

## محاكاة العناصر الفعالة للجريان السطحي باستخدام تقنيات الذكاء الصناعي في حوض نهر مرقية

يمان ابراهيم يوسف \* الدكتور الياس ليوس \*\* الدكتور ياسر حمدان \*\*

### ملخص البحث

تعد النمذجة المائية أداة مهمة جداً في مجال الدراسات الهيدرولوجية حيث تطوّرت من الطرائق الفيزيائية إلى التصويرية ومن ثمّ الطرائق التجريبية، وبالتالي سهّلت هذه التقنيات التنبؤ بحدوث الفيضانات وغزارتها وأماكن الغمر على ضفاف المجاري المائية، لذلك تهدف الدراسة الحالية إلى استخدام الشبكات العصبية الصناعية، التي تعدّ إحدى أنواع هذه التقنيات، لنمذجة العلاقة ( الهطول المطري - الجريان السطحي) في حوض نهر مرقية في محافظة طرطوس. حيث تمّ الاعتماد على شبكة (Elman) الصناعية للتنبؤ بالجريان السطحي باختبار اثنين وعشرين نموذجاً ذات معماريات مختلفة، كما تمّ اختبار كلّ موديل باستخدام عدد مختلف من العصبونات الخفية، وذلك باستخدام مكتبة (nntool) المتاحة في حزمة برمجيات (Matlab).

أثبتت نتائج هذه الدراسة أن الموديل الذي يحوي في طبقة المدخلات على كلّ من درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري بتأخر زمني مقداره يومان (2:0-) إضافةً إلى قيم سابقة للتصريف بتأخر زمني (1:-3) ومع استخدام (25) عصبون في الطبقة الخفية يعطي أفضل أداء بمتوسط مربع خطأ مقداره (  $3.1 \times 10^{-5}$  ) ومعامل ارتباط (0.97) 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 Matlab, Elman.

\*طالب دراسات عليا (دكتوراه)- كلية الهندسة المدنية- جامعة البعث  
\*\*أستاذ- في قسم هندسة وإدارة الموارد المائية- كلية الهندسة المدنية- جامعة البعث- حمص - سورية .  
\*\*أستاذ- في قسم هندسة وإدارة الموارد المائية- كلية الهندسة المدنية- جامعة البعث- حمص - سورية .

## Simulation of effective elements of surface runoff using artificial intelligence techniques in the Marqia River Basin

### Abstract

Water modeling is a very important tool in the field of hydrological studies. It developed from physical methods to conceptual and then experimental methods, these technologies facilitated the prediction of the occurrence of floods, their intensity, and places of inundation on the banks of waterways. There for the current study uses artificial neural networks, which is one type of these technologies, to model the relationship (Rainfall–Runoff) in the Marqia River Basin in Tartous Governorate. The artificial (Elman) network was relied upon to predict surface runoff by testing twenty-two models with different architectures, and each model was tested using a different number of hidden neurons using the (nntool) library available in the (matlab) software package.

The results of this study proved that the model contains in the input layer the temperature, relative humidity, evaporation and precipitation with a time delay of two days (-2:0) in addition to values preceding the discharge with a time delay (-3:-1) and with the use of (25) neurons in the hidden layer gives the best performance with mean square error Its amount ( $3.1 \times 10^{-5}$ ) and correlation coefficient (0.97) for the data set used, It was concluded that Elman networks give good results in relationship modeling (R<sub>R</sub>), and It can be considered an alternative to traditional methods of relationship modeling (R<sub>R</sub>).

**key words:** Rainfall\_ Riverflow , Artificial Neural Network, Networks Elman ,Matlab ...

**1. مقدمة Introduction:**

تعدّ النمذجة الدقيقة للعلاقة بين الهطول المطري\_جريان السطحي (Rainfall\_Runoff) ( $R_R$ ) مهمة معقدة جداً، على الرغم من حقل النمذجة الواسع الذي يشمل كلاً من الطرائق الموجهة بالمعرفة والطرائق الموجهة بالبيانات. تتطلب الموديلات 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 حيث 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 البعض 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 أوحى للهيروولوجيين باستخدام هذه الشبكات في نمذجة العلاقة بين الهطول المطري\_جريان النهري في أماكن مختلفة من العالم. لقد 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 نتائج مع الطرائق التقليدية [1]. هذا وقد نشر (Dhamge, N. et, 2012) al. 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، واقترحت 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 (موديلات 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 أنموذج الهطول المطري\_ الجريان النهري المشكّل باستخدام شبكة Elman ذات التغذية الراجعة لتدريب ومحاكاة قياسات التدفق النهري في حوض Colorado في Creek Fountain [4]. كما اقترح (Alok, A. 2013) في دراسة

أجراها لنمذجة العلاقة R\_R في نهر Brahmani في الهند اعتبار الشبكات العصبية الصناعية أداة للتنبؤ بالتصريف، حيث استخدم الباحث في دراسته نوعان للشبكات العصبية الصناعية هي شبكات Elman الإرجاعية وشبكات Cascade [5].

## 2. أهمية البحث وأهدافه The importance of the research and its goals

انطلاقاً من أهمية التنبؤ بقيم التصريف المستقبلية للنهر، باعتباره ضرورياً للتنبؤ بالفيضان، إضافةً إلى دوره في إدارة الموارد المائية، تأتي ضرورة 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 عدد كبير من البارامترات، لذلك يهدف هذا البحث إلى وضع أنموذج 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 ثمّ بناء أنموذج للعلاقة بين الهطول المطري\_الجريان النهري باستخدام شبكات (Elman) الصناعية.
- ❖ تقويم أداء الأنموذج المشكل باستخدام تقانة (Simulink) المتاحة في حزمة برمجيات الماتلاب.

### 3. موقع منطقة البحث :The site of the research area

يعتبر نهر مرقية من أهم المجاري المائية في المنطقة الساحلية وتبلغ مساحة الحوض الصباب ( 358 كم<sup>2</sup> ) ، يتميز القسم العلوي للحوض بشبكه الهيدروغرافية الكثيفة وأهم روافده وادي تعنيتا الحاج حسن - صوراني الشكل (1). تعتبر الجيولوجيا السائدة لهذا الحوض متنوعة حيث تنتشر تشكيلات متنوعة تبدأ بالجوراسي في المناطق العليا للحوض وتليها تشكيلات الكريتاسي المختلفة مع صبات بازلتية في مناطق متفرقة حيث المواصفات الهيدروجيولوجية لهذه التشكيلات تتصف بانتشار الشقوق والكاريست مع فوالق متنوعة الاتجاهات وتزيد نفوذية هذه التشكيلات وتوزع المياه على الروافد الأتية:

1- نهر الصوراني ومساحة حوضه الصباب ( 110 كم<sup>2</sup> ) .

2- نهر تعنيتا ومساحة حوضه الصباب ( 50 كم<sup>2</sup> ) .

3- نهر السكاف ومساحة حوضه الصباب ( 55 كم<sup>2</sup> ) .

4- مسيل وادي إبراهيم ومساحة حوضه الصباب ( 50 كم<sup>2</sup> ) .

وهناك مسيلات أخرى ووديان بمساحة حوض صباب ( 93 كم<sup>2</sup> ) ويصب النهر في البحر على مسافة ( 15 كم ) شمالي طرطوس الشكل (2). استخدمت في هذه الدراسة سلاسل زمنية يومية لكل من الهطول المطري، التبخر، درجة الحرارة، الرطوبة النسبية والتدفق عند مخرج الحوض متوافرة للفترة ما بين (2010-2005). حيث جمعت قياسات الهطول المطري من محطات منتشرة في الحوض وجرى حساب قيمة متوسط الهطول المطري اليومي للمحطات (القدموس - صايا - الصوراني- سريجس) باستخدام طريقة مضلعات تيسين. كما يتطلب عمل الشبكات الصنعية إجراء عملية التقييس لكل من قيم متجهات المدخلات والهدف، وذلك لجعل قيم عنصريهما قريبة من بعضها البعض؛ 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 المعادلة (1):

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

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

محاكاة العناصر الفعالة للجريان السطحي باستخدام تقنيات الذكاء الصناعي في حوض نهر مرقية



الشكل (2): حوض نهر الغمفة



#### 4. طرائق البحث ومواده:

##### 1.4. الشبكات العصبية الصناعية

تعتبر 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 المخترنة 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 كل 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].

##### 1.1.4. المفاهيم الأساسية لهيكل الشبكات العصبية الصناعية:

في الشبكات العصبية الصناعية تتم عملية معالجة البيانات بين الخلايا العصبية من خلال نقل الإشارات بواسطة وصلات عصبية موجودة في الشبكات بين الخلايا بعضها البعض. 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 صافى مدخلات خلية معينة إلى إشارات خرج (Output Signals) [8].

ومن أهم مفاهيم تقانات الشبكات العصبية الصناعية:

- الطبقات (Layers): العدد الكلي لطبقات الشبكة العصبية، التي بدورها هي 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 ) بالوزن الموافق له ( W ) ثم تجمع النتائج للقيمة الإضافية التي تدعى بالانحياز b كما هو موضح بالشكل (3).



الشكل (3): تمثيل تخطيطي للتحويلات داخل عصبونات الشبكة العصبية الصناعية

والوزن حقيقة هو عبارة عن متحول يأخذ قيم متغيرة، وعندما يضرب 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:

$$\text{Net} = (P_1W_1 + P_2W_2 + \dots + P_nW_n) + b \quad (2)$$

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

يعد شعاع الانحياز (bj) 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.

$$Y = f(\text{Net}) \quad (3)$$

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


#### 2.1.4. التصميم الهيكلي لبناء الشبكة العصبية الصناعية

1. يتضمن التصميم الهيكلي لبناء الشبكات العصبية الصناعية الخطوات الآتية:
2. 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].

### 3.1.4. 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 (4).
- شبكات إرجاعية Recurrent: وهي الشبكات التي تجد لمخارجاتها طريقاً خلفياً مرة أخرى لتصبح مدخلات؛ لكي تعطى أفضل النتائج الممكنة كما يبين الشكل (5).

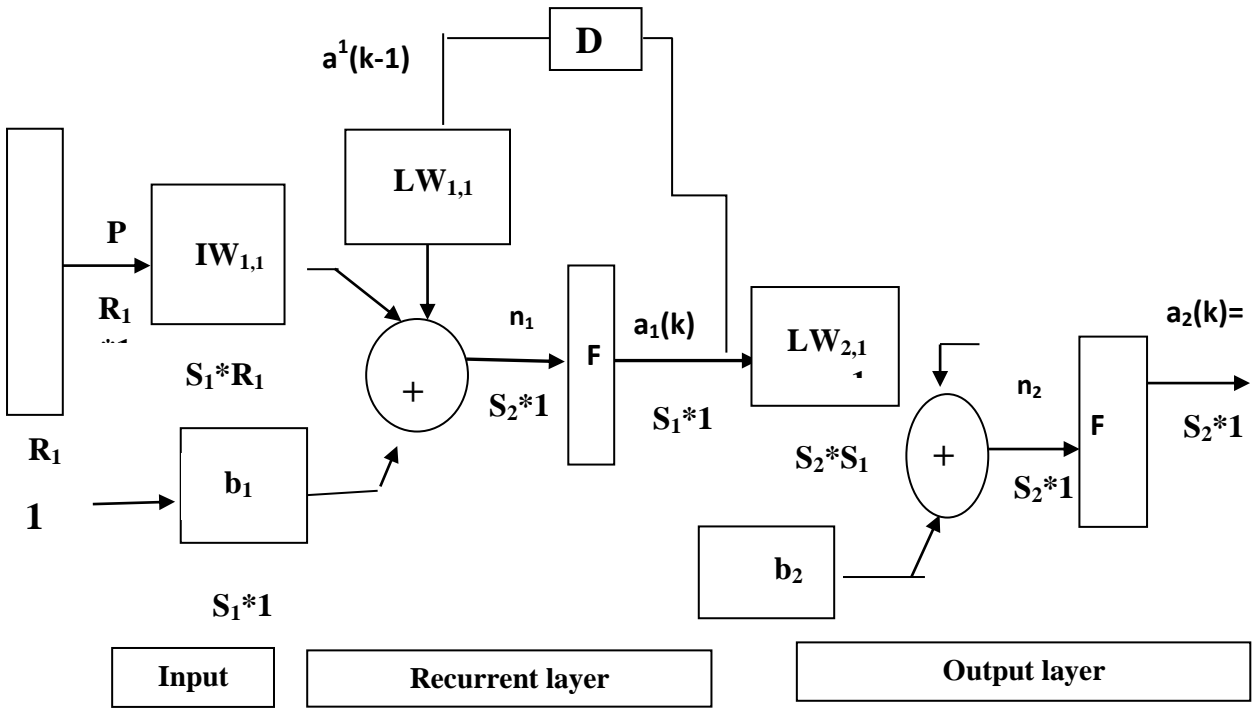


الشكل (5): شبكات التغذية الإرجاعية

الشكل (4): شبكات التغذية الأمامية

استخدمت في هذه الدراسة شبكات Elman حيث تتكون هذه الشبكات من طبقتين ويتم اعتماد تغذية الانتشار العكسي في هذه الشبكة. إنَّ 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 (6) شبكة Elman .



$$a_1(k) = \text{Tansig}(IW_{1,1}P + LW_{1,1}a_1(k-1) + b_1)$$

$$a_2(k) = \text{purelin}(LW_{2,1}a_1(k) + b_2)$$

الشكل (6): 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.

$IW$ : أوزان الطبقة الخفية،  $b_{(1)}$ : عامل الانحياز للطبقة الأولى،  $a_{(1)}$ : مخرجات الوحدة الخفية،  $LW$ : أوزان طبقة المخرجات،  $b_{(2)}$ : عامل الانحياز للطبقة الثانية،  $a_{(2)}$ : المخرجات الفعلية.

#### 4.1.4. 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 الدخول والمخرج على الشبكة، تحاول بعد ذلك خوارزميات الأمثلة تصغير خطأ خرج الشبكة، وذلك بواسطة 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 (the coefficient of )

(R) correlation) المعادلة (4) .

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

حيث: y : المخرجات الهدف Target؛  $a_2$ : قيمة خرج الشبكة المحسوبة calculated.

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

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.

## 3.4. هيكلية 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 اثنان وعشرين نموذجاً بعدد مختلف من العصبونات كما هو موضح في الجدول (1). حيث تُظهر هذه النماذج تأثير عدّة تشكيلات للمدخلات على أداء الشبكة العصبية الصناعية.



الجدول (1): النماذج المختبرة في هذه الدراسة

رقم النموذج	عدد العصبونات في الطبقة الخفية	وصف النموذج
1	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, H_t)$
2	5,10,15,20,25,30	$Q_t=f(R_{t-1}, EV_{t-1}, T_{t-1}, H_{t-1}, Q_{t-1})$
3	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, H_t, R_{t-1}, EV_{t-1}, T_{t-1}, H_{t-1}, Q_{t-1})$
4	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, H_t, R_{t-1}, EV_{t-1}, T_{t-1}, H_{t-1}, R_{t-2}, EV_{t-2}, T_{t-2}, H_{t-2}, Q_{t-1}, Q_{t-2})$
5	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, H_t, R_{t-1}, EV_{t-1}, T_{t-1}, H_{t-1}, R_{t-2}, EV_{t-2}, T_{t-2}, H_{t-2}, R_{t-3}, EV_{t-3}, T_{t-3}, H_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
6	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, H_t, R_{t-1}, EV_{t-1}, T_{t-1}, H_{t-1})$
7	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t)$
8	5,10,15,20,25,30	$Q_t=f(R_{t-1}, EV_{t-1}, T_{t-1}, Q_{t-1})$
9	5,10,15,20,25,30	$Q_t=f(R_t, EV_t, T_t, R_{t-1}, EV_{t-1}, T_{t-1}, Q_{t-1})$
10	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, R_{t-1}, EV_{t-1}, T_{t-1}, R_{t-2}, EV_{t-2}, T_{t-2}, Q_{t-1}, Q_{t-2})$
11	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, R_{t-1}, EV_{t-1}, T_{t-1}, R_{t-2}, EV_{t-2}, T_{t-2}, R_{t-3}, EV_{t-3}, T_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
12	5,10,15,20,25,30	$Q_t=f(R_t, Evt, T_t, R_{t-1}, EV_{t-1}, T_{t-1})$
13	5,10,15,20,25,30	$Q_t=f(R_t, Evt)$
14	5,10,15,20,25,30	$Q_t=f(R_{t-1}, EV_{t-1}, Q_{t-1})$
15	5,10,15,20,25,30	$Q_t=f(R_t, Evt, R_{t-1}, EV_{t-1}, Q_{t-1})$
16	5,10,15,20,25,30	$Q_t=f(R_t, Evt, R_{t-1}, EV_{t-1}, R_{t-2}, EV_{t-2}, Q_{t-1}, Q_{t-2})$
17	5,10,15,20,25,30	$Q_t=f(R_t, Evt, R_{t-1}, EV_{t-1}, R_{t-2}, EV_{t-2}, R_{t-3}, EV_{t-3}, Q_{t-1}, Q_{t-2}, Q_{t-3})$
18	5,10,15,20,25,30	$Q_t=f(R_t, Evt, R_{t-1}, EV_{t-1})$
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	$Q_t=f(R_t, R_{t-1}, R_{t-2}, Q_{t-1}, Q_{t-2})$

$R_t$ : الرطوبة النسبية،  $Evt$ : التبخر،  $T_t$ : درجة الحرارة،  $H_t$ : الهطول المطري،  $Q_t$

التصريف، بالإضافة لقيم بتأخر زمني مقداره يومان (0:-2).

$R_{t-1}$ : الرطوبة النسبية بتأخر مقداره يوم واحد،  $EV_{t-1}$ : التبخر بتأخر زمني مقداره يوم واحد،

$T_{t-1}$ : درجة الحرارة بتأخر زمني مقداره يوم واحد،  $H_{t-1}$ : الهطول المطري بتأخر زمني مقداره

يوم واحد.

## 5. النتائج والمناقشة The Results and Discussion

### 1.5. إدخال البيانات وبناء الشبكة العصبية الصناعية:

تم تطوير اثنان وعشرون موديلاً بعدد مختلف من العصبونات في الطبقة الخفية في كل من هذه النماذج للتحقق من تأثير وجود كل مدخل على أداء النموذج، وأيضاً للتحقق من أفضل عدد من العصبونات في الطبقة الخفية لكل موديل. 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 التنكير، وبين قابليتها على إعطاء استجابة جيدة لمدخلات مشابهة، لكنها غير مطابقة لتلك المدخلات المستخدمة في عملية التدريب (عملية التحقق validation). لذلك جرى الاعتماد على طريقة التوقف المبكر، بغية التوصل إلى صفة التعميم الكفوء، 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 بوساطة اختبار عدّة معماريات تحتوي على عدد مختلف من العصبونات الخفية حتى يتحسن أداء الشبكة بشكل جيد. جرت هذه الاختبارات باستخدام مكتبة nntool المتاحة في حزمة برمجيات الماتلاب، وباستخدام خوارزمية Levenberg–Marquardt backpropagation لتدريب الشبكة.

يظهر الجدول (2) أداء بعض النماذج المشكّلة والتي أعطت نتائج جيّدة مقارنة بباقي النماذج المشكّلة والتي تمّ ذكرها سابقاً في الجدول (1)، حيث جرى اختبار عدّة معماريات للشبكة العصبية الصناعية، بهدف التوصل إلى أفضل أداء (أصغر قيمة

لمتوسط مربع الخطأ). حيث تبين أن الشبكة العصبية الصناعية ذات المعمارية 19-1 (25-19) مدخل في طبقة المدخلات تمثل درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري بتأخر زمني مقداره يومان (0:2-) إضافة 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)  $3.1 \times 10^{-5}$  من أجل المجموعات الثلاثة، ومعامل ارتباط 97% للمجموعات الثلاثة أيضاً.

الجدول (2): أداء النماذج المشكلة

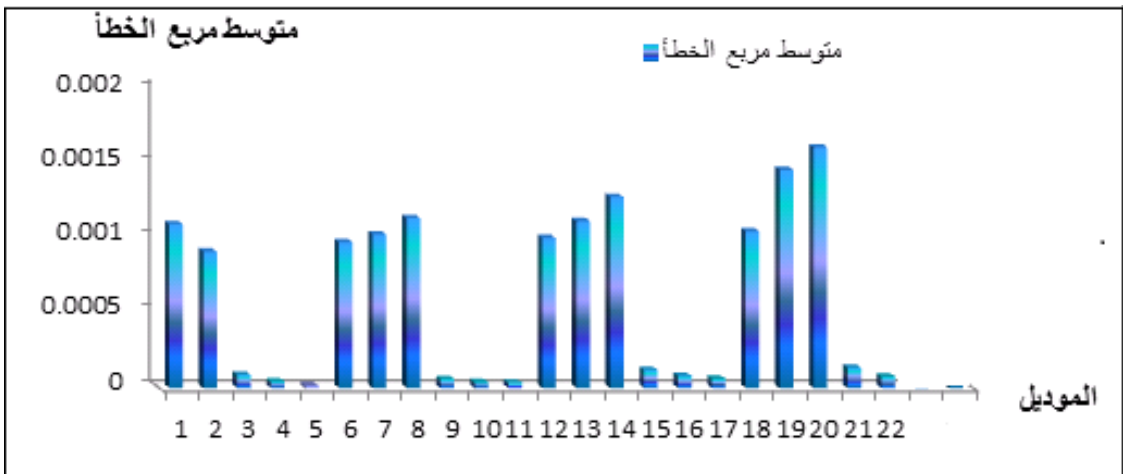
Model	Number of hidden layer	متوسط مربع الخطأ MSE	معامل الارتباط %R	Model	Number of hidden layer	متوسط مربع الخطأ MSE	معامل الارتباط %R
1	5	480.001	55	12	5	0.00123	46
	10	160.001	45		10	0.0015	30
	15	180.001	3.55		15	0.000878	65
	20	200.001	48		20	0.00183	53
	25	500.001	75		25	0.00111	56
	30	120.001	53		30	0.00109	33
2	5	80.0010	9.64	13	5	0.00122	36.7
	10	130.001	7.35		10	0.00137	47.5
	15	8080.000	46		15	0.00135	50.34
	20	780.000	65		20	0.00135	49.82
	25	80.0010	67		25	0.00133	50.69
	30	8940.000	62		30	0.00111	37.92
3	5	330.0001	92	14	5	0.00147	35.12
	10	70.00010	93		10	0.00133	42.13
	15	150.0001	91		15	0.0015	42.65
	20	0.000123	.288		20	0.00134	50.38
	25	$6.82 \times 10^{-5}$	93		25	0.00127	47.59
	30	$5.67 \times 10^{-5}$	89.1		30	0.00146	40.67
4	5	0.000188	91	15	5	0.000168	92
	10	$6.5 \times 10^{-5}$	92		10	0.00012	92.9
	15	$7.63 \times 10^{-5}$	90		15	0.000158	90
	20	$3.84 \times 10^{-5}$	96		20	0.000151	92.8
	25	$6.8 \times 10^{-5}$	95		25	0.000131	91.3
	30	$3.9 \times 10^{-5}$	94.6		30	0.000126	91.7
5*	5	0.000115	91	16	5	0.000135	92.7
	10	$2.98 \times 10^{-5}$	94		10	0.000127	94.9
	15	$6.7 \times 10^{-5}$	91.3		15	0.00015	89

محاكاة العناصر الفعالة للجريان السطحي باستخدام تقنيات الذكاء الصناعي في حوض نهر مرقية

	20	$4.5 \times 10^{-5}$	92.5		20	$8.67 \times 10^{-5}$	89
	25	$3.1 \times 10^{-5}$	97		25	$8.08 \times 10^{-5}$	92.5
	30	$2.89 \times 10^{-5}$	91.8		30	$8.6 \times 10^{-5}$	91
6	5	0.00112	48.7	17	5	0.000132	89
	10	0.00114	55		10	$9.54 \times 10^{-5}$	90
	15	0.00065	53		15	$6.3 \times 10^{-5}$	91.1
	20	0.00113	62		20	$6.11 \times 10^{-5}$	96.5
	25	0.000346	56.9		25	$8.35 \times 10^{-5}$	93
	30	0.0034	42.3		30	$8.89 \times 10^{-5}$	92.9
	7	5	0.00125		43	18	5
10		0.00116	53.4	10	0.00132		44
15		0.00123	59.2	15	0.00104		59
20		0.00132	62	20	0.00136		43
25		0.00171	61	25	0.00122		45
30		0.00115	56	30	0.00133		49
8	5	0.00154	45	19	5	0.00156	34.69
	10	0.00132	51		10	0.00154	37.17
	15	0.00114	53		15	0.00155	36.66
	20	0.00134	48.5		20	0.00145	35.7
	25	0.00112	33		25	0.00147	34.25
	30	0.00117	42.8		30	0.00151	35.12
9	5	0.000135	92	20	5	0.00161	37.62
	10	$8.78 \times 10^{-5}$	95		10	0.00163	30.8
	15	0.000114	91		15	0.00162	44.28
	20	$6.56 \times 10^{-5}$	92.2		20	0.0016	30.48
	25	$4.76 \times 10^{-5}$	94		25	0.0016	36.7
	30	$9.85 \times 10^{-5}$	92.6		30	0.00163	36.6
10	5	0.000119	90	21	5	0.000208	92
	10	$6.98 \times 10^{-5}$	85		10	0.000178	94
	15	$5.46 \times 10^{-5}$	94.5		15	0.000204	92
	20	$2.94 \times 10^{-5}$	95.6		20	0.000151	91
	25	$4.67 \times 10^{-5}$	93		25	0.000134	92
	30	$3.89 \times 10^{-5}$	86		30	0.000141	91
11	5	0.000143	90.8	22	5	0.000229	92
	10	$3.98 \times 10^{-5}$	93.4		10	0.00015	90
	15	$4.01 \times 10^{-5}$	92.8		15	0.000141	91.5
	20	$3.45 \times 10^{-5}$	95		20	0.000209	93
	25	$5.7 \times 10^{-5}$	94.7		25	0.000185	92
	30	$2.34 \times 10^{-5}$	92		30	$7.51 \times 10^{-5}$	90

\* : أفضل نموذج لشبكات Elman المختبرة

يظهر الشكل (7) أنّ أداء شبكة Elman الصناعية يتحسن بشكلٍ كبير عند استخدام قيم سابقة للتصريف، كما أنّ شبكات Elman تعطي أفضل أداء عند استخدام البارامترات الأربعة (الهطول المطري، التبخر، الحرارة، والرطوبة) وذلك بتأخر زمني يتراوح بين [ 0 3] مع استخدام قيم سابقة للتصريف بتأخر زمني يتراوح بين [3 1]. كما أنّ شبكات Elman الصناعية تعطي أداء جيد عند استخدام مدخلات تمثل الهطول المطري بتأخر زمني يتراوح بين [2 0]، 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 إضافةً 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)، ليلبغ متوسط مربع الخطأ 0.000057 ومعامل الارتباط 94.7%، 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(7): متوسط مربع الخطأ لكل نموذج

## 2.5. تقويم أداء الشبكة العصبية الصناعية المقترحة

يعدُّ فحص أداء أي نموذج رياضي مقترح من التطبيقات الاعتيادية والتقليدية في عملية النمذجة الرياضية، حيث يُقِيمُ حسنُ 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 اختُصِرَ أنموذج 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 (8) جمع كل من خرج الشبكة العصبية الصناعية وقيم الجريان السطحي في قالب يسمى Mux، وبذلك يمكن ربطها بمرتمس واحد.



الشكل (8): يبين قالب الشبكة العصبية الصناعية


### 3.5. 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 المقیسة، حيث لوحظ التوافق الأدائي بين نتائج الشبكة الصناعية والقيم الحقيقية للتصريف للشكل (9).



الشكل (9): قيم التصريف اليومي المقیسة والنتيجة من أنموذج شبكة Elman لمجموعة الاختبار

كما بلغت قيمة متوسط مربع الخطأ 0.00317 وقيمة معامل الارتباط لمجموعة البيانات المختبرة (0.97)، كما هو واضح في الشكل (10). بالتالي تُظهر النتائج أداءً جيداً لأنموذج الشبكة المشكل في نمذجة العلاقة بين الهطول المطري\_الجريان النهري.



الشكل (10): التوافق الخطي بين قيم التصريف اليومية المقيسة وقيم التصريف اليومي الناتجة من شبكة Elman لمجموعة الاختبار

## 6. الاستنتاجات والتوصيات:

☒ إن استخدام تشكيل موحد من البارامترات يضمّ كلاً من درجة الحرارة، الرطوبة النسبية، التبخر والهطول المطري يزيد من دقة أداء الشبكة المشكلة 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.

☒ هناك ارتباط خطي بين مخرجات شبكة Elman الصناعية وبيانات التصريف المقيسة بمعامل ارتباط قدره 97%، مما يبيّن إمكانية استخدام هذه التقنية في التنبؤ بقيم التصريف المستقبلية في حوض نهر مرقية.



✘ 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:

- ❖ الاستفادة من طرق الذكاء الصناعي في تحديد قيم معامل الجريان السطحي في الأحواض المدروسة ومقارنة تلك القيم مع الدراسات النظرية لها .
- ❖ استخدام أنواع أخرى من الشبكات العصبية الصناعية بنوعها شبكات التغذية الأمامية وشبكات التغذية الراجعة لإجراء تحليل الحساسية أي لاختبار المدخلات الأكثر تأثيراً على نتائج الشبكة. ومن ثمّ مقارنة أداء الشبكات العصبية الصناعية ذات التغذية الأمامية والشبكات العصبية الصناعية ذات التغذية الراجعة في التنبؤ بقيم التصريف المستقبلية.
- ❖ التنبؤ بالتصريف في حوض نهر مرقية 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 Multidispl. Research & Advcs. in Engg. (IJMRAE) India, Vol. 4, N<sup>o</sup>. 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, 279-2013.
6. KUMARE, M. et, al. *Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering ASCE U.S.A. Vol. 128, N<sup>o</sup>. 4, 2002, 224-233.
7. Matlab/R2012b/Help/Historical Networks (Neural Network Toolbox).
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.
10. عمار غطفان ، حايك شريف . العلاقة بين الهطل المطري والجريان في حوض نهر مرقية . مجلة جامعة تشرين للبحوث والدراسات العلمية (2015).