



البحث عن شروط التشغيل الامثل لعملية تنقية المياه المدمجة في محول حراري مع اعادة تدوير الطاقة باستخدام شبكة عصبية اصطناعية معكوسة محلولة بواسطة خوارزميات جينية واسراب الجسيمات

## Search for Optimum Operating Conditions for a Water Purification Process Integrated to a Heat Transformer with Energy Recycling using Artificial Neural Network Inverse Solved by Genetic and Particle Swarm Algorithms

Youness El Hamzaoui, Bassam Ali, J. Alfredo Hernandez, Obed Cortez Aburto, and Outmane Oubram

### الخلاصة

تم الحصول على افضل معامل الاداء (COP) (coefficient of performance) لعملية تنقية المياه المدمجة في محول امتصاص حراري مع اعادة تدوير الطاقة باستخدام الذكاء الاصطناعي. الهدف من هذه الورقة العلمية هو تطوير طريقة متكاملة باستخدام شبكة عصبية اصطناعية عكوسة (artificial neural network inverse) (ANNi) مرتبطة مع طرق المفاضلة: خوارزميات جينية (genetic algorithms) (GAs) وخوارزمية مجموعة جسيمات (particle swarm algorithm) (PSA). لهذا فقد تم حل ANNi بطرق المفاضلة تلك لتقدير افضل متغيرات ادخال عندما يكون معامل الاداء مطلوباً. تتبنى هذه الورقة العلمية حالتين دراسيتين لإنجاز دراسة مقارنة. تبين النتائج ان GAs يتفوق على PSA. وتبين الدراسة في النهاية ان GAs المعتمدة على ANNi هي طريقة المفاضلة احسن للتحكم on-line في اداء النظام، وتحتوي على اطار عمل واعد جدا لإيجاد مجموعة من الحلول الجيدة.

**الكلمات المفتاحية:** الذكاء الاصطناعي artificial intelligence، خوارزميات تطويرية evolutionary algorithms، ذكاء الاسراب swarm intelligence، وظيفة هادفة function objective مضخة حرارية heat pump.

**ملاحظات الكاتب:** يبدي يونس الحمزوري امتنانه لمؤسسة CONACyT وذلك علي المنحة الدراسية المقدمة للدارسات العليا - الاتصال مع المؤلف على [baali@cie.unam.mx](mailto:baali@cie.unam.mx).



## 1. مقدمة Introduction

يتكون نظام محول امتصاص الحرارة من جهاز ديناميكي حراري قادر علي إنتاج حرارة مفيدة علي مستوى حراري أعلي من المصدر (Torres, 1997). يلعب هذا المحول الحراري دورا خاصا في صناعة العمليات لتخفيف استهلاك الطاقة إلي الحد الأدنى، وذلك لإمكانية استخدامها مع أي نظام اخر يتطلب حرارة أعلي من الحرارة المزودة من المصدر. بالإضافة إلي ذلك يستخدم محول امتصاص الحرارة علي نطاق واسع وبشكل منتظم في عملية تنقية المياه. من المعروف ان معامل الاداء (COP) هو متغير مهم جداً في تحديد كفاءة محول امتصاص حرارة وذلك بناءً علي المعادلة (1). يعرف معامل الاداء COP علي أنه الحرارة المزودة للممتص لكل وحدة حمل حراري مقدمة للمولد والمبخر (Huicochea et al., 2004).

$$COP = \frac{Q_{AB}}{Q_{GE} + Q_{EV}} \quad (1)$$

علي الرغم من ذلك، لوصف سلوك الـ COP، استخدم (Siqueiros & Romero (2007) نموذج حراري ديناميكي لمحاكاة قيم COP لعملية تنقية المياه المدمجة مع محول امتصاص حراري. تم بناء هذا النموذج علي مجموعة من الافتراضات مثل الفقد الحراري، وانخفاض الضغط في الأنابيب، وعلي كل الأحوال يصعب استكمال متطلبات هذه الافتراضات في التطبيق. لذلك، من المستحيل التحكم في هذه العملية بسبب عدم وجود النموذج الحراري الديناميكي في حالة ثباته. لذلك فانه من الناحية العملية يمكن أن توفر بعض أدوات الشبكات العصبية الاصطناعية ANN طرق جديدة للمعالجة بدون أخذ فرضيات مسبقة بعين الاعتبار (Hernandez et al., 2008 & Hernandez et al., 2009). تعتبر الـ ANN مجموعة من عناصر الحوسبة المترابطة والتي تعمل كخلايا العصبية في الدماغ البيولوجي. ولديها القدرة علي نمذجة العمليات بواسطة التعلم من بيانات المدخلات والمخرجات، وبدون معرفة حسابية عن العملية.

يمكن حساب معامل الاداء COP بطريقة on-line، عندما تكون متغيرات الادخال معروفة بشكل جيد في عملية تنقية المياه المدمجة في المحول الحراري مع اعادة تدوير الطاقة. في الواقع، المشكلة في حساب معامل الاداء بواسطة ANN ليست مثالية في النظام، ولهذا فانه من الضروري ان تكون متغيرات الادخال معروفة جيدا عندما يكون مطلوب معامل اداء محدد، بمعنى ايجاد التأثير لهذا السبب. على أي حال اذا استخدمت لتحويل القياسات الملحوظة إلى معلومات حول النظام، فان هذا النوع من المشاكل يخص فئة المشكلة العكوسة، هناك يوجد الكثير من مجالات العلوم حيث تظهر المشاكل العكوسة. بعض الامثلة هي: الفلك



(صور بها زيغ من قمر هابل الاصطناعي)، الاقتصاد القياسي (متغيرات فعالة)، رياضيات مالية (نموذج معايرة التقلبات أو التذبذبات)، عملية التصوير الطبي (اشعة اكس المقطعية)، الفيزياء الكوانتية ( quantum homodyne tomography). هذه المشاكل لاحظاها بطريقة غير مباشرة للجسم (الدالة) والتي نريد ان نقوم بتركيبها أو بنائها.

البنية المشتركة لكل هذه المشاكل ناتجة من المجالات المختلفة جدا، والتي نصل لها فقط بطريقة الملاحظات الغير مباشرة بسبب طبيعتها الغير مباشرة، ويكون حل المشكلة العكوسة في العادة اصعب. مع ذلك، في هذه الدراسة وجدنا ان استراتيجية التحكم على نظام معامل الاداء هو مشكلة عكوسة طورت من خلال عكس الشبكة العصبية الاصطناعية (ANNi) لتحديد متغيرات الادخال الافضل لمعامل الاداء المطلوب في النظام (Hernandez et al. 2009) الطريقة المقترحة ANNi هي اداة جديدة تعكس الشبكة العصبية الاصطناعية (ANN) وتستخدم طريقة الحصول على افضل الشروط لإيجاد افضل قيم المعاملات (او المعاملات الغير معروفة) لأي شروط مطلوبة في العملية. لكي نقوم بهذا، في البداية من الضروري بناء نموذج شبكة عصبية اصطناعية (ANN) تحاكي المعاملات الناتجة لعملية تنقية المياه تحتوي على شبكة تغذية امامية مع طبقة مخفية لمحاكاة المخرجات، مع اعتبار معامل ادخال واحد او اكثر للعملية معروف بشكل جيد.

تم اعتبار كلا من خوارزمية Levenberg-Marquardt للتعلم، ودالة hyperbolic tangent sigmoid transfer ودالة التحول الخطي والعديد من الخلايا العصبية في الطبقة المخفية (بسبب تعقيد العملية) لبناء النموذج. بمجرد ان اصبح النموذج متحقق، فان الخطوة الثانية هو عكس النموذج. مع توفر المخرجات المطلوبة وبعض متغيرات الادخال فانه من الممكن حساب معاملات الادخال المجهولة.

على أي حال، من المهم ان تلاحظ ان الحل التحليلي مع وتواجد خلية عصبية واحدة في الطبقة المخفية للنموذج العصبي، وهذا موضح في الجزء الفرعي 1.1.4. مع ذلك، في حالة ان النموذج المفترض ANN يمتلك اكثر من خلية عصبية في الطبقة المخفية فانه من الضروري استخدام طريقة المفاضلة. طبق Hernandez et al (2009) النموذج المعكوس للشبكة العصبية في محول امتصاص حراري واحد مع اعادة تدوير الطاقة للتنبؤ بمعامل ادخال واحد فقط والذي يمكن التحكم به لإيجاد القيمة المثالية لمعامل الاداء باستخدام خوارزمية Nelder Mead، والمعروف جيدا على انه طريقة عددية للمشتقة الثانية ومشاكل الوساطة الاحادية الغير مناسبة لهذه الخوارزمية هو انها مناسبة فقط للمفاضلة الدوال الخطية الغير مقيدة، كما



انها لا تقدر اكثر من معامل واحد، ويمكن ان تعطي حلول موضوعية فقط (Lagarias et al 1998). لكن عندما تتطلب مشكلة المفاضلة اكثر من متغير واحد في هذه الحالة فان العملية تصبح اكثر تعقيدا.

في هذا البحث العلمي قمنا بافتراض حل لمشكلة المفاضلة والتي ذكرت من قبل لدالة الملائمة من خلال ANNi باستخدام خوارزميات جينية (GAs) وخوارزميات particle swarm (PSA). بالاضافة إلى اجراء دراسة مقارنة بين هذه الخوارزميات. الكثير من الابحاث استخدم GAs و PSA وتقنيات اخرى في محاولة لحل مشاكل متنوعة للمحاكاة والمفاضلة في عمليات الهندسة الكيميائية (Chang et al. 2011; El Hamzaoui et al. 2010; Gharebagh and Mostoufi 2004; Hamidipour et al. 2005; Iranshahi et al. 2004; Mehrpooya et al. 2010; Mostoufi et al. 2005; Ravagnani et al. 2005).

هذه الورقة العلمية منظمة حسب الترتيب التالي: في الجزء الثاني سوف نعرض مقدمة عن وصف النظام والبيانات العملية. الجزء الثالث يناقش نموذج الشبكة العصبية الاصطناعية. الجزء الرابع مكرس للوصول للمفاضلة المطبقة على ANNi، وخصص الجزء الخامس للنتائج والمناقشات. وفي النهاية عرض للاستنتاجات المتعلقة بهذا العمل.

## 2. وصف النظام والبيانات التجريبية System description and experimental data

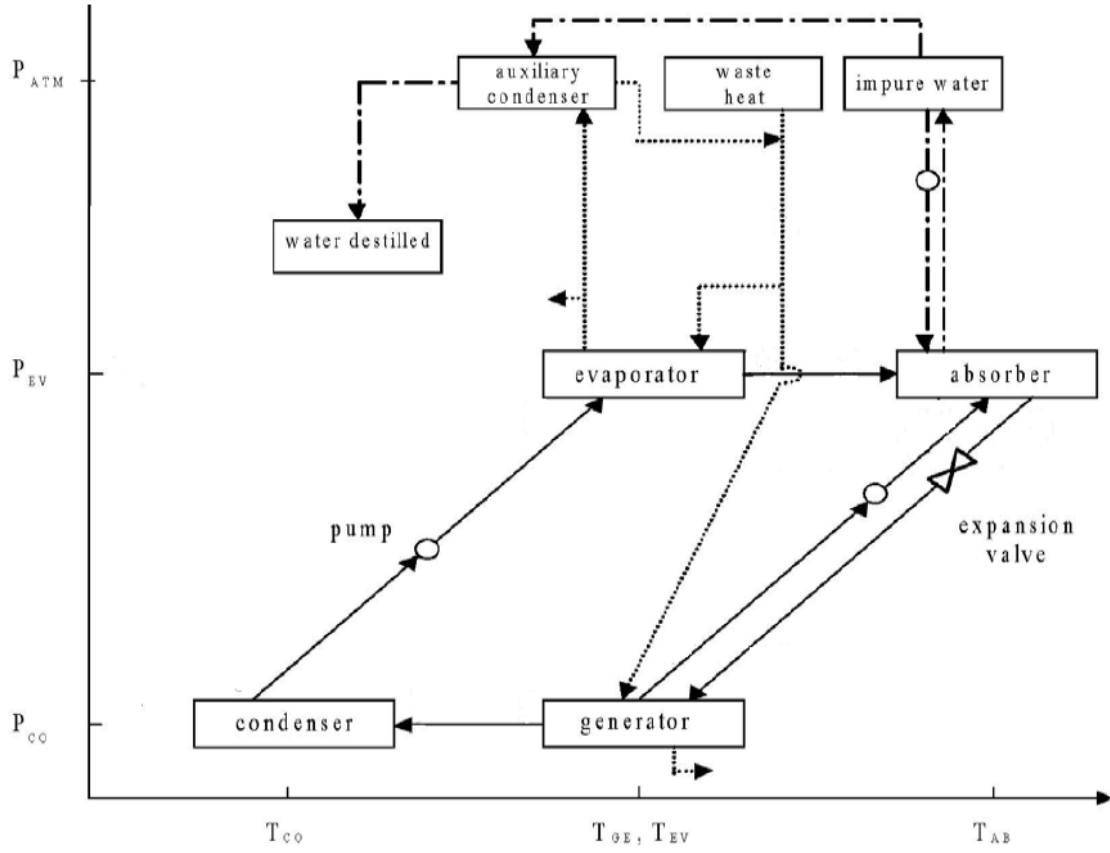
يبين الشكل 1 رسم تخطيطي لمحول حراري. الحرارة المفيدة ( $Q_{AB}$ ) هي نتيجة التفاعل بين الغاز المسال العامل والمحول الماص (والذي ينتج من المبخر والمولد على التوالي). بعد هذه العملية، يدخل محلول مائي مخفف water/LiBr، في المولد. داخل المولد، يستقبل المحلول المائي كمية من الحرارة ( $Q_{GE}$ ) من مزود حراري خارجي. تحت هذه الظروف، يغادر بخار السائل قيد العمل المولد ويدخل إلى مكثف حيث يفقد حرارة ( $Q_{CO}$ ) ويكثف السائل. السائل المكثف يدخل إلى المبخر حيث تزود الحرارة الخارجية ( $Q_{EV}$ ) ويتبخر السائل قيد العملية إلى ضغط مرتفع ويذهب إلى الماص، وفي هذه النقطة، تبدأ الدورة مرة أخرى. كما يمكن أن تلاحظ المحول الحراري يتكامل مع نظام تنقية المياه. يزود الماص بالحرارة المفيدة الوحيدة ( $Q_{AB}$ ) في المحول الحراري. تستخدم  $Q_{AB}$  لتسخين المياه الغير نقية حتي تصل إلى نقطة الغليان وتتبخر جزئياً. في الحالتين (الماء السائل والبخار) تغادر الماص وينفصل من خلال فاصل للطور. يعود طور السائل إلى



مضخة الشفط والبخار الناتج ينتقل من خلال المكثف المساعد حيث تنتقل الحرارة كبخار مكثف بينما يتم تسخين مصدر الحرارة البخاري (Siqueiros et al., 2007). بالإضافة إلي ما يظهره الشكل في ما سبق، تتكامل أيضاً عملية تنقية المياه مع المحول الحراري مع مدور للطاقة في مصدر الحرارة. (Huicochea and Siqueiros, 2010).

قاعدة البيانات التجريبية المزودة من قبل (Morales, 2005) تتكون من قيم COP مختلفة، والتي تم الحصول عليها من عملية تنقية مياه متنقلة مصحوبة بمحول امتصاص حراري مع إعادة تدوير للطاقة. تم الحصول على مجموعة البيانات التجريبية في تراكيز ابتدائية مختلفة لخليط LiBr في  $\text{LiBr} + \text{H}_2\text{O}$ ، ودرجات حرارة مختلفة في الماص، وفي المولد، وفي المبخر، وفي المكثف كذلك عند ضغوط مختلفة في الماص وفي المولد. كما تم الأخذ بالاعتبار الحالة الانتقالية والحالة المستقر لكل من التراكيز الابتدائي للخليط. بعد ساعتين من بدء التشغيل، تم جمع البيانات لمدة 4 ساعات، وتم تنفيذ التجربة بثمانية ظروف ابتدائية مختلفة وإعادة مرتين على الأقل. وكانت الترتيبات علي الشكل  $2 \times 8$  بأربع ساعات من جمع المعلومات. لذلك، تم الحصول علي قاعدة بيانات تحتوي على 11882 عينة. ملخص لـ 16 معامل تشغيل (10 مستويات حرارة و4 درجات تكثيف ودرجتان للضغط) كما هو موضح بالجدول 1. تم تقدير الخواص الحرارية الديناميكية لخليط  $\text{LiBr} + \text{H}_2\text{O}$  بواسطة ارتباطات Alefeld المشار إليها من قبل (Torres, 1997). تم الحصول علي درجة حرارة الإدخال والإخراج لكل مركب (AB, GE, CO and EV) تجريبياً. وفي نفس الوقت، تم تسجيل ضغط المركبات (AB & GE) بواسطة نظام قراءة الضغط (مزدوج حراري ومعدات Agilent مزودة ببرنامج حاسوب).

استنتجت تراكيز الدخول والخروج في الـ AB و GE بواسطة مقياس الانكسار (معامل الانكسار). في هذه العملية، تم استخدام خليط من  $\text{LiBr} + \text{H}_2\text{O}$  كخليط عمل في الممتص والمولد، بينما تم استخدام  $\text{H}_2\text{O}$  في المبخر والمكثف.



الشكل 1 الرسم التوضيحي لتكامل عملية تنقية المياه مع محول امتصاص حرارة مع تدوير الطاقة. الخط المستمر (-) يمثل محول امتصاص الحرارة، الخط والنقطة (- . -) هما عملية تنقية المياه والخط المنقط (.....) هو عملية تدوير الطاقة.



الجدول 1 شروط التشغيل العملية التي تم دراستها للحصول علي قيم COP

Variables	Mean±Standard deviation	Limiting conditions
Operation parameters, °C		
$T_{in.GE-AB}$	88.60±1.99	76.29-91.53
$T_{in.EV-AB}$	83.96±2.39	74.56-89.93
$T_{out.AB-GE}$	93.85±2.28	84.31-98.27
$T_{in.AB-GE}$	87.17±1.53	74.99-92.58
$T_{out.GE-CO}$	88.60±1.99	76.29-91.53
$T_{out.GE-AB}$	82.03±0.88	77.03-83.89
$T_{in.CO}$	48.67±3.47	40.37-65.03
$T_{out.CO}$	30.44±1.53	26.77-33.79
$T_{in.EV}$	35.57±7.70	28.52-85.33
$T_{out.EV-AB}$	83.96±2.40	74.56-89.93
Operational parameters, %		
$X_{in.AB}$	53.84±1.31	51.66-55.36
$X_{out.AB}$	52.77±1.33	50.75-54.36
$X_{in.GE}$	52.76±1.32	50.75-54.36
$X_{out.GE}$	55.01±1.03	53.16-56.07
Operational parameters, in Pascal (Pa) (absolute)		
$P_{AB}$	8.64±1.12	7-11.5
$P_{GE}$	20.54±0.49	19-21.10



### 3. نموذج الشبكة العصبية الاصطناعية Artificial neural network model

طبقا لـ Hernandez et al (2009) و Kůrková (1992) فان قواعد البيانات السابقة الذكر في الجزء 2 استخدمت بنجاح لتدريب نموذج AVV باستخدام طريقة الانتشار الخلفي، للتنبؤ بمعامل الاداء في انظمة تنقية المياه المدمجة في محول حراري مع اعادة تدوير الطاقة، بهذا الدافع لتحديد افضل خوارزمية تدريب انتشار خلفي، تم دراسة عشرة خوارزميات انتشار خلفي. بالإضافة الى استخدام ثلاثة خلايا عصبية في الطبقة المخفية لكل خوارزميات الانتشار الخلفي.

يوضح الجدول 2 مقارنة لخوارزميات تدريب الانتشار الخلفي المختلفة. تمتلك خوارزمية -Levenberg Marquardt لتدريب الانتشار الخلفي على اصغر خطأ لجذر متوسط المربع (RMSE) واصغر انحراف معياري نسبي (RSD)، على التوالي، على الجانب الاخر، وجدنا ان التدريب باستخدام خوارزمية -Levenberg Marquardt يعمل بسلاسة في انظمة كمبيوتر بمواصفات ذاكرة موسعة (EMS) قليلة، وزمن التدريب اصغر من خوارزميات الانتشار الخلفي الاخرى. بسبب ان خوارزمية -Levenberg Marquardt قد صممت للوصول لسرعة تدريب من الرتبة الثانية بدون الحالة لحساب مصفوفة Hessian. عندما تكون دالة الاداء في صورة مجموع مربعات (مثل تدريب شبكات التغذية الامامية القياسية)، فان مصفوفة Hessian يمكن ان تقرب على النحو التالي:

$$H = J^T J \quad (2)$$

ويمكن حساب الانحدار على النحو التالي:

$$g = J^T e \quad (3)$$

حيث ان مصفوفة Jacobian التي تحتوي على المشتقات الاولية لأخطاء الشبكة بالنسبة للأوزان والانحيازات، وهي متجه اخطاء الشبكة. يمكن حساب مصفوفة Jacobian من خلال تقنية الانتشار الخلفي القياسية والتي هي اقل تعقيدا من حساب مصفوفة Hessian. تستخدم خوارزمية -Levenberg Marquardt هذا التقريب لمصفوفة Hessian في طريقة نيوتن المحدثة التالية:

$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T e \quad (4)$$





عندما تكون  $\mu$  القياسية تساوي صفر، هذه هي طريقة نيوتن، باستخدام تقريب مصفوفة Hessian. عندما تكون  $\mu$  كبيرة تصبح هذه انحدار متناقص بخطوات صغيرة الحجم. طبقاً لـ Hagan و Menhaj 1994، فإن طريقة نيوتن أسرع وأكثر دقة بجوار القيم الدنيا للخطأ، لذا فإن الهدف هو الانتقال نحو طريقة نيوتن بأسرع ما يمكن، بهذا فإن  $\mu$  تتناقص بعد كل خطوة ناجحة (تتناقص في دالة الاداء) وتزداد فقط عندما تعمل خطوة تجريبية على زيادة دالة الاداء. في هذا السياق، تقل دالة الاداء دائماً عند كل تكرار للخوارزمية. لذلك فإن لهذه الحجج، اعتبرت خوارزمية Levenberg-Marquardt خوارزمية تدريب في الدراسة الحالية. على أي حال، تم قياس اداء نموذج ANN بشكل احصائي من خلال خطأ جذر متوسط المربع ( $RMSE$ )، والانحراف المعياري النسبي ( $RSD$ ) ومعامل التراجع ( $R^2$ )، والذي يحسب مع القيم العملية وتوقعات الشبكة. تستخدم هذه الحسابات كمعيار لكفاية النموذج على النحو التالي:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (y_{n,pred} - y_{n,exp})^2}{N}} \quad (5)$$

$$RSD = \frac{RMSE}{y_m} \times 100 \quad (6)$$

$$R^2 = 1 - \frac{\sum_{n=1}^N (y_{n,pred} - y_{n,exp})^2}{\sum_{n=1}^N (y_{n,exp} - y_m)^2} \quad (7)$$

حيث  $N$  هي عدد نقاط البيانات، و  $y_{n,pred}$  هي توقع الشبكة، و  $y_{n,exp}$  هي الاستجابة العملية، و  $y_m$  هو متوسط القيم الفعلية و  $n$  مؤشر البيانات. يتوقع الشكل 2 أيضاً معمارية الشبكة المتكررة لقيم معامل الاداء والطريقة المستخدمة لتعليم الشبكة العصبية. بينما يوضح الجدول 3 أيضاً بعض الامثلة للقياسات العملية والمحاكاة من قبل نموذج ANN.



بناء على ذلك فقد استخدمت كلا من RMSE و RSD كدالة خطأ تقيس اداء الشبكة. لهذا فقد تم اختيار شبكة باقل قيمة RMSE واقل RSD و اعلى R2 كأفضل نموذج ANN.

بناء على Hernandez et al (2008)، فان النموذج المفترض يمثل بالمعادلة التالية:

$$COP = \sum_{i=1}^S \left[ LW(1, s) \cdot \left( \frac{2}{1 + \exp\left(-2 \left( \sum_{k=1}^K (IW(s, k) \cdot \ln(k) + b1(s)) \right)\right)} - 1 \right) + b2 \right] \quad (8)$$

حيث s هو عدد الخلايا العصبية في الطبقة المخفية و k عدد المدخلات و IW و W<sub>0</sub> و b هي الازان والانحيازات على التوالي. يوضح الجدول 4 المعاملات القابلة للتعديل (IW, W<sub>0</sub>, b<sub>1</sub>, b<sub>2</sub>) للنموذج المفترض.

**الجدول 2** مقارنة لعشرة خوارزميات انتشار خلفي مع ثلاثة خلايا عصبية في الطبقة الخفية

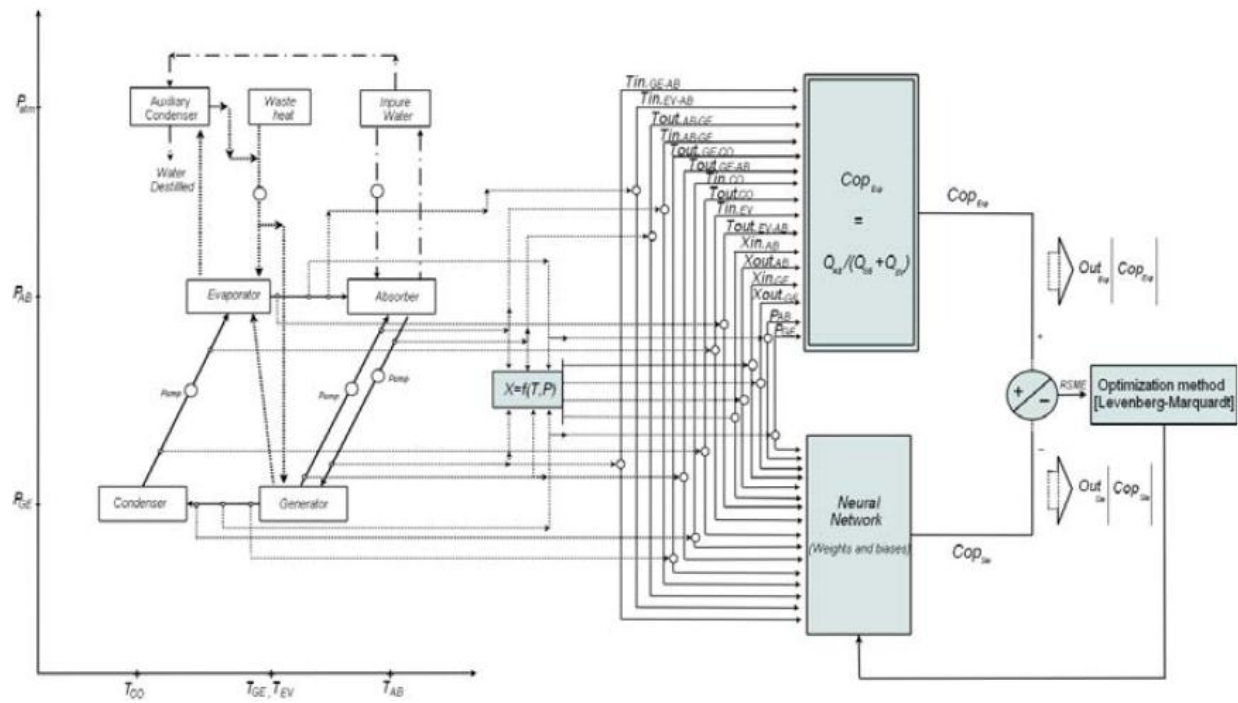
Backpropagation algorithms	Function	RMSE	R <sup>2</sup>	RSD %	Best linear equation
Levenberg-Marquardt	<i>trainlm</i>	9.5219×10 <sup>-7</sup>	0.998	2.9343×10 <sup>-4</sup>	Y=0.998X+0.3
Batch gradient descent	<i>traingd</i>	8.3247×10 <sup>-6</sup>	0.988	0.0026	Y=0.986X+0.9
Batch gradient descent with momentum	<i>traingdm</i>	7.8918×10 <sup>-5</sup>	0.987	0.0243	Y=0.988X+0.8
Polak-Ribiere conjugate gradient	<i>traincgp</i>	7.9934×10 <sup>-5</sup>	0.979	0.0246	Y=0.957X+2.5
Scaled conjugate gradient	<i>trainscg</i>	6.4627×10 <sup>-4</sup>	0.974	0.1992	Y=1.020X-0.7
BFGS quasi-Newton	<i>trainbfg</i>	6.9871×10 <sup>-4</sup>	0.971	0.2153	Y=0.982X+1.2
Powell-Beale conjugate gradient	<i>traincgb</i>	6.9997×10 <sup>-4</sup>	0.965	0.2157	Y=0.960X+2.0
One step secant backpropagation	<i>trainoss</i>	6.9287×10 <sup>-3</sup>	0.782	2.1352	Y=0.617X+45.
Fletcher-Reeves conjugate gradient	<i>traincgf</i>	6.4159×10 <sup>-2</sup>	0.725	19.7716	Y=0.425X+34.
Variable learning rate	<i>traingdx</i>	6.9781×10 <sup>-1</sup>	0.718	215.0416	Y=0.386X+38



#### 4. طريقة المفاضلة Optimization approach

تشتمل المفاضلة على ايجاد ادنى/اعلى دالة موضوعية  $f(x)$  معرضة لبعض المحددات  $x \in S$ . اذا لم توجد أي محدّدات لـ  $x$  لتتحقق او مكافئة و  $S$  هي الكون فإنها تعرف بالمفاضلة بدون محدّدات، والا فإنها ستكون مفاضلة محددة.

للمفاضلة يتم حساب النتائج المرغوبة في الشكل المعكوس. معاملات مطلوبة معطاة هي المفضلة. ما هي المعاملات التي تثبت للحصول على هذه الشروط؟ هذه مشكلة كبيرة نواجهها في معظم الاحيان في غرفة التحكم. لهذا وطبقا للمعادلة (8)، فانه من الممكن محاكاة معامل الاداء في انظمة تنقية المياه المدمجة في المحول الحراري مع اعادة تدوير الطاقة، عندما معاملات الادخال تكون معروفة بشكل جيد. على أي حال في الكثير من الحالات فان المشكلة هي ان معامل الاداء المحسوب عن طريق ANN ليس مثاليا في النظام، ولهذا فانه من الضروري ان تكون متغيرات الادخال معروفة جيدا عندما يعطى معامل اداء مطلوب. استراتيجية التحكم الجديدة والمقترحة هنا باستخدام نموذج ANN لمحول الحرارة المدمج مع نظام اعادة تدوير الطاقة والموصوف اعلاه كنموذج قياسي. الحل المفترض هو استخدام معكوس شبكة عصبية لمفاضلة معاملات الاداء للعملية باستخدام خوارزميات المفاضلة (PSA و GAS) لإيجاد قيم الادخال الافضل للنتائج المطلوب. في هذا البحث كما ذكر اعلاه فان الناتج المطلوب هو معامل الاداء، لكن معاملات مدخلات التشغيل الافضل التي يجب ان توجد هي الضغط في الماص والمولد على التوالي، لان الضغط هو مفتاح اساسي في معامل اداء النظام، بالإضافة الى انه يمكن تعديله مع طريقة التشغيل. لهذا السبب هذين المتغيرين اللذان يتحكمان في النظام يجب ضبطهما للحصول على معامل الاداء المطلوب.



الشكل 2. معمارية شبكة التكرار لقيم معامل الاداء والطريقة المستخدمة في تعليم الشبكة العصبية.



الجدول 3. بعض العينات العملية ومعلومات المحاكاة للنظام

Input	Test					
	A	B	C	D	E	F
$T_{in,GE-AB}$	90.54	89.52	89.72	89.49	89.64	87.7
$T_{in,EV-AB}$	83.79	82.63	85.79	85.94	79.61	81.67
$T_{out,AB-GE}$	96.06	92.67	94.17	92.67	95.1	94.32
$T_{in,AB-GE}$	85.68	86.18	88.93	85.26	89.12	87.93
$T_{out,GE-CO}$	90.54	89.52	89.72	89.49	89.64	87.7
$T_{out,GE-AB}$	81.56	82.1	83.33	80.88	82.51	81.28
$T_{in,CO}$	48.92	48.15	48.98	49.6	42.32	56.09
$T_{out,CO}$	30.89	33	30.53	29.39	28.52	33.23
$T_{in,EV}$	31.84	34.56	37.5	31.77	36.5	34.86
$T_{out,EV-AB}$	83.79	82.63	85.79	85.94	79.61	81.67
$X_{in,AB}$	52.39	52.98	54.3	53.6	55.31	55.25
$X_{out,AB}$	51.08	51.74	53.16	52.28	54.33	54.33
$X_{in,GE}$	51.08	51.74	53.16	52.28	54.33	54.33
$X_{out,GE}$	53.49	54.65	55.36	55.47	56.07	55.97
$P_{AB}$	10	9.5	8	7.5	11	9
$P_{GE}$	20	20	20.5	21	21	21.1

Output	Test					
	A	B	C	D	E	F
$COP_{Exp}$	0.35	0.3	0.38	0.21	0.39	0.35
$COP_{Sim}$	0.3474	0.2987	0.3767	0.2133	0.3913	0.3506



الجدول 4 معاملات قابلة للضبط تم الحصول عليها (الاوزان والانحياز) في النموذج المفترض مع  $S=3$  و  $K=16$

$W_i$ (s,k)	1.0471 1.6234 -8.5413 1.7987 7.1516 -1.1964 -1.0951 2.5118 -0.0034 -2.3428 242.3930 159.4554 72.5887 20.8372 -19.4769 -65.5883 20.0710 -6.4628 -46.4698 6.3265 26.4226 -16.5479 14.6389 37.4539 0.3227 4.4175 -216.8707 135.7784 115.0829 10.2770 17.5255 -47.0385 -3.7487 0.1137 3.5127 0.5452 0.6408 0.3451 -0.0254 0.0001 0.0032 0.1114 -0.4314 -7.1419 12.6125 3.2912 0.1576 1.1184
$W_o$ (l,s)	-0.1866 0.0239 -0.8825
$b1$ (s)	129.0939 -17.7516 -6.4906
$b2$ (l)	0.2427

#### 4.1 الشبكة العصبية الاصطناعية المعكوسة (ANNi) Artificial neural network inverse

##### 1.1.4 شبكة عصبية معكوسة مع خلية عصبية واحدة في الطبقة المخفية في نموذج ANN

يمكننا ان نعبر تحليليا عن حل ANNi عندما يكون لدينا خلية عصبية واحدة في الطبقة المخفية:

- اذا تم اعتبار كلا من *purelin* و *tansig* كدالة *hyperbolic tangent sigmoid* ودالة تحول خطي في الطبقة المخفية وطبقة الاخراج، و  $k=1$

$$Out (1) = LW (1,1) \cdot \left( \frac{2}{1 + \exp(-2 \cdot (IW (1, k) \cdot In(k) + b1))} - 1 \right) + b2 \quad (9)$$

هذه يمكن ان تتحول إلى الشكل التالي:



$$Out(1) = \frac{2 \cdot LW(1,1)}{1 + \exp(-2 \cdot (IW(1,k) \cdot In(k) + b1))} - LW(1,1) \quad (10)$$

$$1 + \exp\left(-2 \left( IW(1,k) \cdot In(k) + b1 = \frac{2 \cdot LW(1,k)}{Out(1) + LW(1,1) - b2} \right)\right) \quad (11)$$

$$\exp(-2 \cdot (IW(1,k) \cdot In(k) + b1)) = \frac{2 \cdot LW(1,1) - Out(1) - LW(1,1) + b2}{Out(1) + LW(1,1) - b2} \quad (12)$$

$$-2 \cdot (IW(1,k) \cdot In(k) + b1) = Ln\left(\frac{LW(1,1) - Out(1) + b2}{Out(1) + LW(1,1) - b2}\right) \quad (13)$$

$$IW(1,1) = -\frac{1}{2} Ln\left(\frac{LW(1,1) - Out(1) + b2}{Out(1) + LW(1,1) - b2}\right) - b1 \quad (14)$$

لنفترض  $k=k(1)$  هي معامل الادخال التي ستحسب عندما يكون مطلوب معامل اخراج واحد وبالتالي فان:

$$k(1) = -\frac{1}{2 \cdot IW(1,1)} Ln\left(\frac{LW(1,1) - Out(1) + b2}{Out(1) + LW(1,1) - b2}\right) - \frac{b1}{IW(1,1)} \quad (15)$$

- اذا تم اعتبار كلا من *purelin* و *logsig* كدالة *logistic tangent sigmoid* ودالة تحول خطي في الطبقة المخفية وطبقة الاخراج و  $k=1$

$$Out(1) = LW(1,1) \cdot \left( \frac{1}{1 + \exp(-IW(1,1) \cdot In(k) + b1)} \right) + b2 \quad (16)$$

بالنالي فان معامل الادخال يمكن ان يحسب من المعادلة (14):



$$k(1) = \frac{b1 - Ln \left( \frac{LW(1,1)}{Out(1)} - 1 \right)}{IW(1,1)} \quad (17)$$

#### 2.1.4 شبكة عصبية عكوسة لعملية تنقية المياه المدمجة في محول حراري مع اعادة تدوير الطاقة

للحصول على الناتج المرغوب به من عملية تنقية المياه المدمجة في محول الحرارة مع اعادة تدوير الطاقة فانه من الواضح ان نختار متغيرات صحيحة قابلة للتعديل من الدوائر الخارجية. يمكن اعتبار شبكة عصبية معكوسة كنموذج يعتمد على طريقة التحكم الاشرافي، بحيث ان قيم المتغيرات القابلة للتعديل قد تم الحصول عليها من حل مشكلة مفاضلة on-line للحصول على الناتج المرغوب به (Kohlenbach, 2006; Lecuona et al. 2009). موضح في الشكل 3 شبكة عامة تحتوي على دالة تحول TANSIG وPURELIN. عليه فان مخرجات ANNi موضح على النحو التالي في ترتيب يجنب أي غموض:

$$y_k = b2_{(l)} + \sum_s \left\{ Tansig \left( b1_{(s)} + \sum_k IW_{(s,k)} \cdot In(k) \right) \cdot LW_{(l,s)} \right\} \quad (18)$$

عند استخدام دالة tansig، فان  $y_k$  تعطى من خلال

$$y_k = b2_{(l)} + \sum_s \left\{ \left[ \frac{2}{1 + \exp \left( -2 \left( b1_{(s)} + \sum_k IW_{(s,k)} \cdot In(k) \right) \right)} - 1 \right] \cdot LW_{(l,s)} \right\} \quad (19)$$

As  $y_k = COP$

طبقا للمعادلة (19)، يمكن التعبير عن المعادلة (8) على النحو التالي:

$$COP = b2_{(l)} - \sum_s LW_{(l,s)} + \sum_s \frac{2 \cdot LW_{(l,s)}}{1 + \exp \left( -2 \left( b1_{(s)} + \sum_k IW_{(s,k)} \cdot In(k) \right) \right)} \quad (20)$$





عند هذه الخطوة، في الحالة العامة، حصلنا على الدالة التي يجب ان تقلل عند صفر لايجاد معاملات الادخال الافضل  $In_{(k=x)}$ ، حيث ان معاملات معامل الاداء للنظام والتي يمكن ان نتحكم بها وهي الضغط في الماص والمواد على التوالي، هي في الحقيقة معامل الاداء المطلوب، لهذا فان المعادلة (20) يمكن التعبير عنها كما في الشكل التالي:

$$COP = b2_{(l)} - \sum_s LW_{(l,s)} + \sum_s \left[ \frac{2.LW_{(1,s)}}{1 + \exp\left(-2\left(IW_{(s,k)} \cdot In_{(x)} + \sum_{k \neq x} IW_{(s,k)} \cdot In_{(k)} + b1_{(s)}\right)\right)} \right] \quad (21)$$

حيث  $x$  هي شروط التشغيل الافضل للنظام والغير معروفة، والتي يجب ان نجدها. ومع ذلك، في حالة نموذج ANN المفترض يمتلك اكثر من خلية عصبية واحدة في الطبقة المخفية فانه من الضروري ان نستخدم طريقة المفاضلة. في هذه الدراسة تم حل شبكة عصبية اصطناعية عكوسة بواسطة (GAs) و (PSA)، لان كلا الطريقتين تستخدم عدد كبير من نقاط البحث الابتدائية وتمتلك احتمالية عالية لايجاد الشروط الافضل العالمية.

#### 2.4 خوارزميات جينية Genetic algorithms


مصطلح الخوارزميات الجينية يختصر الان بـ GAs لقد كان اول ما استخدم من قبل Jhon Holland (1975). الخوارزميات الجينية هي تقنيات بحث تستخدم في الكمبيوتر لايجاد الحل التقريبي المضبوط للمفاضلة ومشاكل البحث، على أي حال، يمكن وصف خطوات GAs على النحو التالي:

**الخطوة 1:** يتولد تعداد ابتدائي بطريقة عشوائية، هذه الطريقة تضمن تعداد ابتدائي متنوع يغطي كامل فراغ البحث.

انجزت الخطوات التعلية لكي تعبر من التعداد الحقيقي (P) إلى الذي يليه (P+1). في البداية يتولد تعداد متوسط في الخطوة 2 إلى 4.

**الخطوة 2:** تختار طريقة elitism افضل المفردات لكل معيار، ومن ثم توضع في التعداد المتوسط.

**الخطوة 3:** اختيار عدد متساوي من المفردات لكل معيار باستخدام روليت Goldberg المنحاز.



الشكل 3. نموذج توقع قيم معامل الاداء.

**الخطوة 4:** يكتمل التعداد المتوسط مع تولد مفردات بطريقة الانتقال. نلاحظ ان المفردات التي طبقت عليهم الطريقة تم اختيارهم بشكل عشوائي من التعداد (P).

**الخطوة 5:** طبقت طريقة التحول على عدد ثابت من المفردات المختارين عشوائيا. فقط نقطة واحدة من الكروموزوم قد تعدلت، وتغيرت قيمتها من 0 إلى 1 او العكس.

**الخطوة 6:** اصبح التعداد الجديد هو التعداد الحالي واعيدت الخطوات من 2 إلى 5 حتى تم الوصول لاقصى عدد من الاجيال.



بأي حال من الأحوال فان تفاصيل عملية GAS قد شرحت بالتفصيل من قبل العديد من الباحثين ولهذا لم يتم تكرارها في هذه الورقة العلمية. مزيد من المعلومات عن عملية GAS يمكن ان تجدها في بحث Goldberg المنشور في العام 1989.

### 3.4 خوارزميات اسراب الجسيمات Particle swarm algorithms

اقترحت خوارزمية اسراب الجسيمات (PSA) particle swarm algorithm بواسطة Kennedy واخرون (Kennedy et al, 1995; Shi et al, 1998) وطبقت كحاكاة للنظام الاجتماعي المبسط بحيث ان اعضاء افراد المدرسة يمكنهم الاستفادة من الاكتشافات والخبرات السابقة لكل الاعضاء الاخرين في المدرسة اثناء البحث. تشير PSA إلى عدد من الحلول الهامة لمشكلة المفاضلة، حيث ان كل حل يشار له كموضع جسيم. كل تتم تهيئة كل جسيم بواسطة موضع عشوائي في مشكلة متعددة الابعاد في الفضاء ومن ثم تطوير من خلال هذا الفضاء لتحديد افضل موضع. كل جسيم يتحرك في اتجاه موضعين، افضل موضع لكل جسيم (pbest) وافضل موضع حتى الان هو بواسطة كل الجسيمات في التعداد (gbest)، مع معاملين وزن، واوزان العطالة وتسارع ثابت موضحة في المعادلات (22) و(23):

$$v_{i,k+1} = wv_{i,k} + c_1.r_1.(y_{i,k} - x_{i,k}) + c_2.r_2.(y_g - x_{i,k}) \quad (22)$$

$$x_{i,k+1} = x_{i,k} + v_{i,k+1} \quad (23)$$

حيث تمثل  $v_i$  سرعة الجسيم  $i$ ، و  $k$  تشير إلى عدد التكرارات و  $w$  تمثل وزن العطالة، و  $c_1$  و  $c_2$  هما ثوابت التسارع، و  $r_1$  و  $r_2$  هي دالتين عشوائيتين في المدى  $[0, 1]$ ، وتمثل  $x_i$  الموضع الحالي للجسيم  $i$ ، و  $y_i$  هي افضل موضع شخصي للجسيم  $i$  (pbest) و  $y_g$  هي افضل موضع لكل الجسيمات الموجودة في الوقت الحالي (gbest).



#### 4.4 ضبط المعاملات لخوارزميات GAs و PSA

كفاءة كلا من GAs و PSA تعتمد بشكل كبير على معاملاتها القابلة للضبط والتعديل. باستخدام ANNi كدالة ملائمة (fitness function) فإنه تم تنفيذ كلا من GAs و PSA لمفاضلة معامل اداء النظام، لقد تم استخدامهما لإجراء خوارزمية بحث عالمية لتحديث معاملات ادخال الشبكة العصبية. استخدمت مجموعات معاملات التحكم لتشغيل GAs و PSA وهي موضحة في الجدول 5.

الجدول 5. المعاملات المستخدمة لتشغيل خوارزميات GAs و PSA

Algorithms	Parameters	Value
GAs	Number of population	49
	Number of generations	1000
	Crossover probability	0.40
	Mutation probability	0.05
	Elitism	1
PSA	Number of particles	49
	Number of generations	1000
	Inertial weight	1.00
	Acceleration constants	2.00



## 5. النتائج والمناقشة Results and discussion

### 1.5 تحليل الحساسية Sensitivity analysis

لكي نقيم الاهمية النسبية لمتغيرات الادخال، اعتمدت العملية على مصفوفة وزن شبكة عصبية ومعادلة Garson (1991). لقد افترض معادلة تعتمد على تجزئة اوزان التوصيل.

$$I_j = \frac{\sum_{m=1}^{N_h} \left( \left( \frac{|W_{jm}^{ih}|}{\sum_{k=1}^{N_i} |W_{km}^{ih}|} \right) \times |W_{mn}^{ho}| \right)}{\sum_{k=1}^{N_i} \left\{ \sum_{m=1}^{N_h} \left( \frac{|W_{km}^{ih}|}{\sum_{k=1}^{N_i} |W_{km}^{ih}|} \right) \times |W_{mn}^{ho}| \right\}} \quad (24)$$

حيث  $I_j$  هي الاهمية النسبية لمتغير الادخال  $j$ th على متغير الاخراج، و  $N_i$  و  $N_h$  هما عدد مدخلات والخلايا العصبية المخفية على التوالي. و  $W$  هي وزن التوصيل، والرموز السفلية 'I' و 'h' و 'O' تشير إلى خلايا الادخال والمخفية والخراج العصبية، على التوالي. لاحظ ان البسط في المعادلة (24) يصف مجاميع النواتج المطلقة للأوزان لكل مدخل. على أي حال، يمثل المقام في المعادلة (24) مجموع كل الاوزان المغذية في الوحدة المخفية بأخذ القيم المطلقة.

يوضح الجدول 6 الاهمية النسبية لمتغيرات الادخال المحسوبة بواسطة المعادلة (24).

في الحقيقة، يوضح تحليل الحساسية (الجدول 6) ان كل متغيرات الادخال التي درست لها تأثير على معامل اداء النظام. بالإضافة على ذلك فان التراكيز هي العامل الاكثر تأثيرا، يتبعه بعد ذلك الضغط. على أي حال في الزمن الحقيقي، التراكيز مثل  $X_{GB-GE}$  و  $X_{GE-AE}$  لا يمكن ان يتم التحكم بها on-line، لان النظام مغلق. على الجانب الاخر، الضغط يمتلك تأثير قوي اكثر من درجات الحرارة على محول امتصاص الحرارة. علاوة على ذلك فانه بالاعتماد على الخبرة العملية التي اجريت بواسطة Hernandez et al في العام 2009 اثبتت ان كلا من PAB و PGE هي معاملات اساسية للتحكم في اداء قيم معامل الاداء. اما بالنسبة لمعاملات درجة الحرارة التي تظهر في النموذج يمكن ان تعدل شكلها المثالي، ويمكن ان يتم التحكم بها on line في



الوقت الفعلي، مثل تطبيقات ANNi الأخرى. على أي حال في هذه الحالة لم يتم ذلك حيث ان ذلك سوف يجعل من هذه الورقة العلمية كبيرة جدا.

## 2.5 قيمة كافية قدرت بواسطة ANNi

تم دراسة حالتين مختلفتين هنا لإثبات امكانية تطبيق هذه الطريقة. المخرجات المرغوب بها او دالة الملائمة التي يجب مفاضلتها في كل حالات الدراسة هي معامل الاداء، بينما عدد معاملات التشغيل الافضل المطلوب حسابها يختلف. لقد اعتبرنا قيود للحصول على معاملات الادخال: قيم الادخال هي جميعا في مدى التشغيل الموضح في الجدول 1، والمعادلات (25) هي معيار للتأكد من القيم الافضل.

في الحالة 1 كان ضغط الماص هو متغير الادخال الوحيد الذي يمكن تعديله والذي تم حسابه للحصول على معامل الاداء المرغوب به. في الحالة 2 تم التحكم في معامل اداء النظام من خلال متغيرين ادخال يمكن تعديلهما: ضغط الماص والمولد. في كلا الحالتين تم اعتبار القيود. في هذه الحالة وكما ذكر اعلاه، فان الناتج المرغوب به هو معامل اداء النظام مع ضغط الماص ( $P_{AB}$ ) هو معامل غير معروف (متغير يمكن تعديله).

من المعادلة (8) للحالة 1 مع معامل واحد ( $P_{AB}$ ) غير معروف يأخذ الشكل التالي:

$$COP = b2_{(i)} - \sum_s LW_{(i,s)} + \sum_s \left[ \frac{2.LW_{(1,s)}}{1 + \exp\left(-2\left(IW_{(z,k)} \cdot P_{AB} + \sum_{k \neq P_{AB}} IW_{(z,k)} \cdot In_{(k)} + bl_{(z)}\right)\right)} \right] \quad (26)$$

## حالة 2

الفرق بين الحالة 1 والحالة 2 هو ان معامل اداء النظام تم التحكم به بواسطة معاملين هنا  $P_{AB}$  و  $P_{GE}$ .

هنا، المعادلة (26) للمعاملين تأخذ شكل مختلف قليلا، ويمكن التعبير عن هذه المعادلة على النحو التالي:

$$\text{Minimize } COP = \text{Fun} (P_{AB}, P_{GE}) \quad (29)$$



حيث

$$Fun(P_{AB}, P_{GE}) = \sum_s \left[ \frac{2LW_{(i,s)}}{1 + e^{-2 \left( \sum_{k=1}^{15} m_{(s,k)} P_{AB} + \sum_{k=1}^{16} m_{(s,k)} P_{GE} + \sum_{k=1}^{15} m_{(s,k)} P_{AB} + \sum_{k=1}^{16} m_{(s,k)} P_{GE} + b_{(s)} \right)}} \right] + (b_{2(1)} - LW_{(1,1)} - LW_{(1,2)} - LW_{(1,3)}) \quad (30)$$

تم ضبط المعاملات الخوارزمية GAS على النحو التالي: حجم التعداد هو 49، وعدد الاجيال هو 1000، واحتمالية الانتقال هي 0.40 واحتمالية التحول هي 0.05 والنخبة هي 1، وبالنسبة لمعاملات خوارزمية PSA فهي على النحو التالي: عدد الجسيمات هو 49 والتكرارات هو 1000، ووزن العطالة هو 1 وثوابت التسارع هي 2.

من ناحية عملية فان الحسابات المطلوبة للنظام تكون معقدة جدا ولهذا فان وقت CPU تم حسابه على انظمة لينيكس: Intel(R)D CPU 2.80 GHz, 2.99 GB RAM. طبقا للجدول 7، يمكننا ان نميز النتائج التالية:

## الفحص B

تم حساب افضل النتائج سبعة مرات باستخدام GAS في الفحص B وقورنت مع PSA كما هو موضح في الجدول 7. في الفحص B، فان معامل الاداء المطلوب هو 0.3، وافضل PAB تم حسابه بواسطة GAS هو 0.63% كان احسن من PSA بحوالي 0.63%. على الجانب الاخر مع متغيرين فان افضل معاملات P<sub>AB</sub> و P<sub>GE</sub> تم حسابها بواسطة GAS كانت افضل من PSA بين 0.21% و 0.50%.



## جدول 6 الاهمية النسبية لمتغيرات الادخال

Input variable	Importance %
$X_{in.AB}$	9.2134
$X_{out.AB}$	8.1695
$X_{in.GE}$	7.9731
$P_{AB}$	6.5694
$X_{out.GE}$	5.9002
$P_{GE}$	5.8800
$T_{outAB-GE}$	5.7163
$T_{out.GE-CO}$	5.6955
$T_{outCO}$	5.6262
$T_{outEV-AB}$	5.6236
$T_{inAB-GE}$	5.6155
$T_{inEV-AB}$	5.6129
$T_{outGE-AB}$	5.6065
$T_{inCO}$	5.6050
$T_{inGE-AB}$	5.6043
$T_{inEV}$	5.5886
<b>Total</b>	<b>100</b>

### الفحص C

النتائج الامثل تم الحصول عليها بالحساب لسبعة مرات باستخدام كلا من GAS و PSA في الفحص C. في هذا الفحص كان معامل الاداء المطلوب هو 0.38، والان نحن نرغب بحساب القيمة الافضل لمتغير ادخال واحد فقط ( $P_{AB}$ ) معطى بـ GAS وهو احسن من PSA بحوالي 0.75%. في الوقت الحالي، القيم الافضل لمتغيرين ادخال  $P_{AB}$  و  $P_{GE}$  وجد ان النتائج المعطاة بواسطة GAS احسن من PSA بين 0.63% و 1.63%.





## الفحص E

النتائج الامثل تم الحصول عليها بالحساب لسبعة مرات باستخدام كلا من GAS و PSA في الفحص E، في هذه الحالة كان معامل الاداء المطلوب هو 0.39، لقد وجدنا ان افضل PAB التي حسبت بواسطة GAS احسن من PSA بحوالي 0.64%. في حين ان المعاملات الامثل  $P_{AB}$  و  $P_{GE}$  حسبت بواسطة GAS و PSA، والنتائج تبين ان GAS احسن من PSA بين 0.81% و 1.98%.

في هذا السياق يوضح الشكلين 4 و 5 على التوالي سلوك دالة الملائمة (fitness function) مقابل التكرارات. يمكن ان نرى من هذين الشكلين ان عملية التقارب تنتج منحنيات ملساء مع تزايد سريع عند البداية ومن ثم تتباطأ تدريجياً. التجارب التي اجريت عشر مرات للتأكد من ان دالة الملائمة تتقارب إلى قيمة دنيا.

اداء التقارب لدالة الملائمة لأحسن قيمة توفرت بواسطة PSA وكان التقارب بمقدار 0.41 في اول 450 تكرار في الحالة الاولى.

مع ان، اداء التقارب لـ GAS ودالة الملائمة لأحسن قيمة قد وصل إلى 0.39 في اول 325 تكرار، لكن في الحالة الثانية وصلت المتغيرات لأحسن قيمة قد وصلت للتقارب في 0.39 في 500 تكرار. هذا يوضح ان خوارزمية GAS مع قيم المعاملات تمتلك اداء جيد في تقارب المتغير ( $P_{AB}$ ). على أي حال في حالة متغيرين ( $P_{GE}$  و  $P_{AB}$ ) تقارب دالة الملائمة هي 0.41 في 500 تكرار.

بصفة عامة من النتائج الموضحة في الجدول 7 والشكلين 4 و 5 على التوالي عند اجراء مقارنة بين نتائج المفاضلة بين نموذج ANNi-GAS ونموذج ANNi-PSA:

وجد ان ANNi-GAS يعطي اداء احسن بمعنى ان GAS فعال جدا في حل ANNi وغالبا ما يصل لأفضل معامل اداء من خلال عملية جينية مثل التقاطع والتحول. ووجد ان ANNi-PSA ليست فعالة في نمذجة معامل اداء النظام، هذا بسبب تعدد الاوزان لـ ANNi-PSA لا يكون قادرا على الوصول للافضلية العالمية عندما تمت محاكاة التطور على نفس عدد الاجيال مثل ما حدث مع نموذج ANNi-GAS. العدد الكبير من الاجيال قد يستخدم ولكن هذا ليس مستحب بسبب زمن التقارب الكبير.




مقارنة نتائج المفاضلة بين GAS و PSA موضحة في الجداول والاشكال. النتائج التي تم الحصول عليها بواسطة GAS كانت احسن من PSA، بالأخذ بعين الاعتبار الخطأ الصغير والتقليل الكبير في جهد الحسابات الكمبيوترية لإيجاد افضل حل على ثلاثة فحوصات (B, C, E)، بالإضافة الى ان نتائج GAS اسرع في التقارب، وعليه يمكننا ان نرى ان اداء GAS اكثر فعالية ويعطي حل في حدود 0.36% من المفاضلة العالمية، توفر GAS ايضا حلول مدهشة من ناحية الجودة وكذلك زمن الحسابات الكمبيوترية، وهذا يعود إلى بحث GAS عن التعداد (ليست نقطة واحدة) تشمل المؤثرات الجينية طبيعة حوسبتها المتوازية التي يمكن ان تطبق للتعامل مع تعقيدات المشكلة التي نتعامل معها بدون المزيد من الحسابات الرياضية المعقدة من مثل المؤثرات البسيطة مثل التشفير، وفك التشفير وحساب قيم الاهداف. على أي حال، تتميز PSA ببساطة تركيبها، وامكانية تطبيقها فقط في حدود ضبط المعاملات مثل: عدد الجسيمات، وعدد التكرارات، ووزن العطالة وثوابت التسارع.

هذه النتائج توضح ايضا ان GAS المعتمدة على ANNi تمتلك قدرة مفاضلة اكبر من PSA.




الجدول 7: نتائج مقارنة بين PSA وGSa

Tests	Variables	Particle Swarm Algorithm				Genetic Algorithms				
		<i>Exp</i>	<i>Opt</i>	<i>Error %</i>	<i>CPU Times (s)</i>	<i>Exp</i>	<i>Opt</i>	<i>Error %</i>	<i>CPU Times (s)</i>	
Test B	One var.	$P_{AB}$	9.5	9.41	0.95	40.7	9.5	9.47	0.32	11.3
	Two var.	$P_{AB}$	9.5	9.54	0.42	43.1	9.5	9.52	0.21	14.7
		$P_{GE}$	20	19.87	0.65		20	19.97	0.15	
Test C	One var.	$P_{AB}$	8	8.04	0.5	3.95	8	7.98	0.25	09.5
	Two var.	$P_{AB}$	8	7.84	0.75	4.32	8	7.97	0.37	13.4
		$P_{GE}$	20.5	20.41	0.44		20.5	20.54	0.20	
Test E	One var.	$P_{AB}$	11	10.92	0.73	3.14	11	10.99	0.10	10.9
	Two var.	$P_{AB}$	11	10.87	1.18	3.24	11	11.09	0.81	16.2
		$P_{GE}$	21	20.79	1.00		21	20.96	0.19	



الشكل 4 دالة الملائمة مقابل التكرار لمتغير واحد  $P_{AB}$



الشكل 5 دالة الملائمة مقابل التكرار لمتغيرين  $P_{GE}$  و  $P_{AB}$

## 6. الاستنتاجات Conclusions

تم اجراء عملية مفاضلة لمعامل الاداء COP لعملية تنقية المياه المدمج في محول امتصاص حراري مع اعادة تدوير الطاقة وذلك باستخدام شبكة عصبية اصطناعية معكوسة لكي نحسب قيم الادخال المثالية من معامل الاداء المثالي والايخذ بالاعتبار قيم الادخال اعلاه المعروفة جيدا باستثناء قيمة الادخال المطلوبة مثل PAB و PGE. ثم تم تطبيق كلا من الخوارزميات الجينية وخوارزمية اسراب الجسيمات في المشكلة المعكوسة لمفاضلة شروط التشغيل الامثل. مزيد من المقارنة لنتائج المفاضلة بين الخوارزميات الجينية واسراب الجسيمات بينت ان GAS تفوقت على PSA، واكثر سرعة في التقارب (اقل من ثانيتين)، وهذا مناسب بشكل كافي للتحكم المباشر في عملية تنقية المياه المدمجة في محول امتصاص حراري مع اعادة تدوير الطاقة. كما ان الخوارزميات الجينية الموضحة في هذا البحث العلمي سوف يكون مفيدا في تقليل جهد



الحسابات الكمبيوترية بينما كلا من عملية المفاضلة ومهندسو الضمانة للوصول عند اقرب حل مثالي لا يمكن ان نحصل عليه بسهولة باستخدام برامج النمذجة العامة او من خلال التجربة والخطأ. على أي حال هذه النتائج مهم جدا لأنها تشرح فعالية GAS في حل المشكلة المعقدة. في النهاية فان تنفيذ عملية المفاضلة باستخدام ANNi مدربة مدمجة في GAS قل بشكل كبير زمن الحسابات الكمبيوترية مع تقارب احسن للحل المثالي، ولتعزيز اداء نظام تنقية المياه بواسطة مكثف نظام تنقية المياه.

الطريقة الموضحة في هذا البحث العلمي سوف تكون مفيدة في تقليل جهد الحسابات الكمبيوترية في اجراء مفاضلة لمعامل الاداء لنظام يشغل حيز كبير.

**تمت الترجمة في المركز العلمي للترجمة**

**11-7-2012**

**[www.trgma.com](http://www.trgma.com)**