

أنموذج شبكة عصبية اصطناعية للعلاقة بين الهطل المطري والجريان النهري حالة دراسة حوض نهر الأبرش

د. غطفان عبد الكريم عمّار*

أماني غسان حسين**

(تاريخ الإيداع 22 / 10 / 2018. قُبِلَ للنشر في 4 / 3 / 2019)

□ ملخّص □

تُعتبر العلاقة بين الهطل المطري و الجريان النهري (R_R) Rainfall_Runoff من أكثر الظواهر الهيدرولوجية تعقيداً بسبب طبيعتها غير الخطية، نظراً للتباين المكاني والزمني الكبير لخصائص الأحواض النهرية وأنماط هطول الأمطار، كما تلعب دوراً هاماً في التنبؤ بالأحداث المتطرفة (فيضانات وجفاف)، وتُسهم في تحقيق الإدارة الجيدة لمشاريع تنمية الموارد المائية. تهدف هذه الدراسة إلى نمذجة العلاقة بين الهطل المطري_الجريان النهري في حوض نهر الأبرش باستخدام تقانة الشبكة العصبية الاصطناعية (ANN) Artificial Neural Network، والاعتماد على البيانات اليومية للهطل المطري، التبخر، منسوب المياه في بحيرة سد الباسل، بالإضافة إلى بيانات الجريان النهري السابق للأشهر الماطرة الممتدة بين عامي (2009-2013) باستخدام برنامج Matlab. وقد أظهرت النتائج أن الشبكة العصبية الاصطناعية ذات الهيكلية (1-10-11) أعطت أفضل أداء بمعامل ارتباط $R=98.15\%$ ، وجذر متوسط مربّع الخطأ $RMSE = 1.3721 \text{ m}^3/\text{s}$ خلال مرحلة الاختبار، أثبتت الدراسة أنّ تقانة الشبكة العصبية الاصطناعية تقدّم نتائج جيدة في نمذجة العلاقة R_R لمنطقة البحث.

الكلمات المفتاحية: الشبكة العصبية الاصطناعية، النمذجة، الهطل المطري_الجريان النهري.

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

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

Artificial Neural Network Model for Rainfall _ Runoff relationship: A Case Study of Al-Abrash Catchment

Dr. Ghatfan Ammar*
Amany Hossein**

(Received 22 / 10 / 2018. Accepted 4 / 3 / 2019)

□ ABSTRACT □

Rainfall _ Runoff relationship (R-R) is one of the most complex hydrological phenomena because of its nonlinear nature, due to the large spatial and temporal variability of the watershed characteristics and rainfall patterns, It also plays an important role in predicting the extreme events (floods and droughts), and it contributes to a good management for water resources development projects. This study aims at modeling the relationship between rainfall and runoff in Al-Abrash catchment using Artificial Neural Networks technology (ANN), and depending on the daily data of rainfall, evaporation, water level in Al-Bassil lake, as well as data of the previous runoff for the rainy months between (2009-2013) using Matlab program. The results showed that ANN (11-10-1) gave the best performance with a correlation coefficient equals 98.15%, and a root mean square error equals 1.3721 m³/s for testing data set, The study proved that artificial neural network technology offers good results in modeling the Rainfall_ Runoff relationship for research area.

Keywords: Artificial Neural Network, Modeling, Rainfall_ Runoff.

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

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

مقدمة

تُشكّل الأنهار جزءاً مهماً من مصادر المياه في العالم، وتُعدّ تحليلات الجريان السطحي مهمة جداً للتنبؤ بالأحداث الطبيعية المتطرفة مثل الفيضانات والجفاف للتخفيف من أضرارها المحتملة، كما تلعب دوراً حيوياً في تصميم وتشغيل المكونات المختلفة لمشاريع الموارد المائية مثل الأبنية المحمولة والسدود ومشاريع الإمداد بالمياه وغيرها، لذا كان الشرط المسبق لأيّة خطة لتطوير الأحواض النهرية هو فهم هيدرولوجيا الحوض وتحديد الجريان السطحي [1]. ويشكل الهطل المطري العنصر الرئيسي للدورة الهيدرولوجية، والمصدر الرئيسي للجريان السطحي. لكن طريقة تحويل الأمطار إلى جريان سطحي معقدة للغاية، فهي ديناميكية، غير خطية، وتتعرض للتقلبات الزمنية والمكانية [2]. يمكن تقسيم طرائق التنبؤ بحساب الجريان السطحي إلى قسمين: الأول هو النماذج الفيزيائية التي تهدف إلى محاكاة سلوك الأحواض الساكنة باستخدام إطار رياضي، وعلى الرغم من أنّ النماذج الفيزيائية تساعد في فهم العمليات الهيدرولوجية المنفصلة، لكنها تتطلب عدداً كبيراً من البيانات التي عادةً تكون غير متوافرة أو مكلفة، كما تتطلب أدوات رياضية متطورة وخبرة كبيرة للمستخدم، بالتالي فإنّ إمكانية تطبيقها تكون محدودة و تستغرق زمناً طويلاً. والقسم الثاني هو النهج القائم على البيانات، والذي يحاول استخدام البيانات التاريخية للجريان السطحي و العوامل المناخية لتوقع جريان المياه في المستقبل [3,4]. وتشمل هذه الفئة النماذج الخطية المتمثلة بنماذج الانحدار الذاتي المتوسط المتحرك Autoregressive Integrated Moving average (ARIMA)، والنماذج المعتمدة على تقانات الذكاء الاصطناعي Artificial Intelligence (AI)، المتميزة بقدرتها على استخراج العلاقات بين المدخلات والمخرجات دون حاجة إلى فهم مفصل للخصائص الفيزيائية للأحواض النهرية، ومن أهمها نماذج الشبكة العصبية الاصطناعية (ANN)، التي استُخدمت بشكل متزايد في مختلف جوانب العلوم والهندسة بسبب قدرتها على نمذجة كل من النظم الخطية وغير الخطية دون الحاجة إلى أيّ من الافتراضات الضمنية التي تتطلبها معظم الأساليب الإحصائية التقليدية [5]، كما أنها لا تتطلب عدداً كبيراً من البيانات، ويُمكنها التعامل مع بيانات غير مكتملة [6].

- حاول العديد من الباحثين نمذجة العلاقة بين الهطل المطري _الجريان النهري في مناطق مختلفة من العالم باستخدام الشبكات العصبية الاصطناعية وطرائق مختلفة أخرى:

- حيث درس (Solaimani, k. 2009) علاقة R_R في حوض نهر Jarhi في إيران، مستخدماً البيانات الشهرية للهطل المطري، درجة الحرارة و الجريان السابق للفترة الزمنية بين عامي (1969-2000)، حيث درس الجريان كتابع لدرجة الحرارة فقط، ثم كتابع للهطل فقط، ثم للحرارة و الهطل والجريان السابق معاً، حيث حقّق الأخير الأداء الأفضل ، وفقاً لقيم معاملات الارتباط $R = (0.47, 0.96, 0.99)$ على الترتيب، كما أظهرت الدراسة كفاءة خوارزمية التعلّم Levenberg-Marquardt (L-M) في السرعة والأداء [7].

-قَدّم (عمار وآخرون، 2014) دراسة تناولت تقييم البارامترات الفعّالة للجريان السطحي في حوض نهر الكبير الجنوبي باستخدام شبكات Elman، أثبتت النتائج أن النموذج الذي يحوي في طبقة الإدخال على بيانات درجة الحرارة، الرطوبة النسبية، التبخر، الهطل المطري وقيم سابقة للجريان بتأخر زمني مقداره ثلاثة أيام يعطي أفضل أداء بدقّة $R = (0.96)$ ، و أنّ شبكات Elman تقدّم نتائج جيدة في نمذجة العلاقة R-R [8].

-أجرى (Aichouri, I. et al., 2015) في الجزائر دراسة لنموذج العلاقة R_R في حوض نهر Seybouse الذي يتبع مناخ البحر المتوسط حيث هطول الأمطار والجريان السطحي غير مُنتظمين، باستخدام بيانات الهطل والجريان، وبالمقارنة بين أداء نموذج الشبكة العصبية الاصطناعية MLP multilayer perceptron، ونموذج الانحدار الخطي MLR multiple linear regression، أظهرت النتيجة أنّ نموذج MLP أكثر ملاءمة للتنبؤ بجريان النهر من نموذج MLR وذلك وفقاً لقيم معامل الارتباط $R=(0.921, 0.89)$ ، على الترتيب [9].

-قدّم (Tayyab, M. et al., 2016) دراسة للتنبؤ بالفيضان في حوض نهر Jinsh في الصين، بالمقارنة بين الشبكة العصبية ذات الانتشار العكسي للخطأ للـ (FFBPNN) feed forward back propagation، والشبكة العصبية ذات الانحدار المعمّم (GRNN) generalized regression، والشبكة العصبية ذات الأساس الشعاعي (RBFNN) radial basis function، و أظهرت نتائج الدراسة تفوق FFBPNN، حيث كانت قيم معامل الارتباط للشبكات الثلاث $R=(0.99, 0.92, 0.89)$ ، على الترتيب [10].

-استخدم (Patel and Joshi, 2017) خوارزمية الانتشار العكسي لنموذج العلاقة بين الهطل المطري والجريان النهري لحوض Dharoi في الهند، باعتماد بيانات الهطل الشهرية والسنوية لأشهر الماطرة الممتدة من شهر حزيران حتى شهر تشرين الأول بين عامي (1986-2014)، وتوصلت الدراسة إلى أن الشبكة التي احتوت على طبقتين خفيتين و68 عصبوناً في الطبقة الخفية أفضل نتيجة بدقة $(R=0.99, RMSE=8.73)$ [11].

ومن خلال استعراض كم كبير من الدراسات المرجعية يتبين أهمية العلاقة بين الهطل والجريان بشكل عام من أجل إدارة الموارد المائية في مناطق هذه الأحواض ونظراً للأهمية الاقتصادية الكبيرة لنهر الأبرش كان من المفيد جدا دراسة العلاقة بين الهطل والجريان في حوض هذا النهر.

أهمية البحث وأهدافه

تعدّ نمذجة العلاقة بين الهطل المطري_الجريان النهري مهمة جداً من أجل التنبؤ بالفيضانات الممكن حدوثها للتخفيف من أضرارها، كما أنها تساعد في استكمال البيانات الناقصة للهطل المطري والجريان النهري، وذلك من أجل الإسهام في تحقيق الإدارة الجيدة للموارد المائية.

يعتبر نهر الأبرش من الموارد المائية الهامة في حوض الساحل، حيث تنتشر الأراضي الزراعية والتجمعات السكانية والمنشآت السياحية والزراعية على أطراف سرير النهر وعلى أطراف بحيرة سد الباسل وفي سهل عكار، وتوجد على جوانب واديه الأدنى بعض الآثار القديمة، وجاءت أهمية البحث من حاجة الناس لمياهه في ري الأراضي الزراعية والاستخدامات الأخرى، وكذلك الخسائر التي يمكن أن تحدث في المنطقة السهلية في حال حدوث فيضان في فصل الشتاء.

يهدف هذا البحث إلى وضع أنموذج رياضي للعلاقة بين الهطل المطري_الجريان النهري في حوض نهر الأبرش باستخدام تقانة الشبكة العصبية الاصطناعية (ANN).

منطقة البحث

يقع حوض نهر الأبرش في الجزء الجنوبي الشرقي من محافظة طرطوس، ويشكل جزءاً من حوض الساحل السوري الممتد على سواحل البحر المتوسط، بين خطي عرض $34^{\circ} 40' 27''$ و $34^{\circ} 55' 58''$ شمالاً، وبين خطي طول $36^{\circ} 18' 47''$ و $35^{\circ} 56' 57''$ شرقاً. حيث يقع نهر الأبرش على المنحدرات الغربية للجبال الساحلية على ارتفاع 750 م، طوله 41 كم ومساحة حوضه 235 كم²، يقع منها نحو 207 كم² في محافظة طرطوس، و 26 كم² في محافظة حمص، ونحو 2 كم² في محافظة حماه، ويتراوح عرض الحوض بين 5 و 10 كم، أما متوسط انحدار المجرى المائي فيبلغ 0.0183، يحد حوض نهر الأبرش من الشرق حوض نهر العاصي، ومن الغرب البحر المتوسط ومن الشمال حوضي الغمقة و المنطار، ومن الجنوب والجنوب الشرقي حوض نهر الكبير الجنوبي. ويصب نهر الأبرش في البحر المتوسط على مسافة 3 كم جنوبي بلدة الحميدية. ويوضح الشكل (1) موقع حوض نهر الأبرش بالنسبة للأحواض المجاورة، كما يوضح الشكل (2) الموقع العام لحوض الساحل بالنسبة للجمهورية العربية السورية.



الشكل (1) موقع حوض نهر الأبرش بالنسبة للأحواض المجاورة




الشكل(2) الموقع العام لحوض الساحل في سورية

طرائق البحث ومواده

الشبكات العصبية الاصطناعية (ANN)

تُعتبر الشبكات العصبية الاصطناعية من أهم مجالات الذكاء الاصطناعي، وتدور فكرة الشبكات العصبية الاصطناعية حول محاكاة العقل البشري باستخدام الحاسب الآلي كما هو مبين في الشكل(3)، وهي عبارة عن بنية رياضية مكونة من وحدات معالجة تسمى عصبونات أو عقد، و قوى اتصال بين العصبونات تسمى الأوزان. وتتشابه الشبكات العصبية مع العقل البشري من ناحيتين، حيث تُكتسب المعرفة من قبل بيئة الشبكات العصبية من خلال عملية التعلّم، وتقوم بتخزين المعرفة ضمن الأوزان التشابكية [12].



الشكل(3) محاكاة العصبون الاصطناعي للعصبون البيولوجي في الشكل والأداء [13]

آلية عمل العصبون الاصطناعي

العصبونات هي وحدة المعالجة الأساسية في الشبكة العصبية [14]، حيث يستقبل العصبون الاصطناعي عناصر الدخل X_i ، ثم يُضرب كل عنصر دخل بالوزن الموافق له W_i (Weights)، ثم تجمع النتائج للقيمة الإضافية التي تدعى بالانحياز b_j وفق المعادلة الآتية:

$$Y_i = \sum_{i=1}^m W_i X_i + b_j$$


بعد ذلك تُجرى عملية إدخال ومعالجة الإشارة في تابع التفعيل (Activation function)، وهذا التابع يحد من خرج العصبون لذلك يسمى تابع التخديد، حيث يجعل الخرج ضمن المجال $[0, 1]$ أو $[-1, +1]$ لينتج بذلك خرج الشبكة العصبية y كما يظهر في الشكل (3). حيث أنّ أوزان التوصيل هي الروابط بين العصبونات في الطبقات المتتالية، و يرتبط كل عصبون في طبقة معينة بجميع العصبونات في الطبقة التالية بواسطة روابط لها وزن اتصال مناسب وقابل للتعديل [15].

هيكلية الشبكة العصبية الاصطناعية متعددة الطبقات ذات التغذية الأمامية (MLP_FFNN)

أطلقت تسمية "ذات التغذية الأمامية" من اتجاه تدفق المعلومات، حيث تتدفق المعلومات على التوالي باتجاه الأمام فقط، أي من طبقة الإدخال عبر الطبقة الخفية إلى طبقة الخرج. يتم ترتيب العصبونات في الشبكة العصبية الاصطناعية في مجموعات تسمى طبقات، كل العصبونات في الطبقة تعمل بالتوازي المنطقي أي مخرجات الطبقة لا تؤثر إلا في الطبقة التي تليها، كما لا يوجد أي ترابط بين عصبونات الطبقة الواحدة [16].

ويتكون الهيكل الأساسي للشبكة عادة من ثلاث طبقات كما يظهر في الشكل (4):

- 1-طبقة الإدخال (input layer): لا تقوم بأي عملية معالجة، فهي ببساطة مكان تغذية الشبكة بالبيانات، تقوم طبقة الدخل بنقل المعلومات إلى الطبقة الخفية.
- 2-الطبقة أو الطبقات الخفية (Hidden Layer): حيث تتم معالجة البيانات، وقد تحتوي الشبكة العصبية الاصطناعية على طبقة خفية واحدة أو أكثر، تقوم الطبقة الخفية بتغذية طبقة الخرج.
- 3-طبقة الخرج: حيث تنتج نتائج المُدخلات المُعطاة (Output Layer) [17].



الشكل (4) هيكلية شبكة عصبية اصطناعية متعددة الطبقات ذات تغذية أمامية MLP_FFNN [18].

خطوات بناء النموذج باستخدام الشبكة العصبية الاصطناعية

1_ تقييس البيانات (Data normalization):

إن إدخال البيانات الأصلية مباشرة إلى الشبكة يقلل من دقة وسرعة أداؤها، لذا لا بد من طريقة لتسوية البيانات، الأمر الذي يمنع الحد المفرط للأوزان والتشبع المبكر من العصبونات [19]، بعد جمع البيانات تقوم بمعالجتها قبل البدء بعملية التدريب من خلال إجراء عملية التقييس لكل من متجهات المدخلات والهدف، وذلك لجعل عناصرها قريبة من بعضها البعض وتقليل الخطأ بين القيم المحسوبة من الشبكة والقيم الهدف، وهذا يُحسن من عملية التدريب ومن كفاءة أداء الشبكة العصبية الاصطناعية [20]، ويمكن إجراء عملية التقييس بعدة طرائق وفي هذه الدراسة جرى اعتماد المعادلة الآتية [21]:

$$P_{(norm)} = 0.5 * \left(\frac{P_{(real)} - P_{(mean)}}{P_{(max)} - P_{(min)}} \right) + 0.5 \quad (1)$$

حيث: $P_{(norm)}$: القيم المقيسة، $P_{(real)}$: القيمة الأصلية، $P_{(mean)}$: متوسط القيم الأصلية، $P_{(max)}$: أقصى قيمة مُدخلة، $P_{(min)}$: أدنى قيمة مُدخلة.

2_ تقسيم البيانات إلى ثلاث مجموعات:

- أ_ مجموعة التدريب Training: للوصول إلى شبكة عصبية بأقل خطأ.
- ب_ مجموعة التحقق Validation: لتحقيق أفضل أداء للشبكة على بيانات لم تدخل بمرحلة التدريب.
- ج_ مجموعة الاختبار Testing: للتأكد من التوافق الأدائي للشبكة [22].

3_ تحديد هيكلية الشبكة:

- 1_ عدد العصبونات في طبقة الإدخال: ويساوي عدد المتغيرات المُدخلة المستقلة.
- 2_ عدد الطبقات الخفية (طبقة واحدة أو أكثر): ويُحدّد من خلال التجربة.

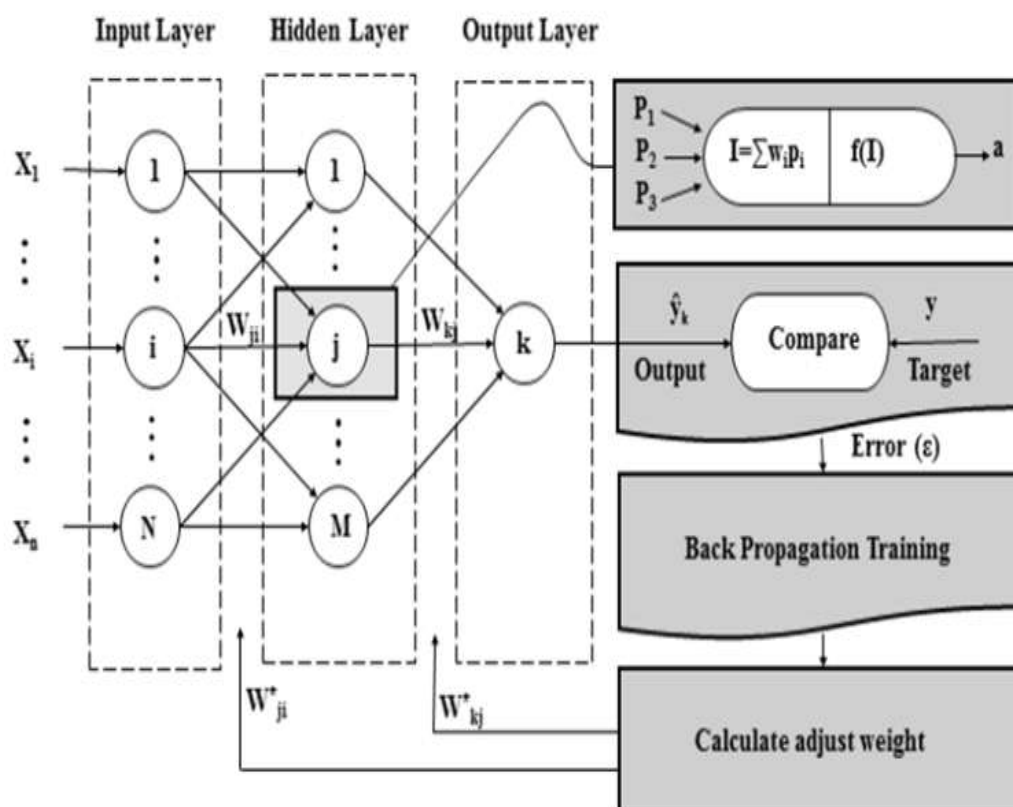
3_ عدد العصبونات في الطبقة الخفية: ويُحدّد من خلال التجربة.

4_ عدد العصبونات في طبقة الخرج: ويساوي عدد متغيرات الخرج.

5_ خوارزمية التدريب وتوابع التفعيل [23].

4_ تدريب الشبكة العصبية الاصطناعية:

الشبكات العصبية لا تُبرمج ولكن تُدرّب [24]. حيث تسمّى عملية تحديد أوزان الشبكة العصبية الاصطناعية "التعلّم" أو "التدريب"، وهو يشبه معايرة نموذج رياضي، الذي يبحث عن الأوزان عن طريق تقليل الخطأ بين خرج الشبكة والهدف. ويتم تدريب الشبكة بمجموعة من أزواج الإدخال / الخرج المعروفة. حيث يُطلق على المُدخلات والهدف المقابل لها اسم "زوج التدريب" [25]. في بداية التدريب، يتم تهيئة الأوزان إما بمجموعة من القيم العشوائية أو بناءً على الخبرة السابقة. بعد ذلك، وباستخدام خوارزمية الانتشار العكسي للخطأ يتم تطبيق عملية الانتشار الأمامي للحصول على مخرجات الشبكة، ثم مقارنة المخرجات الفعلية بالمخرجات المطلوبة وتحديد قيمة الخطأ، بعد ذلك يتم التراجع بالخطأ عبر الشبكة وتعديل الأوزان بشكل منهجي بواسطة خوارزمية التعلّم لتقليل قيمة الخطأ والحصول على فرق صغير بين خرج الشبكة العصبية والهدف، وعندما يقترب هذا الفرق من الصفر، يُعتبر أنّ الشبكة قد تمّ تدريبها [26, 27]. ويُوضّح الشكل (5) آلية تدريب الشبكة باستخدام خوارزمية الانتشار العكسي للخطأ.



الشكل (5) آلية تدريب الشبكة العصبية الاصطناعية باستخدام خوارزمية الانتشار العكسي

5- التحقق من أداء الشبكة باستخدام معايير تقييم أداء النموذج

توجد معايير مختلفة للتحقق من الأداء الأفضل للشبكة العصبية الاصطناعية، استخدمنا منها المعايير الآتية:

- جذر متوسط مربع الخطأ (RMSE) root mean square error:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x - y)^2}$$

- معامل الارتباط (R) Coefficient of correlation:

$$R = \frac{\sum_{i=1}^n (x - \bar{x})(y - \bar{y})}{\sqrt{\sum_{i=1}^n (x - \bar{x})^2} \sqrt{\sum_{i=1}^n (y - \bar{y})^2}}$$

حيث: y قيمة الجريان المنتبأ بها من خلال الشبكة، \bar{y} متوسط الجريان المحسوب بالشبكة.
 x الجريان الحقيقي، \bar{x} متوسط الجريان الحقيقي، n عدد البيانات.

النتائج والمناقشة

-تتضمن مجموعة البيانات المستخدمة في هذه الدراسة القيم اليومية لكل من الهطل المطري (R) Rainfall، التبخر (E) Evaporation، ومنسوب المياه في بحيرة سد الباسل (L) Level، للأشهر الماطرة الممتدة (من شهر تشرين الثاني حتى شهر أيار) للفترة الزمنية بين عامي (2009-2013)، كما جرى إضافة بيانات الجريان النهري السابق لإعداد بعض النماذج، ثم القيام ببناء النماذج وفق الخطوات الآتية:

1- جمعت بيانات الهطل المطري من بعض المحطات المنتشرة داخل الحوض ويجواره، المحطات هي : محطة سد الباسل، محطة مشتى الحلو، محطة الكفرون، محطة حصن سليمان، محطة بيت أصلان.

2- حساب متوسط الهطل المطري فوق الحوض باستخدام طريقة مضلعات تيسين كما يظهر في الشكل (6)، حيث كانت نسبة تأثير كل محطة في الهطل الكلي كما يلي: محطة سد الباسل 34.5%، محطة مشتى الحلو 19.3%، محطة الكفرون 22.3%، محطة بيت أصلان 20.2% ومحطة حصن سليمان 3.7%.



الشكل (6) المحطات المناخية_مضلعات تيسين

3- معالجة البيانات من خلال إجراء عملية التقييس باستخدام المعادلة (1).

4- تدريب الشبكة العصبية الاصطناعية:

تضمّنت البيانات 906 قيمة يومية، وقُسمت عشوائياً ضمن مكتبة Neural Network tool (nntool) المتاحة في حزمة برمجيات MATLAB إلى ثلاث مجموعات هي: مجموعة التدريب، مجموعة التحقق ومجموعة الاختبار، وذلك بنسبة 70 % لمجموعة التدريب و 15 % لمجموعتي التحقق والاختبار، بالتالي شملت مجموعة التدريب 634 قيمة، في حين احتوت كل من مجموعتي التحقق والاختبار على 136 قيمة.

خصائص الشبكة العصبية المقترحة للتدريب

استخدمنا الشبكة العصبية الاصطناعية متعددة الطبقات (MLP) ذات التغذية الأمامية مع خوارزمية الانتشار العكسي للخطأ (FFBPNN)، بطبقة خفية واحدة، و عصبون واحد في طبقة الخرج يُمثّل الجريان النهري المطلوب في الزمن (t). كما جرى اعتماد خوارزمية التعلّم (LM) Levenberg – Marquardt، وتابع التفعيل Tan sigmoid لكل من الطبقة الخفية وطبقة الخرج. عدد العصبونات في الطبقة الخفية حُدّد بالتجربة وذلك بتغيير عدد العصبونات من 1 إلى 20 لكل نموذج. أمّا طبقة الإدخال فاحتوت مبدئياً على بيانات الهطل المطري الوسطي المحسوب وفق طريقة تيسين، وقيم التبخر والمنسوب. حيث جرى تدريب العديد من النماذج باستخدام مجموعات مختلفة للمدخلات بتأخرات زمنية مختلفة دون إضافة قيم الجريان السابق كما هو مبين في الجدول (1).

الجدول (1) مدخلات الشبكة العصبية قبل إضافة قيم الجريان النهري السابق

Model	Input Variables
Model_1	$Q(t)=f\{ R_t \}$
Model_2	$Q(t)=f\{ R(t),E(t) \}$
Model_3	$Q(t)=f\{ R(t),L(t) \}$
Model_4	$Q(t)=f\{ R(t),E(t),L(t) \}$
Model_5	$Q(t)=f\{ R(t), R(t-1) \}$
Model_6	$Q(t)=f\{ R(t),E(t),L(t), R(t-1) \}$
Model_7	$Q(t)=f\{ R(t),E(t),L(t), R(t-1), R(t-2) \}$
Model_8	$Q(t)=f\{ R(t),E(t),L(t), R(t-1),E(t-1),L(t-1), R(t-2),E(t-2), L(t-2) \}$
Model_9	$Q(t)=f\{ R(t), R(t-1), R(t-2), R(t-3) \}$
Model_10	$Q(t)=f\{ R(t),E(t),L(t), R(t-1),E(t-1),L(t-1), R(t-2),E(t-2), L(t-2), R(t-3), E(t-3),L(t-3) \}$
R (t): Rainfall at a specified time(mm).	
E (t): Evaporation at a specified time(mm/day).	
L (t): water Level in the dam lake at a specified time(m).	
Q (t): the runoff at a specified time(m ³ /s).	
R _{t-1} ; R _{t-2} ; R _{t-3} ;...: Rainfall at t-1; t-2; t-3;...respectively.	

ثم جرى اختيار الهيكلية الأفضل لكل نموذج والتي أعطت أعلى قيمة لمعامل الارتباط R وأدنى قيمة لجذر متوسط مربع الخطأ RMSE. أظهرت النتائج المبينة في الجدول (2) أن النماذج التي احتوت في طبقة الإدخال على بيانات (الهطل المطري، التبخر، المنسوب) بتأخرات زمنية مختلفة، دون إضافة قيم الجريان السابق إلى المدخلات لم تعط نتائج جيدة. حيث أعطى النموذج Model-8 بالهيكلية (1-10-9) و الذي احتوى 9 مدخلات وعشرة عصبونات في الطبقة الخفية، أصغر قيمة للخطأ خلال مرحلة الاختبار بدقة $RMSE=2.28 \text{ m}^3/\text{s}$.

الجدول (2) قيم R و RMSE لأفضل النماذج قبل إضافة بيانات الجريان النهري السابق

Model	Network structure	Training set		Validation set		Testing set	
		R (%)	RMSE (m ³ /s)	R (%)	RMSE (m ³ /s)	R (%)	RMSE (m ³ /s)
Model_1	1-8-1	45.35	7.1096	41.09	7.4436	47.86	5.4118
Model_2	2-20-1	55.67	6.6575	48.44	7.2158	30.67	5.9771
Model_3	2-20-1	70.05	5.1831	85.09	5.4460	78.41	4.7931
Model_4	3-14-1	72.68	70.37	70.37	5.6271	75.86	4.0322
Model_5	2-16-1	66.51	5.9695	73.29	5.4752	67.74	4.8636
Model_6	4-10-1	79.97	74.37	74.37	4.5210	84.00	4.1079
Model_7	3-16-1	83.46	4.3024	84.92	4.2633	88.15	3.4604
Model_8	9-10-1	94.41	2.5298	94.04	2.5245	96.59	2.2839
Model_9	4-19-1	79.10	62.88	74.91	5.0435	5.1702	4.2723
Model_10	12-13-1	93.60	94.14	95.00	2.7154	2.9028	2.6874

ثم قمنا بإضافة قيم الجريان السابق إلى المُدخلات واختبار النماذج باحتمالات مختلفة للمُدخلات وبتغيير عدد العصبونات في الطبقة الخفية، وبيّن الجدول (3) أفضل عشرة نماذج جرى الحصول عليها:

الجدول (3) مُدخلات الشبكة العصبية بعد إضافة قيم الجريان النهري السابق

Model	Input Variables
Model_11	$Q(t)=f\{R(t),E(t),R(t-1),Q(t-1)\}$
Model_12	$Q(t)=f\{R(t),L(t),E(t),E(t-1),R(t-1),Q(t-1)\}$
Model_13	$Q(t)=f\{R(t),R(t-1),R(t-2),Q(t-1),Q(t-2)\}$
Model_14	$Q(t)=f\{R(t),E(t),L(t),E(t-1),L(t-1),R(t-1),R(t-2),Q(t-1),Q(t-2)\}$
Model_15	$Q(t)=f\{R(t),E(t),L(t),R(t-1),E(t-1),L(t-1),R(t-2),E(t-2),L(t-2),Q(t-1),Q(t-2)\}$
Model_16	$Q(t)=f\{R(t),E(t),R(t-1),R(t-2),R(t-3),Q(t-1),Q(t-2),Q(t-3)\}$
Model_17	$Q(t)=f\{R(t),E(t),L(t),R(t-1),R(t-2),R(t-3),Q(t-1),Q(t-2),Q(t-3)\}$
Model_18	$f\{R(t),E(t),E(t-1),E(t-2),E(t-3),R(t-1),R(t-2),R(t-3),Q(t-1),Q(t-2),Q(t-3)\}$
Model_19	$Q(t)=f\{R(t),L(t),L(t-1),L(t-2),R(t-1),R(t-2),R(t-3),Q(t-1),Q(t-2),Q(t-3)\}$
Model_20	$f\{R(t),L(t),E(t),E(t-1),L(t-1),L(t-2),L(t-3),R(t-1),R(t-2),R(t-3),Q(t-1),Q(t-2),Q(t-3)\}$
Qt-1; Qt-2; Qt-3;....: Runoff at t-1; t-2; t-3;....respectively	

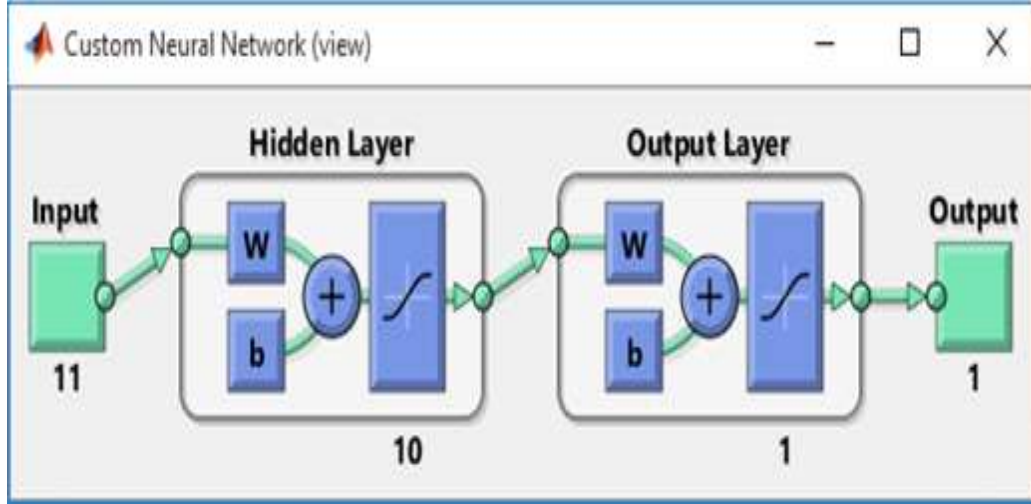
وبيّن الجدول (4) قيم كل من R و RMSE للنماذج المختبرة في المراحل الثلاث (تدريب_تحقق_اختبار) بعد إضافة قيم الجريان السابق إلى المُدخلات.

الجدول (4) قيم R و RMSE للنماذج المختبرة في المراحل الثلاث (تدريب_تحقق_اختبار).

Model	Network structure	Training set		Validation set		Testing set	
		R (%)	RMSE (m ³ /s)	R (%)	RMSE (m ³ /s)	R (%)	RMSE (m ³ /s)
Model_11	4-14-1	94.35	2.5594	93.63	3.0580	97.81	1.4423
Model_12	6-12-1	97.89	1.6152	98.34	1.2543	98.33	1.5029
Model_13	5-5-1	93.77	2.8148	96.23	2.0761	96.86	1.4956
Model_14	9-12-1	95.86	2.2594	92.07	2.9949	98.00	1.4423
Model_15	11-10-1	98.21	1.5012	98.56	1.2641	98.15	1.3721
Model_16	8-12-1	96.54	2.0126	97.34	2.0696	97.37	1.5045
Model_17	9-20-1	95.49	2.4247	94.93	2.2949	98.14	1.4050
Model_18	11-21-1	95.94	2.2649	97.97	1.5088	97.82	1.4202
Model_19	10-14-1	95.70	2.3244	93.40	2.5807	98.08	1.4772
Model_20	13-11-1	96.46	2.1292	96.95	1.8944	98.34	1.4005

يتبيّن من النتائج أنّ أداء الشبكة يتحسن بشكل كبير عند إضافة قيم سابقة للجريان إلى المدخلات. حيث أعطى نموذج الشبكة العصبية الاصطناعية Model-15 بالهيكلية (11-10-1) المبينة في الشكل (7)، والذي احتوى في طبقة الإدخال على بيانات الهطل المطري، التبخر، المنسوب بالإضافة إلى بيانات الجريان السابق بتأخر زمني مقداره

يومان(أي الجريان السابق قبل يومين)، وعلى 10 عصبونات في الطبقة الخفية، أفضل أداء، حيث كانت قيم معامل الارتباط للمراحل الثلاث (تدريب_تحقق_اختبار) كما يلي (98.21% ، 98.56% ، 98.15%)، على الترتيب وقيمة جذر متوسط مربع الخطأ $RMSE=1.3721m^3/s$ لمرحلة الاختبار.



الشكل (7) يبين أفضل هيكلية للشبكة العصبية الاصطناعية للبيانات قيد الدراسة

كما جرى اختبار لتوابع التفعيل، وذلك من أجل الشبكة العصبية الاصطناعية ذات الهيكلية (11-10-1) التي أعطت أفضل أداء، وبالاعتماد على مكتبة nntool تبيّن أنّ أفضل أداء للشبكة العصبية الاصطناعية يكون باستخدام تابع التفعيل Tan sigmoid لكل من الطبقة الخفية وطبقة الخرج، كما هو مبين في الجدول (4).

الجدول (4) أداء الشبكة العصبية الاصطناعية عند استخدام توابع تفعيل مختلفة لكل من الطبقة الخفية وطبقة الإخراج

الطبقة المخفية	طبقة الخرج	R(%)				RMSE(m ³ /s)			
		Train	Val	Test	Total	Train	Val	Test	Total
Logsig	Tansig	96.37	95.97	93.45	95.98	2.1181	2.3091	2.3723	2.1874
Logsig	Purelin	95.32	93.45	92.34	94.60	2.3326	3.0308	2.7399	2.5126
Tansig	Tansig	98.21	98.56	98.15	98.25	1.5012	1.2641	1.3721	1.4490
Tansig	Purelin	94.31	94.98	94.94	94.47	2.3969	2.3808	3.2566	2.5423

كما جرى اختبار الشبكة العصبية الاصطناعية ذات الهيكلية (11-10-1) والتي أعطت أفضل أداء باستخدام نسب تقسيم مختلفة للبيانات في كل مجموعة (تدريب_تحقق_اختبار) وتبيّن أنّ نسبة التقسيم 70% لمجموعة التدريب، و15% لمجموعة التحقق و15% لمجموعة الاختبار هي الأفضل، ويوضّح الجدول (5) نتائج مجموعة الاختبار.


الجدول (5) أداء الشبكة العصبية الاصطناعية في مرحلة الاختبار عند استخدام نسب تقسيم مختلفة للبيانات

عدد العصبونات في الطبقة الخفية	Train (%)	Validation (%)	Test (%)	Test	
				R (%)	RMSE (m ³ /s)
10	70	15	15	98.15	1.3721
10	70	20	10	95.65	2.9429
10	75	10	15	91.99	3.0919
10	80	10	10	97.22	1.6076
10	80	15	5	95.92	1.5832

10	65	20	15	94.32	3.1087
10	65	15	20	96.25	2.0087
10	60	20	20	92.35	2.6746

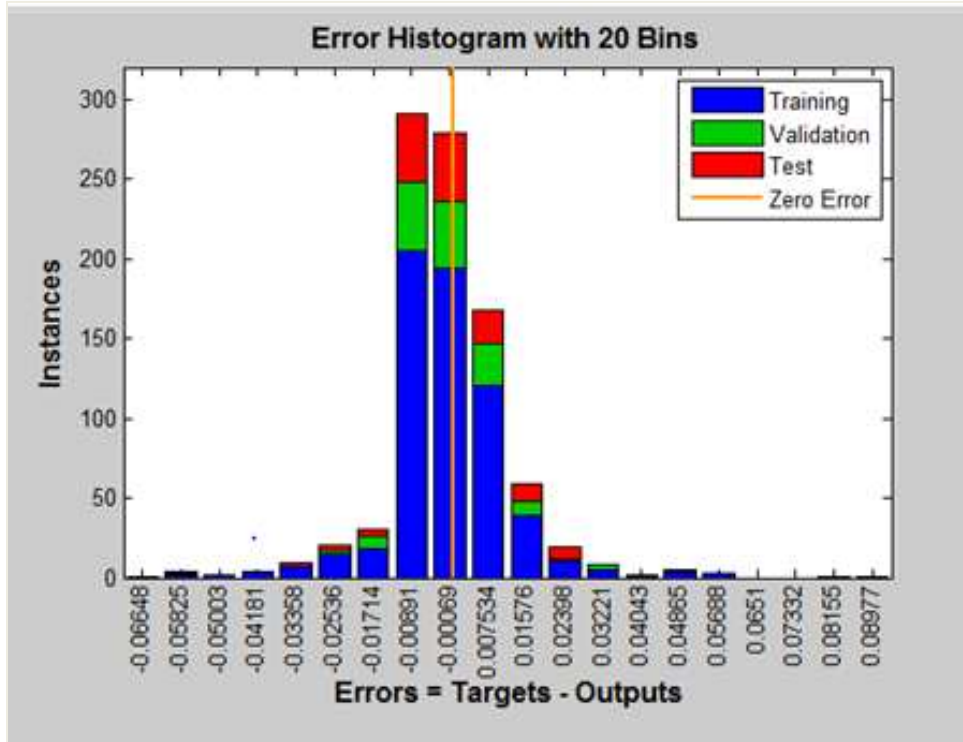
محاكاة النموذج:

يبين الشكل (8) أداء الشبكة العصبية الاصطناعية للمجموعات الثلاث (تدريب_تحقق_اختبار)، ويعكس الشكل الأداء الجيد للشبكة العصبية المقترحة ذات الهيكلية (11-10-1) ، حيث يبين نقطة توقف التدريب بمتوسط مربع خطأ Mean Square Error (MSE) صغير و يساوي إلى (0.00013411) لمجموعة التحقق، كما أعطى معامل الارتباط لهذه المجموعة قيمة كبيرة بدقة 98.56 %.



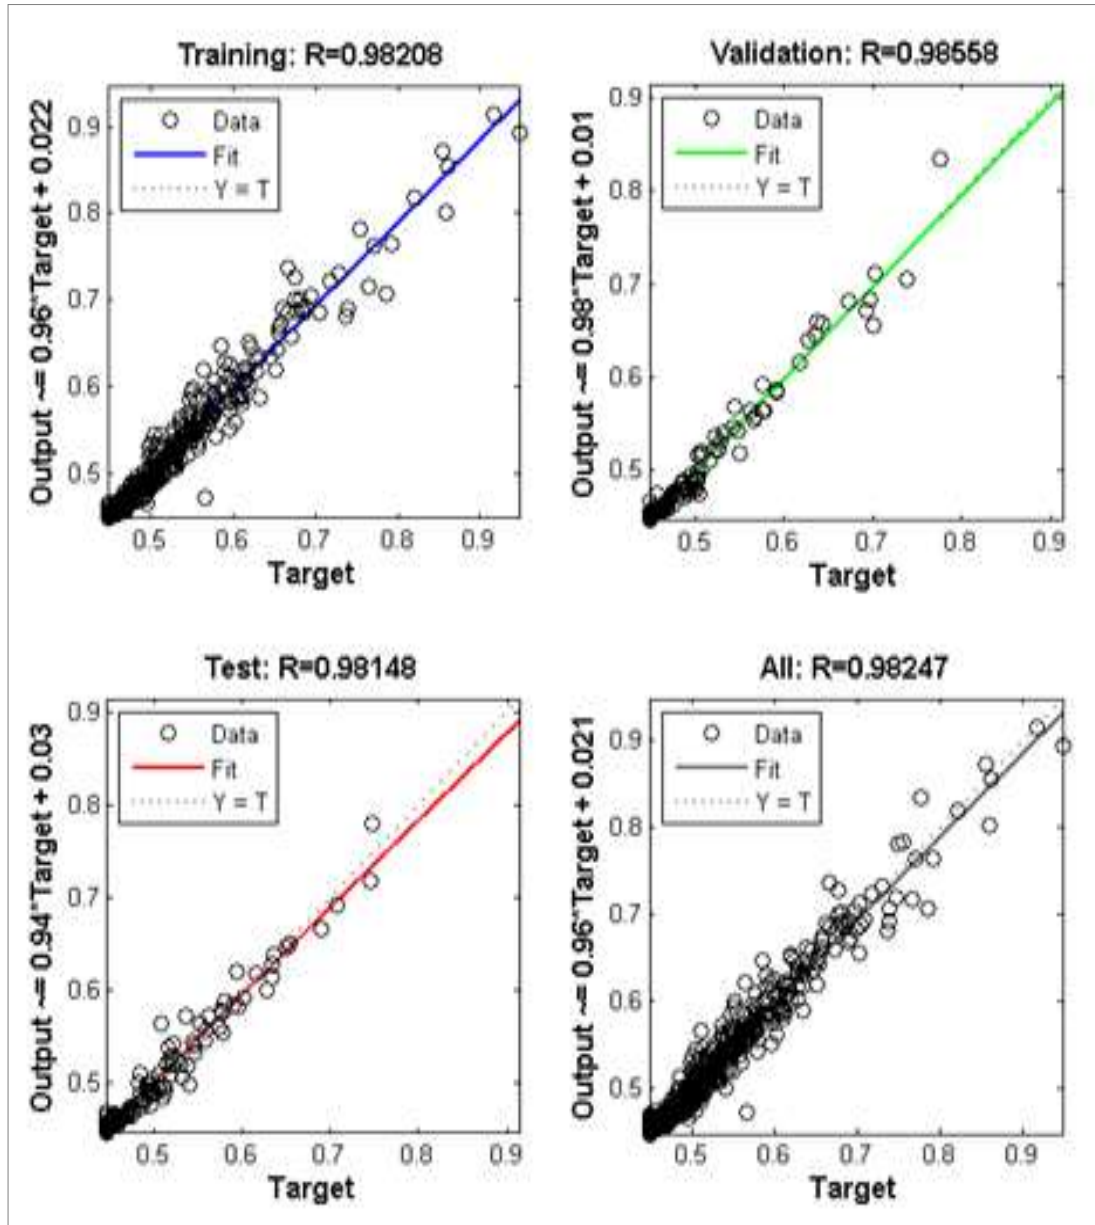
الشكل (8) يبين أداء الشبكة (11-10-1) خلال مراحل التدريب والتحقق والاختبار

كما يبين الشكل (9) مخطط الخطأ بين القيم المقيسة والمتنبأ بها للشبكة العصبية ذات الهيكلية (11-10-1) ونلاحظ أن قيم الأخطاء صغيرة وتقترب من الصفر.



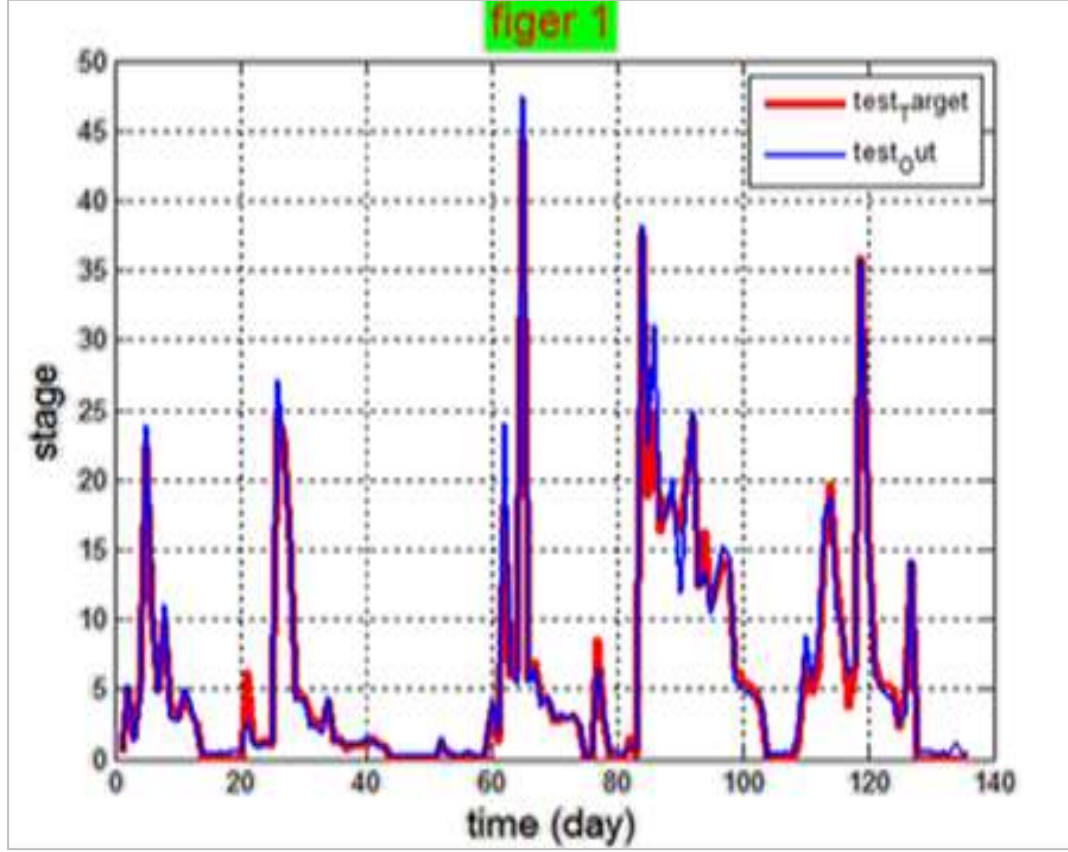
الشكل (9) مخطط الخطأ بين القيم المقيسة والمتنبأ بها للشبكة العصبية (11-10-1)

كما يوضح الشكل (10) قيم معاملات الارتباط للمجموعات الثلاثة وقيمة معامل الارتباط للبيانات كاملة. ونلاحظ من خلال الشكل التراكمي والتوافق الخطي بين نتائج الشبكة العصبية الاصطناعية والقيم المقيسة، حيث أعطى معامل الارتباط لمجموعة البيانات خلال مرحلة الاختبار قيمة جيدة بدقة 98.148%.



الشكل (10) يبيّن الارتباط بين قيم الجريان المقيسة والمنتبأ بها خلال المراحل الثلاث، وعلى مجموعة البيانات الكلية

ويوضح الشكل (11) التوافق الأدائي الجيد بين القيم المقيسة للجريان و نتائج الشبكة الاصطناعية الناتجة عن النموذج المقترح (10-1-11) خلال مرحلة الاختبار على بيانات لم تدخل في عمليتي التدريب والتحقق، كما يعكس الشكل قدرة الشبكة العصبية على التنبؤ بالأحداث المستقبلية بدقة جيدة.



الشكل (11) التوافق الأدائي بين القيم المقيسة والمتنبأ بها

الاستنتاجات والتوصيات

- ✓ قَدَمَ نموذج الشبكة العصبية الاصطناعية (Model-15) بالهيكلية (1-10-11) أفضل أداء
- يمعامل ارتباط لمرحلة الاختبار يساوي إلى $R=98.15\%$ و جذر متوسط مربع الخطأ $RMSE=1.3721 m^3/s$.
- ✓ إن إدخال قيم الجريان السابق في طبقة الإدخال إضافة إلى البيانات المناخية يُقَدِّمُ تحسناً ملحوظاً
- في أداء الشبكة حيث يعطى قيم أعلى ل R وأدنى ل $RMSE$ بالتالي يزيد من دقة الشبكة العصبية الاصطناعية في التنبؤ.
- ✓ يؤكد التوافق الخطي والأدائي بين نتائج الشبكة العصبية الاصطناعية والقيم المقيسة على كفاءة استخدام الشبكة العصبية الاصطناعية متعددة الطبقات MLP ذات التغذية الأمامية بخوارزمية الانتشار العكسي للخطأ (FFBP) في تقدير الجريان النهري لمنطقة البحث.
- ✓ يُفضَّلُ إضافة العوامل المناخية الأخرى كالرطوبة وسرعة الرياح عند توافرها كمداخلات للشبكة العصبية الاصطناعية.
- ✓ التوسع في استخدام الشبكات العصبية الاصطناعية ونماذج الذكاء الاصطناعي لدراسة مسائل متنوعة تتعلق بالموارد المائية في سورية.

المراجع

1-BABY, N; VARIJA, K. *Modeling of Rainfall - Runoff relationship using Artificial Neural Networks*. International Journal on Recent and Innovation Trends in Computing and Communication (IJRITCC), ISSN: 2321-8169, India, Vol. 4, No. 12, 2016, 233 – 237. <http://www.ijritcc.org>.

2- PATEL, SH. HARDAHA, M. K. SEETPAL, M. K. MADANKAR, K. K. Multiple Linear Regression Model for Stream Flow Estimation of Wainganga River. American Journal of Water Science and Engineering, India, Vol. 2, No. 1, 2016, 1-5.

3-YOUNG, CH. CH; LIU, W. CH. *Prediction and modelling of rainfall–runoff during typhoon events using a physically-based and artificial neural network hybrid model*. Hydrological Sciences Journal – Journal des Sciences Hydrologiques, Taiwan, Vol. 60, No. 12, 2015, 2102- 2116.

4-CHU, H; WEI, J; LI, J; QIAO, Z; CAO, J. *Article Improved Medium- and Long-Term Runoff Forecasting Using a Multi model Approach in the Yellow River Head waters Region Based on Large-Scale and Local-Scale Climate Information*. Water, China, Vol. 9, 2017. Doi:10.3390/w9080608.

5-RIAD, S; MANIA, J. BOUCHAOU,L;NAJJAR,Y. *Rainfall-Runoff Model Using an Artificial Neural Network Approach*. Mathematical and Computer Modeling, Vol. 40, 2004, 839–846.

6- DAWSON, C. W; WILBY, R. L. *Hydrological modelling using artificial neural networks*. Progress in Physical Geography, U. S. A. Vol. 25, No. 1, 2001, 80–108.

7-SOLAIMANI, K. *Rainfall-runoff Prediction Based on Artificial Neural Network (A Case Study: Jarahi Watershed)*. American-Eurasian J. Agric & Environ, Sci, Iran, Vol. 5, No. 6. 2009, 856-865.

8 –عمار، غطفان؛ حيدر، بادية؛ عليان، ميس. *نمذجة الهطول المطري_الجريان النهري باستخدام الشبكة العصبونية الصناعية في حوض نهر الكبير الجنوبي*. مجلة جامعة تشرين للبحوث والدراسات العلمية_سلسلة العلوم الهندسية، سورية، المجلد (36)، العدد(2)، 2014.

9. AICHOURI, I; HANI, A; BOUGHERIRA, N; DJABRIL; CHAFFAI, H; LALLAHEM,S. *River flow model using artificial neural networks*. Energy Procedia, Vol. 74, 2015, 1007 – 1014.

10- TAYYAB, M; ZHOU, J; ZENG, X, ADNAN, R. *Discharge Forecasting By Applying Artificial Neural Networks At The Jinsha River Basin, China*. European Scientific Journal , vol. 12, No. 9, 2016, 108-127

11- PATEL, A. B; JOSHI, G. S. *Modeling of Rainfall-Runoff Correlations Using Artificial Neural Network-A Case Study of Dharoi Watershed of a Sabarmati River Basin*. Civil Engineering Journal, India, Vol. 3, No. 2, 2017, 78-87.

12-HAYKIN, S. *Neural Networks and Learning Machine*. Third Edition prentice Hall international Pvt. Ltd. New York. 1999, 906.

http://usnet.us.edu.pl/files/statsoft/STATISTIC A_EN_10_0.zip13-

14-DU, K. L; SWAMY, M. N. S. *Neural Networks and Statistical Learning*. Concordia University, Canada, 2013, 856. DOI: 10.1007/978-1-4471-5571-3.

<https://www.researchgate.net/publication/264912450>.

15-SINGH, SH. K; JAIN, SH. K; BARDOSSY, A. *Training of Artificial Neural Networks Using Information-Rich Data*. Hydrology, ISSN 2306-5338, Vol. 1, 2014, 40-62. Doi:10.3390/hydrology1010040.

16- SHAMSELDIN, A. Y; NASR, A. E; CONNOR, K. M. *Comparison of different forms of the Multi-layer Feed-Forward Neural Network method used for river flow forecasting*. Hydrology and Earth System Sciences, Vol. 6, No. 4, 2002, 671-684.

17-SHRIVASTAV, M. B; GANDHI, H. M; RAMANUJ, P. S. *Prediction of Runoff using Artificial Neural Networks (A Case study of Khodiyar Catchment Area)*.

IJSRD - International Journal for Scientific Research & Development, ISSN (online): 2321-0613, Vol. 2, No. 2, 2014, 36-39.

18-SHAMSLDIN, A. Y. *Artificial neural network model for river flow forecasting in a developing country*. Journal of Hydroinformatics, Vol. 12, No. 1, 2010, 22-35.

19-SOLG,A; ZAREI,H; NOURAN,V; BAHMAN,R. *A new approach to flow simulation using hybrid models*. Appl Water Sci, 2017. DOI:10.1007/s13201-016-0515-z.

20-عمار، غطفان؛ حيدر، بادية. تحديد العناصر المناخية الأكثر تأثيراً على علاقة (الهطل_جريان) باستخدام

الشبكات العصبية الاصطناعية /حالة دراسية:نهر الكبير الشمالي/. مجلة جامعة البعث، المجلد (39) ، العدد(22) ، 2017 ،

21-BASHEER, I. A; HAJMEER, M. *Artificial neural networks: fundamentals, computing, design, and application*. Journal of Microbiological Methods, U. S. A, Vol. 43, 2000, 3–31.

22-CHIANG, Y. M; CHANG, L. CH; CHANG, F. J. *Comparison of static-feed forward and dynamic-feedback neural networks for rainfall–runoff modeling*. Journal of Hydrology, Vol. 290, 2004, 297–311.

23-KALTEH, A. M. *Rainfall-Runoff Modelling Using Artificial Neural Networks (ANNs)*. Doctoral Thesis, LUND university, ISSN 1101-9824, Iran, 2007. <http://aqua.tvrl.lth.se/>.

24-KUCKOH, H . *The relaxation method for learning in artificial neural networks*. Iowa State University, Order Number 9311525, 1992. <http://lib.dr.iastate.edu/rtd>.

25-AMARDEEP, R; THIPPESWAMY, K. *Training Feed forward Neural Network With Back propogation Algorithm*. International Journal Of Engineering And Computer Science (IJECS), ISSN: 2319-7242, Vol. 6, No. 1, 2017, 19860-19866.

26-KUMAR, D; BHISHM, S. K; KHATI, S. *Black box model for flood forecasting*. Journal of Civil Engineering (IEB), India, Vol. 40, No. 1, 2012, 47-59.

27-ABBA, S. I; HADI, S. J; ABDULLAHI, J. *River water modelling prediction using multi-linear regression, artificial neural network, and adaptive neuro-fuzzy inference system techniques*. International Conference on Theory and Application of Soft Computing, Computing with Words and Perception (ICSCCW), Procedia Computer Science, Turkey, Vol. 120, 2017, 75–82.