، التباين في النموذج المخمن، $m = 1 + k + m_d$ ، تمثل مجموع المعلمات في النموذج المخمن،

• حجم الجيل Population size : يقصد به عدد الأفراد ضمن الجيل وهو من العوامل المهمة والتي يتوقف عليها أداء الخوارزمية.

N : عدد أفراد الجيل.

تتم طريقة الانتخاب بإدارة العجلة بشكل عشوائي وانتظار وقوف العجلة عند مؤشراً،

ويؤخذ الفرد الذي أشار إليه المؤشر. فكلما زاد عدد قطاعاته زادت درجة لياقته ومن ثم زاد احتمال انتخاب هذا الفرد وهذا يعني دخوله في الجيل الخلف وتأثيره الإيجابي في هذا الجيل على أقل تقدير. [1]

• **العبور Crossover:** عملية العبور من العمليات المهمة في الخوارزميات الجينية فالمعتقد السائد هو أن التزاوج بين أفراد يتمتعون بمواصفات جيدة سوف ينتج عنهما أفراد يتمتعون بمواصفات جيدة على أقل تقدير. ومن ثم يتم انتخاب الأفراد ذوي مقياس اللياقة الجيد بعد ذلك تنفذ عملية مزج عشوائي Shuffling للتخلص قدر الإمكان من إجراء العبور بين الفرد ونفسه والنتائج عن احتمال تكرار الفرد أكثر من مرة بشكل متتالي. نتيجة عملية الانتخاب التي تسبق العبور. أيضاً تتم عملية العبور باحتمال العبور لكل فرد ضمن الجيل، فبعد عملية المزج العشوائي لأفراد الجيل تتم عملية العبور بين الفرد والذي يليه باستخدام إحدى طرائق العبور كالعبور المنقوص أو نقطة البسيط المستخدمة في هذه الدراسة (Simple n-point Crossover) وحسب الشكل (2) الذي يوضح كيفية تطبيق العبور من نوع نقطة البسيط -2 على صيغتين متتاليتين من جيل الآباء وفق القيم العشوائية لقيمة العبور = 2، وقيمة العبور = 6.

لذلك فإن زيادة حجم الجيل سوف يقلل من الخطأ المرتقب في النتيجة. أيضاً هناك مشكلة عند كون حجم الجيل صغيراً إذ تنخفض دقة النتائج بشكل ملحوظ، لأنه لن يشمل كامل المجال المدروس بشكل جيد.

• **دالة اللياقة Fitness Function:** سلسلة الصبغيات المكونة للجيل القديم من البيانات المتطرفة وغير المتطرفة تتغير إلى الجيل الجديد اعتماداً على دالة اللياقة 'BIC' في المعادلة (6).

• **عدد تكرار الأجيال Generation:** كل تكرار للخوارزمية يعني الحصول على جيل جديد من الأبناء وفقاً لمبدأ داروين في الوراثة الذي ينص على أن البقاء للأصلح وأن جيل الأبناء عمومياً يكون أكثر تكيفاً مع الظروف البيئية الجديدة بسبب فناء الأفراد الأقل تكيفاً. فكلما زاد عدد الأجيال فإن الحلول الأقرب للحل الأمثل سوف تحافظ على نفسها على أقل تقدير في الأجيال اللاحقة.

• **الاختيار وفق مبدأ العجلة المتحركة Roulette Wheel Selection:** لمحاكاة هذه الطريقة تعتبر وجود عجلة تم تقسيمها إلى 100 قطاعاً. أعرف أفراد الجيل على هذه القطاعات وفقاً لمتوسط احتمالية الانتخاب لكل فرد من أفراد الجيل الحالي والذي يعطى رياضياً بالمعادلة (7):

$$P_{\text{select}}(i) = \frac{F_i}{\sum_{j=1}^N F_j} \quad \dots\dots 7$$

حيث:

Pselect(i): احتمالية انتخاب الفرد i

Fi: درجة ملائمة الفرد i

قيمة نقطة العبور		1	2	3	4	5	6	7	8
جيل الآباء	Chromosome 1	1	1	0	1	1	1	1	0
	Chromosome 2	0	0	0	0	1	0	0	1
		↓	↓↑	↓↑	↓↑	↓↑	↓↑	↓	↓
جيل الأبناء	Chromosome 1	1	0	0	0	1	0	1	0
	Chromosome 2	0	1	0	1	1	1	0	1

الشكل رقم (2): عبور نقطة البسيط -2


الخوارزمية الجينية تتطلب وقت طويلاً لتنفيذها لكن في تقنيات الحاسوب الحديث تم التغلب على طول الوقت بتنفيذ هذا النوع من الخوارزميات في حاسبات متوازية الهدف منه الحصول على الحل الأمثل بسرعة عالية. الخوارزمية الجينية المتوازية طبقت على أساس المدير/العامل Manager/Worker بعدة حاسبات، حاسبة رئيسية تعتبر المدير، و N من الحاسبات الطرفية كعمال، الموضحة بالشكل (3). المدير يعمل على تأسيس الاتصال مع العمال من خلال إرسال إشارة الاتصال، ثم يقوم بتوليد صبغيات الجيل الابتدائي عشوائياً وتوزيعها على العمال بالتساوي، تهيئة متطلبات الخوارزمية الجينية وتوزيعها على العمال Worker-N. أيضاً يقوم المدير باستلام النتائج من كل عامل لإعادة تمثيلها عشوائياً ليتسنى تكرار تلك العمليات،

• **الطفرة Mutation:** هي المرحلة الأخيرة من سلسلة العمليات التكرارية التي تسهم بشكل جيد في الوصول إلى الحل الأمثل بسرعة وهي مستمدة من كون الخوارزميات الجينية قراءاً من تقنيات البحث العشوائي عن الحل الأمثل ومن ثم فإن حدوث تغيير مفاجئ (عشوائي) وغير متوقع في الجيل ولو كان باحتمال حدوث طفيف سوف يكون له الأثر الإيجابي في الاقتراب من الحل الأمثل، فعند استخدام طريقة الترميز الثنائي تكون الطفرة عبارة عن عكس إحدى المورثات ضمن الصبغي أي من الصفر إلى الواحد أو العكس، واحتمال حدوث هذا التغير يعرف باحتمال الطفرة (Pm) probability of Mutation حيث يتم اختياره بقيمة متكيفية. [15]

2-3 الخوارزمية الجينية المتوازية

الجزئية الى المدير، العمليات تكرر لكل عامل مع كل إرسال من المدير إلى أن يستلم إشارة بإنهاء الاتصال بعد الوصول إلى الحل الأمثل النهائي [5][3]. والنظام المقترح للخوارزمية الجينية المتوازية (PGA) يوضح في الشكل (4).

إرسال إشارة لإنهاء الاتصال مع كل العمال بعد الحصول على الحل الأمثل النهائي. أما العمال N ، يقوم كل عامل من البداية باستلام الإشارة من المدير لتأسيس الاتصال والانتظار لحين البدء بإرسال متطلبات الخوارزمية الجينية ، وجزء من الصبغيات الكلية لتنفيذ الخوارزمية بدالة اللياقة 'BIC' ، ومن ثم إرسال ناتج الخوارزمية



الشكل (3) الخوارزمية الجينية المتوازية

استحداث قيد بكل متطلبات -----ga)options = gaoptimset(@

الخوارزمية الجينية

Option.UseParallel='Always'

Option.PopulationSize=1000

Option.Generations= 50

Option.CrossoverFraction=0.0.01

Initial Population : option.population= Rand (population)

Create M-file for (Fitness):

[BIC]=function Fitness(N, K, σ , md)

BIC=Log(σ^2)+(1+ k) log (N) / N+ κ * md* log(N) / N

End

[Repeat Until Termination Condition is satisfied Do]

spmd (Instruction of Single programming multiple data)

D = codistributed(population,option);

worker 1: This lab stores D(:,1:250).

worker 2: This lab stores D(:,251:500).

worker 3: This lab stores D(:,501:750).

worker 4: This lab stores D(:,751:1000).

FitnessResult= codistributed (Fitness);

[option] = ga(Fitness,options)

End

[Replace] Use new generation population and look for minimum of BIC'

[Test] If the final condition is satisfied on BIC'

Stop, and return to best

solution in current population.

[Loop] Go to [Repeat Until]

3- مواد البحث وطرائقه :

وفقا لما تقدم في المقطع الثاني ، تم استخدام بيانات الأرصاد الجوية من درجات الحرارة اليومية ، الإشعاع الشمسي ، سرعة الرياح ، اليوم من السنة ونسبة التبخر اليومي للأراضي المزروعة في مدينة الموصل للأعوام 1999-2001 للكشف عن البيانات المتطرفة في نموذج الاتحاد الخطي المتعدد. تم استخدام بيانات الجدول رقم (1) في تمثيل نموذج الخوارزمية الجينية المتوازية .

كما استخدمت MATLAB Distributed Computing Server (MDCS) المعروفة بخوادم الحاسبات الموزعة والموجودة في MatlabR2010b وتأسيسها على مجموعة حاسبات. واستخدام تقنية المدير/العامل Manager/Worker ، حيث ربطت 5 حاسبات ، (المدير الذي يعمل على إدارة العمل كحاسبة Server خادم ، العمال Worker-N الذين يعملون كحاسبات طرفية وهنا عدد الحاسبات Worker-N=4. وتم تأسيس الاتصال بين المدير والعمال مع


تنفيذ الخوارزمية الجينية فيها حسب الخطوات التالية:

- 1- Install the MDCE Service on all computers
- 2- In Dos for the Folder Matlab execute instructions:
Matlabroot2010b\distcomp\bin\Mdce install
Matlabroot2010b\distcomp\bin\Mdce start
Matlabroot2010b\distcomp\bin\admincenter.bat
- 3- In admincenter: Create Job Manager : Jm1, Worker (1 – 4)
- 4- In Matlab: matlab pool open local Jm1 فتح الاتصال [Initialize GA] :

الجدول رقم (1) بيانات نموذج الخوارزمية الجينية المتوازية

حجم البيانات N= 1000	
50	عد الاجيال
1000	حجم افراد الجيل الكلي المولد في المدير Manager
250	حجم الجيل المستلم لكل عامل Worker
BIC'	دالة اللياقة
1	العبور
0,01	الطفرة

MDCS Cluster




الشكل (4) مخطط النظام المقترح PGA للكشف عن البيانات المتطرفة حسب مقياس BIC'

4- مناقشة النتائج:


تشير النتائج التي تم الحصول عليها ان تطبيق الخوارزمية الجينية المتوازنة لها تأثير في الكشف عن البيانات المتطرفة في نماذج الانحدار الخطي المتعدد. تبين ذلك من خلال استخدام بيانات الأرصاد الجوية من درجات الحرارة اليومية، الإشعاع الشمسي، وسرعة الرياح لاي يوم من السنة كمستغيرات مستقلة (X)، ونسبة التبخر اليومي للأراضي المزروعة كمستغير تابع (Y) لثلاث سنوات بما يعادل 1000 عينة، وقيمة $K=4$ (عدد المتغيرات المستقلة).

فعند تحليل البيانات احصائيا باستخدام نموذج الانحدار الخطي المتعدد تبين ان قيمة معامل التحديد المعدل تصل الى 0.732 وهي قيمة مقبولة احصائيا والتي جاءت من العلاقة الخطية بين المتغيرات المستقلة والمتغير التابع. ازدادت قيمة معامل التحديد المعدل بعد تطبيق الخوارزمية الجينية المتوازنة واستخراج القيم المتطرفة من البيانات الأصلية حيث كانت مساوية لـ 0.974 .

يلاحظ من زيادة قيمة معامل التحديد ان البيانات المستخدمة في تحليل الانحدار المتعدد حصلت على تصحيح بنسبة عالية جدا من خلال الكشف عن البيانات المتطرفة باستخدام الخوارزمية الجينية المتوازنة. فبعد إجراء التجارب على البيانات المستخدمة وبواقع 50 عملية تكرار كإرسال من المدير الى العمال وقيمة $Kappa (\kappa)=4$ تم الكشف عن وجود بيانات متطرفة بقيمة معيارية BIC' مساوية (-6.6037) وبواقع (12) عينة في المواقع (937,801,714,646,567,547,395,378,346,272,126,75) من حجم البيانات الكلية يوضحها الشكل (5) والموضحة بدائرة ضمن البيانات الكلية التي كانت ضمن التوزيع الطبيعي للبيانات والمحصورة بين $(\mu + 3\sigma)$ و $(\mu - 3\sigma)$ وضحها الشكل (6). تم إلغاء البيانات المتطرفة من البيانات الأصلية ليصبح حجم العينة الجديد 988 عينة وعند إعادة التجارب وبنفس التكرار عليها لم يكتشف أي حالة أخرى من البيانات المتطرفة.




الشكل رقم (5) يوضح البيانات المتطرفة في البيانات الكلية



الشكل رقم (6) يوضح البيانات المتطرفة ضمن التوزيع الطبيعي للبيانات


أما من ناحية قيمة $Kappa (\kappa)$ تبين أن لها تأثير كبير على تصحيح البيانات من خلال التباين في اكتشاف البيانات المتطرفة فعندما كانت قيمتها = 1 أو 2 كانت هناك كشف عن حالات قليلة من البيانات المتطرفة تراوحت بين (2-5)، لكن مع زيادة قيمة $Kappa (\kappa)=3$ كان هناك زيادة في اكتشاف البيانات المتطرفة وصلت إلى (7) حالات. لكن عندما كانت قيمة $Kappa (\kappa)=4$ كانت هناك زيادة ملحوظة في الكشف عن البيانات المتطرفة وصلت إلى (12) حالة وبأقل قيمة لدالة اللياقة BIC' والتي يوضحها الشكل (6). من جهة أخرى، احتمال الطفرة كان له تأثير إيجابي في سرعة الوصول إلى الحل وبخطوة صغيرة كانت احتمالية الطفرة مساوية

حيث يمثل $Pm = [0 : 0.01 : 1]$ التي يوضحها الشكل رقم (7). حيث يمثل المحور الشاقولي قيمة دالة اللياقة BIC' ضمن مجال الحل لها في حين يمثل المحور الأفقي احتمال حدوث الطفرة، كانت النتيجة تتأرجح حول قيمة (-6.6037) التي تم الحصول عليها أي أن أعظم خطأ لا يتجاوز 0.06 وهذه نتيجة جيدة. ونتيجة التكرار المستمر للبرنامج تم الحصول على نتائج متشابهة بشكل كبير وخاصة فيما يتعلق بكون الخطأ ضئيل عند كون احتمال الطفرة ضمن نفس المجال وأن أكبر خطأ هو عندما كانت الطفرة باحتمالية مساوية للصفر



الشكل رقم (7) تأثير احتمال الطفرة في نتيجة الحل


ولغرض بيان تأثير احتمالية الطفرة تم تقسيم قيم احتمالية الطفرة إلى عشرة مجالات متساوية ومتدرجة، إيجاد المتوسط الحسابي للنتائج التي تم الحصول عليها، مع إيجاد الخطأ النسبي لكل مجال، لوحظ ما يؤكد



الشكل (8) الخطأ النسبي مع تغير مجال احتمال الطفرة

خاصة بعد زيادته عن حد معين. وإن عدد مرات التكرار عندما يكون صغيراً يزيد من الخطأ بشكل ملحوظ وهذا ما يوضحه الجزء الثاني من الشكل (9) حيث تم تقسيم حجم الجيل إلى عشرين مجالاً، لذلك كان أفضل وأسرع تكرار للخوارزمية المتوازية عندما 50 جيل والموضح في الجزء الثالث من الشكل (9).

أما عدد الأجيال في الخوارزمية الجينية المتوازية كان له تأثير في سرعة الوصول إلى الحل الأمثل، حيث لوحظ أن الحلول الأقرب للحل الأمثل سوف تحافظ على نفسها بأقل تقدير في الأجيال اللاحقة فكانت النتيجة تتأرجح حول قيمة (-6.6037) بعد تكرار يتراوح بين (100-200) جيل أي أن الخطأ لا يتجاوز 0.04 وهذا ما يوضحه الجزء الأول من الشكل (9). كما لوحظ أن زيادة عدد مرات التكرار يقلل من الخطأ



الشكل رقم (9) تأثير عدد مرات تكرار الخوارزمية في نتيجة الحل

كفاءة هذه الطريقة حيث وصلت قيمة معامل التحديد المعدل الى 0.732 قبل اكتشاف البيانات المتطرفة في حين وصلت قيمة المعامل الى 0.974 بعد اكتشاف كافة البيانات المتطرفة. اوصي باستخدام تلك البيانات لبناء نموذج تنبؤي باستخدام الشبكات العصبية الاصطناعية. استخدام الخوارزميات الجينية المتوازنة في الكشف عن البيانات المتطرفة قبل بناء نماذج الانحدار المتعدد. استخدام التقنية المتوازنة في ايجاد الحلول لاي مشكلة اذا كان عامل السرعة مهم لحلها.

4- الاستنتاجات والتوصيات

الخوارزميات الجينية المتوازنة أثبتت نجاحها للوصول إلى الحل الأمثل بسرعة وكفاءة عاليتين بتقنية المدير/العامل وبدالة معيار المعلمات بايزي (BIC) للكشف عن البيانات المتطرفة في نماذج الانحدار الخطي المتعدد. أعطت النتائج قيمة مثلى لـ BIC مساوية (-6.6037) في الكشف عن كافة البيانات المتطرفة في البيانات الأصلية بحيث وصلت نسبة تقليل الأخطاء إلى 98%. تطبيق الانحدار الخطي المتعدد على البيانات قبل وبعد اكتشاف البيانات المتطرفة كان له دور في قياس

6- المصادر

[8] J. Tolvi, "Genetic Algorithms For Outlier Detection and Variable Selection in Linear Regression Models", S.Computing, Vol. 8, No. 8, 527-533, 7, Oct. 2003.
 [9] Abdoun, O., Abouchabaka, J. "A Comparative Study of Adaptive Crossover Operators for Genetic Algorithm to Resolve the Traveling Salesman Problem", International Journal of Computer Applications, Vol. 31, No. 11, Oct. 2011.
 [10] Ishibuchi, H., Nakashima, T., Nii, M., "Genetic Algorithm Based Instance and Feature Selection", In: Liu H, Motoda H, Instance Selection and Construction for Data Mining, Kluwer Academic, (2001).
 [11] Jo-Anne, T., Aaron, D., "Automatic Outlier Detection: A Bayesian Approach", IEEE International Conference (ICRA), Apr. 2007.
 [12] Hancong, L., Sirish, S., Weu, J., "On-Line Outlier detection and Data Cleaning", Comp. & Chemical Engineering, 1635-1647, 20 Jan. 2004
 [13] Dragoljub, P., Aleksandar, L., "Incremental Local outlier Detection for Data Streams", IEEE Symposium on computational Intelligence and Data Mining (CIDM), Apr. 2007.
 [14] Schwarz, G., "Estimating the Dimension of a model", The annals of Statistics, 461-464, 1978.
 [15] الحجار، م. عبید، م. (2003). الخوارزميات الجينية. إشراف العرفي، هادي مشروع دبلوم، جامعة دمشق، كلية الهندسة الميكانيكية والكهربائية.

[1] Ozlem, A. Serdar, K., "Genetic Algorithms Based Outlier Detection Using Bayesian Information Criterion in Multiple Regression Model Having Multicollinearity Problem", G.U. Journal of science, 2009.
 [2] Amidan, B., Ferryman, T., Cooley, S., "Data Outlier Detection Using the Chebyshev Theorem, In: Aerospace", IEEE Aerospace Conference Proceedings, IEEE, Piscataway NJ USA, 3814-3819 (2005).
 [3] P. Borovska, "Solving the Travelling Salesman Problem in Parallel by Genetic Algorithm on Multicomputer Cluster", Computer Systems Department, Technical University of Sofia, 2006.
 [4] Salena, A., Mozammel, K., "Multiple -Case Outlier Detection in Multiple Linear Regression Model Using Quantum-Inspired Evolutionary Algorithm", J. computer, Vol. 5, No. 12, Dec. 2010.
 [5] S. Tongcham, Prabhas, "Parallel Genetic Algorithm for Finite-State Machine Synthesis From Input/Output Sequences", Department of Computer Engineering, Chulalongkorn University Bangkok 10330, Thailand, email g41stc@cp.eng.chula.ac.th, 2000
 [6] Ozlem, A. Serdar, K., "Genetic Algorithms For Outlier Detection in Multiple Regression with different information criteria", Journal of Statistical Computation and simulation, Vol. 81, Issue, 1, 2011.
 [7] Matthew, S. S., Elizabeth, H. S., "Bayesian Outlier Detection with Dirichlet Process Mixtures", 6, No. 4, PP. 665-690, 2012

Using Parallel Genetic Algorithm for outlier detection Based on BIC

Shahla A. AbdAlKader

Dept. of Computer Systems, Technical Institute , Mosul , Iraq

shahla_ak71@yahoo.com

(Received: 8 / 6 / 2011 --- Accepted: 2 / 4 / 2012)

Abstract

The genetic algorithm is one of the intelligent research techniques, which is used for finding approximate solutions for the problems that require optimal solutions.

The objective of this research is to use the parallel genetic algorithm using the technique of Manager/ Worker in parallel computers with Bayesian Information Criterion (BIC) to detect the outlier data in the multiple linear regression model.

Weather forecast data was used including daily temperature, sunshine, wind speed and the day in a year to prepare them in order to construct a predictive model of the daily water vaporization of the cultivated lands in Mosul city for years 1999-2001. The results showed that the BIC Function, as a fitness function in parallel genetic is of high efficiency in detecting the outlier data with least errors, as percentage of error minimizing was 98% . The study that the genetic algorithm factors (selection, mutation, crossover and generations) have an evident impact on minimizing those errors. The Manager/ Worker technique in parallel computer, which operates with the servers of the distributed computers, was of high efficiency in increasing the speed in this type of intelligent genetic algorithms. Moreover, the multiple linear regression method was used to evaluate the results and the adjusted R square (R^2) was also used in judging the results and the value of the adjusted R square was 0.732 before detecting the outlier data and it increased to be 0.974 after detecting them .

Keywords: Parallel Genetic Algorithm, outlier, BIC, manager/worker