



المنتجات الكيميائية ونمذجة العملية

Chemical Product and Process Modeling

المقالة رقم 7

2012

العدد السابع، الإصدار الأول

نماذج ANN و ANFIS للتنبؤ بـ COP في عملية تنقية المياه
الدمجة في محول الحرارة مع إعادة تدوير الطاقة

ANN and ANFIS Models for COP Prediction of a Water
Purification Process Integrated to a Heat Transformer
with Energy Recycling

Youness El Hamzaoui, *Autonomous University of Morelos State*

J.A Hernandez, *Autonomous University of Morelos State* **Abraham Gonzalez**

Roman, *Autonomous University of Morelos State*

José Alfredo Rodríguez Ramírez, *Autonomous University of Morelos
State*



نماذج ANN و ANFIS لتنبؤ بـ COP في عملية تنقية المياه المدمجة في محول الحرارة بإعادة تدوير الطاقة

ANN and ANFIS Models for COP Prediction of a Water Purification Process Integrated to a Heat Transformer with Energy Recycling

Youness El Hamzaoui, J.A Hernandez, Abraham Gonzalez Roman, and José

Alfredo Rodríguez Ramírez

الخلاصة

تهدف هذه الدراسة إلى عرض مقارنة بين الشبكات العصبية الاصطناعية (ANN artificial neural network) والنظام العصبي للاستدلال الغامض (ANFIS adaptive neuro fuzzy inference system) بهدف التنبؤ بمعامل الأداء (COP) لعملية تنقية المياه المدمجة في نظام محول امتصاص حراري مع تدوير الطاقة. اخذت نماذج ANN و ANFIS بعين الاعتبار كلا من درجة حرارة المدخلات والمخرجات لكل من المكونات الأربعة (الماص والمولد والمبخر والمكثف)، بالإضافة إلى ضغطين وتراكيز $\text{LiBr}+\text{H}_2\text{O}$. أجريت النتائج التجريبية للتأكد من صحة نتائج طريقة ANN وطريقة ANFIS. تم استخدام تغذية امامية بالنسبة للشبكة مع طبقة مخفية واحدة، وخوارزمية Levenberg-Marquardt للتعلم، ودالة ترحيل المماس السيني للقطاع الزائد sigmoid transfer. hyperbolic tangent. تم الحصول على أفضل ملائمة لبيانات تدريب مناسبة بثلاث خلايا عصبية في الطبقة المخفية. باستخدام مجموعة بيانات التحقق، كانت بيانات المحاكاة والبيانات العملية متفقة جيداً ($R^2 > 0.9980$). كما ان تطوير نموذج ANFIS تم باستخدام نفس متغيرات الإدخال. القيم الإحصائية اعطيت كما في الجداول. المقارنة بين النموذجين تبين أن ANN يقدم نتائج أفضل من نتائج ANFIS. وفي النهاية يوضح هذا البحث العلمي ملائمة نمودجي ANN و ANFIS للنمذجة الكمية مع دقة معقولة.



الكلمات المفتاحية: تنقية المياه water purification، محول امتصاص الحرارة absorption، heat transformer، توقع معامل الاداء COP prediction، الشبكات العصبية الاصطناعية artificial neural network، نظام التكيف العصبي للاستدلال الغامض adaptive neuro، دوال العضوية fuzzy inference system، membership functions.

ملاحظات الكاتب: يبدي كل من يونس الحمزوري و A. González امتنانهم لـ Consejo Nacional de Ciencia y Tecnología (CONACyT) وذلك علي المنحة الدراسية المقدمة للدارسات العليا - الاتصال مع المؤلف على alfredo@uaem.mx.

يتكون نظام محول امتصاص الحرارة من جهاز ديناميكي حراري قادر علي إنتاج حرارة مفيدة علي مستوي حراري أعلى 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 أعلى 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، وعلی 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 كالأخلايا العصبية في الدماغ البيولوجي. ولديها القدرة علي نمذجة العمليات بواسطة التعلم من بيانات المدخلات والمخرجات، وبدون معرفة حسابية عن العمليات، كما وتتطلب تدريب إحصائي أقل، وتكمن القدرة علي تقدير قيمة المعاملات المهمة في كونها تعتمد علي توفر معلومات قليلة، والقدرة الحصرية علي اكتشاف العلاقات المعقدة الغير خطية بين المتغيرات التابعة والمستقلة، والقدرة علي اكتشاف جميع التفاعلات ما بين قيم المتنبئ، ونظرياً القدرة علي تقريب أي دالة بطريق ثابتة وفعالة، والتنفيذ بشكل أفضل في حالة عدم وجود توجهات مكانية غير خطية في قواعد البيانات ومع وجود خوارزميات تعليم متعددة. تبعاً لذلك، يمكن احتساب الـ COP خلال عملية on-line، عندما تكون متغيرات الإدخال معروفة في عملية تنقية المياه المدمجة مع محول الحرارة المصاحب لتدوير الطاقة.



المقترحات الضبابية هي عبارات تتصل بمتغيرات ضبابية. مفهوم المجموعة الضبابية هي أساس المنطق الضبابي. المجموعة الضبابية هي مجموعة بدون وضوح، وبدون حدود معرفة بوضوح. النظام العصبي للاستدلال الغامض (ANFIS) و ANN يمكن النظر لها كأداة قوية في خوارزمية التعرف على النمط الإحصائي ولإعداد نموذج مكافئ بأفضلية إمكانات دوال التقريب والتصنيف (Singh et al., 2007). تقدم النماذج الضبابية مزايا أكثر من النماذج الرياضية، فعلمية الاستدلال أقرب إلى التفكير البشري وأسهل في التعامل مع النظم المعقدة الغير خطية. أكثر من ذلك، يمكن أن تكون هذه الطرق مفيدة للناس الغير خبراء في النمذجة.

يمكن دراسة مهام ANFIS من خلال صندوق أدوات الضبابية Fuzzy toolbox الخاص ببرنامج Matlab طبقاً لـ (Jang, 1993). يشار لـ ANFIS علي أنه نظام تعلم ضبابي عصبي ويضبط نظام استنتاج ضبابي مع خوارزمية back-propagation المعتمد على مجموعة من بيانات المدخلات/المخرجات. النمذجة الضبابية وصندوق التعريف تشكل نموذج ضبابي Takagi–Sugeno من بيانات التجميع الضبابية لفضاء الناتج باستخدام خوارزمية Gustafson– Kessel (Babuska, 1998). اكتسبت الأنظمة الضبابية شعبية متزايدة في الهندسة خلال العقود القليلة السابقة، إيجاد تطبيقات متعددة جداً في نظرية التحكم، والتعرف على النمط، أنظمة الطاقة وأنظمة التنبؤ الخبيرة (Jang and Gulley, 1996). بالإضافة إلي المزايا السابقة، يمكن دمج الأنظمة الضبابية مع الشبكات العصبية لإيجاد ANFIS والذي يملك المزايا التالية: الكفاءة في الاحتساب، يعمل بشكل جيد مع التقنيات الخطية، ويعمل بشكل جيد مع التحسين والأساليب المتكيفة، وتزود بتواصل مضمون مع سطح الإخراج، وهو مناسب جداً مع التحليل الرياضي. لقد وجدنا القليل من البحوث العلمية المنشورة ذات الصلة بنمذجة استخدام الطاقة وكفاءة استخدام الطاقة في عملية التسخين والتبريد. في هذه المادة، يوجد الكثير من الدراسات حول ANN و ANFIS لأنظمة الطاقة. فحص (Bechtler et al (2001a) تطبيقات الـ ANN لأنظمة الطاقة. قدم (Bechtler et al (2001a) نموذج ANN لتقدير كفاءة الحالة الثابتة لمضخة ضغط البخار. قدم (Swider (2003) مقارنة معمقة لنماذج بنيت تجريبياً لنمذجة الحالة الثابتة في ضاغط البخار بمبردات السوائل. طور (Yang et al (2003) نموذج ANN محسن ليحدد أفضل وقت لتشغيل نظام التدفئة في مبني. حدد (Arcaklioglu et al (2004) كفاءة مضخة تسخين ضاغط بخار باستخدام ANN. استخدم (Ertunc and Hosoz (2006) نموذج ANN طريقة لتقدير معاملات كفاءة مختلفة لنظام تبريد R123a بتوظيف مكثف مبخر. قدم (Ceylan & Aktas (2008) مجفف بندق hazelnut dryer من خلال



مضخة تسخين باستخدام ANN. طور (Hernández et al., 2008) نموذج تنبؤ لعملية تنقية مياه متكاملة مع محول امتصاص حرارة باستخدام ANN للحصول علي خط تنبؤ لـ COP. طور (Sahu et al., 2008) نموذج التنبؤ بقابلية التسخين العفوي للفحم مع نظام خبير ضبابي و ANN. وصف (Esen & Inalli, 2010) إمكانية تطبيق ANN و ANFIS لتقدير كفاءة مضخة تسخين من مصدر عمودي الأرضية. بالمقابل، وفي الوجود العام تحاول تقنيات حل مشاكل متعددة للمحاكاة وتحسين أداء عملية الهندسة الكيميائية، بمثل طريقة 'monte carlo'، الخوارزمية الجينية، تحسين اسراب الجزينات، الشبكات العصبية المعكوسة (Chang et al., 2011; El Hamzaoui et al., 2010; El Hamzaoui et al., 2011; Gharebagh & Mostoufi, 2004; Hamidipour et al., 2005; Hernández et al., 2009; Iranshahi et al., 2004; Mostoufi et al., 2005 and Cortés et al., 2009). تقدم هذه الورقة العملية تنبؤ كفاءة الاداء COP لتكامل عملية تنقية المياه في محول حراري مع تدوير للطاقة، بمساعدة نظام استقرار عصبي قابل للتكيف ANFIS مع ادوات توقع مثل الشبكات العصبية الاصطناعية. تمت عمليات التحليل الإحصائي بهدف تقدير المعامل الإحصائي لقيم COP. وتم التأكد من النموذج بتطبيق بيانات تجريبية مقدمة من (Morales, 2005).

2. وصف النظام والبيانات التجريبية

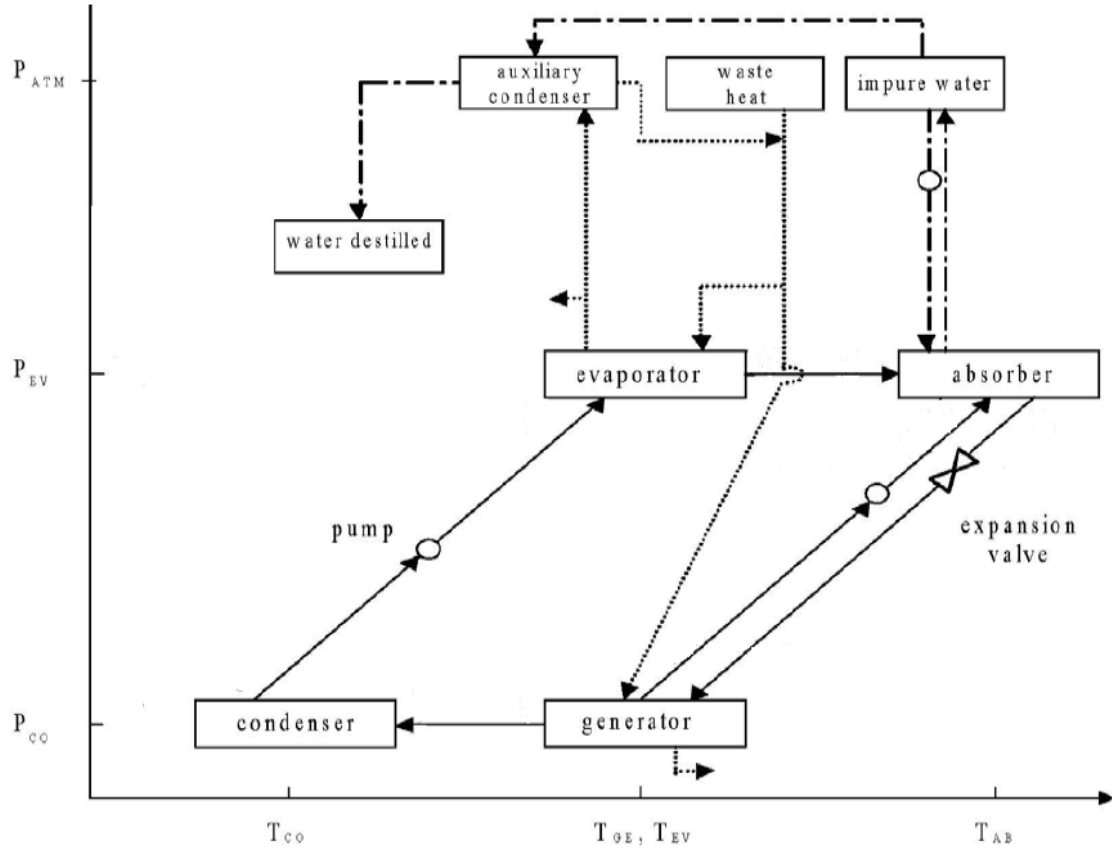
يبين الشكل 1 رسم تخطيطي لمحول حراري. الحرارة المفيدة (Q_{AB}) هي نتيجة التفاعل بين الغاز المسال العامل والمحول الماص (والذي ينتج من المبخر والمولد على التوالي). بعد هذه العملية، يدخل محلول مائي مخفف water/LiBr، في المولد. داخل المولد، يستقبل المحلول المائي كمية من الحرارة (Q_{GE}) من مزود حراري خارجي. تحت هذه الظروف، يغادر بخار السائل قيد العمل المولد ويدخل إلي مكثف حيث يفقد حرارة (Q_{CO}) ويكثف السائل. السائل المكثف يدخل إلي المبخر حيث تزود الحرارة الخارجية (Q_{EV}) ويتبخر السائل قيد العملية إلي ضغط مرتفع ويذهب إلي 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 إلي نقطة الغليان وتتبخر جزئياً. في الحالتين (الماء السائل والبخار) تغادر الماص وينفصل من خلال فاصل للطور. يعود طور السائل إلي 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 وبإعادة مرتين على الأقل. وكانت الترتيبات علي الشكل 2×8 بأربع ساعات من جمع المعلومات. لذلك، تم الحصول علي قاعدة بيانات تحتوي على 11882 عينة. ملخص لـ 16 معامل تشغيل (10 مستويات حرارة و 4 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 (مزودج 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 H_2O في المبخر والمكثف.

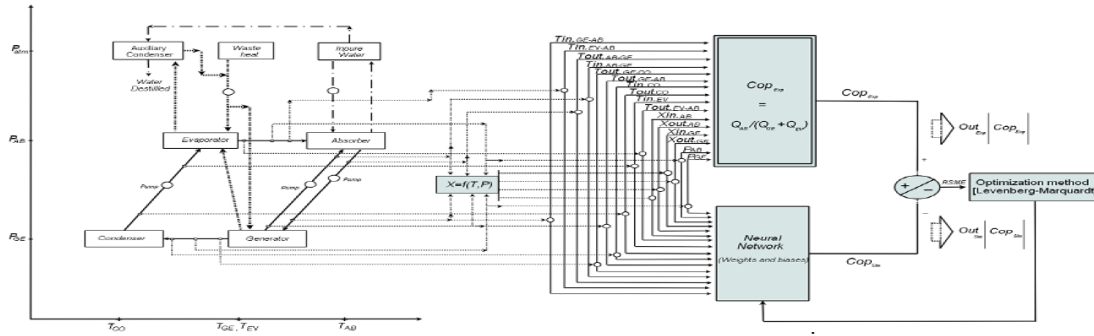


الشكل 1 الرسم التوضيحي لتكامل عملية تنقية المياه مع محول امتصاص حرارة مع تدوير الطاقة. الخط المستمر (-) يمثل محول امتصاص الحرارة، الخط والنقطة (- . -) هما عملية تنقية المياه والخط المنقط (.....) هو عملية تدوير الطاقة.



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



الشكل 2 معمارية الشبكة المتكررة لقيم وإجراءات COP المستخدمة في نظام تعلم الشبكات العصبية

الجدول 2: مقارنة لعشرة خوارزميات للانتشار العكسي مع ثلاث خلايا عصبية في الطبقة الخفية

Backpropagation algorithms	Function	RMSE	R ²	RSD %	Best linear equation
Levenberg-Marquardt	<i>trainlm</i>	9.5219×10^{-7}	0.998	2.9343×10^{-4}	$Y=0.998X+0.306$
Batch gradient descent	<i>traingd</i>	8.3247×10^{-6}	0.988	0.0026	$Y=0.986X+0.927$
Batch gradient descent with momentum	<i>traindm</i>	7.8918×10^{-5}	0.987	0.0243	$Y=0.988X+0.837$
Polak-Ribiere conjugate gradient	<i>traincgp</i>	7.9934×10^{-5}	0.979	0.0246	$Y=0.957X+2.53$
Scaled conjugate gradient	<i>trainscg</i>	6.4627×10^{-4}	0.974	0.1992	$Y=1.020X-0.783$
BFGS quasi-Newton	<i>trainbfg</i>	6.9871×10^{-4}	0.971	0.2153	$Y=0.982X+1.23$
Powell-Beale conjugate gradient	<i>traincgb</i>	6.9997×10^{-4}	0.965	0.2157	$Y=0.960X+2.03$
One step secant backpropagation	<i>trainoss</i>	6.9287×10^{-3}	0.782	2.1352	$Y=0.617X+45.3$
Fletcher-Reeves conjugate gradient	<i>traincgf</i>	6.4159×10^{-2}	0.725	19.7716	$Y=0.425X+34.8$
Variable learning rate	<i>trainidx</i>	6.9781×10^{-1}	0.718	215.0416	$Y=0.386X+38$

3. المواد والطرق

1.3. الشبكات العصبية الصناعية

استخدمت قواعد البيانات التي تم ذكرها في الجزء الثاني بنجاح لتدريب نموذج ANN باستخدام عملية الانتشار العكسي، وذلك بهدف التنبؤ بقيمة COP في نظام تنقية المياه المدمج في محول حراري مع تدوير للطاقة. بالمقابل كما هو مبين في الشكل 2، أثبتنا ان ثلاثة طبقات ANN وثلاث خلايا عصبية في الطبقة الخفية، يمكن أن تتنبأ بنجاح بنتائج تجربة نظام تنبؤ COP في هذا البحث العلمي.

لكن بهدف فحص أفضل تدريب لخوارزمية الانتشار العكسي، تم دراسة عشرة خوارزميات للانتشار العكسي، ويبين الجدول 2 مقارنة بين خوارزميات انتشار عكسي مختلفة. ويمكن ان يكون لخوارزمية تدريب الانتشار العكسي Levenberg- Marquardt قيمة أصغر لخطأ جذر متوسط المربع (RMSE) وانحراف نسبي قياسي (RSD) على التوالي. بالإضافة إلي ذلك وجدنا أن التدريب بواسطة خوارزمية Levenberg- Marquardt يمكن أن يعمل بسلاسة علي الحواسيب بذاكرة موسعة أقل (EMS)، وبوقت تدريب أسرع من خوارزمية انتشار عكسي اخري. بسبب تصميم خوارزمية Levenberg- Marquardt الهادف إلي الوصول إلي سرعة الدرجة الثانية من التدريب بدون الاضطرار إلي حساب مصفوفة Hessian. عندما تكون دالة الكفاءة علي شكل مجموع المربعات (كما هي الحالة النموذجية في شبكات التغذية الأمامية، feed-forward networks)، لذلك فإن مصفوفة Hessian يمكن أن تقرب على النحو التالي:

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

ويمكن حساب الميل على النحو التالي:

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

حيث تكون J هي مصفوفة Jacobian والتي تحتوي علي أول اشتقاقات أخطاء الشبكة بالاعتماد علي الأوزان والانحياز، و e هي متجه أخطاء الشبكة. يمكن حساب مصفوفة Jacobian من خلال الية انتشار عكسي قياسية والتي هي أقل تعقيداً بكثير من حساب مصفوفة Hessian. يستخدم خوارزمية Levenberg-Marquardt هذا التقريب لمصفوفة Hessian كاستخدام التحديث الشبيه بنيوتن التالي:

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

عندما يصبح المقدار القياسي μ صفراً، فهذه تكون طريقة نيوتن، باستخدام تقريب مصفوفة Hessian. عندما تكون μ كبيرة، نحصل على انحدار منخفض مع خطوة صغيرة الحجم. حسب (Hagan & Menhaj (1994)، وتعتبر طريقة نيوتن أسرع وأكثر دقة بالقرب من أقل خطأ، لذلك فإن الهدف هو الانتقال لطريقة نيوتن بأسرع وقت ممكن لذلك تم تقليل قيمة μ بعد كل خطوة ناجحة (انخفاض في دالة الكفاءة) ويتم زيادتها فقط عندما تعمل الخطوة التجريبية على زيادة دالة الكفاءة. وفي هذا السياق، تنتج دالة الكفاءة دائماً عند كل دورة تكرار لخوارزمية (Khataee &

(Kasiri.,2010). وهنا يكمن السبب في هذه الاختلافات، وعليه تعتبر خوارزمية Levenberg-Marquardt خوارزمية تدريب في هذه الدراسة العلمية.

على أي حال، فإن كفاءة نموذج ANN تم قياسها إحصائياً باستخدام خطأ متوسط الجذر التربيعي (RMSE) وباستخدام الانحراف النسبي المعياري (RSD) ومعامل التراجع أو الانحسار (R2)، والتي يتم حسابها باستخدام قيم تجريبية وتوقعات شبكة ويتم اعتماد هذه الحسابات كمعاملات لملائمة النموذج ويتم الحصول عليها كما يلي:

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

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

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

وذلك حيث N هو عدد نقاط البيانات، و $y_{n,pred}$ هي توقع الشبكة و $y_{n,exp}$ هو الاستجابة العملية، و y_m هو متوسط القيم الفعلية و n هو مؤشر للبيانات.

يصور الشكل 2 المذكور ادناه ايضاً معمارية الشبكة المتكررة لقيم COP والعملية المستخدمة في تعلم الشبكة العصبية وأداء الشبكة. لذلك تم اختيار الشبكة بأقل RMSE وأقل RSD وأكبر R2 علي أنها أفضل نموذج ANN.

طبقاً لـ (Hernandez et al., 2008)، يمكن تمثيل النموذج المقترح بالمعادلة التالية:

$$COP = \sum_{s=1} \left[W_o(1,s) \cdot \left(\frac{2}{1 + \exp\left(-2 \left(\sum_{k=1} (IW(s,k) \cdot In(k)) + b1(s) \right)\right)} - 1 \right) \right] + b2 \quad (8)$$

حيث s هو عدد الخلايا العصبية في الطبقة الخفية، k هو عدد المدخلات، W_o و b هما الأوزان والانحياز على التوالي. يوضح الجدول 4 المعاملات القابلة للضبط والتعديل (W_o, b)، (b_1, b_2) للنموذج المفترض. على أي حال، يمكن كتابة المعادلة (8) على النحو التالي:

$$COP = 2 \left[\frac{W_o(1)}{1+e^{X_1}} + \frac{W_o(2)}{1+e^{X_2}} + \frac{W_o(3)}{1+e^{X_3}} \right] - (W_o(1) + W_o(2) + W_o(3)) + b_2 \quad (9)$$

يبدو من الواضح بناءً على المعادلة (9) أنه من الممكن محاكاة COP في نظام تنقية المياه المدمج في محول حراري مع تدوير للطاقة. على أي حال، في عدة حالات تكمن المشكلة في أن COP تم حسابها بواسطة ANN الغير مثالية في النظام، ولذلك من الضروري معرفة قيم المدخلات بشكل جيد عند اعطاء قيمة COP المطلوبة.

3.2 الشبكات المتكيفة والمبنية على نظام استدلال ضبابي (ANFIS)

الشبكات المتكيفة وكما يشير اسمها هي شبكة يشتمل بنائها على عقد ووصلات متجهة خلالها والتي بدورها تقوم بتوصيل تلك العقد. علاوة على ذلك، فإن الأجزاء أو جميع العقد تكون قابلة للتكيف، والتي تعني ان مخرجات كل من هذه العقد تعتمد على معاملات التدريب المبدئية لهذه العقد وقاعدة التعليم المحددة لكيفية تغيير هذه المعاملات بهدف تقليل الأخطاء الموصوفة إلي الحد الأدنى (Jang, 1993). للتبسيط، نفترض نظام الاستدلال الضبابي قيد البحث يمتلك مدخلان هما x و y ومخرج واحد هو z . افترض أن قاعدة المبدأ تحتوي علي قاعدتين ضبابيتين لـ if then لنوع Sugeno و Takagi :

Rule 1: *If (x is A_1) and (y is B_1) then ($f_1 = p_1x + q_1y + r_1$).*

Rule 2: *If (x is A_1) and (y is B_1) then ($f_2 = p_2x + q_2y + r_2$).*

حيث A_i و B_i هما مجموعتان ضبابيتان، f_i هي مخرجات داخل المنطقة الضبابية المحددة بواسطة القاعدة الضبابية، p_i و q_i و r_i هم معاملات التصميم والمحددة خلال عملية التدريب. معمارية نموذج ANFIS لتطبيق هاتان القاعدتان موضحة في الشكل 3، حيث تبين الدائرة عقدة ثابتة، بينما يشير المربع لعقدة متكيفة (Guler and Ubeyli, 2005).

الطبقة 1: لكل عقدة i في هذه الطبقة هي عقدة مربعة بدالة عقدة على النحو التالي

$$O_i^1 = \mu_{A_i}(x), i=1,2 \quad (13)$$

$$O_i^1 = \mu_{B_{i-2}}(y), i=3,4 \quad (14)$$

حيث x هو المدخل إلى العقدة i ، و A_i هو الاسم اللغوي (كبير، صغير، إلخ). المرتبط مع دالة العقدة وحيث $\mu_{A_i}(x)$ ، $\mu_{B_{i-2}}(y)$ يمكن أن تحتوي على أي دوال عضوية ضبابية (MFs) عادةً نختار $\mu_{A_i}(x)$ لتكون على شكل جرس بقيمة عليا 1 وقيمة دنيا 0 مثل

$$\mu_{A_i} = \frac{1}{1 + \left\{ \left(\frac{x - c_i}{a_i} \right)^2 \right\}^{b_i}} \quad (15)$$

حيث a_i و b_i و c_i هي مجموعة المعاملات. يشار إلى هذه المعاملات في هذه الطبقة كمعاملات المقدمة.

الطبقة 2: العقد في هذه الطبقة ثابتة. وهذه العقد تعنون بـ M للإشارة إلى انها تلعب دور المضاعف البسيط. ومخرجات هذه العقد تعطى على النحو التالي:

$$O_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \quad i=1,2 \quad (16)$$

والتي تعرف باسم firing strengths للقواعد.

الجدول 3 المعاملات القابلة للتعديل (الأوزان والانحياز) والتي تم الحصول عليها من النموذج

المقترح مع قيم $S=3$, $K=16$



$IW_{(s,k)}$	$W_i(1,1)$	$W_i(1,2)$	$W_i(1,3)$	$W_i(1,4)$	$W_i(1,5)$	$W_i(1,6)$	$W_i(1,7)$	$W_i(1,8)$	$W_i(1,9)$	$W_i(1,10)$	$W_i(1,11)$	$W_i(1,12)$	$W_i(1,13)$	$W_i(1,14)$	$W_i(1,15)$	$W_i(1,16)$
	1.04	1.62	-8.54	1.79	7.15	-1.19	-1.09	2.51	-0.003	-2.34	242.39	-159.45	-172.58	20.83	-19.47	-65.58
	$W_i(2,1)$	$W_i(2,2)$	$W_i(2,3)$	$W_i(2,4)$	$W_i(2,5)$	$W_i(2,6)$	$W_i(2,7)$	$W_i(2,8)$	$W_i(2,9)$	$W_i(2,10)$	$W_i(2,11)$	$W_i(2,12)$	$W_i(2,13)$	$W_i(2,14)$	$W_i(2,15)$	$W_i(2,16)$
	20.07	-6.46	-46.46	6.32	26.42	-16.54	-14.63	37.45	0.32	4.41	-216.87	135.77	115.08	10.27	17.52	-47.03
	$W_i(3,1)$	$W_i(3,2)$	$W_i(3,3)$	$W_i(3,4)$	$W_i(3,5)$	$W_i(3,6)$	$W_i(3,7)$	$W_i(3,8)$	$W_i(3,9)$	$W_i(3,10)$	$W_i(3,11)$	$W_i(3,12)$	$W_i(3,13)$	$W_i(3,14)$	$W_i(3,15)$	$W_i(3,16)$
	-3.74	-0.11	3.51	-0.54	0.64	0.34	-0.02	0.001	0.003	0.11	-0.43	-7.14	12.61	3.29	-0.15	-1.11
$W_6(s)$	$W_6(1)$	$W_6(2)$	$W_6(3)$													
	-0.18	0.02	-0.88													
$b1(s)$	$b1(1)$	$b1(2)$	$b1(3)$													
	129.09	-17.75	-6.49													
$b2$	0.24															

حيث

$$X_1 = -2.(IW_{i(1,1)}Tin_{GE-AB} + IW_{i(1,2)}Tin_{EV-AB} + IW_{i(1,3)}Tout_{AB-GE} + IW_{i(1,4)}Tin_{AB-GE} + IW_{i(1,5)}Tout_{GE-CO} \dots \dots \dots + IW_{i(1,6)}Tout_{GE-AB} + IW_{i(1,7)}Tin_{CO} + IW_{i(1,8)}Tout_{CO} + IW_{i(1,9)}Tin_{EV} + IW_{i(1,10)}Tout_{EV-AB} \dots \dots \dots + IW_{i(1,11)}Xin_{AB} + IW_{i(1,12)}Xout_{AB} + IW_{i(1,13)}Xin_{GE} + IW_{i(1,14)}Xout_{GE} + IW_{i(1,15)}P_{AB} + IW_{i(1,16)}P_{GE} + bl_{(1)}) \quad (10)$$

$$X_2 = -2.(IW_{i(2,1)}Tin_{GE-AB} + IW_{i(2,2)}Tin_{EV-AB} + IW_{i(2,3)}Tout_{AB-GE} + IW_{i(2,4)}Tin_{AB-GE} + IW_{i(2,5)}Tout_{GE-CO} \dots \dots \dots + IW_{i(2,6)}Tout_{GE-AB} + IW_{i(2,7)}Tin_{CO} + IW_{i(2,8)}Tout_{CO} + IW_{i(2,9)}Tin_{EV} + IW_{i(2,10)}Tout_{EV-AB} \dots \dots \dots + IW_{i(2,11)}Xin_{AB} + IW_{i(2,12)}Xout_{AB} + IW_{i(2,13)}Xin_{GE} + IW_{i(2,14)}Xout_{GE} + IW_{i(2,15)}P_{AB} + IW_{i(2,16)}P_{GE} + bl_{(2)}) \quad (11)$$

$$X_3 = -2.(IW_{i(3,1)}Tin_{GE-AB} + IW_{i(3,2)}Tin_{EV-AB} + IW_{i(3,3)}Tout_{AB-GE} + IW_{i(3,4)}Tin_{AB-GE} + IW_{i(3,5)}Tout_{GE-CO} \dots \dots \dots + IW_{i(3,6)}Tout_{GE-AB} + IW_{i(3,7)}Tin_{CO} + IW_{i(3,8)}Tout_{CO} + IW_{i(3,9)}Tin_{EV} + IW_{i(3,10)}Tout_{EV-AB} \dots \dots \dots + IW_{i(3,11)}Xin_{AB} + IW_{i(3,12)}Xout_{AB} + IW_{i(3,13)}Xin_{GE} + IW_{i(3,14)}Xout_{GE} + IW_{i(3,15)}P_{AB} + IW_{i(3,16)}P_{GE} + bl_{(3)}) \quad (12)$$

الطبقة 3: كل عقدة في هذه الطبقة هي عقدة دائرية تعنون بـ N . وتقوم العقدة ith بحساب نسبة قاعدة ith firing strengths لمجموع كل قواعد firing strengths:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (17)$$

بهدف التسهيل، سوف نطلق على مخرجات هذه الطبقة اسم normalized firing strengths.

الطبقة الرابعة: في هذه الطبقة، العقد هي عقد متكيفة. ومخرجات كل عقدة في هذه الطبقة هو ببساطة ناتج ضرب normalized firing strengths ومتعدد الحدود من الرتبة الأولى (لترتبة الأولى من نموذج Sugeno). لذلك فان مخرجات هذه الطبقة تعطى على النحو التالي:

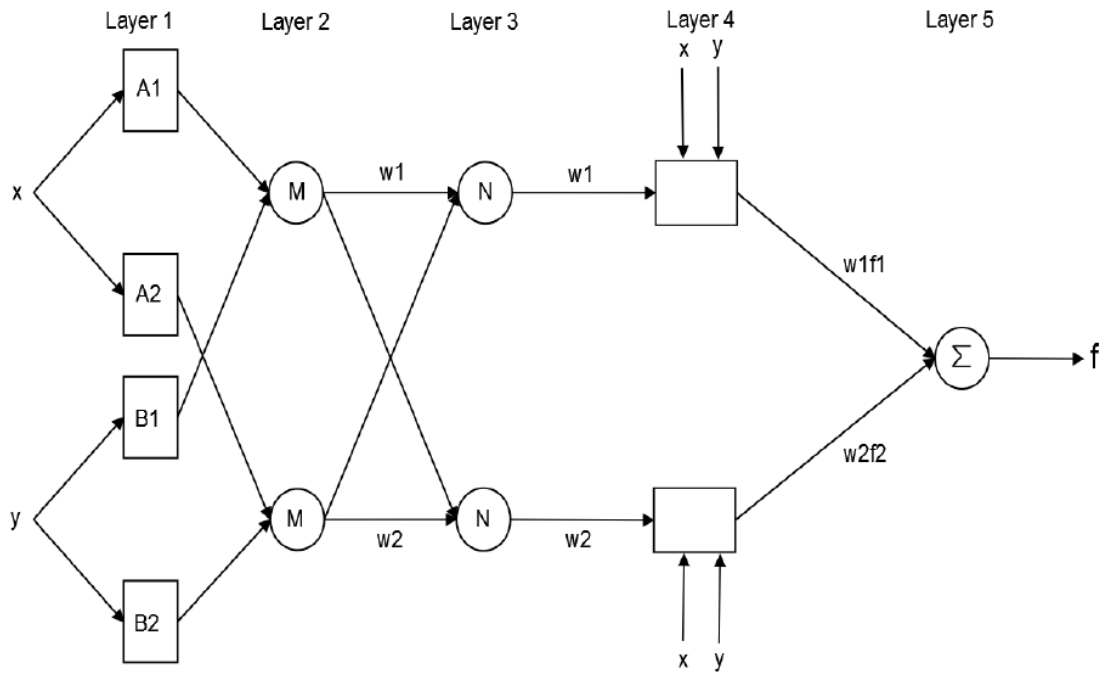
$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad i=1,2 \quad (18)$$

المعاملات في هذه الطبقة سيتم الإشارة إليها علي انها معاملات ناتجة.

الطبقة 5: العقدة المنفردة في هذه الطبقة هي عقدة دائرية تعنون بـ Σ والتي تقوم بحساب إجمالي المخرجات كمجموع لكل الإشارات الداخلة أي انه،

$$O_f = \sum_{i=1}^2 w_i f_i = \frac{\sum_{i=1}^2 w_i f_i}{w_1 + w_2} \quad (19)$$

يمكننا رؤية وجود طبقتين متكيفتين في معمارية ANFIS وهما الطبقة الأولى والطبقة الرابعة. في الطبقة الأولى يوجد ثلاث معاملات قابلة للتعديل $\{a_i, b_i, c_i\}$ ، والمرتبطة في مدخلات الوظائف العضوية الضبابية MFs هذه المعاملات تسمى معاملات اساس في الطبقة الرابعة، يوجد ايضا ثلاث معاملات قابلة للتعديل $\{p_i, q_i, r_i\}$ مرتبطة مع متعددة الحدود من الدرجة الأولى. هذه المعاملات تسمى معاملات ناتجة (Jang, 1993; Sengur, 2008a; Sengur, 2008b; Varol et al., 2007; Despange and Massart, 1998; Jang, 1993; Sengur, 2008a; Sengur, 2008b; Varol et al., 2007)



الشكل 3 معمارية ANFIS

3.2.1 خوارزمية التعلم الـ ANFIS

تهدف خوارزمية التعلم لهذه المعمارية إلى ضبط جميع المعاملات القابلة للتغيير لجعل مخرجات نموذج الـ ANFIS تتطابق مع بيانات التدريب. لاحظ هنا ان هذه المعاملات a_i و b_i و c_i لدالة العضوية (MF) ثابتة وتصف السيجما والميل والوسط لشكل الجرس لـ MF على التوالي. طبقاً لـ (Guler and Ubeyli, 2005)، يمكن كتابة مخرجات نموذج الـ ANFIS على النحو التالي:

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \quad (20)$$

بتعويض المعادلة (19) في المعادلة (20) يؤدي إلي

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad (21)$$

بتعويض قواعد if-then الضبابية في المعادلة (21) تصبح على النحو التالي:

$$f = \bar{w}_1(p_1x + q_1y + r_1) + \bar{w}_2(p_2x + q_2y + r_2) \quad (22)$$

بعد الترتيب يمكن كتابة المخرج كما يلي:

$$f = (\bar{w}_1x)p_1 + (\bar{w}_1y)q_1 + (\bar{w}_1)r_1 + (\bar{w}_2x)p_2 + (\bar{w}_2y)q_2 + (\bar{w}_2)r_2 \quad (23)$$

والتي تكون بمثابة علاقة خطية لتركيبية من المعاملات الخطية القابلة للتغيير p_1, q_2, r_1, p_2 ، ويمكن استخدام طريقة least squares للتعرف بسهولة علي القيم الافضل لهذه المعاملات. عندما تكون المعاملات الأساسية غير مثبتة، يكون فضاء البحث أكبر وتقارب التدريب يصبح أبطأ. يمكن الاعتماد على خوارزمية هجينة تجمع بين طريقة least squares وطريقة تناقص الميل لحل هذه المشكلة. تتألف الخوارزمية الهجينة من مسار امامي ومسار خلفي. يمكن استخدام طريقة least squares (مسار امامي) لتحسين المعامل التابع مع المعامل الأساسي المثبت. عندما نحصل على أفضل معاملات الناتج، يبدأ المسار الخلفي على الفور. تستخدم طريقة تناقص الميل التدريجي (مسار خلفي) لضبط أفضل معامل اساسي مرتبط للمجموعة الضبابية في مجال الإدخال. يتم حساب مخرجات الـ ANFIS بتوظيف المعامل التابع والذي وجد في المسار الامامي. يستخدم خطأ المخرج لتكبير المعامل الأساسي مع طرق

خوارزمية الانتشار الخلفي القياسية. لقد تم برهنة إثبات أن هذه الخوارزمية الهجينة تتمتع بكفاءة عالية في تدريب نموذج الـ ANFIS. (Despange and Massart, 1998; Esen and Inalli, 2010; Jang, 1993; Sengur, 2008a; Sengur, 2008b; Varol et al., 2007).

3.3 نماذج ANN و ANFIS لدراسة الحالة

نموذج ANN، والشبكة العصبية امامية التغذية/الانتشار الخلفي المتعددة الطبقات (MLP/ BP) مع خوارزمية التعلم Levenberg-Marquardt التي تم تطويرها في سياق اعداد هذا البحث العلمي. على الجانب الاخر، كما تم تطوير نموذج ANFIS ايضا باستخدام نفس متغيرات الادخال.

تم تقسيم مجموعة البيانات إلى ثلاثة مجموعات منفصلة عشوائية ومجموعة بيانات التدريب ومجموعة بيانات الفحص. استخدمت مجموعة بيانات التدريب لتدريب نموذج ANN ونموذج ANFIS. ولكن استخدمت مجموعة بيانات الفحص للتحقق من دقة وفعالية نماذج ANN و ANFIS المدربة لعملية تنقية المياه المدمجة في نظام تحويل الحرارة الممتصة مع اعادة تدوير الطاقة.

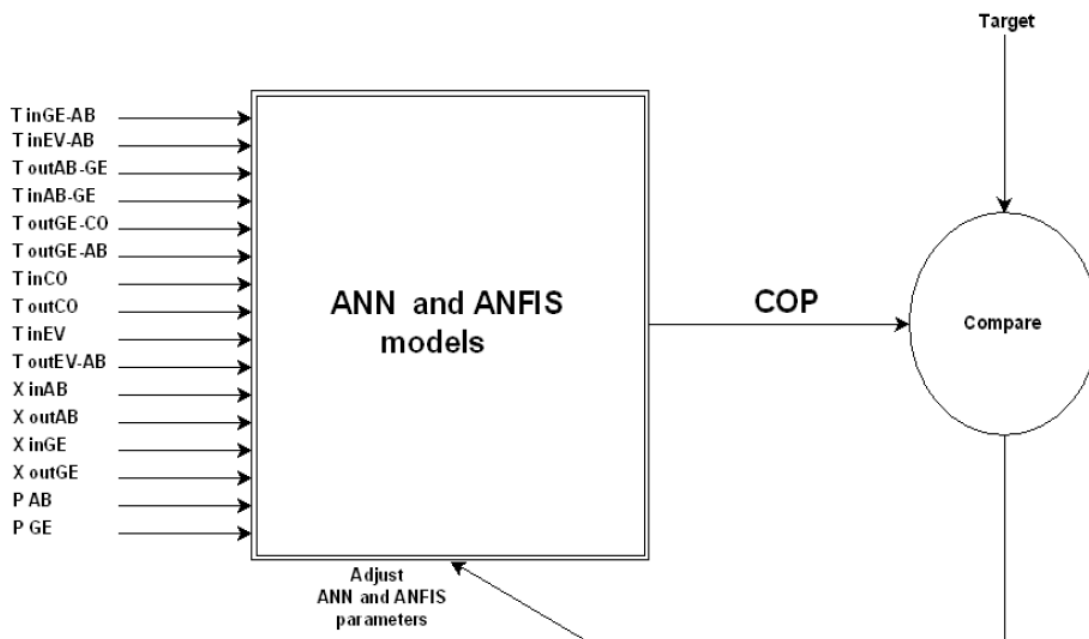
في هذه الدراسة، يوجد في طبقة الادخال 10 مستويات من درجات الحرارة و4 للتركيز و2 للضغط. معامل اداء النظام (COP) يكون في طبقة الاخراج. نظام الـ COP هو المتغير الناتج من نمودجي ANN و ANFIS.

مدخلات هذا النموذج تم تسويتها (normalized) لتصبح في المدى (0.1, 0.9). لذلك فان كل مجموعة بيانات الإدخال X_i (من مجموعة التدريب ومجموعة التحقق ومجموعة الفحص) تم تحجيمها للقيمة الجديدة x_i كما يلي:

$$x_i = 0.8 \left(\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (24)$$

مع ذلك، لم يتم تسوية قيم المخرجات. في الشكل 4 موضح المخطط التمثيلي لنموذجي ANN و ANFIS المقترح. كما ان نرى من الشكل التخطيطي ان نموذجي ANN

و ANFIS قد تم تعديلها أو تدريبها بحيث ان مدخل خاص يؤدي إلي ناتج مستهدف. بشكل عام الكثير من ازواج الادخال والناتج المستهدف استخدمت لتدريب النماذج.



الشكل 4: معمارية ANN و ANFIS المستخدمة في النظام

التحقق من النموذج هو العملية التي فيها متجهات الإدخال من مجموعات بيانات الإدخال/الإخراج والتي لم يتم تدريب نموذج ANN ونموذج ANFIS علي التعامل معها قد قدمت للنموذج المدرب، وذلك بهدف معرفة مدى قدرة النموذج علي التنبؤ بقيم مخرجات مجموعة البيانات المطابقة.

لذلك، العديد من الطرق الإحصائية مثل طريقة متوسط مربع الخطأ (RMSE)، الانحراف المعياري النسبي (RSD) ومعامل الانحدار (R^2)، يمكن أن تستخدم لمقارنة القيم المتنبئة والقيم التجريبية بهدف التحقق من النموذج. لذلك هذه المعاملات الإحصائية يمكن أن تقدر بناءً علي المعادلات.

تم إيقاف تدريب نموذج ANN عندما لم يتحقق مستوي مقبول من الخطأ. ولكن، للحصول علي أفضل معامل للنموذج، تم تصميم القواعد الضبابية لنموذج ANFIS باستخدام أنواع مختلفة من MFs واعداد مختلفة من MFs. تم استخدام قاعدة التعليم الهجينة لتدريب النموذج بناءً علي



أزواج بيانات الإدخال/الإخراج، وعدد من الدورات يصل إلى 10000 علي الرغم من انه تم ملاحظة أن أفضل تعلم تم إنجازه بعد أول 4000 فترة.

استخدمت انواع مختلفة من MFs في نموذج ANFIS مثل دالة عضوية شبه المنحرف (trapmf)، ودالة عضوية الجرس العامة (gbellmf)، ودالة العضوية المثلثية (gbellmf)، ودالة عضوية جاوس (gaussmf) ودالة عضوية تركيب جاوس (gauss2mf) في نموذج ANFIS.

تم تطبيق ANN و ANFIS باستخدام حزمة البرمجيات MATLAB.

4. النتائج والمناقشة

4.1 نموذج الشبكة العصبية المقترح

الشبكة العصبية كما هي مبينة في الشكل 5 المكونة من 5 خلايا عصبية في الطبقة الخفية (51 وزن و 4 انحيازات) نجد أن كفاءة التنبؤ لقيم COP لعملية تنقية المياه المدمجة في محول امتصاص حرارة مع تدوير للطاقة.

تم الحصول علي نتائج مشابهة بواسطة (Hernandez et al., 2008)، والتي اعتبرت الطريقة المقترحة لتسوية (normalizing) المدخلات والأهداف المنشودة بواسطة (Demuth and Beale, 1998).


يبين الشكل 6 البيانات العملية في مقارنة مع نتائج محاكاة قيم COP مع تدوير الطاقة. يمكننا ايضاً مشاهدة كيف أن بيانات المحاكاة تملك العلاقة مع البيانات التجريبية. تصرف الشبكة العصبية مناسب بشكل جيد قاعدة البيانات التعليمية:

$$RMSE = 9.5219 \times 10^{-7},$$


$$RSD = 2.9343 \times 10^{-4} \text{ and } R^2 = 0.9980$$

كما يناسب نموذج الشبكة العصبية بشكل جيد جميع تلك البيانات الغير المعروفة. الشكل التالي يوضح قدرة هذا النموذج لتوقع قيم COP في درجات حرارة مختلفة (in AB,

(GE, CO and EV)، الضغط والتكثف المبدئي لمدي تحقق معطي. يؤكد هذا أهمية الشبكة العصبية الصناعية في محاكاة كفاءة عملية تنقية المياه المتكاملة مع محول امتصاص حرارة مع تدوير للطاقة.



الشكل رقم 5 نموذج توقع قيم COP



الشكل رقم 6 العلاقة ما بين البيانات التجريبية وبيانات توقع نموذج ANN لقيم COP



نؤكد علي أن نموذجنا المقترح تم وضعه بواسطة معاملات الشبكة القابلة للتعديل، والتي تسمى الأوزان والانحياز ($IW, Wo, b1$ and $b2$) كما ذكر اعلاه في الجدول 3، هذه المكافئات تلعب دور خاص وذلك لاستخدامهم في نموذج ANN لمحاكاة قيم COP. ومن هنا النموذج المحسوب تم التحقق منه لاحقاً باستخدام قاعدة بيانات فحص (بيانات جديدة fresh data). لكن قيم COP المذكورة معقدة جداً وبصعب جداً توقعها بناءً علي نموذج يشتمل على الافتراضات فقط. كما يظهر أن توقعات COP صحيحة. بالمقابل الفحص الإحصائي للميل $Slope = 1$ التقاطع $intercept = 0$ ، تم إجرائهما للتأكد إحصائياً من صحة النموذج (Verma et al., 2005).

4.2 تطوير نموذج ANFIS

تم استخدام طرق ANFIS في هذه الدراسة للتنبؤ بقيم COP لعملية تنقية المياه المدمجة في محول امتصاص حرارة مع تدوير للطاقة. لذلك، فإن إيجاد دالة العضوية (MF) كما هو مبين بالشكل 7 يعتبر أفضل مطابقة لنموذج ANFIS مع مكثف نظام تنقية المياه هو الهدف الأول للمحاكاة باستخدام الحاسوب. الهدف الثاني هو إيجاد افضل عدد من MFs المناسبة والتي تؤدي إلي أسوأ أداء. القيم الإحصائية مثل $RMSE$ و RSD و $R2$ المعطاة في الجدول 4 لنظام محول الحرارة مع تدوير للطاقة لأنواع مختلفة من MF. عدد ال MF مثبت علي 3 في عمليات المحاكاة هذه.

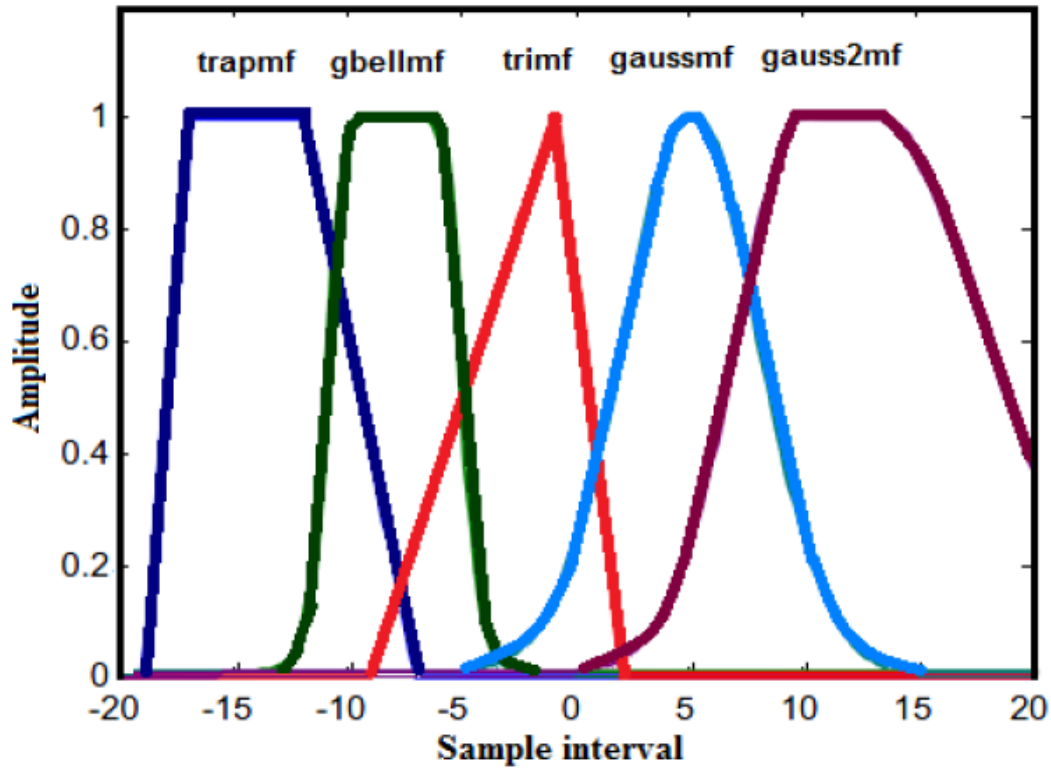
من نتائج COP المعروضة في الجدول 4 ، ظهرت اشكال مثلثية علي كونها أفضل MF نموذجي لنموذج ANFIS. قيمة $RMSE$ وقيمة RSD هي 9.5419×10^{-6} و 0.0029 علي التوالي. علي كل حال فإن $R2$ تكون 0.9897. تم اختيار أفضل تركيب ANFIS متدرب بناءً علي أقل قيمة $RMSE$ و RSD ، حسب التتابع و اعلي قيم $R2$ من مجموعة الفحص.

بيانات ANFIS المستخدمة في برنامج Matlab أعطيت كما يلي:

- عدد العقد 524: Number of nodes
- عدد المعاملات الخطية 243: Number of linear parameters
- عدد المعاملات اللاخطية 30: Number of no linear parameters
- عدد المعاملات الإجمالي 273: Total number of parameters
- عدد أزواج البيانات المدربة 6826: Number of training data pairs

- عدد القواعد الضبابية 243

تم تصنيف ضبابية ANFIS مع دالة العضوية المثلثية إلى ثلاث مجموعات ضبابية كما يلي: منخفض ومتوسط ومرتفع والتي وجد أنها علي قدر من الكفاءة لتوقع معامل الاداء لعملية تنقية المياه المتكاملة مع محول امتصاص حرارة مع تدوير للطاقة. يوضح الشكل 8 مقارنة بين قيم COP التجريبية والمحاكاة باستخدام جميع البيانات المتوفرة.




الشكل رقم 7 دوال العضوية

الجدول 4 MF و عدد قيم الـ MF لـ COP في نموذج ANFIS المقترح

MF ^a - MFN ^b	RMSE	%RSD	R ²
Triangular-3	9.5419×10^{-6}	0.0029	0.9897
Gbell-3	8.3257×10^{-5}	0.0257	0.9656
Gauss2mf-3	6.7318×10^{-4}	0.2075	0.9584
Gauss-3	6.3292×10^{-3}	1.9504	0.9498
Trap-3	6.6487×10^{-3}	2.0489	0.9399

^a دالة العضوية
^b عدد دالة العضوية



الشكل 8 ارتباط القيم التجريبية والمستنتجة من ANFIS لـ COP

تم مقارنة قيم COP التجريبية (COP_{Exp}) مع قيم COP المحاكاة (COP_{ANFIS}) إحصائياً من خلال نموذج الانحدار الخطي (linear regression model). $COP_{ANFIS} = a + bCOP_{EXP}$. بالحصول علي مكافئ الانحدار $R^2 = 0.9897$ حسب ما ورد عن (El Hamzaoui et al., 2011)، لتحقيق التقاطع والميل الاحصائي، القيم العليا والدنيا للتعرض يجب أن تحتوي علي

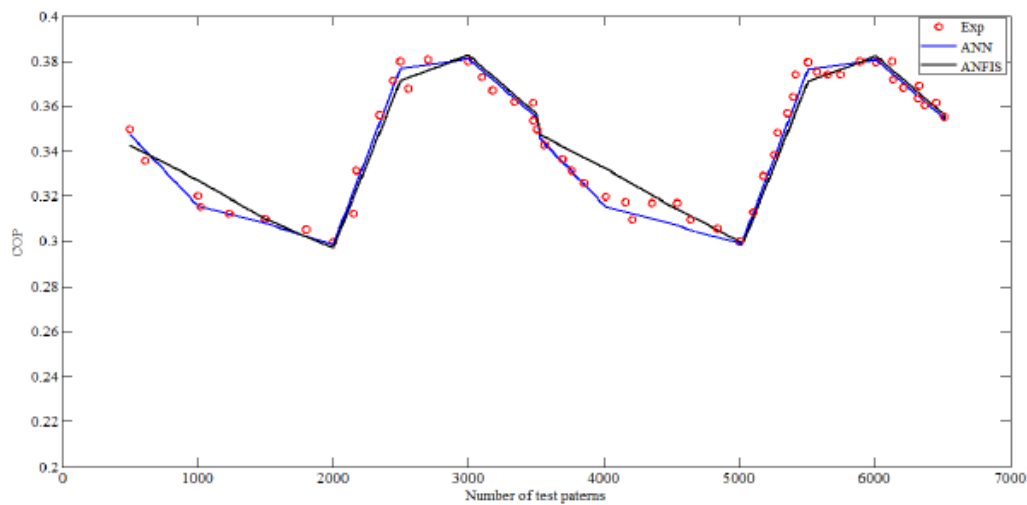
صفر والقيم العليا والدنيا للميل يجب أن تحتوي 1، يبين الجدول 5 حدود مؤشرات الفحص، مع ميل يحتوي علي واحد ومقاطعة تحتوي صفر. بالتالي، النموذج المقترح اجتاز الاختبار بنسبة مستوي ثقة 99%. هذا الاختبار بالمعلومات المذكورة أعلاه يضمن أن ANFIS يتمتع بمستوي مرضي من الثقة.

الجدول 5 الاختبار الإحصائي للتقاطع والميل

COP (Coefficient of performance)	
a_{lower}	a_{upper}
-0.0078	0.0100
b_{lower}	b_{upper}
0.9721	1.0021

4.3 نتائج بالمقارنة

الشيء الرائع هو، حسب الشكل 9، وجود ترتيب جيد بين قيم التوقع المستنتجة بواسطة نماذج ANN و ANFIS مع البيانات التجريبية. بالتأكيد، نجحت هذه نماذج بشكل منقطع النظير في توقع النتائج التجريبية.



الشكل 9 قيم COP بالمقارنة مع عدد أنماط الاختبار لعملية تنقية المياه في محول حراري



نماذج الشبكة العصبية الاصطناعية ANN هذه والنظام الضبابي العصبي المتكيف ANFIS اثبتت فعاليتها بشكل جيد في نمذجة معامل الاداء لعملية تنقية المياه مع محول حراري مع تدوير للطاقة. بينما تصغر قيمة RMSE وقيمة RSD وقيمة أكبر لـ R2 وهذا يعني اداء أفضل. لكن كفاءة ANN و ANFIS في نمذجة COP لنظام تحويل الحرارة الموضح في الجدول 6، حيث تم تدريب النموذجان باستخدام نفس مجموعة بيانات التدريب وتم التحقق منهما باستخدام نفس مجموعات بيانات الفحص (Fresh data). مع ذلك في التطبيق العملي الحسابات المطلوبة للنظام معقدة جداً، لهذا السبب جميع الحسابات تم تنفيذها علي نظام Linux مع معالج Intel D CPU 2.8 Ghz, 2.99 GB RAM

بناءً علي الجدول 6، فقد تم تمييز النتائج التالية:

نموذج ANN يملك أصغر قيمة RMSE و RSD كما يملك قيمة أكبر لـ R2 لكلا مجموعات الفحص التدريبية والتجريبية بالمقارنة مع من نموذج ANFIS.

بهذه الطريقة يحقق ANN اداء أفضل من نموذج ANFIS. لذلك ANN خيار جيد لنمذجة معامل الاداء لعملية تنقية المياه مع محول حراري مع تدوير للطاقة.

من المؤكد ايضاً أن ANN و ANFIS يمكن أن يستخدموا للتعامل مع عدد كبير آخر من المشاكل الخاصة بتنقية المياه.

الجدول 6 اداء كلا من ANN و ANFIS في نمذجة COP للنظام

Model	Training and testing database		
	RMSE	RSD(%)	R ²
ANN	9.5219×10^{-7}	2.9343×10^{-4}	0.9980
ANFIS	9.5419×10^{-6}	0.0029	0.9897

5. الاستنتاج

بسبب التعقيد في العلاقات بين متغيرات الإدخال والإخراج لاستنتاج معامل الأداء (COP) لعملية تنقية المياه المدمجة في محول امتصاص حراري مع تدوير للطاقة، وبهدف التعامل مع



هذه المشكلة، فان هذه الدراسة تقترح كيفية استخدام شبكة ANN وشبكة ANFIS لنمذجة COP للنظام. كما تم عرض دراسة مقارنة بين نموذج ANN ونموذج ANFIS.

يوضح تحليل هذه النتائج والرسوم التوضيحية بشكل جلي أن نموذج ANN أفضل من نموذج ANFIS، وذلك بناءً علي معيار التقييم (RMSE, RSD and R2 values).

علي الرغم من الوظيفة المهمة التي اداها كلا من ANN و ANFIS في نمذجة سلوك COP في نظام تنقية المياه المدمج في محول حراري مع تدوير للطاقة، فقد وجدت بعض الصعوبات في التطبيق.

علي سبيل المثال، تشمل عيوب ANN ما يلي:

- طبيعتها المغلقة مثل الصندوق الأسود.
- كثرة الحسابات المرهقة.
- عرضة لتكون أكثر ملائمة وطبيعية تجريبية خلال تطوير النموذج.

بينما يمكننا ذكر ما يلي من عيوب ANFIS:

- ليست حدسية.
- لا تلاقي قبول واسع.
- غير مناسبة للمدخلات البشرية.

في النهاية، تم عرض نماذج ANN و ANFIS لكونهما ادوات قوية جداً، عندما يتم تطبيقهما بالطريقة الملائمة لنمذجة عمليات هندسية أكثر تعقيداً والتي لا يوجد بداخلها أي عمليات رياضية بديهية للتعبير عن تصرفهم.



b1, b2	bias
COP	coefficient of performance, dimensionless
In	input
K	number of neurons in the input layer
LiBr	lithium bromide solution
Out	output
P	pressure, in Pascal (Pa)
Q	heat flow, in Watt
RMSE	root mean square error
S	number of neurons in the hidden layer
X	concentration, % w/w
IW, W_o	matrix weight

متغيرات الإدخال لنظام للشبكة العصبية الاصطناعية ونظام الاستنتاج الضبابي المتكيف:

Tin.GE-AB	input-temperature in the absorber that comes from generator, °C
Tin.EV-AB	input-temperature in the absorber that comes from evaporator, °C
Tout.AB-GE	output-temperature in the absorber towards generator, °C
Tin.AB-GE	input-temperature in the generator that comes from absorber, °C
Tout.GE-CO	output-temperature in the generator towards condenser, °C
Tout.GE-AB	output-temperature in the generator towards absorber, °C
Tin.CO	input-temperature of the condenser that comes from generator, °C
Tout.CO	output-temperature in the condenser towards evaporator, °C
Tin.EV	input-temperature in the evaporator that comes from condenser, °C
Tout.EV-AB	output-temperature in the evaporator towards absorber, °C
PAB	pressure in absorber, in Pascal (Pa)
PEV	pressure in evaporator, in Pascal (Pa)
PGE	pressure in generator, in Pascal (Pa)
PCO	pressure in condenser, in Pascal (Pa)
Xin.AB	LiBr (Lithium bromide) input-concentration in the absorber, % w/w
Xout.AB	LiBr (Lithium bromide) output-concentration in the absorber, % w/w
Xin.GE	LiBr (Lithium bromide) input-concentration in the generator, % w/w
Xout.GE	LiBr (Lithium bromide) output-concentration in the generator, % w/w



ترجمة المصطلحات

الاختصار	الترجمة	المصطلح
AB	الامتصاص	Absorber
ANN	الشبكات العصبية الاصطناعية	artificial neural network
ANFIS	النظام العصبي للاستدلال الضبابي	adaptive neuro fuzzy inference system
CO	مكثف	Condenser
EV	مبخر	Evaporator
EXP	عملي	Experimental
FL	منطق ضبابي	fuzzy logic
GE	مولد	Generator
MFs	دوال العضوية	membership functions
SIM	محاكاة	Simulated