

## تقييم البارامترات الفعالة للجريان السطحي في حوض نهر الكبير الجنوبي باستخدام شبكات Elman الصناعية

الدكتور غطفان عبد الكريم عمّار\*

الدكتورة بادية يوسف حيدر\*\*

ميس محمد عليان\*\*\*

(تاريخ الإيداع 14 / 12 / 2014. قُبِلَ للنشر في 4 / 3 / 2015)

### □ ملخص □

تعدّ النمذجة الدقيقة للعلاقة بين الهطول المطري\_الجريان السطحي (R\_R) (Rainfall\_Runoff) مهمة معقدة جداً، على الرغم من حقل النمذجة الواسع الذي يشمل كلاً من الطرائق الموجهة بالمعرفة والطرائق الموجهة بالبيانات. تتطلب النماذج الموجهة بالمعرفة كمية ضخمة من البارامترات، وبالتالي فهي تعاني من تأثير كثرة البارامترات. هذا ما يجعل العاملين في حقل النمذجة يبحثون عن طرائق نمذجة بسيطة تتطلب عدد قليل من البارامترات مثل الطرائق الموجهة بالبيانات، لذلك تهدف الدراسة الحالية إلى استخدام الشبكات العصبية الصناعية التي تعدّ إحدى أنواع هذه الطرائق لنمذجة العلاقة R\_R في حوض نهر الكبير الجنوبي في محافظة طرطوس. حيث تمّ الاعتماد على شبكة Elman الصناعية للتنبؤ بالجريان السطحي باختبار أربعة وعشرين نموذجاً ذات معماريات مختلفة، كما تمّ اختبار كل نموذج باستخدام عدد مختلف من العصبونات الخفية، وذلك باستخدام مكتبة nntool المتاحة في حزمة برمجيات Matlab.

أثبتت نتائج هذه الدراسة أن النموذج الذي يحوي في طبقة المدخلات على كل من درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري بتأخر زمني مقداره ثلاثة أيام (3:0-) إضافة إلى قيم سابقة للتصريف بتأخر زمني (1:-3) ومع استخدام 25 عصبون في الطبقة الخفية يعطي أفضل أداء بمتوسط مربع خطأ مقداره  $5 \times 10^{-8} * 2.8$ ، ومعامل ارتباط 0.96 لمجموعة البيانات المستخدمة، تمّ التوصل إلى أنّ شبكات Elman تعطي نتائج جيدة في نمذجة العلاقة R\_R وبالتالي يمكن اعتبارها بديلاً للطرائق التقليدية في نمذجة العلاقة R\_R.

الكلمات المفتاحية: الهطول المطري\_الجريان النهري، الشبكة العصبية الصناعية، شبكات Elman، Matlab.

\* أستاذ - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

\*\*دكتورة - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

\*\*\* طالبة دراسات عليا (دكتوراه) - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

## Evaluation of effective Parameters in the estimation of Runoff in Alkabeer Aljanabee Catchment using Elman Neural Network

Dr. Ghatfan Ammar\*  
Dr. Badia Haidar\*\*  
Mais Alean\*\*\*

(Received 14 / 12 / 2014. Accepted 4 / 3 / 2015)

### □ ABSTRACT □

Accurately modeling rainfall-runoff (R-R) transform remains a challenging task despite that a wide range of modeling, either knowledge-driven or data-driven. knowledge-driven models need a large amount of parameters, so it suffers from plenty numbers of parameters, for this reason the hydrologists start looking for a simple modeling methods, that need a few parameters such as data \_driven methods, so The present study amis to use artificial neural network, which is one type of this methods for modeling the relationship between rainfall and runoff in Alkabeer Aljanonbee river catchment in Tartous City. Elman Neural Network is depended on for prediction of runoff by testing twenty four models have different architectures. So all models have been tested by using different numbers of neurons in the hidden layer, by using nntool book, which is available in the Matlab program.

The results of the research verify that the model which has each of temperature, relative humidity, evaporation and rainfall in the input layer with time delay equal to three days (0:-3), in addation to preveous value of runoff (-1:-3), gives a best performance for used data with mean square error equal to  $2.8 \times 10^{-5}$ , and correlation coefficient 0.96. So it has been reached that Elman network technology gives a good results in modeling the relation rainfall\_runoff So it could be a good alternative instead of traditional approaches.

**Keywords :** Rainfall\_Runoff, Artificial Neural Network, Elman Network, Matlab

---

\*Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

\*\*Associated Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

\*\*\*Postgraduate student, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

**مقدمة:**

تعدّ نمذجة الهطول المطري\_الجريان السطحي، والتي تؤثر فيها كل من مواصفات الهطول المطري والمواصفات الجغرافية الحوض، هدفاً لكثير من الباحثين والمهندسين لفترة طويلة جداً. إنّ تحول الهطول المطري إلى جريان سطحي فوق الحوض هو في الواقع عملية ديناميكية غير خطية ومعقدة جداً؛ وذلك بسبب أنّ استجابة الحوض معقدة جداً. العامل المؤثر على الجريان السطحي في الحوض والعائد إلى مدخل الهطول المطري يتضمن كلاً من مواصفات العاصفة؛ أي شدة العاصفة ومدّة العاصفة المطرية، ومواصفات الحوض؛ أي الحجم والشكل والميل ومواصفات التخزين في الحوض، ومواصفات الشكل الجغرافية، ونماذج استخدام الأراضي، الغطاء النباتي وأنواع الترب التي تؤثر في التسرب، بالإضافة إلى مواصفات المناخ مثل الحرارة، الرطوبة، ومواصفات الرياح. إنّ تأثير كل هذه العوامل مع بعضها بعضاً في توليد الجريان السطحي غير واضح، حيث حاول العديد من الباحثين نمذجة العلاقة  $R_R$  باستخدام العديد من الطرائق لكن معظم هذه الطرائق تتطلب عدد كبير من البيانات. تستخدم العديد من الدراسات في الوقت الحالي الطرائق الموجهة بالبيانات مثل الشبكات العصبية الصناعية، حيث أثبتت الشبكات العصبية الصناعية أنها أداة جيدة في محاكاة العمليات المعقدة والأنظمة اللاخطية، ولقد أحرزت اهتماماً كبيراً في السنوات الأخيرة، ما وحي للهيروولوجيين باستخدام هذه الشبكات في نمذجة العلاقة بين الهطول المطري\_الجريان النهري في أماكن مختلفة من العالم. فلقد استخدم (Solaimani, K. 2009) الشبكات العصبية لنمذجة العلاقة  $R_R$  في المناطق القاحلة في إيران. حيث استخدم الباحث في دراسته شبكات التغذية الأمامية مع خوارزميات تدريب متعددة، وقورنت نتائجه مع الطرائق التقليدية [1]. هذا وقد نشر (Dhamge, N. et, al. 2012) دراسة للتنبؤ بالتدفق النهري اليومي باستخدام ANNs في الهند. بينت الدراسة إمكانية استخدام الشبكة العصبية في نمذجة العلاقة بين الهطول المطري\_الجريان النهري [2]. وفي دراسة قام بها (Lafdani, N. et, al. 2013) لنمذجة العلاقة بين الهطول المطري\_الجريان النهري في حوض Eskandari في إيران، استخدم الباحث كلاً من النظام الضبابي العصبي التكيفي (ANFIS) والشبكة العصبية الصناعية، حيث أثبتت الدراسة أنّ نموذج ANFIS هو أفضل أداءً من نموذج ANN [3].

أثبتت الدراسات السابقة أنه يمكن استخدام ANNs كطريقة بديلة لأنظمة التنبؤ بالفيضان بهدف نمذجة العلاقة  $R_R$  والتنبؤ بالفيضان، واقتُرحت الدراسات العمل بطرائق الذكاء الصناعي نظراً لنتائجها الجيدة في نمذجة العلاقة بين الهطول المطري\_الجريان النهري.

لقد ركزت معظم الأبحاث على ما يدعى بالشبكات العصبية الصناعية ذات التغذية الأمامية وذلك في نمذجة العلاقة  $R_R$ ، والتي تنجز تخطيط ستاتيكي بين دخل وخرج النموذج [1]، وطالما أنّ أحواض الأنهار هي أنظمة ديناميكية لذلك فإن استخدام شبكات عصبية صناعية ذات تغذية راجعة (نماذج ديناميكية) قد تعطي نتائج أفضل بكثير من الشبكات الستاتيكية في تمثيل حالة الحوض الهيدرولوجية، هذا ما توصلت إليه بعض الدراسات التي استخدمت الشبكات العصبية الصناعية ذات التغذية الراجعة في نمذجة هذه العلاقة، مثل الدراسة التي قام بها (Dozier, A. 2012) لدراسة تأثير التغير المكاني للهطول المطري في نموذج الهطول المطري\_الجريان النهري المشكّل باستخدام شبكة Elman ذات التغذية الراجعة لتدريب ومحاكاة قياسات التدفق النهري في حوض Creek Fountain في Colorado [4]. كما اقترح (Alok, A. 2013) في دراسة أجراها لنمذجة العلاقة  $R_R$  في نهر Brahmani في

الهند عد الشبكات العصبية الصناعية أداة للتنبؤ بالتصريف، حيث استخدم الباحث في دراسته نوعان للشبكات العصبية الصناعية هي شبكات Elman الإرجاعية وشبكات Cascade [5].

### أهمية البحث وأهدافه:

انطلاقاً من أهمية التنبؤ بقيم التصريف المستقبلي للنهر، باعتباره ضرورياً للتنبؤ بالفيضان، إضافةً إلى أهميته في إدارة الموارد المائية، حيث تأتي أهمية نمذجة العلاقة بين الهطول المطري\_الجريان السطحي باعتبارها عنصراً أساسياً من عناصر الدورة الهيدرولوجية وتحديدها باستخدام تقانة متطورة لوضع عناصر الموازنة بدقة عالية يمكن الاعتماد عليها لتخطيط الموارد المائية، إضافةً إلى أهمية إيجاد طريقة نمذجة بديلة للطرائق التقليدية التي تتطلب كمية ضخمة من البارامترات، لذلك يهدف هذا البحث إلى وضع نموذج رياضي للعلاقة بين الهطول المطري\_الجريان النهري باستخدام شبكات Elman الصناعية وذلك من خلال:

- ❖ إجراء تحليل حساسية لمدخلات الشبكة بهدف تحديد البارامترات الأكثر تأثيراً على أداء الشبكة العصبية الصناعية، ومن ثم بناء نموذج للعلاقة بين الهطول المطري\_ الجريان النهري باستخدام شبكات Elman الصناعية.
- ❖ تقويم أداء الأنموذج المشكل باستخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب.

### موقع منطقة البحث:

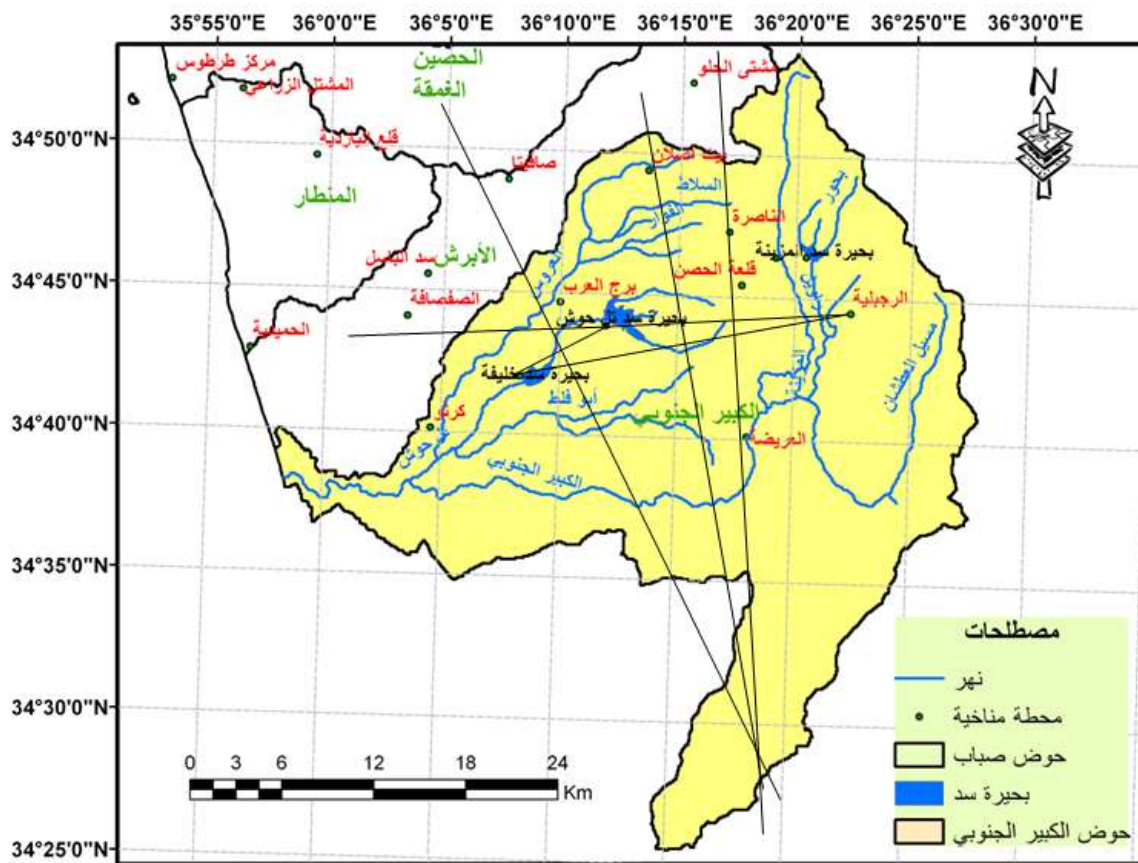
تشكل منطقة الدراسة جزءاً من الساحل السوري حيث تقع جنوب طرطوس إذ يشكل نهر الكبير الجنوبي حدود لبنان الشمالية مع سورية الشكل (1). حيث تبلغ مجمل مساحة حوضها الساكب نحو 990 كيلومتراً مربعاً، منها 295 كيلومتراً مربعاً في لبنان. يقع هذا الحوض بين خطي عرض (°25'0'' 34) و (°50'0'' 34) شمالاً وبين خطي طول (°55'0'' 35) و (°30'0'' 36) شرقاً الشكل (2). استخدمت في هذه الدراسة سلاسل زمنية يومية لكل من الهطول المطري، التبخر، درجة الحرارة، الرطوبة النسبية والتدفق عند مخرج الحوض متوافرة للفترة مابين (2004-2008). حيث جمعت قياسات الهطول المطري من ثلاث محطات منتشرة في الحوض (محطة خليفة، محطة تل حوش، محطة الرجبلية) وجرى حساب قيمة متوسط الهطول المطري اليومي للمحطات الثلاثة باستخدام طريقة مضلعات تيسين. كما يتطلب عمل الشبكات الصناعية إجراء عملية التقييس لكل من قيم متجهات المدخلات والهدف، وذلك لجعل قيم عنصريهما قريبة من بعضها بعضاً؛ لتقليل قيمة الخطأ بين القيم المحسوبة من الشبكة والقيم المأمولة، وهذا يحسن كفاءة العمليات الحسابية وأداء الشبكة. لذلك قيست كافة البيانات باستخدام طريقة (Kumare et al. 2002) [6]، كما هو موضح في المعادل (1):

$$p_{(norm)} = 0.5 \left[ \frac{(p-p_{(mean)})}{p_{(max)}-p_{(min)}} \right] + 0.5 \dots \dots \dots (1)$$

حيث: p: القيم الأصلية ; p(norm): القيم المقيسة; P(mean):معدل القيم الداخلة; p(min): أدنى قيمة داخلة p(max): أقصى قيمة داخلة.



الشكل (1): خارطة الموقع العام لمنطقة البحث



الشكل (2): حوض نهر الكبير الجنوبي

## طرائق البحث ومواده:

### 1. الشبكات العصبية الصناعية

تعد الشبكات العصبية من أهم مجالات الذكاء الصناعي، وتدور فكرة الشبكات العصبية حول محاكاة العقل البشري باستخدام الحاسب الآلي. وقد يعود التطور المنظور في هذا المجال إلى العديد من الدراسات التي تمت في مجال المعالجة العصبية (Neural Processing) وتتم عملية المحاكاة عن طريق حل المشاكل التي تواجهه، وذلك من خلال اتباع عمليات التعلم الذاتي والتي تعتمد على الخبرات المخزنة في الشبكة التي تحقق أفضل نتائج. وقد تم اقتباس أسلوب الشبكات العصبية الصناعية من الشبكات البيولوجية العصبية، ويرجع الفضل في دخولها إلى دائرة الأعمال العالمية على يد كلٍّ من (Mc – Cultch & Pitts) [7].

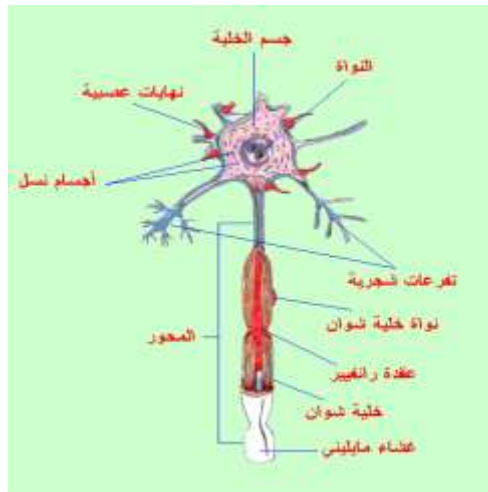
حيث تعرّف الشبكات الصناعية بأنها عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبية الطبيعية للإنسان، حيث تتشابه الشبكة العصبية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، وتخزن هذه المعرفة باستخدام قوى وصل داخل العصبونات تسمى الأوزان التشابكية. ويمكن تدريب الشبكة على إنجاز وظائف معينة من خلال ضبط قيم الأوزان التشابكية بين العناصر [8].

### 1.1. المفاهيم الأساسية لهيكل الشبكات العصبية الصناعية

يتكون هيكل الشبكة البيولوجية كما هو موضح بالشكل (3):

• العصب: وهو الجزء الرئيسي في مخ الإنسان، وهو بمثابة وحدة تشغيل بسيطة تقوم باستقبال ومزج الإشارات التي ترسلها الأعصاب الأخرى، وذلك من خلال هيكل استقبال داخلي يطلق عليه اسم الزائدة (التفرعات) الشجرية (Dendrite).

• المحور: هو محور الإتصال بين محور الخلية العصبية والزوائد الشجرية للعصب. ويقوم الإنسان بتعديل وتغيير قوة الإشتباك عندما يتعلم أكثر حيث يحتوى مخ الإنسان على عشرات المليارات من هذه الأعصاب المتصلة ببعضها بعضا بكثافة شديدة تفوق التصور.



الشكل (3): نموذج للخلية العصبية

وجدير بالذكر أنه في الشبكات العصبية الصناعية تتم عملية معالجة البيانات بين الخلايا العصبية من خلال نقل الإشارات بواسطة وصلات عصبية موجودة في الشبكات بين الخلايا. ولكل وصلة من هذه الوصلات ترجيح بقيمة

معينة تسمى الوزن، حيث يتم ضرب ذلك الوزن بقيمة إشارة خاصة بهذه الوصلة . كما توجد لكل خلية دالة تفعيل Function Activation، والتي تقوم بتحويل صافي مدخلات خلية معينة إلى إشارات خرج (Output Signals) [8].

### 2.1. مفاهيم تقانات الشبكات العصبية الصناعية

• الطبقات (Layers): العدد الكلي لطبقات الشبكة العصبية، أي أنها تمثل طبقات المدخلات (Input Layers)، وطبقات المخرجات (Input Layers). مع ملاحظة أن عقد المدخلات (Nodes) تستخدم فقط لتوزيع الأوزان.

• حجم الطبقة (Layer size): ويحدد بحجم الذاكرة المحددة بالبرنامج الخاص بتشغيل الشبكة الصناعية.  
• الدالة العصبية المستخدمة (Neural Function): هناك عدة أنواع من دوال التفعيل  $f^k$  ذات وظائف مختلفة، وكل واحدة منها تصلح لنوع معين من التطبيقات اعتماداً على المدى المحدد لها. وفيما يأتي سرد لبعض منها بما فيها تلك التي جرى استخدامها في البحث الحالي:

(a) دالة التحويل سيغمويد اللوغاريتمية Log-Sigmoid Transfer Function.

(b) دالة التحويل سيغمويد لظل الزاوية Tan-Sigmoid Transfer Function.

(c) دالة التحويل الخطية (Linear Transfer Function).

صُممت الخلية العصبية الصناعية لتحاكي خصائص الخلية العصبية العضوية حيث تتألف الخلية الصناعية من ثلاثة أقسام أساسية هي: الدخل (الأوزان)، الجامع وتابع التفعيل. حيث تستقبل الخلية العصبية الصناعية عناصر الدخل ومن ثم يُضرب كل عنصر دخل  $P_i$  بالوزن الموافق له  $W_i$  ثم تجمع النتائج للقيمة الإضافية التي تدعى بالانحياز  $b$  كما هو موضح بالشكل (4). والوزن حقيقة هو عبارة عن متحول يأخذ قيم متغيرة، وعندما نضرب به عنصر الدخل نكون بهذه العملية نغير ونعدل من تأثير الدخل على الخلية العصبية الصناعية  $n$  وهذا يقابل عملية المعالجة الكيميائية في المشابك العصبية الحيوية ويكون الناتج على الشكل الآتي:

$$Net = (P_1 W_1 + P_2 W_2 + \dots + P_n W_n) + b \dots \dots \dots (2)$$

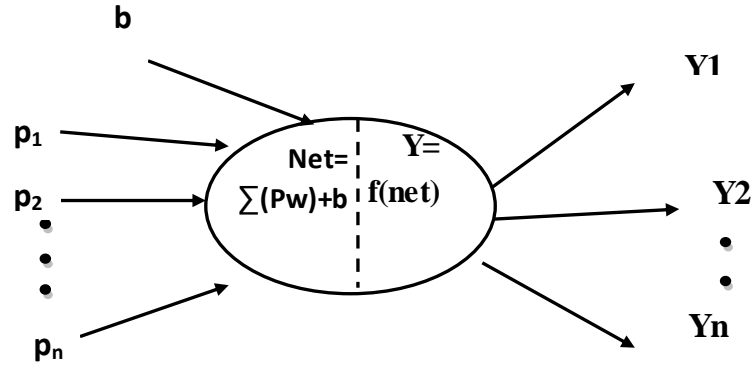
حيث:  $P_i$ : عنصر الدخل؛  $W$ : الوزن؛  $n$ : عدد الخلايا أو الوحدات

يعد شعاع الانحياز ( $b_j$ ) bias بمثابة الحد الثابت في المعادلات الرياضية كثيرات الحدود الذي يساعد في حل تلك المعادلات بصورة أسهل وأسرع.

ثم تجري عملية إدخال ومعالجة الإشارة Net في تابع التفعيل لينتج بذلك خرج الخلية العصبية الصناعية  $Y$ .

$$Y = f(Net) \dots \dots \dots (3)$$

حيث:  $f$ : دالة التحويل (Transfer Function)



الشكل (4): تمثيل تخطيطي للتحويلات داخل عصبونات الشبكة العصبية الصناعية

### 3.1. التصميم الهيكلي لبناء الشبكة العصبية الصناعية


يتضمن التصميم الهيكلي لبناء الشبكات العصبية الصناعية الخطوات الآتية:

- 1 . تجميع البيانات التي تستخدم في تدريب أو اختبار الشبكة ومن ثم وضع خطة التدريب والتعلم.
- 3 . بناء هيكل الشبكة وتحديد تركيب الشبكة في عدد المدخلات والطبقات ونوع الشبكة.
- 4 . اختيار طريقة التعلم حسب ما هو متاح من أدوات أو تطوير الشبكة أو القرارات.
- 5 . وضع قيم للأوزان والمتغيرات، بعد ذلك يتم تعديل قيم الأوزان عن طريق التغذية المرتدة والعكسية.
- 6 . تحويل البيانات إلى النوع المناسب للشبكة ويتم ذلك عن طريق كتابة معادلة لتجهيز البيانات.
- 7 . تتم عمليتي التدريب والاختبار من خلال تكرار عرض المخلات والمخرجات المرغوبة إلى الشبكة. ومنها مقارنة القيم الفعلية مع القيم المحسوبة، ثم حساب الفرق (الخطأ)، ثم تعديل الأوزان لتقليل الفرق حتى يصبح فرقاً مقبولاً. ومن ثم تصل الشبكة من خلال استخدام مدخلات التدريب إلى النتائج المرغوبة، وبهذا يمكن الاعتماد على الشبكة في الاستخدام كنظام مستقل قائم بذاته [8].

### 4.1. أنواع الشبكات العصبية

يمكن تصنيف الشبكات العصبية إلى:


- شبكات أمامية Feed Forward: وهي الشبكات التي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكونة لها. حيث تنتقل العمليات الحسابية في اتجاه واحد إلى الأمام من طبقة المدخلات إلى طبقة المخرجات عبر الطبقات المخفية كما يوضح الشكل (5).



الشكل (5): شبكات التغذية الأمامية

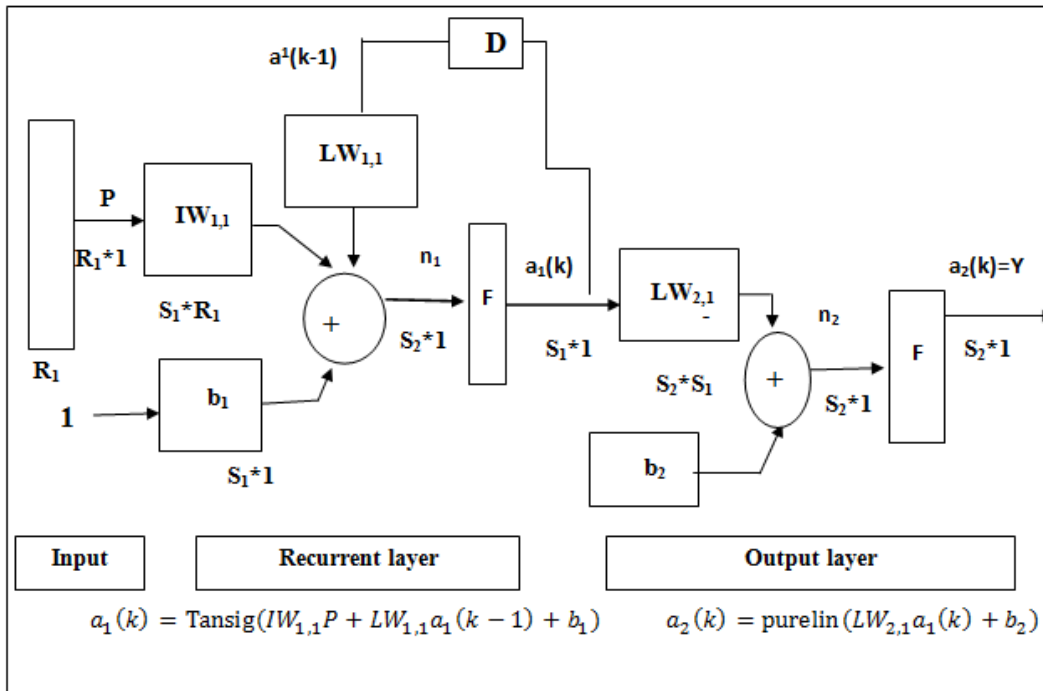
- شبكات إرجاعية Recurrent: وهي الشبكات التي تجد لمخرجاتها طريقاً خلفياً مرة أخرى لتصبح مدخلات، لكي تعطى أفضل النتائج الممكنة كما يبين الشكل (6).





الشكل (6): شبكات التغذية الراجعة

استخدم في هذه الدراسة شبكات Elman حيث تتكون هذه الشبكات من طبقتين ويتم اعتماد تغذية الانتشار العكسي في هذه الشبكة. إن الانتشار العكسي يكون بالتغذية من خرج الطبقة الأولى إلى دخل الطبقة الأولى. تتميز هذه الشبكات بقدرتها على الوصول إلى الحل الأمثل لأنها تعيد خرج الطبقة الخفية إلى طبقة الدخل، مما يزيد من سرعة التدريب وضبط أوزان الشبكة. حيث تسمح طريقة التغذية الراجعة هذه لشبكات Elman بتخزين قيم من خطوة زمنية سابقة واستخدامها في الخطوة الزمنية الحالية. وهذا ما يجعلها مفيدة في التنبؤ حيث يلعب الزمن دوراً مهماً. تستخدم شبكات Elman عصبونات Tansig في الطبقة الخفية (الإرجاعية) وعصبونات Purelin في طبقة الخرج [7]. يوضح الشكل (7) شبكة Elman.



الشكل (7): معمارية شبكة Elman

لكي تملك شبكة Elman أفضل فرصة في تعلم المشكلة فهي بحاجة إلى عدد عصبونات خفية أكبر من ذلك المستخدم عند المحاكاة بطرائق أخرى.

### 5.1. تدريب شبكات Elman

الطريقة الشائعة لتدريب الشبكات العصبية الصناعية في تطبيقات التقارب مثل نمذجة العلاقة R\_R هي طريقة التدريب المراقب. حيث يجري عرض عينات الدخل والخرج على الشبكة، تحاول بعد ذلك خوارزميات الأمثلة تصغير خطأ خرج الشبكة، وذلك بوساطة ضبط مصفوفة أوزان الشبكة. إذ تُدرّب شبكات Elman باستخدام دالة Train. عند استخدام دالة Train لتدريب شبكة Elman فسيحدث الآتي:

- تُقدّم كامل سلسلة الإدخال إلى الشبكة، ومن ثم تُحسب نواتجها وتُقارن مع سلسلة الهدف بهدف توليد سلسلة الخطأ.

- يعاد نشر الخطأ عكسياً Back Propagated وذلك لإيجاد ميول الأخطاء لكل وزن وانحياز حيث أنّ هذه الميول في الحقيقة هي تقريبية، حيث يستعمل هذا الميل التقريبي لتعديل الأوزان بدالة Back Propagated المختارة حيث يوصى باستخدام دالة Traingdx [7].

### 2.4. محاكاة النموذج

إنّ القياسات الأكثر أهمية في محاكاة أداء النموذج المستخدمة في هذه البحث هي متوسط مربع الخطأ (MSE) (Mean Square Error) المعادلة (3)، ومعامل الارتباط (R) (the coefficient of correlation) المعادلة (4).

$$MSE = \frac{1}{2 \cdot q} \sum_{i=1}^{i=q} (Y_i - a_2)^2 \dots \dots \dots (3)$$

حيث: y : المخرجات الهدف Target؛ a<sub>2</sub>: قيمة خرج الشبكة المحسوبة calculated.

$$R = \frac{n \sum(Y-\bar{Y})-(a_2-\bar{a}_2)}{\sqrt{\sum(Y-\bar{Y})^2 \sum(a_2-\bar{a}_2)^2}} \dots \dots \dots (4)$$

في بداية كل محاولة تدريب للشبكة، يجب إعادة إدخال القيم الأولية لكل من أوزان الشبكة وانحيازاتها. الطريقة الأكثر تطبيقاً هي التهيئة المبدئية بشكل عشوائي [9]. الهدف من هذه العشوائية هو إجبار خوارزمية التدريب على البحث عن أجزاء أخرى لفضاء البارامترات، وذلك بهدف الوصول إلى ناتج مثالي عام وزيادة الفرصة بشكل عام لإيجاد الخطأ الأصغري.

### 3. معمارية الشبكة العصبية الصناعية المستخدمة لهذه الدراسة

يتطلب تشكيل الشبكة العصبية الصناعية تحديد كل من الدخل والخرج، وعدد العصبونات الخفية وحساب كفاءة النموذج. يحدد العدد المناسب من العصبونات الخفية في الطبقة الخفية باستخدام التجربة والخطأ. تمّ في هذه الدراسة اختبار أربعة وعشرين نموذجاً بعدد مختلف من العصبونات كما هو موضح في الجدول (1). حيث تُظهر هذه النماذج تأثير عدّة تشكيلات للمدخلات في أداء الشبكة العصبية الصناعية.

الجدول (1): النماذج المختبرة في هذه الدراسة

Model Number	Number of neurons in the Hidden layer	Model description
1	5,10,15,20,25,30	Q t=f(Rt, Evt, Tt, Ht)
2	5,10,15,20,25,30	Q t=f(Rt-1, Evt-1, Tt-1, Ht-1 , Qt-1)
3	5,10,15,20,25,30	Q t=f(Rt, Evt, Tt, Ht, Rt-1, Evt-1, Tt-1, Ht-1 , Qt-1)

4	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, H_t, R_{t-1}, E_{vt-1}, T_{t-1}, H_{t-1}, R_{t-2}, E_{vt-2}, T_{t-2}, H_{t-2}, Q_{t-1}, Q_{t-2})$
5	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, H_t, R_{t-1}, E_{vt-1}, T_{t-1}, H_{t-1}, R_{t-2}, E_{vt-2}, T_{t-2}, H_{t-2}, R_{t-3}, E_{vt-3}, T_{t-3}, H_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
6	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, H_t, R_{t-1}, E_{vt-1}, T_{t-1}, H_{t-1})$
7	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t)$
8	5,10,15,20,25,30	$Q_t = f(R_{t-1}, E_{vt-1}, T_{t-1}, Q_{t-1})$
9	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, R_{t-1}, E_{vt-1}, T_{t-1}, Q_{t-1})$
10	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, R_{t-1}, E_{vt-1}, T_{t-1}, R_{t-2}, E_{vt-2}, T_{t-2}, Q_{t-1}, Q_{t-2})$
11	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, R_{t-1}, E_{vt-1}, T_{t-1}, R_{t-2}, E_{vt-2}, T_{t-2}, R_{t-3}, E_{vt-3}, T_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
12	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, T_t, R_{t-1}, E_{vt-1}, T_{t-1})$
13	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt})$
14	5,10,15,20,25,30	$Q_t = f(R_{t-1}, E_{vt-1}, Q_{t-1})$
15	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, R_{t-1}, E_{vt-1}, Q_{t-1})$
16	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, R_{t-1}, E_{vt-1}, R_{t-2}, E_{vt-2}, Q_{t-1}, Q_{t-2})$
17	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, R_{t-1}, E_{vt-1}, R_{t-2}, E_{vt-2}, R_{t-3}, E_{vt-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
18	5,10,15,20,25,30	$Q_t = f(R_t, E_{vt}, R_{t-1}, E_{vt-1})$
19	5,10,15,20,25,30	$Q_t = f(R_t)$
20	5,10,15,20,25,30	$Q_t = f(R_{t-1}, Q_{t-1})$
21	5,10,15,20,25,30	$Q_t = f(R_t, R_{t-1}, Q_{t-1})$
22	5,10,15,20,25,30	$Q_t = f(R_t, R_{t-1}, R_{t-2}, Q_{t-1}, Q_{t-2})$
23	5,10,15,20,25,30	$Q_t = f(R_t, R_{t-1}, R_{t-2}, R_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
24	5,10,15,20,25,30	$Q_t = f(R_t, R_{t-1})$

## النتائج والمناقشة:

### 1. إدخال البيانات وبناء الشبكة العصبية الصناعية

تم تطوير أربعة وعشرين نموذجاً بعدد مختلف من العصبونات في الطبقة الخفية في كلٍّ من هذه النماذج للتحقق من تأثير وجود كل مدخل في أداء النموذج، وأيضاً للتحقق من أفضل عدد من العصبونات في الطبقة الخفية لكل نموذج. وبغرض الحصول على أفضل هيكلية للشبكة العصبية الصناعية وتحقيق هدف عملية التدريب للشبكة العصبية الصناعية المقترحة، لا بد من الوصول إلى حالة من التوازن بين قابليتها على الاستجابة الصحيحة لبيانات المدخلات المستخدمة في عملية التدريب التي يجري تخزينها في الشبكة لعملية التذكير، وبين قابليتها على إعطاء استجابة جيدة لمدخلات مشابهة، لكنها غير مطابقة لتلك المدخلات المستخدمة في عملية التدريب (عملية التنبؤ). لذلك جرى الاعتماد على طريقة التوقف المبكر، بغية التوصل إلى صفة التعميم الكفؤ، وذلك بتقسيم البيانات إلى ثلاث مجموعات هي مجموعة التدريب، ومجموعة التحقق، ومجموعة الاختبار.

استُخدم في هذه الدراسة نموذج شبكة صناعية (شبكة Elman) ذا معمارية تتكون من عصبون خرج واحد، ثابتة على كامل الدراسة، وطبقة خفية واحدة حيث وجد الحجم المثالي للطبقة الخفية بواسطة اختبار عدّة معماريات تحتوي على عدد مختلف من العصبونات الخفية حتى يتحسن أداء الشبكة بشكل جيد. جرت هذه الاختبارات باستخدام مكتبة

Levenberg–Marquardt خوارزمية وباستخدام خوارزمية backpropagation لتدريب الشبكة.

يظهر الجدول (2) أداء النماذج المشكّلة، حيث جرى اختبار عدّة معماريات للشبكة العصبية الصناعية كما ذكرنا سابقاً، بهدف التوصل إلى أفضل أداء (أصغر قيمة لمتوسط مربع الخطأ). حيث تبين أن الشبكة العصبية الصناعية ذات المعمارية 1-25-19 (19 مدخل في طبقة المدخلات تمثل درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري بتأخر زمني مقداره ثلاثة أيام (-3:0) إضافةً إلى قيم سابقة للتصريف بتأخر زمني (-1:-3)، 25 عصبون في الطبقة الخفية، وعصبون واحد في طبقة الخرج يمثل التصريف عند الزمن ( $t=0$ )) تعطي أفضل أداء (أصغر قيمة لمتوسط مربع الخطأ)  $2.8 \times 10^{-5}$  من أجل المجموعات الثلاثة، ومعامل ارتباط 96% للمجموعات الثلاثة أيضاً.

الجدول (2): أداء النماذج المشكّلة

Model	Number of hidden layer	متوسط مربع الخطأ MSE	معامل الارتباط %R
1	5	0.00157	50
	10	0.00114	52
	15	0.00117	53.5
	20	0.00119	52.7
	25	0.00147	51
	30	0.00109	52.9
2	5	0.00103	48.7
	10	0.00115	54.4
	15	0.000906	61
	20	0.00087	58
	25	0.00101	61
	30	0.000968	61.7
3	5	0.000129	93.5
	10	0.000103	91.8
	15	0.000111	94
	20	0.000104	89.4
	25	$8.72 \times 10^{-5}$	96.1
	30	$7.81 \times 10^{-5}$	92.7
4	5	0.000193	90
	10	$9.5 \times 10^{-5}$	90

	15	$6.37 \cdot 10^{-5}$	92.1
	20	$4.84 \cdot 10^{-5}$	95.3
	25	$5.6 \cdot 10^{-5}$	94
	30	$4.2 \cdot 10^{-5}$	96.2
5*	5	0.000105	90
	10	$3.91 \cdot 10^{-5}$	95
	15	$5.8 \cdot 10^{-5}$	93.1
	20	$4.44 \cdot 10^{-5}$	94.7
	25	$2.8 \cdot 10^{-5}$	96
	30	$3.64 \cdot 10^{-5}$	93.7
6	5	0.00103	48.7
	10	0.00115	54.4
	15	0.00087	58
	20	0.00101	61
	25	0.000968	61.7
	30	0.001	41
7	5	0.00129	42.73
	10	0.00118	51.28
	15	0.00125	60.85
	20	0.00102	59.55
	25	0.00111	60.3
	30	0.00114	57.13
8	5	0.00145	46.77
	10	0.00129	50.79
	15	0.00113	52.94
	20	0.00124	49.27
	25	0.00121	30.39
	30	0.00116	43.94
9	5	0.000134	93.5
	10	$9.19 \cdot 10^{-5}$	94
	15	0.000116	90.5
	20	$7.63 \cdot 10^{-5}$	93.3

	25	$5.88 \cdot 10^{-5}$	9650
	30	$8.29 \cdot 10^{-5}$	94.4
10	5	0.000117	92
	10	$7.45 \cdot 10^{-5}$	89
	15	$6.45 \cdot 10^{-5}$	95.9
	20	$3.82 \cdot 10^{-5}$	94.2
	25	$5.41 \cdot 10^{-5}$	95.6
	30	$5.74 \cdot 10^{-5}$	84
11	5	0.000149	91.6
	10	$4.05 \cdot 10^{-5}$	94.1
	15	$3.98 \cdot 10^{-5}$	93.7
	20	$3.63 \cdot 10^{-5}$	94.8
	25	$6.5 \cdot 10^{-5}$	95
	30	$4.23 \cdot 10^{-5}$	91.3
12	5	0.00104	45
	10	0.0012	27
	15	0.000997	62.2
	20	0.00115	43
	25	0.00109	57
	30	0.00103	29.6
13	5	0.00133	35.5
	10	0.00137	47.5
	15	0.00135	50.34
	20	0.00135	49.82
	25	0.00133	50.69
	30	0.00111	37.92
14	5	0.00147	35.12
	10	0.00133	42.13
	15	0.0015	42.65
	20	0.00134	50.38
	25	0.00127	47.59

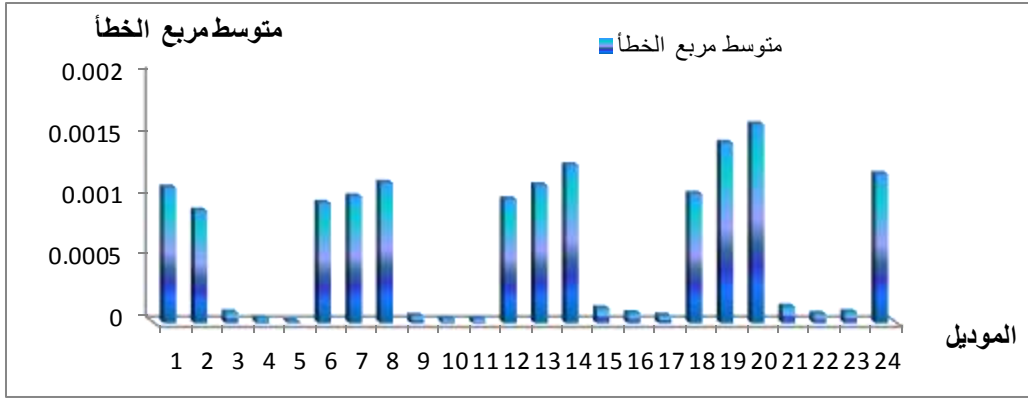
	30	0.00146	40.67
15	5	0.000168	92
	10	0.00012	92.9
	15	0.000158	90
	20	0.000151	92.8
	25	0.000131	91.3
	30	0.000126	91.7
	16	5	0.000135
10		0.000127	94.9
15		0.00015	89
20		$8.67 \cdot 10^{-5}$	89
25		$8.08 \cdot 10^{-5}$	92.5
30		$8.6 \cdot 10^{-5}$	91
17	5	0.000132	89
	10	$9.54 \cdot 10^{-5}$	90
	15	$6.3 \cdot 10^{-5}$	91.1
	20	$6.11 \cdot 10^{-5}$	96.5
	25	$8.35 \cdot 10^{-5}$	93
	30	$8.89 \cdot 10^{-5}$	92.9
18	5	0.00113	46
	10	0.00132	44
	15	0.00104	59
	20	0.00136	43
	25	0.00122	45
	30	0.00133	49
19	5	0.00156	34.69
	10	0.00154	37.17
	15	0.00155	36.66
	20	0.00145	35.7
	25	0.00147	34.25
	30	0.00151	35.12
20	5	0.00161	37.62

	10	0.00163	30.8
	15	0.00162	44.28
	20	0.0016	30.48
	25	0.0016	36.7
	30	0.00163	36.6
21	5	0.000208	92
	10	0.000178	94
	15	0.000204	92
	20	0.000151	91
	25	0.000134	92
	30	0.000141	91
22	5	0.000229	92
	10	0.00015	90
	15	0.000141	91.5
	20	0.000209	93
	25	0.000185	92
	30	$7.51 \cdot 10^{-5}$	90
23	5	0.000112	94.8
	10	0.000109	88.7
	15	0.000137	87
	20	0.000104	89
	25	0.000107	90
	30	$8.94 \cdot 10^{-5}$	91
24	5	0.00158	47
	10	0.00139	33
	15	0.00145	45
	20	0.00134	42
	25	0.00133	51
	30	0.0012	45

\* : أفضل نموذج لشبكات Elman المختبرة



يظهر الشكل (8) أن أداء شبكة Elman الصناعية يتحسن بشكل كبير عند استخدام قيم سابقة للتصريف، كما أن شبكات Elman تعطي أفضل أداء عند استخدام البارامترات الأربعة (الهطول المطري، التبخر، الحرارة، والرطوبة النسبية) وذلك بتأخر زمني يتراوح بين [0 3] مع استخدام قيم سابقة للتصريف بتأخر زمني يتراوح بين [3 1]. كما أن شبكات Elman الصناعية تعطي أداء جيداً عند استخدام مدخلات تمثل الهطول المطري بتأخر زمني يتراوح بين [0 2]، وقيم سابقة للهطول المطري بتأخر زمني يتراوح بين [2 1]، حيث بلغت قيمة متوسط مربع الخطأ 0.0000751 (النموذج 22) وبلغت قيمة معامل الارتباط 90%. ليتحسن أداء الشبكة عند استخدام التبخر إضافة للهطول المطري كمدخلات لتدريب الشبكة إضافة إلى قيم سابقة للتصريف (النموذج 17) حيث بلغت قيمة متوسط مربع الخطأ 0.0000611 ومعامل الارتباط 96.5%، ليتحسن أداء الشبكة عند استخدام مدخل الحرارة إضافة إلى الهطول المطري والتبخر والتصريف (النموذج 11)، ليلعب متوسط مربع الخطأ 0.0000363 ومعامل الارتباط 94.8%، لتعطي شبكة Elman أفضل أداء لها عند استخدام البارامترات الأربعة (الهطول المطري، التبخر، الحرارة، والرطوبة) إضافة إلى قيم سابقة للتصريف كما ذكرنا سابقاً (النموذج 5).

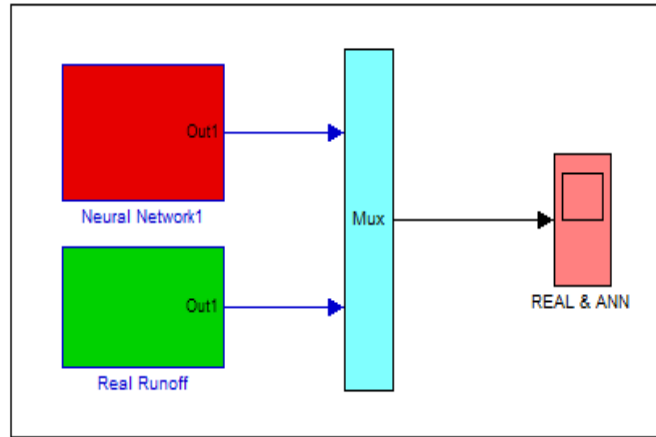


الشكل (8): متوسط مربع الخطأ لكل نموذج

## 2. تقويم أداء الشبكة العصبية الصناعية المقترحة

يعد فحص أداء أي نموذج رياضي مقترح من التطبيقات الاعتيادية والتقليدية في عملية النمذجة الرياضية، حيث يُقيّم حسن الأداء من خلال حساب قيمة الأخطاء بين القيم المقيسة وتلك الناتجة عن الشبكة. ولغرض الاستفادة من التقانات الحديثة في إظهار المقارنة على شكل مرسمات، اقترح بناء نموذج المحاكاة بالاستفادة من تقانة SIMULINK المتاحة في حزمة برمجيات MATLAB، حيث اختُصرَ نموذج المقارنة بوضع الشبكة العصبية الصناعية على شكل قالب جاهز بسيط BLOCK، يحتوي على جميع مفردات الشبكة المقترحة في حزمة قوالب ثانوية يمكن إظهارها بسهولة.


يُظهر النموذج المشكّل باستخدام تقانة Simulink الشكل (9) جمع كل من خرج الشبكة العصبية الصناعية وقيم الجريان السطحي في قالب يسمى MUX، وبذلك يمكن ربطها بمرسم واحد.



الشكل (9): يبين قالب الشبكة العصبية الصناعية


## 3. نتائج المحاكاة

اختُبر نموذج الشبكة العصبية الصناعية المشكل باستخدام مجموعة الاختبار التي تشكل نسبة 20% من البيانات، وذلك للتحقق من أداء الشبكة ومقارنة مخرجات الشبكة المشكلة مع القيم المقيسة، حيث لوحظ التوافق الأدائي بين نتائج الشبكة الصناعية والقيم الحقيقية للتصريف الشكل (10).



الشكل (10): قيم التصريف اليومي المقيسة والنتيجة من أنموذج شبكة Elman لمجموعة الاختبار

كما بلغت قيمة متوسط مربع الخطأ 0.00317 وقيمة معامل الارتباط لمجموعة البيانات المختبرة (0.965)، كما هو واضح في الشكل (11). بالتالي تُظهر النتائج أداء جيداً لأنموذج الشبكة المشكل في نمذجة العلاقة بين الهطول المطري\_الجريان النهري.



الشكل (11): التوافق الخطي بين قيم التصريف اليومية المقاسة وقيم التصريف اليومي الناتجة من شبكة Elman لمجموعة الاختبار

### الاستنتاجات والتوصيات:

- ✘ إن استخدام تشكيل موحد من البارامترات يضمّ كلاً من درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري يزيد من دقة أداء الشبكة المشكّلة للتنبؤ بالتصريف مقارنة مع تشكيلات أخرى تضم جزءاً من البارامترات، كما أنّ استخدام قيم التصريف السابقة في التنبؤ بقيم التصريف المستقبلية يزيد من دقة أداء شبكة Elman الصناعية.
- ✘ يتواجد ارتباط خطي بين مخرجات شبكة Elman الصناعية وبيانات التصريف المقاسة بمعامل ارتباط قدره 96.5%، مما يبيّن إمكانية استخدام هذه التقانة في التنبؤ بقيم التصريف المستقبلية في حوض نهر الكبير الجنوبي.
- ✘ إن استخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب يساعد في تحويل الشبكة المشكّلة إلى شكل قالب Block مما يزيد من دقة وسهولة وسرعة الأداء.

واعتماداً على نتائج البحث يمكن وضع التوصيات الآتية:

- ❖ استخدام أنواع أخرى من الشبكات العصبية الصناعية بنوعيتها شبكات التغذية الأمامية وشبكات التغذية الراجعة لإجراء تحليل الحساسية، أي لاختبار المدخلات الأكثر تأثيراً في نتائج الشبكة. ثم مقارنة أداء الشبكات العصبية الصناعية ذات التغذية الأمامية والشبكات العصبية الصناعية ذات التغذية الراجعة في التنبؤ بقيم التصريف المستقبلية.
- ❖ التنبؤ بالتصريف في حوض نهر الكبير الجنوب باستخدام تشكيلات مختلفة من البارامترات تضمّ كلاً من درجة الحرارة، الرطوبة النسبية، التبخر، الهطول المطري، معامل استخدام الأراضي، نوع التربة، التصريف الجوفي.

## المراجع:

1. SOLAIMANI, k. *Rainfall-runoff Prediction Based on Artificial Neural Network (A Case Study: Jarahi Watershed)*. ISSN United States. 2009, 856-865.
2. DHAMGE, N. ؛KADU, M. ؛ATMAPOOJYA, S. *Rainfall Runoff Modelling Studies Using Artificial Neural Network*. International J.of Multidisp. Research & Advcs. in Engg. (IJMRAE) India, Vol. 4, N°. I, 2012, 27-38.
3. LAFDANI, E.؛ NIA, A.؛ PAHLAVANRAVI, A.؛ AHMADI, A.؛ JAJARMIZADEH, M. *Daily Rainfall-Runoff Prediction and Simulation Using ANN, ANFIS and Conceptual Hydrological MIKE11/NAM Models*. International Journal of Engineering & Technology Sciences Iran. 2013, 32-50.
4. DOZIER, A. *Influence of spatial variation in precipitation on artificial neural network rainfall-runoff model*. Hydrology Days U. S. A. 2012, 29-42.
5. ALOK, A. ؛PATRA, K. C.؛ DAS, S.K. *Prediction of Discharge with Elman and Cascade Neural Networks*. Research Journal of Recent Sciences India, Vol.2, 2013, 279-284.
6. KUMARE, M. et, al. *Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering ASCE U.S.A. Vol. 128, N°. 4, 2002, 224-233.
7. Matlab/R2012b/Help/Historical Networks (Neural Network Toolbox), 2012.
8. عبد الحميد محمد العباسي. مقدمة في الشبكات العصبية الصناعية وتطبيقاتها في العلوم الاجتماعية باستخدام spss . معهد الدراسات والبحوث الإحصائية مصر. 2013، 1-39 .
9. ZIJDERVELD, A. *Neural network design strategies and modelling in hydroinformatics*, Delft University of Technology Netherlands, 2003, 146.