

شبكة عصبية اصطناعية لتشغيل نظام خزن منفرد  
كامل علي عبد المحسن  
ايمن رافع محمد توفيق

E-mail [almohseen2000@yahoo.com](mailto:almohseen2000@yahoo.com)

قسم هندسة السدود والموارد المائية / جامعة الموصل

### المستخلص

يهدف البحث الحالي الى الاستفادة من مخرجات نموذجين رياضيين هما (نموذج للبرمجة الدينامية التصادفية الصريحة ESDP) و (نموذج للبرمجة الدينامية التصادفية الضمنية ISDP) الذين تم استخدامهما في ايجاد سياسة التشغيل المثلى لنظام خزن منفرد (خزان سد القائم المقترح على نهر الخوصر) لبناء نموذج شبكة عصبية اصطناعية لغرض ايجاد علاقة تربط بين حجم الخزين الابتدائي والجريان الوارد الى الخزان من جهة وكمية المياه المطلقة وحجم الخزين النهائي من جهة اخرى.

اعتمد نموذجين لشبكتين عصبيتين اذ تبنت الاولى مدخلات ومخرجات نموذج ESDP وكانت من نوع 2-6-2. اما الشبكة الثانية فقد استخدمت مدخلات ومخرجات نموذج ISDP وكانت معماريتها بالشكل 2-10-2. اظهرت النتائج ان هناك توافقاً جيداً بين المخرجات المستنبطة من الشبكتين العصبيتين مع مخرجات النموذجين حيث اجري تحليل احصائي بالاعتماد على معامل التحديد ( $R^2$ ) لإيجاد التوافق بين حجم الاطلاق المستنبط من الشبكة العصبية وحجم الاطلاق المستنبط من نموذج ESDP وقد تبين ان قيمة هذا المعامل هي 0.934 في حين اعطت الشبكة الثانية معامل تحديد مقداره 0.803 والذي يعبر عن مدى التوافق بين مخرجات الشبكة العصبية وتلك المستنبطة من نموذج ISDP وهذا يدل على امكانية ايجاد سياسة التشغيل المثلى للخزان باستخدام تقنية الشبكات العصبية الاصطناعية.

الكلمات الدالة: البرمجة الدينامية، شبكة عصبية اصطناعية، تشغيل الخزانات.

## Artificial Neural Network for Single Reservoir Operation

K. A. Al-Mohseen

A. R. M. Towfeeq

E-mail <[almohseen2000@yahoo.com](mailto:almohseen2000@yahoo.com)>

Dams & Water Resources Engineering Department  
Mosul University

### Abstract

The current paper aims to explore the capability of Artificial Neural Network models (ANN) to calculate the optimal operating policy of a single reservoir system (Al\_Qaim reservoir on the Al\_Khosar River). The ANN models proposed in this research were making use of the outcomes emerged from two Stochastic Dynamic Programming (SDP) models suggested by previous study on the same reservoir system i.e. Explicit Stochastic Dynamic Programming and Implicit Stochastic Dynamic Programming.

The two ANN models have been used to find pattern between inflow and initial storage of the system in one hand, and the release and the final storage of the system on other hand. It is found that the topology of the first model which adopted the attributes of the ESDP is 2-6-2, while that which was implemented the ISDP attributes has a 2-10-2 ANN topology.

The final results prevail that good agreement have been exist between the output (release) of the proposed ANN models and those obtained by the two (SDP) models with coefficients of determination 0.934 and 0.803 respectively.

Keywords: Artificial Neural Network, Dynamic Programming, Operation reservoir.

## المقدمة والدراسات السابقة

تعتبر المياه من الموارد الطبيعية المهمة للدول ومرتكزاً أساسياً لنموها وتطويرها الامر الذي يحتم البحث عن وسائل الحفاظ على هذه المياه وادارتها والاستفادة المثلى منها بما يتوافق مع المتطلبات بجميع انواعها الزراعية والصناعية والبيئية وغيرها.

تعتبر عملية التشغيل المثلى للخزانات من اهم وسائل الحفاظ على كميات المياه المتاحة لإطلاقها بشكل يتلاءم مع متطلبات اسفل الخزان .

ان استنباط سياسات التشغيل للخزانات هي من المواضيع ذات الاهمية في الدراسات والتحليلات الهيدرولوجية اذ قام العديد من الباحثين بإجراء بحوث ودراسات عدة تبنت العديد من النماذج الرياضية في احتساب هذه السياسات.

تعد الشبكات العصبية الاصطناعية (ANNs) احدى الوسائل المستخدمة في ايجاد سياسة تشغيل منظومات الخزن اعتماداً على مخرجات تم التوصل اليها باستخدام نموذجاً رياضياً معيناً. اعتمد الباحث [1] على تقنيات البرمجة الدائمية المحددة لإيجاد افضل سياسة تشغيل وادارة مثلى لخزان بوزيلوو في ايطاليا لغرض ارواء مساحة قدرها 18000 هكتار وتم تحديد افضل سياسة بالاعتماد على اقل مربع انحراف عن حجم الطلب اسفل الخزان كدالة هدف ومن ثم استخدام هذه السياسات لبناء شبكة عصبية اصطناعية، لقد بينت النتائج بان سياسات التشغيل المبنية على تمثيل النظام بشكل حقيقي وبالمحددات الموجودة بشكل قريب من الواقع يكون ادائها جيد سواءً في الحالات الطبيعية او في حالات الجفاف.


تبني [2] البرمجة الدائمية لاشتقاق سياسات التشغيل لسد ديز والواقع في الجنوب الغربي من ايران لاستخدامها في بناء شبكة عصبية اصطناعية وذكر بان هذه الشبكة تمكن المشغل من اتخاذ القرار في أي مرحلة من مراحل التشغيل حتى في حالة كون قيمة الجريان الداخل الى الخزان قد تغيرت عن القيمة الحقيقية التي تم تبنيها في نموذج البرمجة الدائمية. تمت مقارنة النتائج المستحصلة من الشبكات العصبية مع مخرجات البرمجة الدائمية وكان التوافق جيداً. قام [3] باشتقاق سياسات التشغيل المثلى لسد كارون 5 بتطبيق نموذج (SDP) ومن ثم استخدموا جزء من هذه السياسات لتدريب شبكة عصبية اصطناعية (ANN) واستنتجوا بان المخرجات التي تم التوصل اليها من (ANN) هي قريبة جداً من مخرجات النموذج (SDP). بالإضافة الى ذلك فقد بين [4] بأن الشبكات العصبية الاصطناعية تعطي حلول نموذجية لكثير من النماذج وان الكثير من الدراسات اظهرت بان نماذج (ANN) يمكن الاعتماد عليها في محاكاة الجريان في الانهر كما اعتبرت من انجح التقنيات في تحديد العلاقة المباشرة بين المدخلات والمخرجات دون النظر بالتفصيل في الفعالية الفيزيائية المراد دراستها. تبني [5] الشبكات العصبية الاصطناعية لبناء نموذج رياضي لتقدير التبخر نتج المرجعي اليومي لمنطقة الموصل (شمال العراق). أظهرت النتائج ان هناك توافق خطي بين مخرجات الشبكة العصبية وبيانات التبخر المرصودة بمعامل ارتباط مقداره (0.95).

تحاول الدراسة الحالية تقديم نموذج رياضي يعتمد على الشبكات العصبية الاصطناعية لاستنباط حجم الاطلاق الامثل من خزان سد القائم (المقترح على نهر الخوصر) ولمختلف قيم الجريان الوارد الى نظام الخزن نفسه وذلك بالاستفادة من المعطيات المستحصلة من دراسة سابقة [6] و[7] والتي تبنت تطبيق نماذج البرمجة الدائمية التصادفية بنوعها الصريحة والضمنية ولنفس نظام الخزن اعلاه.

## مفهوم الشبكات العصبية الاصطناعية

كان الباحثان ميكولوج وبتس (Mcculloch and Pitts) اول من وضع مفهوم الشبكات العصبية في عام 1943 بالرغم من ذلك لم يتم العمل بها حتى منتصف عام 1980 حيث بدأ تطوير واستخدام هذه التقنيات واصبحت من اكثر الطرق اعتماداً في مختلف المجالات [8].

تعد الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANNs)) من احدى تقنيات الذكاء الاصطناعي وهي نموذج رياضي مبني على مفهوم الشبكات العصبية الحيوية حيث تتكون من مجموعة من العصبونات الصناعية تحاكي سير ومعالجة المعلومات في العقل البشري. وهذا لا يعني بأن هذه الشبكات تحل محل كل التفاصيل الكهروكيميائية للدماغ البشري ولكن يمكن القول بأن الدماغ البشري مجهزاً بنموذج لتصميم (ANNs). عادةً ما تتكون الشبكة العصبية من طبقتين او اكثر تحتوي كل طبقة على عدد من العصبونات مهمتها هي استلام المدخلات عن طريق خط او عدة خطوط ادخال ويمكن التفكير بان هذه المدخلات عبارة عن اشارات كهربائية بمقاومات مختلفة ولكن المقاومة يمكن التعبير عنها برقم وعليه فيمكن القول وباختصار شديد بان العصبون الصناعي يستلم قائمة من الارقام عبر خطوط الارتباط وهذه الارقام هي عبارة عن اوزان معينة (قيم عددية) حيث تمثل هذه القيم المعلومات الابتدائية التي ستبدأ بها الشبكة حل المشكلة والتي يتم تجديدها لاحقاً بتقديم عملية تدريب الشبكة. يمكن تمثيل العصبون (AN) وكما هو موضح في الشكل (1).



الشكل (1) : هيكلية العصبون الاصطناعي

يتعامل العصبون الاصطناعي مع المدخلات بخطوتين أساسيتين هما:  
**الخطوة الأولى:** يقوم العصبون بضرب كل مدخل من مدخلات النموذج بوزن معين يتم تحديده عشوائياً كمرحلة أولية للتدريب ومن ثم تتم عملية جمع المدخلات ويضاف إليها عامل الانحياز (b) وذلك للحصول على قيمة موجبة للمرحلة الأولى. ويمكن ان يعبر عنه رياضياً بالمعادلة ادناه:

$$net = b + \sum_{i=1}^n w_i x_i \quad (1)$$

حيث أن :

$net$  : ناتج الخطوة الأولى.

$w_i$  : قيم الأوزان.

$b$  : عامل الانحياز.

$x$  : المدخلات

$n$  : عدد المدخلات

**الخطوة الثانية:** تتولى معالجة مخرجات الخطوة السابقة وهي دوال رياضية تدعى بدوال التفعيل ( Activation Function ) حيث تحتوي كل من طبقة الاخراج والطبقات المخفية على دالة تفعيل يمكن اختيارها بالاعتماد على طبيعة المسألة. ويمكن الحصول على صافي المخرجات (Y) من المعادلة ادناه:

$$y = f(net) = f(b + \sum_{i=1}^n w_i x_i) \quad (2)$$

ان هناك العديد من دوال التفعيل التي تحدد ماهي قيمة المخرجات التي يمكن استنتاجها من صافي المدخلات. تعتبر دوال التفعيل (tan-sigmoid, log-sigmoid, pure) من اكثر الدوال المستخدمة في بناء الشبكات العصبية. توضح المعادلة الأولى الصيغة الخاصة بدالة التفعيل من نوع (tan-sigmoid) بينما المعادلة الثانية فتوضح الصيغة الخاصة بدالة التفعيل من نوع (log-sigmoid)، [2].

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

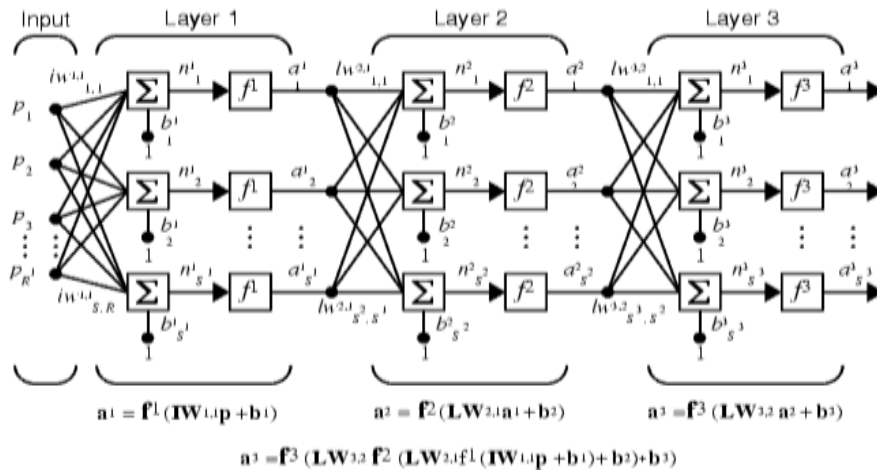
$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

تمتلك الشبكات العصبية ميزة مهمة حيث ان لها القدرة على ان تتعلم بالأتملة فاذا زودت هذه الشبكة بأزواج من البيانات بحيث ان العنصر الاول منها هو نمط لمدخلات معطاة والثاني هو المخرجات المرغوبة فان هذه الشبكة تمتلك القدرة على ان تتدرب لتعدل اوزانها بما يتلاءم مع المخرجات المطلوبة. ان هذه الامكانية مهمة وذلك لوجود العديد من المسائل التي نعلم ماهي نتائجها الصحيحة ولكن لا يمكن ان نضع نهج معين لإيجاد العلاقة التي تربط بين المدخلات والمخرجات.

ان الشبكات العصبية لا تبرمج بل انها تقوم بالتعليم وهناك العديد من خوارزميات التعليم ومن اشهرها خوارزمية الانتشار العكسي (Back propagation Algorithm) اذ تعمل هذه الخوارزمية على حساب الخطأ الناتج من الفرق بين قيمة المخرجات الفعلية للشبكة العصبية وبين القيم المرغوبة. ان المشكلة الاساسية هي ان أي تغييرات في الأوزان ستقود الى سلسلة من التأثيرات التي ستتقدم للأمام خلال الطبقات التي تلي مكان التغيير في الشبكة. وعليه فان كل هذه التغييرات

يجب ان تؤخذ بنظر الاعتبار ان نظرية الانتشار العكسي تتضمن عمل تصحيحات للأوزان التي تربط الطبقة ما قبل الاخيرة مع الطبقة الاخيرة ثم استخدام الحسابات المتضمنة هذه التصحيحات كأساس لحساب التصحيحات للطبقة التالية والى الخلف حتى يتم الوصول الى طبقة الادخال والحصول على اقل خطأ بين المخرجات المرغوبة والمخرجات الفعلية للشبكة. ان هذه المرحلة التي تمر بها الشبكة يطلق عليها مرحلة التدريب.

هناك نوعين اساسيين في بناء الشبكات العصبية بالاعتماد على الاتجاه المزمع تبنيه في عملية اجراء الحسابات المطلوبة لغرض احتساب مخرجات النموذج المقترح. فان تمت الحسابات بشكل منهجي مبتدئاً بطبقة الادخال مروراً بطبقة (بطبقات) الخفية وصولاً الى طبقة المخرجات دون الرجوع الى طبقة الادخال اطلق على تغذية الشبكة بالتغذية الامامية (feed-forward) والاسميت بالشبكة ذات التغذية العكسية (feed-backward). تم هذه الدراسة تبني النوع الاول نظراً لكثرة استخدامه في بناء الشبكات المتعلقة بأنظمة الموارد المائية [5]. يبين الشكل (2) شبكة العصبية نموذجية ذات تغذية امامية.



شكل (2) : شبكة عصبية ذات تغذية امامية [9]


### البنية المعمارية للشبكات العصبية الاصطناعية

يقصد بالبنية المعمارية هي الطريقة التي ترتبط بها العصبونات في كل طبقة من طبقات الشبكة مع بعضها البعض لتشكل الشبكة العصبية حيث تؤثر هذه البنية على مخرجات الشبكة العصبية. لقد وجد ان الشبكات متعددة الطبقات تكون ذات فعالية كبيرة في الحسابات لذا فأنها واسعة الاستخدام. يمكن للشبكات متعددة الطبقات حل العديد من المشاكل المعقدة غير ان تدريبها يستغرق وقتاً أطول ومع هذا فان عدد طبقات الادخال والاخراج وعدد الطبقات المخفية وعدد العصبونات الخاصة بالشبكة العصبية تحدد بطبيعة المسألة المراد دراستها [5].

تهئى برمجيات (MATLAB) حزمة واسعة من خوارزميات التدريب والتي هي من متطلبات عمل الشبكات العصبية. في الدراسة الحالية تم استخدام خوارزمية تدريب من نوع (Levenbreg Marquardt (LM) وهي من اسرع خوارزميات تدريب شبكة الانتشار العكسي للخطأ وهي من الخوارزميات التي ينصح باستخدامها ويمكن الاستفادة منها في التدريبات التي تتطلب بيانات ضخمة نسبياً (MATLAB, User Manual, 2010) فضلاً عن ذلك استنتج [5] بأن هذه الخوارزمية هي افضل خوارزمية للتعليم لكونها تعطي اقل قيمة لمربع الخطأ مقارنة ببقية خوارزميات التعليم. ومن الجدير بالذكر انه قد تم اجراء عدد لا يستهان به من المحاولات وعلى أنواع مختلفة من الهيكليات للتوصل الى افضل بنية للشبكات المقترحة.

### التطبيق (دراسة حالة)


تركزت الدراسة الحالية على خزان سد القائم المقترح انشاءه على نهر الخوصر والموضح في شكل (3) والذي يعتبر من الروافد الموسمية التي تصب في الجهة اليسرى من نهر دجلة قرب مركز مدينة الموصل. يقع خزان سد القائم على بعد 18 كم شمال مدينة الموصل، تقدر مساحة الجابية الخاصة بحوض نهر الخوصر أعلى موقع سد القائم المقترح بـ 640 كم<sup>2</sup> [10].



الشكل (3) : خارطة تبين حوض نهر الخوصر وموقع سد القائم


### بناء نموذج الشبكة العصبية الاصطناعية

تم الاعتماد على سياسات التشغيل المستنبطة لخزان سد القائم والمستحصلة من تطبيق نماذج البرمجة الدينامية التصادفية بنوعها الصريحة (Explicit Stochastic Dynamic Programming (ESDP)) والضمنية (Implicit Stochastic Dynamic Programming (ISDP)) [7] في بناء شبكتين عصبيتين الاولى تعتمد على سياسات التشغيل المستنبطة من النموذج (ESDP) والثانية تعتمد على مخرجات النموذج (ISDP).  
 حُدثت البنية المعمارية للشبكة العصبية الاصطناعية المستخدمة للتدريب على مخرجات النموذج (ESDP) وبعد محاولات عديدة لا يتسع المجال لذكرها لمحدودية الفضاء المتاح. تضمنت البنية المعمارية للشبكة الاولى طبقة للمدخلات والتي تتكون من عصبونان (لتمثيل حجم الجريان الداخل وحجم الخزين الابتدائي)، اما الطبقة الخفية فتتكون من (6) عصبونات في حين تحتوي طبقة الاخراج على عصبونان ليمثلا حجم الاطلاق الامثل وحجم الخزين النهائي. والشكل (4) يوضح بنية هذه الشبكة.



شكل (4) : البنية المعمارية للشبكة العصبية المقترحة لمعطيات نموذج ESDP

اما الشبكة الثانية فهي مبنية على سياسات التشغيل الخاصة بنموذج (ISDP) [7] وكانت بنيتها مؤلفة من طبقة للمدخلات والتي تتكون من عصبونان (لتمثيل حجم الجريان الداخل وحجم الخزين الابتدائي) وطبقة مخفية تتكون من (10) عصبونات وطبقة اخراج واحدة تتكون من عصبونان ايضا وذلك للتعبير عن حجم الاطلاق الامثل وحجم الخزين النهائي. والشكل (5) يوضح بنية هذه الشبكة.



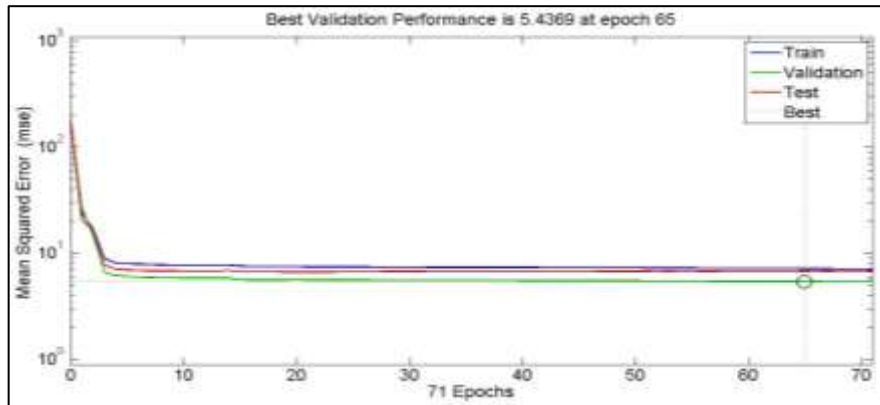
شكل (5) : البنية المعمارية للشبكة العصبية المقترحة للنموذج ISDP

يلخص الجدول (1) تأثير استخدام دالات تفعيل مختلفة وعدد عصبونات مختلف للطبقة (للطبقات) الخفية على أداء الشبكة العصبية، حيث يلاحظ أن استخدام دالة التفعيل (Tansigmoid) في الطبقة الخفية تتبع بدالة تفعيل من نوع (Pure) في طبقة الإخراج هي الأفضل إذ أعطت أقل قيمة للمعيار المعتمد (معدل مربع الخطأ MSE) لكلا النموذجين. يدلل نفس الجدول على أن أفضل بنية معمارية للشبكة المستخدمة للنموذج (ESDP) هي 2-6-2 (عصبونات في طبقة المدخلات - 6 عصبونات في الطبقة الخفية - عصبونات لطبقة المخرجات). أما نموذج (ISDP) فإن أفضل معمارية للشبكة المقترحة هي 2-10-2. كما يمثل هذا الجدول نموذج من عدد لا يستهان به من المحاولات بتغيير عدد الطبقات الخفية وعدد العصبونات في كل طبقة ونوع دالة التفعيل المستخدمة. يلاحظ من الجدول أيضاً أن قيم معدل مربع الخطأ (MSE) هي قيم كبيرة مقارنةً بالقيم المعتادة ويمكن تبرير ذلك بالقول أن البيانات المستخدمة في التدريب لم يتم إجراء عملية التقييس لها (تم تدريب أحد الشبكات العصبية بالاعتماد على عملية التقييس ولم يكن هناك فرق في الأداء إلا أن قيمة (MSE) كانت أقل من الواحد وذلك لأن البيانات المستخدمة في التدريب هي أقل من الواحد). زد على ذلك أن الجدول يدل على أن الشبكة العصبية الاصطناعية الخاصة بنموذج (ESDP) هي الأفضل في الأداء اعتماداً على قيمة (MSE) المستخرجة.

الجدول (1) : دالات التفعيل المختارة لكلا النموذجين

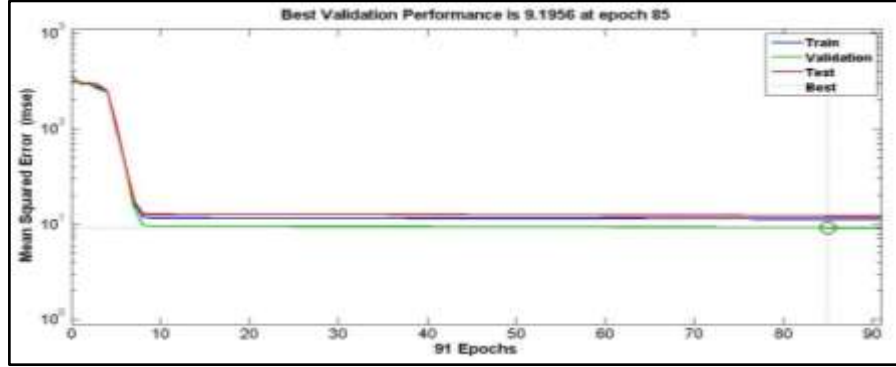
النموذج التصادفي	MSE	بنية الشبكة المقترحة	دالة التفعيل لطبقة المخرجات	دالة التفعيل للطبقة الخفية
ESDP	8.2	1-2-4-2	TAN	LOG- TAN
ISDP	12.58	1-2-5-2	TAN	PURE- LOG
ESDP	6.77	2-8-2	PURE	TAN
ISDP	10.85	2-12-2	PURE	TAN
ESDP	5.43	2-6-2	PURE	TAN
ISDP	9.1	2-10-2	PURE	TAN

جرى تدريب الشبكة الخاصة بمعطيات نموذج ESDP على سياسات التشغيل المستنبطة لـ 12 شهر حيث يحتوي كل شهر على أربع احتمالات للجريان الداخلى الى نظام الخزن وعلى 24 حالة من حالات الخزين الابتدائي، انظر المصدر [6] رجاءً. تتكون سياسات التشغيل من مجموعتين من البيانات تمثل المجموعة الاولى مدخلات النموذج وهما حجم الخزين الابتدائي وحجم الجريان الوارد الى الخزان في حين تتمثل المجموعة الثانية بالإطلاق والخزين النهائي واللذين يعبران عن مخرجات النموذج. تشكلت مجموعة المدخلات من صفين و (1152) عمود، كل عمود من هذه الأعمدة يمثل قيمة لحجم الجريان الداخلى والخزين الابتدائي، أما بيانات المخرجات فتضمنت صفين و (1152) عموداً كل عمود يمثل قيمة لحجم الإطلاق والخزين النهائي على التوالي. تقوم الشبكات العصبية تلقائياً بتجزئة المدخلات الى ثلاث مجاميع وهي مجموعة للتدريب (Training) واخرى للتحقق (Validation) واخرى للاختبار (Testing). تُستخدم المجموعة الاولى لتدريب الشبكة العصبية الاصطناعية اذ ان غايتها الوصول الى اقل قيمة لمعدل مربع الخطأ (MSE) فيما استخدمت المجموعة الثانية لتحقيق افضل أداء للشبكة العصبية الاصطناعية اما المجموعة الثالثة فتستخدم لغرض التأكد من التوافق الادائي لتدريب الشبكة. يوضح الشكل (6) مسار تدريب الشبكة العصبية الاصطناعية المقترحة باستخدام خوارزمية التدريب (LM) وبنية هندسية (2-6-2) حيث يبين عدد الدورات التكرارية اللازمة للوصول إلى الهدف المعرف مسبقاً.



الشكل (6) : مسار تدريب الشبكة العصبية الاصطناعية لنموذج ESDP باستخدام خوارزمية التدريب (Levenberg Marqwardt LM)

أما فيما يخص الشبكة الثانية فقد تم تبني سياسات التشغيل المستنبطة من السلاسل المولدة باستخدام احد النماذج التصادفية ومنها نموذج (Thomas – Fiering) وذلك لتمثيل جزء من قيم الجريان المحتملة مستقبلاً. في الدراسة الحالية تم اجراء العديد من المحاولات اذ تم توليد العديد من سلاسل الجريان وبأطوال مختلفة وقد وجد ان طول السلسلة المكونة من 19 سنة (228 شهر) والتي اعطت اكبر تطابق للمعالم الاحصائية للبيانات المرصودة والمولدة وكما بينه [7] في صفحة 81 و82 فيما يتعلق بمعدل التصريف ومعامل الانحدار ومعامل الالتواء. تم الاعتماد على هذه البيانات في تدريب الشبكة العصبية الخاصة بنموذج (ISDP) بنفس الاسلوب المتبع اعلاه ولكن مصفوفة المدخلات والمخرجات تتكون في هذه الحالة من صيفين و(5460) عموداً. يوضح الشكل (7) مسار تدريب الشبكة العصبية الاصطناعية المقترحة باستخدام خوارزمية التدريب (LM) وبنية هندسية (2-10-2).

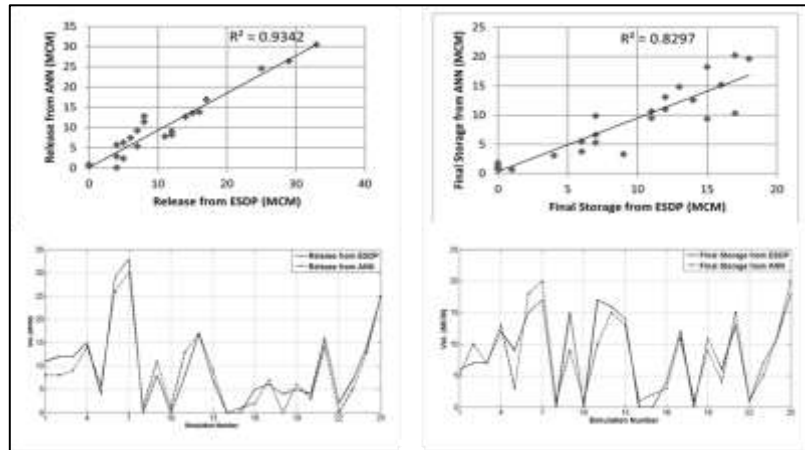


الشكل (7) مسار تدريب الشبكة العصبية الاصطناعية لنموذج ISDP باستخدام خوارزمية التدريب (Levenberg Marqwardt LM)

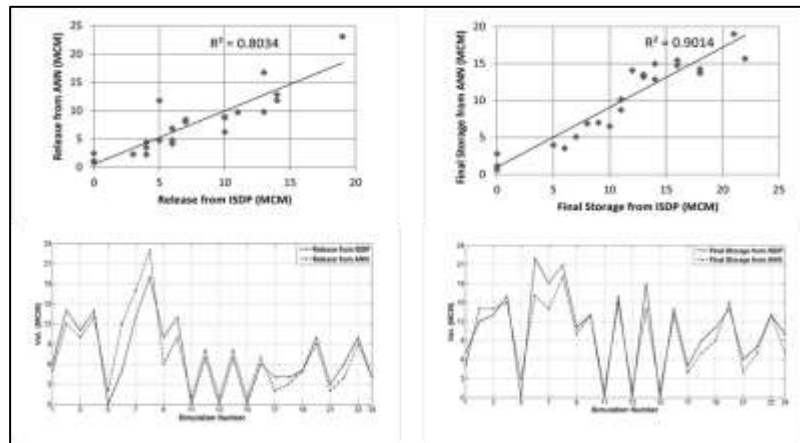
### النتائج المستحصلة من الشبكتين العصبيتين

تم اختيار قيم عشوائية لكل من حالات الخزين الابتدائي وحالات الجريان الواردة الى نظام الخزن وتم ادخال هذه القيم الى الشبكة المعتمدة والخاصة بكل نموذج كما وتستخدم نفس القيم العشوائية اعلاه كمدخلات للنماذج التصادفية لاحتساب حجم الاطلاق الامثل وحجم الخزين النهائي.

اجريت مقارنة بين سياسات التشغيل (حجم الاطلاق الامثل وحجم الخزين النهائي) المستنبطة من نموذج (ESDP) والتي تقابل كل من القيم العشوائية لحالات الخزين الابتدائي وحالات الجريان مع مخرجات الشبكة العصبية المقترحة للتأكد من اداء هذه الشبكة اذ حدد حجم الاطلاق الامثل بالاعتماد على المخطط البياني (Nomograph) والذي يمثل مخرجات نموذج (ESDP) بينما استخدمت الشبكة العصبية المقترحة لاستنباط حجم الاطلاق الامثل وحجم الخزين النهائي لهذه المدخلات. ان الشكل (8) يسهل المقارنة بين مخرجات نموذج (ESDP) مع مخرجات الشبكة العصبية المقترحة ويبين مدى التطابق بينهما. كما اعتمد نفس الاسلوب لإجراء المحاكاة بين مخرجات الشبكة العصبية الخاصة بنموذج (ISDP) مع المخرجات الفعلية للنموذج المعني. الشكل (9) ادناه يبين معامل التحديد بين مخرجات نموذج (ISDP) مع مخرجات الشبكة العصبية المقترحة ومدى التطابق بينهما.



الشكل (8): التوافق بين مخرجات الشبكة العصبية المقترحة مع مخرجات النموذج ESDP



الشكل (9): التوافق بين مخرجات الشبكة العصبية المقترحة مع مخرجات النموذج ISDP

### الاستنتاجات

- بينت الدراسة بأن أفضل بنية معمارية للشبكة المستخدمة للنموذج (ESDP) هي 2-6-2 (عصبونات في طبقة المدخلات – 6 عصبونات في الطبقة الخفية – عصبونات لطبقة المخرجات). أما النموذج (ISDP) فكانت أفضل معمارية للشبكة العصبية هي 2-10-2.
- اوضحت النتائج وجود توافق خطي بين حجم الاطلاقات المستنبطة من الشبكة العصبية ومخرجات نموذج (ESDP) بمعامل تحديد مقداره 0.934 وهو افضل نسبياً من معامل التحديد بين حجم الاطلاقات المستنبطة من الشبكة العصبية ومخرجات نموذج (ISDP) حيث كانت قيمته 0.803 وذلك بسبب طبيعة المدخلات والمخرجات المستخدمة لتدريب الشبكة الاولى مقارنة بطبيعة البيانات المستخدمة لتدريب الشبكة الثانية.
- سلطت هذه الدراسة الضوء على امكانية استخدام تقنية الشبكات العصبية الاصطناعية في استنباط سياسات تشغيل لمنظومات الخزن المائي.

### المصادر

1. Cancelliere, A., Giuliano, G., Ancarani, A., and Rossi, G., " A Neural Networks Approach for Deriving Irrigation Reservoir Operating Rules", Water Resources Management Vol.(16): 71–88, 2002
2. Sharifi, F., Haddad, O. B. and Naderi, M., " Reservoir Optimal Operation Using DP-ANN", Evolutionary Computation, 2005.  
<http://www.wseas.us/e-library/conferences/2005lisbon/papers/496-281.pdf>
3. Haddad, O. B., and Alimohammadi, S. " Combining Stochastic Dynamic Programming (SDP) and Artificial Neural Networks (ANN) in Optimal Reservoir Operation", 2005  
<http://www.wseas.us/e-library/conferences/2005lisbon/papers/496-258.pdf>
4. Abdulrahman, K. Z. "Artificial Neural Network-finite Volume Coupled Model For River flow ". Ph. D thesis, University of Sulimani, Sulimani, Iraq, 2012
5. العاني، افتخار ، المحسن، كامل، الدباغ، عبد الستار، " تقدير التبخر\_نتح المرجعي اليومي لمنطقة الموصل باستخدام الشبكات العصبية الاصطناعية"، مجلة هندسة الرافدين، المجلد (15) ، العدد (4) ، 2007.
6. توفيق، ايمن رافع و المحسن، كامل ، " نموذج تصادفي داينمي لتشغيل نظام خزن منفرد (دراسة حالة)" ، مقبول للنشر في مجلة هندسة الرافدين، 2013.
7. توفيق، ايمن رافع، " نموذج تصادفي داينمي لتشغيل خزان سد القائم على نهر الخوصر " ، رسالة ماجستير، كلية الهندسة، جامعة الموصل، 2013.



8. Wang, A. , Yiliao, H. and Huang, C. "Reservoir inflows forecasting with artificial neural networks during typhoon period-for Shihmen Reservoir in Taiwan", WSEAS International Conference on WHH , Chalkida, Evia Island, Greece, 2006  
<http://rd.cycu.edu.tw/RD2008/H2500/rtd/project6/95/wseas%20ID%20516-138%20final%20version.pdf>
9. العاني، افتخار، " تقدير التبخر- نتح المرجعي اليومي لمنطقة الموصل باستخدام الشبكات العصبية الاصطناعية"، اطروحة دكتوراه، كلية الهندسة، جامعة الموصل، 2007.
10. Sogreah Consulting Engineer, "Al-Qaim Dam planning Rep.", Ministry of Irrigation, General Establishment Of Studies And Designs,1982.

تم اجراء البحث فى كلية الهندسة = جامعة الموصل