

نمذجة الهطول المطري_الجريان النهري باستخدام الشبكة العصبونية الصناعية في حوض نهر الكبير الجنوبي

الدكتور غطفان عمار*

الدكتورة بادية حيدر**

ميس محمد عليان***

(تاريخ الإيداع 2 / 3 / 2014. قبل للنشر في 30 / 3 / 2014)

□ ملخص □

تُشكّل العلاقة بين الهطول المطري_الجريان النهري (R_R) Rainfall_Runoff إحدى المركبات الأساسية لدورة المياه في الطبيعة، كما أنها تُشكّل واحدة من أكثر الظواهر الهيدرولوجية تعقيداً وصعوبةً في الفهم؛ وذلك بسبب كثرة عدد البارامترات المتضمنة في نمذجة العمليات الفيزيائية وبسبب اتساع فضاءها البارامتري والتغير المؤقت في مواصفات الحوض، إضافةً إلى تعدد نماذج الهطولات المطرية. هذا وتعدّ نمذجة العلاقة بين الهطول المطري_الجريان النهري مهمة جداً من أجل التصميم الهندسي والإدارة المتكاملة للموارد المائية، إضافةً إلى التنبؤ بالفيضان ودرء مخاطره. حيث يهدف هذا البحث إلى نمذجة العلاقة بين الهطول المطري_الجريان النهري في حوض نهر الكبير الجنوبي في سوريا، بالاعتماد على تقانة الشبكة العصبونية الصناعية (ANN) Artificial Neural Network، حيث بُني النموذج الرياضي باستخدام كلٍّ من nntool و nntool مكتبتين ملحقتين ببرنامج الماتلاب، واعتمد النموذج على البيانات اليومية للهطول المطري، درجة حرارة الهواء، الرطوبة النسبية والتبخّر في المحطات المناخية المنتشرة في الحوض، كما استُخدمت بيانات الجريان النهري اليومية لغرض التحقق من صحة أداء الشبكة باستخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب.

أثبتت نتائج الدراسة أنّ تقانة الشبكة العصبونية الصناعية تعطي نتائج جيدة في نمذجة العلاقة بين الهطول المطري_الجريان النهري، اعتماداً على مجموعة البيانات المستخدمة، وبالتالي يمكن اعتبارها بديلاً للطرائق التقليدية في نمذجة العلاقة R_R.

الكلمات المفتاحية: الهطول المطري_الجريان النهري، الشبكة العصبونية الصناعية، الماتلاب.

* 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 هندسة الري والصرف - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

Rainfall-Runoff Modelling by Artificial Neural Network in Alkabeer Aljonobee Catchment

Dr. Ghadfan Ammar*
Dr. Badia Haider**
Mais Mohammed Olayan***

(Received 3 / 2 / 2014. Accepted 30 / 3 / 2014)

□ ABSTRACT □

The relation between rainfall and runoff forms one of the main hydrological cycle elements. It is one of the most complex hydrological phenomena because of the great numbers of parameters used in modeling the physical processes, the expansion of their parameter space, and the temporary change in watershed specifications. Thus, modeling the relation between rainfall and runoff is necessary for hydrological and hydraulic engineering design, integrated management of water resources, and forecasting flood and preventing its dangers. This research aims at modeling the relation between rainfall and runoff in Alkabeer Aljononbee catchment. It depends on the technique of Artificial Neural Network (ANN). The mathematical model was built by the ntstool and nntool available in the Matlab program. This model depends on daily rainfall, evaporation, air temperature, and relative humidity data taken from meteorological stations that are distributed in the watershed. The daily runoff data have also been used for checking the performance accuracy of the network, using the Simulink technique. The results of this research confirm that artificial neural network technology offers good results in modeling the relation rainfall-runoff, depending on the set of data used. So it could be a better alternative than traditional approaches.

Keywords: Rainfall-Runoff, Artificial Neural Network, Matlab

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

**Assistant Professor, Department of Water Engineering and Irrigation, 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 :

يعدّ تطوير النماذج الحسابية القادرة على إجراء محاكاة دقيقة لاستجابة الحوض للهطول المطري واحداً من التحديات البحثية الرئيسية في مجال الهيدرولوجيا. مثل هذه النماذج قادرة على التنبؤ بقيم التصريف المستقبلي للنهر الضرورية للتصميم الهندسي الهيدرولوجي والهيدروليكي وفي إدارة مصادر المياه. حيث حاول العديد من الهيدرولوجيين نمذجة هذه العلاقة انطلاقاً من وجهتي نظر مختلفتين وهما: النمذجة الموجهة بالمعرفة (Knowledge-driven R-R modelling) والنمذجة الموجهة بالبيانات (data-driven modelling) [1].

تهدف النمذجة الموجهة بالمعرفة إلى إعادة إنتاج النظام الهيدرولوجي للعالم الحقيقي وسلوكه بطريقة فيزيائية واقعية. اعتمدت هذه الطريقة في نمذجة العلاقة R_R على وصف تفصيلي للنظام والعمليات التي ينطوي عليها في إنتاج الجريان النهري. تعتبر طرق النمذجة الفيزيائية من أفضل الأمثلة لطرق النمذجة الموجهة بالمعرفة، والتي تستخدم بشكل عام الإطار الرياضي المعتمد على الكتلة، كمية الحركة ومعادلات حفظ الطاقة في حيز توزع الموديل. تتطلب مثل هذه الموديلات مدخلات للشروط المبدئية والمحيطية، حيث توصف عمليات التدفق من خلال معادلات تفاضلية [1]. أحد الأمثلة لطرق النمذجة الفيزيائية هو النظام الهيدرولوجي الأوروبي (Hydrologique (SHE Europe'en The Syste'me والحوض المبدئي النموذجي (the Representative Elementary Watershed) (REW) [2]. تتطلب طرق النمذجة الفيزيائية كمية ضخمة من البارامترات كما انها تتطلب الكثير من العمليات الحسابية، وبالتالي فهي تعاني من تأثير كثرة البارامترات وتأثير البارامترات المحيطة، هذا ما يجعل الممنذجين يبحثون عن طرق نمذجة بسيطة تتطلب عدد قليل من البارامترات [3].

تعتمد الطرق الموجهة بالبيانات للتنبؤ بالجريان النهري في الحوض على إعادة استخدام واستخلاص المعلومات المتضمنة في البيانات الهيدرولوجية مباشرة، وذلك بدون الأخذ بعين الاعتبار القوانين الفيزيائية التي تكمن وراء عمليات الهطول المطري_الجريان النهري (مثل قانون حفظ الطاقة). يضم حقل النمذجة الموجهة بالبيانات عدداً ضخماً من التقانات (مثل سلاسل البيانات، الانحدار التجريبي، أنظمة تعتمد على قانون الضبابية ونمذجة الشبكات العصبونية الصناعية)، معظمها ينشأ من الذكاء الصناعي والإحصائي. حيث تُعتبر النماذج الموجهة بالبيانات المستخدمة لنمذجة العلاقة R_R بشكل عام أسهل وأسرع تطوراً وفعالية ولا تعاني من معظم المشاكل التي تعاني منها النماذج الموجهة بالمعرفة، لكنها تعاني من بعض السلبات، بسبب تدني مستوى شفافيتها، الناتجة عن عدم قدرتها على تفسير عملياتها الداخلية بطريقة ذات أساس فيزيائي، فهي غالباً ماتقشل في إعطاء فهم عميق للنظام قيد البحث [1].

أثبتت الشبكات العصبونية الصناعية أنها أداة جيدة في محاكاة العمليات المعقدة والأنظمة اللاخطية، ولقد أحرزت اهتماماً كبيراً في السنوات الأخيرة، أوحى هذا للهيدرولوجيين باستخدام الشبكات العصبونية الصناعية في نمذجة العلاقة بين الهطول المطري_الجريان النهري في أماكن مختلفة من العالم.

حيث استخدم (Modarres, A. 2009) الشبكة العصبونية الصناعية لنمذجة العلاقة بين الهطول المطري_الجريان النهري في حوض Plasjan في غرب منطقة Zayandehrud في إيران. استخدم الباحث في هذه الدراسة 17 إحصائية عامة. أظهرت الدراسة أنّ الشبكة العصبونية الصناعية المكونة من أربع طبقات خفية تعطي أفضل أداء مقارنةً مع شبكات عصبية أخرى وأيضاً مقارنةً مع نموذج الانحدار التجريبي [4].

كما استخدم (Post, D. 2009) ANNs لنمذجة العلاقة بين الهطول المطري_الجريان النهري لتسعين حوضاً في Tasmania في استراليا بهدف التنبؤ بالجريان النهري، تملك هذه الأحواض قياسات تدفق للفترة ما بين

(1975-2007)، أشارت تحاليل أداء هذا النموذج من ناحية كل من المعايير والتحقق أنّ طريقة النمذجة هذه تؤمن تقويمات تدفق مقنعة من ناحية كل من التغيرات اليومية والموازنة المائية الكلية [5].

في دراسة قام بها (Nasri, M. 2010) للنتبؤ بالفيضان في حوض Zayandehrud في إيران، استخدم الباحث الشبكة العصبونية الصناعية للنتبؤ بحوادث الفيضان في هذا الحوض، حيث أظهرت الدراسة أنّ الاختيار الصحيح للمدخلات هو الجزء الأكثر أهمية في عملية النمذجة هذه. حيث توصلت الدراسة إلى أنّه بإمكان الشبكة العصبونية الصناعية تأمين حسابات دقيقة ومناسبة للنتبؤ بحوادث الفيضان في هذا الحوض ومما يساعد على درء مخاطره وتخفيضه وهذا يعد مهماً في عملية إدارة الموارد المائية [6].

كما قام (Jalal, J. et, al. 2010) باستخدام ثلاثة موديلات ل ANNs لنمذجة العلاقة (R_R) في حوض نهر Vamanapuram في الهند. الشبكات المستخدمة هي شبكة عصبية متعددة الطبقات (Multi Layer Perceptron (MLP)) وشبكة عصبية إرجاعية (Recurrent Neural Network (RNN)) وشبكة عصبية ذات أساس شعاعي (Radial Basis Function Network (RBF)). اعتمدت هذه الدراسة على قياسات شهرية للهطولات المطرية والتدفق النهري ودرجة الحرارة جُمعت لمدة تسع سنوات. أظهرت الدراسة أن MLP هي أفضل أداءً مقارنةً مع RNN و RBF [7].

وفي دراسة قام بها (Arslan, C. 2011) لنمذجة العلاقة بين الهطول المطري_الجريان النهري في حوض KhasaChai في بريطانيا، استخدم الباحث تسع معماريات مختلفة للشبكة العصبونية الصناعية تختلف فيما بينها في عدد العصبونات الخفية وفي المدخلات، حيث تضمنت المدخلات كلاً من الهطول المطري، الجريان النهري، درجة الحرارة، الرطوبة النسبية والتبخّر. توصل الباحث إلى أنّ أفضل أداء هو للشبكة العصبونية الصناعية التي تحتوي على تسع عصبونات خفية وعلى تسع مدخلات، حيث اعتمد في إجراء مقارنته على معامل الارتباط [8].

كما استخدم (Joshi, J. 2011) في دراسة قام بها لنمذجة العلاقة بين الهطول المطري_الجريان النهري في منطقة Gujarat في الهند، ثلاثة أنواع لشبكات عصبونية صناعية (Artificial Neural Network (ANN)) هي شبكات التغذية الأمامية ذات الانتشار العكسي للخطأ (Feed Forward Back Propagation (FFBP))، الشبكات ذات الأساس الشعاعي (Radial Basis Function (RBF)) وشبكات الإنحدار العام (Generalized Regression Neural Network (GRNN))، اعتماداً على قياسات الهطول المطري اليومي وقيم تدفق نهر Maleshri اليومية لفترة 10496 يوماً، حيث قورنت الطرائق الثلاثة مع طريقة الإنحدار الخطي المتعدد. توصلت الدراسة إلى أنّ الطرائق الثلاثة قد طبقت بنجاح في نمذجة العلاقة (R_R) ولكن شبكات التغذية الأمامية ذات الانتشار العكسي للخطأ تعطي نتائج أفضل مقارنة مع باقي الطرائق [9].

وفي دراسة أجراها (Patil, S. et, al. 2012) للنتبؤ بالجريان النهري اليومي في مقاطعة Maharashtra في الهند، بهدف الإدارة المثلى للمياه، وذلك باستخدام كل من الخوارزمية الجينية والشبكات العصبونية الصناعية والنظرية الضبابية. بينت هذه الدراسة مساوئ ومحاسن استخدام هذه الخوارزميات واقترحت العمل بها نظراً لنتائجها الجيدة في نمذجة العلاقة بين الهطول المطري_الجريان النهري [10].

هذا وقد نشر (DHAMGE, N. et, al. 2012) دراسة للنتبؤ بالتدفق النهري اليومي باستخدام ANNs في الهند. بينت الدراسة إمكانية استخدام الشبكة العصبونية في نمذجة العلاقة بين الهطول المطري_الجريان النهري [11].

كما أجرى (Dozier, A. 2012) دراسة لتأثير التغير المكاني للهطول المطري في نموذج الهطول المطري_الجريان النهري المشكّل باستخدام الشبكة العصبونية الصناعية، حيث استخدم الباحث شبكة Elman ذات التغذية الراجعة لتدريب ومحاكاة قياسات التدفق النهري في حوض Creek Fountain في Colorado باستخدام كميات مختلفة من معلومات الهطول المكانية. حيث حُدِّت تسع مناطق ضمن منطقة تصريف الحوض المائي. كما تُمذِّج خمسة سيناريوهات مختلفة تضمنت 9 مناطق، 6 مناطق، 3 مناطق، 2 منطقة ومنطقة واحدة [12].

أهمية البحث وأهدافه:

انطلاقاً من أهمية التنبؤ بقيم التصريف المستقبلي للنهر، باعتباره ضرورياً للتنبؤ بالفيضان، إضافةً إلى أهميته في التصميم الهندسي الهيدرولوجي والهيدروليكي وفي إدارة الموارد المائية، حيث تأتي أهمية نمذجة العلاقة بين الهطول المطري_الجريان النهري بوصفها عنصراً أساسياً من عناصر الدورة الهيدرولوجية للمياه في الطبيعة وتحديدتها بدقة باستخدام تقانة متطورة لوضع عناصر الموازنة بدقة عالية يمكن الاعتماد عليها لتخطيط الموارد المائية. حيث يهدف هذا البحث إلى وضع نموذج رياضي للعلاقة بين الهطول المطري_الجريان النهري باستخدام الشبكة العصبونية الصناعية من خلال:

① إجراء تحليل حساسية لخوارزمية تدريب الشبكة بهدف تحديد الخوارزمية الأفضل أداءً في تدريب الشبكة العصبونية الصناعية، ومن ثم بناء نموذج للعلاقة بين الهطول المطري_الجريان النهري باستخدام الشبكة العصبونية الصناعية.

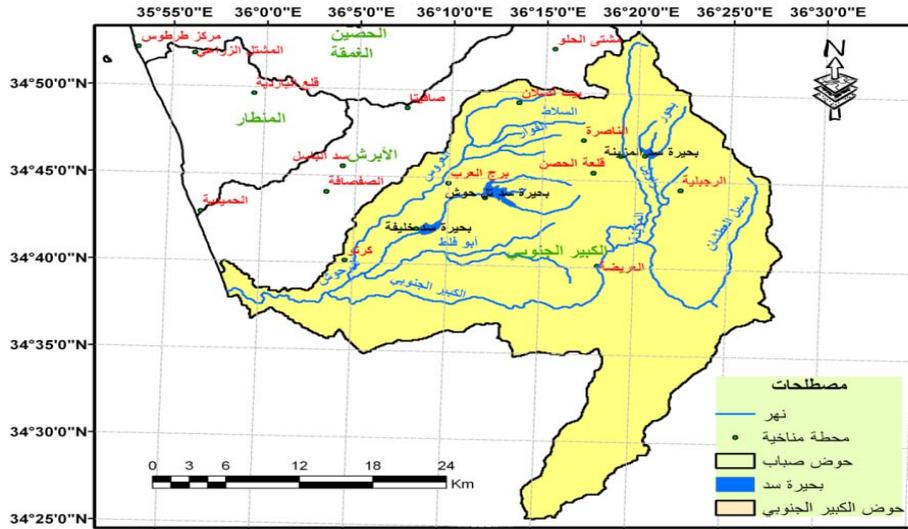
② تقويم أداء النموذج المشكّل باستخدام تقانة Simulink المتاحة في حزمة برمجيات الماتلاب.

موقع منطقة البحث

تُشكّل منطقة الدراسة جزءاً من الساحل السوري حيث تقع جنوب طرطوس إذ يشكل نهر الكبير الجنوبي حدود لبنان الشمالية مع سورية الشكل (1). وتبلغ مجمل مساحة حوضها الساكب نحو 990 كيلومتراً مربعاً، منها 295 كيلومتراً مربعاً في لبنان. يقع هذا الحوض بين خطي عرض ($34^{\circ}25'0''$) و ($34^{\circ}50'0''$) شمالاً وبين خطي طول ($35^{\circ}55'0''$) و ($36^{\circ}30'0''$) شرقاً الشكل (2). استخدم في هذه الدراسة سلاسل زمنية يومية لكل من الهطول المطري، التبخر، درجة الحرارة، الرطوبة والتدفق عند مخرج الحوض متوافرة للفترة ما بين (2004-2008).



الشكل(1): خارطة الموقع العام لمنطقة البحث

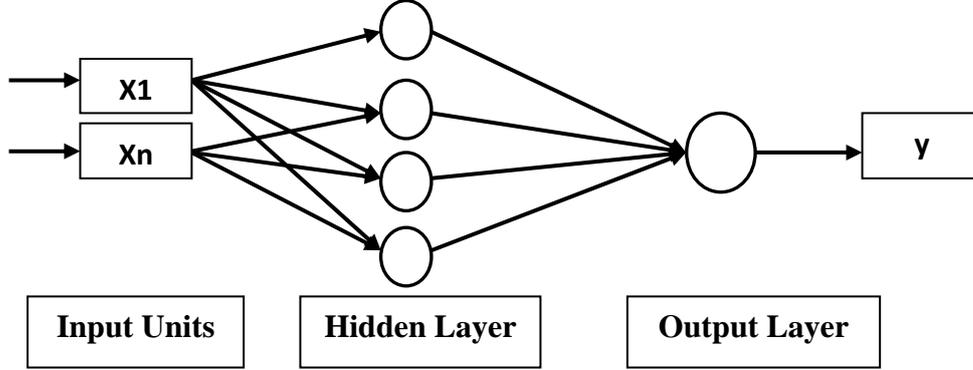


الشكل (2): حوض الكبير الجنوبي

طرائق البحث ومواده:

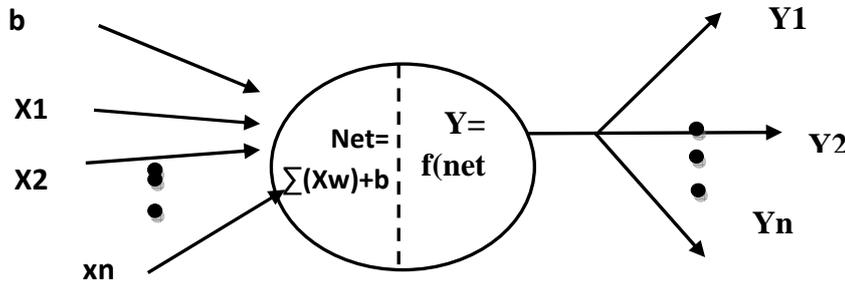
تعتمد هذه الدراسة على إنشاء نموذج رياضي للشبكة العصبونية الصناعية، حيث تعرّف الشبكة العصبونية الصناعية بأنها عبارة عن نظام لمعالجة البيانات بشكل يحاكي ويشابه الطريقة التي تقوم بها الشبكات العصبونية الطبيعية للإنسان، حيث تتشابه الشبكة العصبونية الصناعية مع الدماغ البشري في أنها تكتسب المعرفة بالتدريب، 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.

تتكون الشبكات العصبونية بشكل عام من نظام من الخلايا العصبونية ، التي تم ترتيبها في طبقات الشكل (3)، حيث تتلقى هذه الشبكات الإشارات من خلال وحدات الإدخال، ثم يتم معالجتها وإعادة بثها باتجاه عصبونات الخرج. يدعى هذا النوع من الشبكات الصناعية والذي تنتقل فيه المعلومات باتجاه الخرج بشبكات التغذية الأمامية.



الشكل (3): الشبكة العصبونية الصناعية ذات التغذية الأمامية بطبقة خفية واحدة فقط

يوضح الشكل (4) عملية تحويل البيانات المارة في الشبكة، حيث تضرب مدخلات الشبكة (سواء قيم الدخل أو الخرج من العصبونات السابقة) بالأوزان المرافقة لاتصالاتها (W)، إذ تعبر هذه الأوزان عن قوة الاتصال بين العصبونات، ثم تجمع النتائج للقيمة الإضافية التي تدعى بالانحياز (b). يُعدّل ناتج الشبكة هذا بواسطة تابع التحويل f إلى قيمة فعالة للعصبون، يرمز لها في المخطط ب Y، حيث يعاد نشر هذه القيمة الفعالة إلى العصبونات التالية.



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

في دراستنا هذه، استخدم نوعان من الشبكات الديناميكية: النوع الأول هو شبكات عصبونية ذات تأخر زمني مركز (Focused Time _Delay Neural network (FTDNN)، الشكل (5)). تعرف هذه الشبكات بأنها عبارة عن شبكة تغذية أمامية مع خطوط تأخر زمنية للمدخلات. حيث تظهر القوة المحركة في طبقة المدخلات للشبكات الستاتيكية ذات التغذية الأمامية متعددة الطبقات. تُعتبر هذه الشبكات مناسبة للتنبؤ بالسلاسل الزمنية. حيث تعرف معادلة هذه الشبكات بالشكل الآتي:

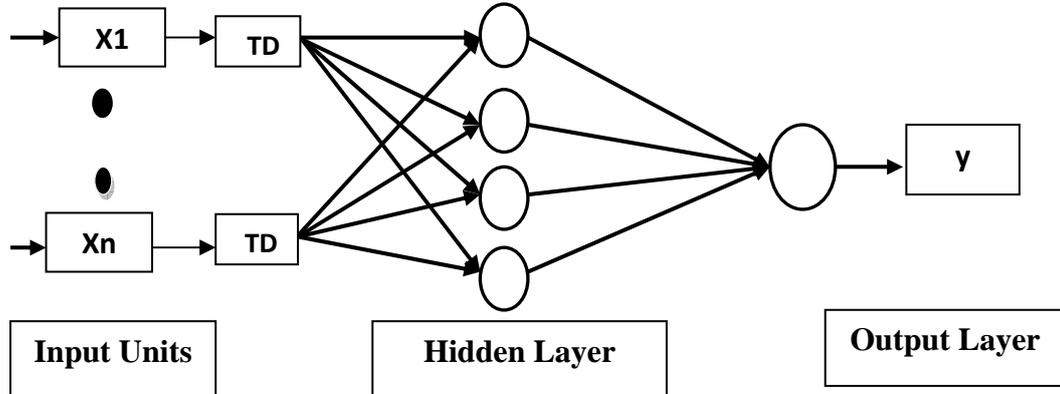
$$y(t) = f(x(t-1), \dots, x(t-d)) \quad (1)$$

حيث:

Y(t): خرج الشبكة عند الزمن t.

$X(t-1)$: الدخل عند الزمن $t-1$.

d : التأخر الزمني.

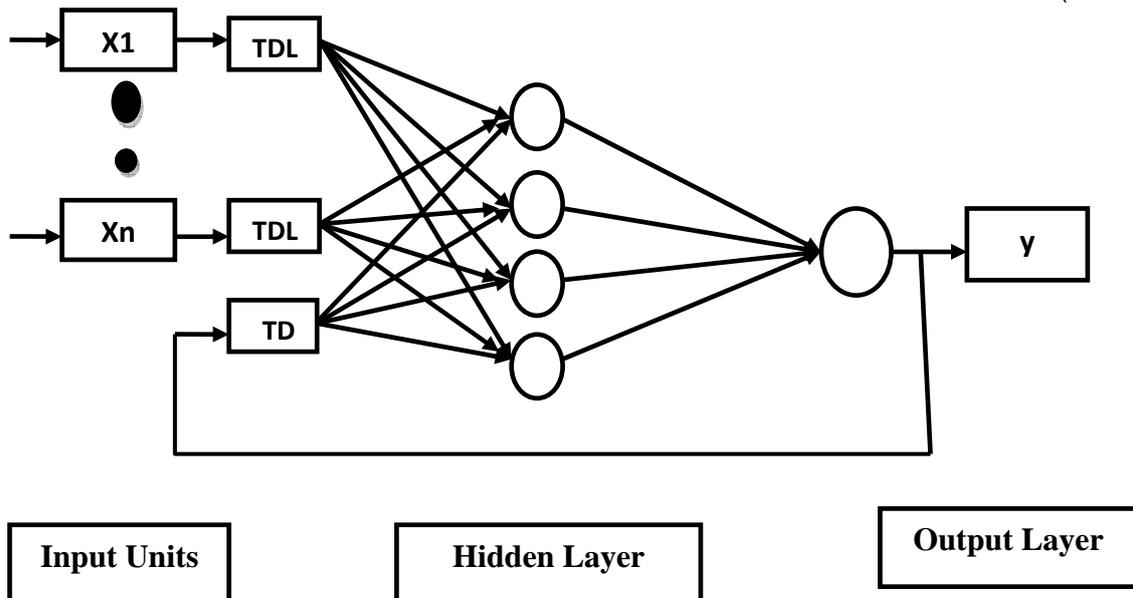


الشكل (5): الشبكات العصبونية ذات التأخر الزمني المركز (Focused Time-Delay Neural network(FTDNN))

النوع الثاني من الشبكات الديناميكية والذي استخدم في هذه الدراسة هو شبكات (NARX) الشكل (6). وهي شبكة ديناميكية ذات تغذية راجعة، تملك توصيلات للتغذية الراجعة تغلق عدّة طبقات في الشبكة. يعتمد نموذج NARX على نموذج ARX الخطي، الذي غالباً ما يستخدم في نمذجة السلاسل الزمنية. تعرّف شبكة NARX بالمعادلة الآتية:

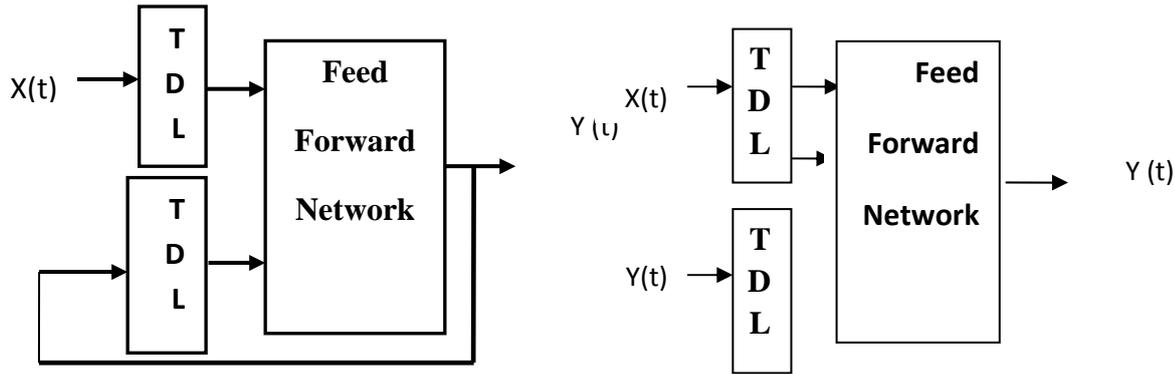
$$Y(t) = f(y(t-1), y(t-2), \dots, y(t-d), \dots, x(t-1), x(t-2), \dots, x(t-d)) \dots (2)$$

حيث تعتمد القيمة التالية لإشارة الخرج التابعة $Y(t)$ على القيم السابقة لإشارة الخرج والقيم السابقة لإشارة الدخل (الخارجية) المستقلة.



الشكل (6): شبكة NARX

تملك هذه الشبكات العديد من التطبيقات، حيث يمكن استخدامها كمتنبأ، للتنبؤ بالقيمة التالية لإشارة الدخل. هذا ويتوافر نوعان لشبكات NARX، النوع الأول يستخدم خرج الشبكة كتغذية راجعة لدخل الشبكة العصبونية ذات التغذية الأمامية، ويستخدم هذا النوع للتنبؤ بسلاسل زمنية بعدة خطوات، الشكل (7-a). في حين يعتمد النوع الثاني من شبكات NARX على قيم الخرج الحقيقية في أثناء تدريب الشبكة بدلاً من التغذية الراجعة للخرج المقوم، الشكل (7-b)، حيث استخدم النوع الثاني من شبكات NARX في دراستنا وذلك لأنه يملك ميزتين، الأولى هي أنّ الدخل المستخدم لشبكات التغذية الأمامية هو أكثر دقة، والثانية هو استخدام الانتشار العكسي الستاتيكي لتدريب الشبكة.



الشكل (7-a) معمارية متوازية
Parallel Architecture

الشكل (7_b): معمارية سلاسل متوازية
Series-Parallel Architecture

تدريب الشبكة:

تُدرَّب الشبكة بتطبيق خوارزمية أمثلة، والتي تحاول إنقاص الخطأ في خرج الشبكة بواسطة ضبط مصفوفة أوزان الشبكة W وانحيازات العصبونات b . الطريقة الشائعة لتدريب الشبكة في تطبيقات تابع التقارب مثل نمذجة الهطول المطري_ الجريان النهري، هي استخدام خوارزميات التدريب تحت الإشراف. تستخدم هذه الخوارزميات كلاً من بيانات الدخل والخرج للنظام المحاكى. تعدل الأوزان وفقاً للأمثلة بعض قياسات الأداء، والتي هي القياس في درجة التناسب (أو الفرق) بين تقويمات الشبكة وقيم الخرج الحقيقية. التعديل في بارامترات الشبكة في حالة التدريب غالباً ما يتوقف قبل الوصول إلى أفضل تدريب، بسبب أنّ الشبكة سوف تبدأ بالتعلم بشكل عشوائي في مجموعة بيانات التدريب وبالتالي تفقد قدرتها على التعميم (ظاهرة فوق التوافق). على أية حال، يقصد بالتوقف المبكر جداً بأنّ الشبكة لم تتعلم حتى الآن كل المعلومات عن بيانات التدريب (ظاهرة تحت التوافق). كلتا الحالتين سوف تنتجان أداء غير مثالي لنموذج الشبكة. لهذا السبب غالباً ما تقسم مجموعة بيانات الشبكة إلى ثلاث مجموعات منفصلة: الأولى هي مجموعة التدريب، الثانية هي مجموعة التحقق والثالثة هي مجموعة الاختبار. تؤمن المجموعة الأولى بيانات خاصة بتدريب الشبكة، وتستخدم الثانية في أثناء تدريب الشبكة لإنقاص من احتمالية حصول ظاهرة فوق التوافق للشبكة، حيث يتوقف تصغير خطأ التدريب حالما يبدأ خطأ مجموعة التحقق بالتزايد. تعتبر هذه النقطة واقعة بين فوق التوافق وتحت التوافق للشبكة. التوقف المبكر يعني أنّ الشبكة لم تأخذ كامل الفائدة للمعلومات الموجودة في إشارات الدخل، والتوقف لاحقاً يعني أنّ الشبكة تختار كافة بيانات التدريب وتفقد قدرتها على التعميم. لذلك تُستخدم المجموعات الثلاث للمصادقة على أداء الشبكة المدربة. تدعى هذه الطريقة بطريقة تقسيم العينات حيث استخدمت هذه الطريقة في هذه الدراسة.

محاكاة النموذج:

القياسات الأكثر أهمية في محاكاة أداء النموذج المستخدمة في هذه المقالة هي متوسط مربع الخطأ (MSE) المعادلة (3) ومعامل الارتباط المعادلة (4)، [3].

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

Y : المخرجات الهدف Target؛ a_2 : قيمة خرج الشبكة المحسوبة calculated.

$$R = \sqrt{1 - \frac{F}{F_0}} \dots \dots \dots (4)$$

حيث

$$F = \sum_{k=1}^k (Q_K - Q^{\wedge}_K)^2 \dots \dots \dots (5)$$

$$F_0 = \sum_{k=1}^k (Q_K - \bar{Q}_K)^2 \dots \dots \dots (6)$$

F_0 هو التباين الأول لقيم التصريف و F هو تباين النموذج المتبقي. في هذه المعادلات، K هو العدد الكلي لعناصر البيانات، Q_K و Q^{\wedge}_K هي قيم التصريف المراقبة والمحسوبة عند الفاصل الزمني K^{th} على التوالي، \bar{Q}_K هو متوسط التصريف على امتداد الزمن. قيمة R المساوية للواحد تشير إلى أفضل ارتباط.

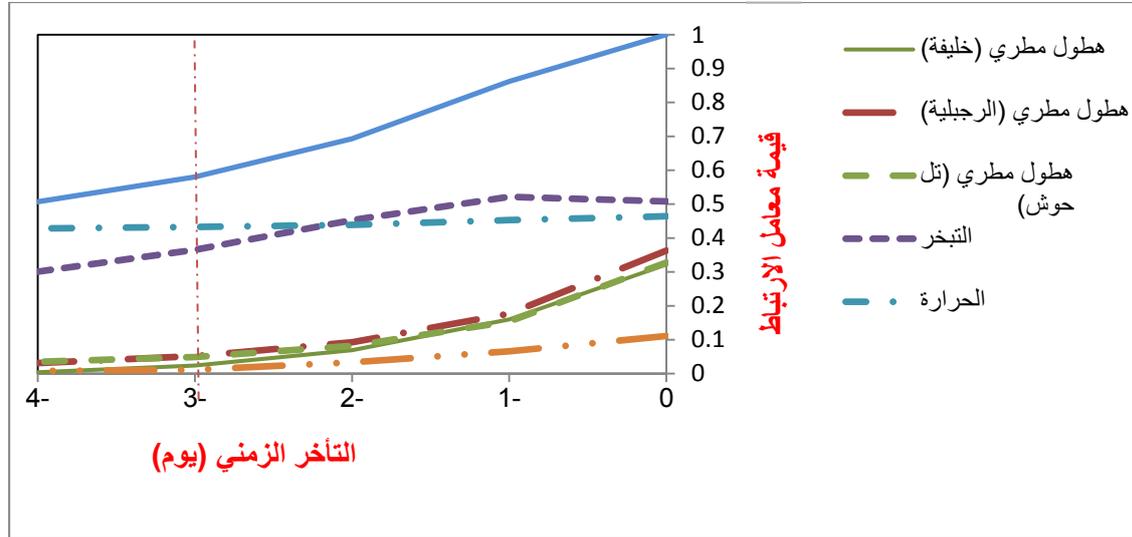
في بداية كل محاولة تدريب للشبكة، يجب إعادة إدخال القيم الأولية لكل من أوزان الشبكة وانحيازاتها. الطريقة الأكثر تطبيقاً هي التهيئة المبدئية بشكل عشوائي [13]. الهدف من هذه العشوائية هو إجبار خوارزمية التدريب على البحث عن أجزاء أخرى لفضاء البارامترات، وذلك بهدف الوصول إلى ناتج أمثلة عام قوي وزيادة الفرصة بشكل عام لإيجاد الخطأ الأصغري. تسبب هذه الطريقة اختلافاً في أداء الشبكة عند كل محاولة تدريب، حتى لو استخدمت نفس خوارزمية التدريب. حيث تتواجد ثلاثة أسباب لعدم قدرة خوارزمية التدريب على إيجاد نفس مجموعة البارامترات لكل محاولة تدريب عندما يبدأ التدريب بجزء مختلف من الفضاء البارامترية. السبب الأول هو بسبب تواجد أكثر من نقطة أمثلة عامة لمجموعة التدريب. السبب الثاني هو بسبب عدم قدرة خوارزمية التدريب على إيجاد نقطة الأمثلة العامة والتصاقها بنقطة الأمثلة المحلية، وذلك في المساحات المسطحة والتلالية لمستوي الخطأ. السبب الثالث أنه في حالة تطبيق مجموعة التحقق لمنع ظاهرة فوق التوافق، قد لا تتوافق نقطة الأمثلة لمجموعة بيانات التدريب مع نقطة الأمثلة لمجموعة بيانات التحقق، وذلك بسبب توقف الخوارزمية قبل إيجاد نقطة الأمثلة العامة بسبب تزايد خطأ مجموعة التحقق.

إشارات الدخل:

يجب أن تضم إشارات الدخل لنموذج الشبكة العصبونية الصناعية كل المعلومات المتعلقة بالخرج الهدف، ومن جانب آخر، يجب أن تتضمن أقل ما يمكن من المعلومات الغير مرتبطة بالخرج [13]. وذلك من أجل تسهيل عمل خوارزمية التدريب، لأن العدد المتزايد من إشارات الدخل يقود إلى معمارية للشبكة أكثر تعقيداً، وبما أن مهمة خوارزمية التدريب معقدة قد يؤثر ذلك سلباً على أداء الشبكة.

يتزايد عدد وحدات الإدخال مع تزايد طول الذاكرة لخط التأخر الزمني. من أجل اختيار شحيح لمدخلات الشبكة، نختبر الارتباط الخطي بين السلاسل الزمنية للمدخلات والمخرجات. لا تعطي الطريقة الخطية البسيطة هذه كل المعلومات المحتواة في النقانة اللاخطية مثل الشبكة العصبونية الصناعية والتي يمكن الإستفادة منها. ولكنها قد تعطي مؤشراً جيداً لمقدار التأخر الزمني المؤثر للمدخلات. يظهر الشكل (8) معاملات الارتباط بين متحولات مختلفة

وسلاسل زمنية يومية للتصريف عند محطة الدبوسية من أجل تأخرات زمنية مختلفة. حيث يلاحظ أنّ قيمة معامل الارتباط من أجل تأخر زمني يزيد عن الثلاثة أيام يقارب الصفر لبعض البارامترات، وبالتالي سيتم الاختبار في هذه الدراسة لمجموعة البارامترات من أجل تأخرات زمنية تقع ضمن المجال [3 1].



الشكل (8): معاملات الارتباط بين متحولات مختلفة وسلاسل زمنية يومية للجران النهري عند محطة الدبوسية من أجل تأخرات زمنية مختلفة.

في هذه الدراسة سوف نقارن بين أداء الشبكة العصبونية الصناعية في حال استخدامها كنموذج مسبب مؤثر صافٍ (Pure Cause-and-Effect Models) وأدائها في حال جمعت بين كلٍّ من نموذج (Pure Cause-and-Effect Models) ونموذج السلاسل الزمنية (Time Series Model). تتكون مدخلات الشبكة العصبونية الصناعية في حال استخدامها كنموذج مسبب مؤثر (model spure cause-and-effect) من قيم سابقة لكلٍّ من الهطول المطري عند المحطات الثلاث، التبخر، الحرارة والرطوبة، أما الخرج فهو عبارة عن قيم مستقبلية للتصريف. في حين تتكون هذه المدخلات من قيم سابقة لكلٍّ من الهطول المطري عند المحطات الثلاث، التبخر، الحرارة، الرطوبة والتصريف ويكون الخرج قيم مستقبلية للتصريف وذلك عندما تستخدم الشبكة العصبونية الصناعية لكلٍّ من نموذج (pure cause-and-effect) ونموذج السلاسل الزمنية (time series model) معاً. سيتم تقييس بيانات الدخل والخرج ضمن المجال 0 إلى 1 باستخدام المعادلة (7) وذلك لأن المكتبة المستخدمة تعتمد على تابع التحويل السيجمويدي في الطبقة الخفية:

$$X_{\text{norm}} = \frac{X - X_{\text{average}}}{X_{\text{max}} - X_{\text{min}}} \quad (7)$$

حيث: X : القيمة الحقيقية .

X_{average} : القيمة المتوسطة لسلسلة البيانات.

X_{max} : القيمة العظمى لسلسلة البيانات.

X_{min} : القيمة الصغرى لسلسلة البيانات.

النتائج والمناقشة:

1- خوارزميات التدريب:

دربت الشبكات العصبونية الصناعية باستخدام خوارزميات تدريب تحاول تصغير قيمة تابع الأداء أي متوسط مربع الخطأ (MSE). يظهر الجدول (1) أداء هذه الخوارزميات من حيث MSE، وعدد التكرارات حيث يعطي الأخير مؤشر لسرعة تقارب الخوارزمية. حيث أجريت المقارنة بين عدّة شبكات صناعية تملك نفس المواصفات وذلك باستخدام مكتبة nntool المتاحة في حزمة برمجيات الماتلاب.

الجدول (1): أداء خوارزميات التدريب من حيث MSE وعدد التكرارات

عدد التكرارات Epochs	متوسط مربع الخطأ MSE	خوارزمية التدريب
51	0.00123	TRAINBFG
1000	0.00838	TRAINGDM
30	0.00142	TRAINCGF
46	0.00165	TRAINCGP
1000	0.00761	TRAINGD
1000	0.0131	TRAINGDM
114	0.00538	TRAINGDA
182	0.0027	TRAINGDX
14	0.000532	TRAINLM
65	0.00153	TRAINOSS
40	0.00306	TRAINRP
32	0.00254	TRAINSCG

يتفوق إنجاز خوارزمية L-M algorithm على الخوارزميات الأخرى من ناحية الدقة وسرعة التقارب في كل حالات الاختبار. تظهر النتائج في الأعلى إلى أنّ أداء الشبكة العصبونية الصناعية قادر على الاعتماد وبشكل كبير على خوارزميات الأمثلة لإيجاد مجموعة جيدة من الأوزان والانحيازات. حيث تتواجد ثلاث مزايا من استخدام خوارزمية جيدة: أولاً دقة جيدة تقود إلى أداء شبكة عصبونية أفضل، ثانياً تقارب أسرع يقود إلى زمن حساب أقل، وثالثاً سرعة منخفضة في الأداء تجعل منه أسهل وأكثر مصادقية لمحاكاة ومقارنة الشبكات العصبونية الصناعية.

تصميم الشبكة:

كما ذكر سابقاً سوف يستخدم في هذه الدراسة نموذجان للشبكة العصبونية الصناعية:

• نموذج (pure cause-and-effect models) أو مايسمى بالنموذج العام (global model):

استخدم في هذا النموذج شبكة عصبونية صناعية ذات معمارية تتكون من عصبون خرج واحد، ثابتة على كامل الدراسة، من أجل وضع تنبؤ رئيسي بخطوة زمنية واحدة، وطبقة خفية واحدة حيث وجد الحجم المثالي للطبقة الخفية بواسطة التزايد المنتظم لعدد العصبونات الخفية حتى يتحسن أداء الشبكة بشكل جيد. طبق هذا النموذج باستخدام شبكة (Focused Time _Delay Neural network (FTDNN)، والتي تحتوي في طبقة المدخلات على كل من الهطول المطري عند المحطات الثلاث، التبخر والحرارة والرطوبة عند محطة واحدة، وذلك باستخدام عدّة

تأخرات زمنية للمدخلات. حيث جرى اختبار عدّة معماريات للشبكة العصبونية الصناعية، بهدف التوصل إلى أفضل أداء (أصغر قيمة لمتوسط مربع الخطأ). جرت هذه الاختبارات باستخدام مكتبة ntstool المتاحة في حزمة برمجيات الماتلاب، والتي تستخدم خوارزمية Levenberg–Marquardt backpropagation لتدريب الشبكة وتابع السيفمويد كتابع تحويل للطبقة الخفية والتابع الخطي كتابع تحويل لطبقة المخرجات.

يظهر الجدول (2) أداء نموذج الشبكة العصبونية الصناعية هذا، حيث تبين أن الشبكة العصبونية الصناعية ذات المعمارية 18_22_1 تعطي أفضل أداء 0.00127 من أجل المجموعات الثلاثة ومعاملات ارتباط للمجموعات الثلاث التدريب، التحقق والاختبار (86.3 ، 76.8 ، 31.6)% على التوالي.

الجدول (2): نموذج الشبكة العصبونية الصناعية العام (Global Model)

الكل	متوسط مربع الخطأ MSE			الكل	معامل الارتباط R %			عدد العصبونات الخفية	التأخر (يوم)	المدخلات	
	مجموعة اختبار $*10^{-3}$	مجموعة تحقق $*10^{-3}$	مجموعة تدريب $*10^{-3}$		مجموعة اختبار	مجموعة تحقق	مجموعة تدريب				
0.0048	6.5	8.06	4.83	57.42	34.53	62.17	60.64	3	1	r1 هطول (محطة الرجيلية)	
0.00488	8.14	8.94	5.24	50.55	59.36	50.1	50	4		r2 هطول (محطة تل حوش)	
0.00447	15.2	4.27	4.65	54.5	15.97	50	68.98	5		r3 هطول (محطة خليفة)	
0.00453	5.15	5.27	4.77	64.2	36.53	69.99	67.78	6		تبخّر E مم/يوم	
0.00446	6.74	5.06	5.84	54.26	47.21	34.9	58.85	7		حرارة T °C	
0.00391	7.95	10.44	4.13	56.5	24.19	61.47	63.48	8		رطوبة rh %	
0.00386	7.48	11	6.1	50.45	52.6	51.5	50.4	9			
0.00383	11.14	5.88	4	59.38	51.76	55.2	65.23	10			
0.00372	11	6.88	4	60.35	37	31.28	72.72	11			
0.00379	8.8	5.6	4.43	60.51	39.8	43.97	67.86	12			
0.00377	12.94	6.98	4.22	53.52	30.35	29.11	65.56	13			
0.00388	8.2	9.61	5.69	47.22	36.33	54.82	47.49	14			
0.00379	9.67	4.6	6.46	54.66	33.86	45	59.91	15			
0.00315	12.3	5.57	3.49	63.8	22.13	70.54	74.78	16			
0.00375	7.33	7.9	5	56.24	38.27	27	64.22	17			
0.00371	7.38	5.87	4.63	62.7	44	34.8	70.74	18			
0.00372	13.7	11.18	4.91	47.49	36.95	35.18	60.76	19			
0.00386	16.85	5.33	4.17	52	38.38	33.27	64.19	20			
0.00365	3.65	4.95	4.46	68.4	23.97	75.5	69.9	3		1-2	r1 هطول (محطة الرجيلية)
0.00335	6.17	4.8	3.9	68.65	61	60	17	4			r2 هطول (محطة تل حوش)
0.00357	4.28	4.65	4.23	69.35	60.96	63.2	73	5	r3 هطول (محطة خليفة)		
0.00325	5	5.52	3.85	69.67	52.97	39.18	77.15	6	تبخّر E مم/يوم		
0.00298	5	3.5	3.7	73.15	84	54.67	70.29	7	حرارة T °C		
0.00294	4.73	5.77	3.7	71.3	54.14	64.4	75.3	8	رطوبة rh %		
0.00268	3.45	5.66	3.46	73.96	31.73	54.5	80.77	9			
0.0024	6	11.3	5.79	48.6	58.3	45.99	49.98	10			
0.00211	11.13	5.96	3.84	63.4	61.5	52.6	67.9	11			
0.0024	7.66	6.33	2.74	72	70.46	55.59	78	12			

0.0021	6.49	5.18	3	73.25	49.88	72	78.9	13	
0.00225	5.29	3.57	3.31	75.71	47.1	78.11	79.77	14	
0.0023	10.5	8.7	3.24	63.8	52.26	37.7	75.4	15	
0.00192	10.9	8.7	2.67	66.69	47.9	30.24	80.71	16	
0.00199	9.76	6.17	2.2	73.62	44	74.1	84.2	17	
0.0022	8.7	11.2	2.75	63.8	55.8	39.25	75.8	18	
0.00175	8.49	8.9	2.15	74.48	45.63	69.76	84.83	19	
0.00194	10.4	5.8	2.57	72.39	42.34	58	84.12	20	
0.00344	5.45	4.38	4.5	68.7	45.47	65.9	74.2	3	هطول (محطة الرجيلية) r1 هطول (محطة تل حوش) r2 هطول (محطة خليفة) r3 تبخر E مم/يوم حرارة T °C رطوبة rh %
0.00349	4.3	5.7	4.12	68.47	67.8	67.55	69.16	4	
0.00334	6.24	3.36	4.32	68.16	41.8	53.87	73.6	5	
0.00222	13.3	4.2	2.69	70.5	44.3	57.4	83.22	6	
0.00239	6.4	6.76	3.31	69.91	38.12	67.33	77.31	7	
0.00228	5	6.25	2.68	75.77	36	57.9	83.73	8	
0.00191	6.3	5.35	2.69	74.9	57.6	57.9	82	9	
0.00189	8	5.23	2.6	74.3	39.17	56.5	83.99	10	
0.00218	5.7	6.3	2.9	73.2	69.13	40.89	80	11	
0.00155	6.24	11	2.69	70.5	52.65	52.5	82	12	
0.00184	4.18	7.2	2.55	76.95	68.86	54.7	84.5	13	
0.00173	10.7	5.87	2.18	73.39	53.23	48.38	85.29	14	
0.00174	6.9	5.9	2.6	74.4	64.8	42.8	81.9	15	
0.00189	8.66	6	2.9	70	61.2	50	77.5	16	
0.00131	4.9	5.11	2.311	79.11	44.7	66.6	86.6	17	
0.00161	9	8.49	2.24	71.2	44.7	54.9	84.2	18	
0.00188	5.4	6.5	3.39	71.1	74.9	74.7	70.3	19	
0.00173	7	5.8	2.59	76.5	34.28	53	86.33	20	
0.00139	8.5	8.38	2.22	77.6	80.6	39.74	86.9	21	
0.00127*	7.4	4.43	2.33	77.8	31.6	76.8	86.3	22	
0.00148	6.38	7.4	3.6	75.5	63.4	55	82.7	23	
0.00138	10.2	6.86	2.57	72.9	48.16	53.3	84.9	24	
0.00135	6.3	8.4	2.32	74.2	42.8	68.5	83.2	25	

• نموذج يضم كلاً من نموذج (pure cause-and-effect models) (Global Model) ونموذج السلاسل الزمنية (Local Model):

استخدم في هذا النموذج شبكة عصبونية صناعية ذات معمارية مشابهة لمعمارية نموذج (pure cause-and-effect models). طبق هذا النموذج باستخدام شبكة NARX والتي تحتوي في طبقة المدخلات على كل من الهطول المطري عند المحطات الثلاثة، التبخر والحرارة والرطوبة عند محطة واحدة، والتصريف عند محطة واحدة وذلك باستخدام عدّة تأخرات زمنية للمدخلات. يظهر الجدول (3) أداء نموذج الشبكة العصبونية الصناعية هذا، حيث تبين أن الشبكة العصبونية الصناعية ذات المعمارية 21_24_1 تعطي أفضل أداء (أصغر قيمة لمتوسط لمربع الخطأ) 0.000162 من أجل المجموعات الثلاثة، ومعاملات ارتباط المجموعات الثلاث التدريب، التحقق والاختبار 93.32,91.16,95.64% على التوالي.

الجدول (3): أداء نموذج الشبكة الذي يضم كلاً من الموديل العام (Global Model) والموديل المحلي (Local Model)

الكل	متوسط مربع الخطأ MSE			الكل	معامل الارتباط R %			عدد العصبونات الخفية	التأخر (يوم)	المدخلات		
	مجموعة اختبار $*10^{-3}$	مجموعة تحقق $*10^{-3}$	مجموعة تدريب $*10^{-3}$		مجموعة اختبار	مجموعة تحقق	مجموعة تدريب					
0.000808	3.4	2.28	0.97	91.13	93.13	81.5	92.9	3	1	هطول (محطة الرجبيلية) r1 هطول (محطة تل حوش) r2 هطول (محطة خليفة) r3 تبخر E مم/يوم حرارة T °C رطوبة rh % التصريف Q م ³ /ثانية		
0.000769	2.66	1.5	0.93	91.94	86.74	89.27	93.93	4				
0.000853	0.924	1.33	1.09	93.13	92.8	89.3	93.96	5				
0.000883	1.7	4.71	0.965	89.78	87.64	85.2	93.6	6				
0.000873	3.64	0.69	0.996	91.52	88.88	92.27	92.74	7				
0.000733	4.55	9.27	1.6	84.6	75.36	79.4	92.79	8				
0.000474	3.36	1.65	0.54	92.94	83.75	89.73	96.41	9				
0.000637	0.884	0.97	0.766	94.97	92.3	92.36	95.78	10				
0.000507	3.54	2.59	0.69	91.72	82.78	89.3	95.4	11				
0.000428	4	0.46	0.5	93.77	81	96.75	96.9	12				
0.000375	3.7	1.37	0.6	92.8	85	87.11	96.32	13				
0.00043	2.44	1.56	0.6	93.6	81.89	90	96.4	14				
0.000494	2.16	2.15	0.74	92.72	85	89	95.6	15				
0.00047	2	2.11	0.73	93.17	85.76	91.69	95.45	16				
0.000341	4.67	3.5	0.5	90.5	79.79	85.16	96.6	17				
0.000363	2.86	1.65	0.57	93.41	84.43	84.27	96.85	18				
0.00038	2.84	2	0.94	91.7	87.5	81.4	94.64	19				
0.000368	1.84	7.12	0.68	88.42	80.23	71.16	95.64	20				
0.000664	1.76	1.52	1.16	92.43	87.68	89.82	93.79	3			1-2	هطول (محطة الرجبيلية) r1 هطول (محطة تل حوش) r2 هطول (محطة خليفة) r3 تبخر E مم/يوم حرارة T °C رطوبة rh % التصريف Q م ³ /ثانية
0.000675	7.4	1	0.8	90.18	88.46	91.76	94.8	4				
0.000362	2.63	1.44	0.5	94.1	85.4	90.8	96.9	5				
0.000313	1.17	1.77	0.926	93.2	88.7	88.2	94.7	6				
0.000322	5.24	2.39	0.39	91.63	84.15	80.64	97.62	7				
0.000444	2	1.79	0.71	93.68	93.56	90.75	95.59	8				
0.000225	1	2.8	0.69	93.4	92.8	85	95.94	9				
0.000338	1.98	3.3	0.41	93.24	91.74	83	96.95	10				
0.000301	2.6	1	0.59	94.1	77	88.21	97	11				
0.000266	2.55	3.12	0.639	92.19	93.6	83.5	95.39	12				
0.000273	3.4	3	0.56	91.3	83.46	89.49	95.19	13				
0.000319	2	3.75	0.44	92.68	88.57	78.69	97.3	14				
0.000147	3.88	3.54	0.47	91.3	84.6	77.37	96.99	15				
0.000383	1.47	0.96	1.24	92.32	92.5	94.43	92.39	16				
0.000391	1	1	0.58	95.52	91.13	91.15	96.82	17				
0.000292	0.83	0.47	0.62	96.16	90.95	92	97	18				
0.000287	1	1.53	1.16	94.11	91.88	92.28	94.75	19				
0.000274	1.4	1.64	0.49	95	93.53	90.43	97	20				

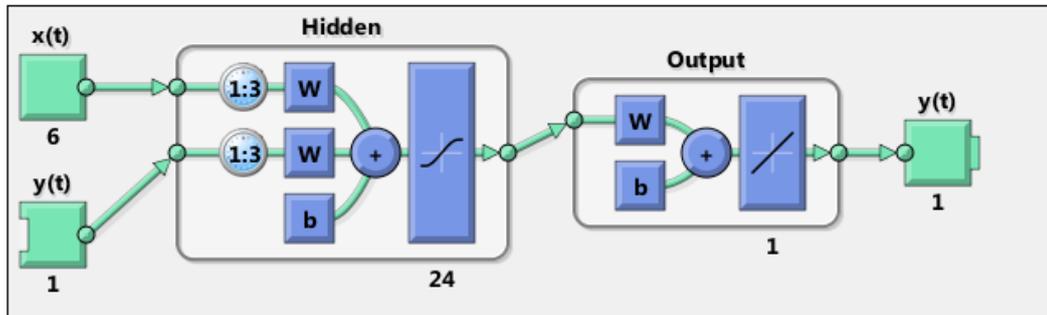
0.000497	2.14	1	0.616	94.4	91.11	95.52	95.26	3
0.000331	2.7	0.66	0.61	94.35	82.7	92.46	96.75	4
0.000304	1.77	3.2	0.37	93.74	88.4	78.4	97.77	5
0.000447	1.77	2.22	1.4	90.27	86.7	79.5	93.8	6
0.000464	1.66	2	0.84	92.9	89.6	92.8	94.2	7
0.000292	2.5	2.58	0.54	92.89	89	84.85	96.3	8
0.000175	1.74	3.17	0.84	91.7	86.3	78.28	95.45	9
0.000281	1.82	1.91	0.61	93.94	91.6	91.9	95.58	10
0.000302	1.24	1.24	0.88	94	94.7	92.8	94.25	11
0.000375	1.82	1.69	0.98	92.58	91.13	92.48	93.4	12
0.000213	3	1.22	0.85	92.7	89.4	93.2	94.98	13
0.000228	4.47	1.17	0.67	93.23	92.8	93.2	95.9	14
0.000256	1.58	3.67	0.92	90.92	89.4	90.77	93.35	15
0.000177	1.79	2.75	0.62	94	91.2	90.5	96.3	16
0.000239	2.66	1.81	0.68	92.9	90.2	93.4	94.48	17
0.000275	1.38	2.22	0.6	94	91	91.7	95.7	18
0.000163	4.34	0.86	0.45	93.77	89.5	92.85	96.99	19
0.000205	1.08	1.62	1.25	92.27	90.39	93.16	93.5	20
0.000198	0.98	1.53	1	93.6	92.8	90.9	94.6	21
0.000342	1.24	2.4	0.7	93.6	88.7	91.74	95.52	22
0.000196	1.35	2.31	1.14	93	94.55	91.99	93.5	23
0.000162**	2.26	2.46	1.46	94.1	93.69	91.16	95.64	24
0.000196	1.21	2.64	1.1	94	95.4	90	95.3	25
0.000144	0.83	0.46	0.37	96.16	95.4	96.75	97.77	

1-3

هطول (محطة الرجيلية) r1
هطول (محطة تل حوش)
r2
هطول (محطة خليفة) r3
تبخر E م/م/يوم
حرارة T °C
رطوبة rh %
التصريف Q م³/ثانية

بمقارنة أداء النموذجين (المذكورين أعلاه) يتبين أنّ أداء الشبكة يتحسن بشكل كبير عند إضافة قيم سابقة للتصريف إلى المدخلات، وبالتالي تكون أفضل معمارية للشبكة العصبونية الصناعية للبيانات قيد الدراسة هي

الشكل (9) . 21_24_1

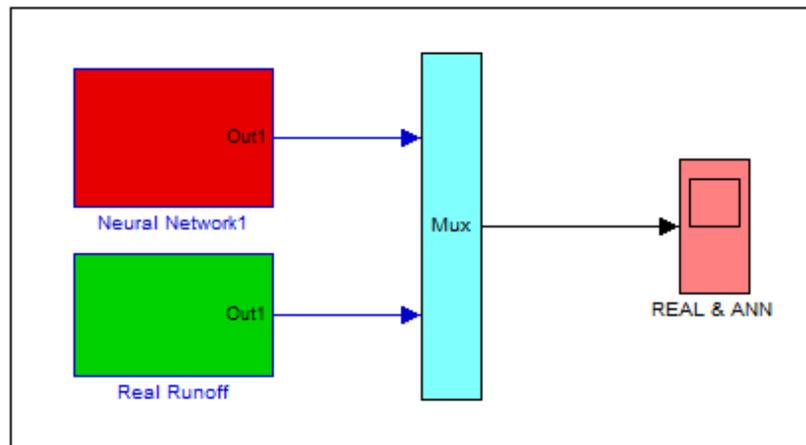


الشكل (9): يبين أفضل معمارية للشبكة العصبونية الصناعية للبيانات قيد الدراسة

تقويم أداء الشبكة العصبونية الصناعية المقترحة

يعدُّ فحص أداء أي نموذج رياضي مقترح من التطبيقات الاعتيادية والتقليدية في عملية النمذجة الرياضية، حيث يُقيّم حسن الأداء باستخدام الأساليب الإحصائية المعروفة، كحساب قيمة معامل الارتباط (R). ولغرض الاستفادة من التقانات الحديثة في إظهار المقارنة على شكل مرتسمات، اقترح بناء نموذج المحاكاة بالاستفادة من تقانة SIMULINK المتاحة في حزمة برمجيات MATLAB، حيث اختُصر نموذج المقارنة بوضع الشبكة العصبونية الصناعية على شكل قالب جاهز بسيط BLOCK، يحتوي على جميع مفردات الشبكة المقترحة في حزمة قوالب ثانوية يمكن إظهارها بسهولة.

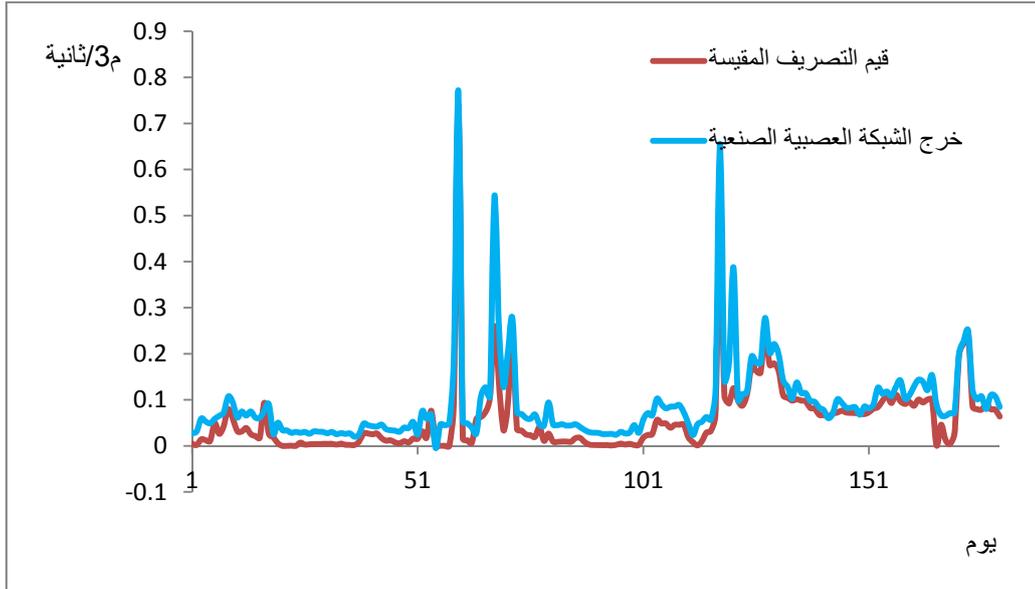
يبين الشكل (10) كيفية تركيب وبناء نموذج المحاكاة باستخدام تقانة Simulink حيث يظهر النموذج جمع كل من خرج الشبكة العصبونية الصناعية وقيم التصريف الحقيقية في قالب يسمى Mux، وبذلك يمكن ربطها بمرتسم واحد.



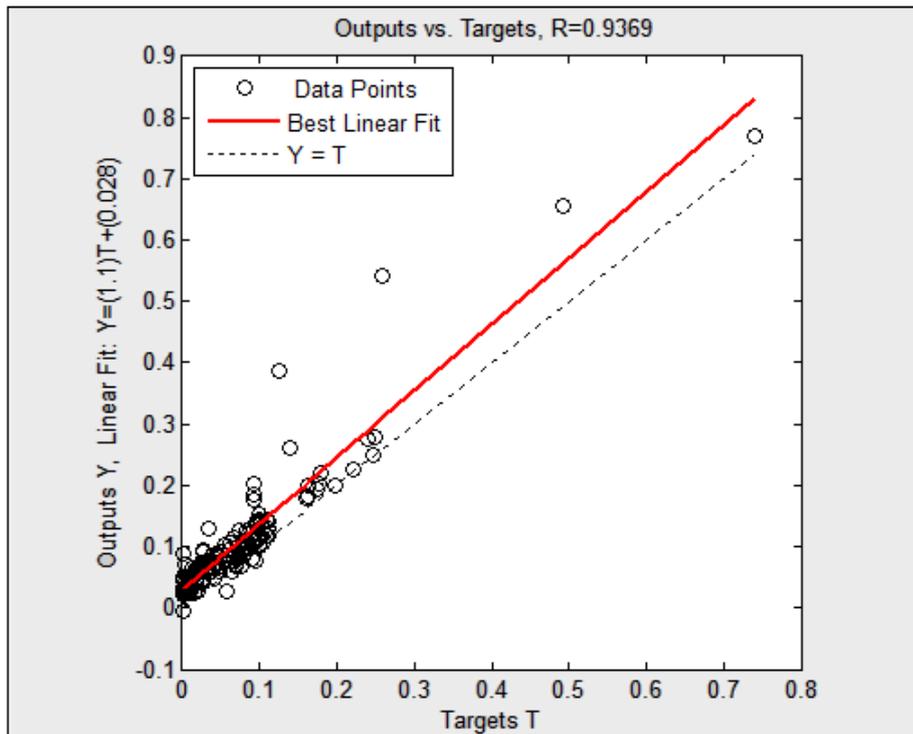
الشكل (10): يبين قالب الشبكة العصبونية الصناعية

نتائج نموذج المحاكاة:

تم اختبار نموذج الشبكة العصبونية الصناعية المشكل باستخدام مجموعة الاختبار التي تشكل نسبة 15% من البيانات، وذلك للتحقق من أداء الشبكة ومقارنة مخرجات الشبكة المشكلة مع القيم المقيسة كما هو موضح في الشكل (11)، حيث يلاحظ التوافق الأدائي بين نتائج الشبكة الصناعية والقيم الحقيقية للتصريف. كما يوضح الشكل (12) التوافق الخطي بين نتائج الشبكة العصبونية الصناعية والقيم المقيسة، حيث بلغت قيمة معامل الارتباط لمجموعة البيانات المختبرة (93.69%) فيما كان متوسط مربع الخطأ لنفس المجموعة 2.26×10^{-3} ، حيث تُظهر النتائج أداءً جيداً لنموذج الشبكة الصناعية المشكل في نمذجة العلاقة بين الهطول المطري _ الجريان النهري.



الشكل (11): قيم التصريف اليومي لحوض الكبير الجنوبي لمجموعة الاختبار المقيسة والناتجة من نموذج الشبكة العصبونية الصناعية المشكّل



الشكل(12): يبين التوافق الخطي بين قيم التصريف اليومية المقيسة وقيم التصريف اليومي المحسوبة بطريقة الشبكة العصبونية الصناعية لمجموعة الاختبار

الاستنتاجات والتوصيات:

✓ إن استخدام قيم التصريف السابقة في التنبؤ بقيم التصريف المستقبلية يزيد من دقة أداء الشبكة العصبونية الصناعية.

✓ يوجد توافق خطي بين مخرجات الشبكة العصبونية الصناعية وبيانات التصريف المقيسة، مما يبيّن إمكانية استخدام هذه التقانة في التنبؤ بقيم التصريف المستقبلية في حوض نهر الكبير الجنوبي.

✓ إنَّ استخدام تقانة Simulink في بناء نموذج المقارنة يتميّز بفائدة هندسية كبيرة من حيث السرعة والكفاءة العالية في بناء النماذج.

واعتماداً على نتائج البحث يمكن وضع التوصيات الآتية:

✓ استخدام الشبكة العصبونية الصناعية لإجراء تحليل الحساسية وذلك لاختبار المدخلات الأكثر تأثيراً على نتائج الشبكة.

✓ توسيع بناء شبكة عصبونية صناعية للتنبؤ بقيم التصريف بافتراض أسلوب التدريب دون إشراف.

✓ التوسع في استخدام الشبكات العصبونية لدراسة مسائل متنوّعة تتعلق بالموارد المائية في سورية.

المراجع:

- 1-Rientjes, T. H. M.؛ De Vos, N. J. *Constraints of artificial neural networks for rainfall-runoff modelling: trade-offs in hydrological state representation and model evaluation*. Hydrology and Earth System Sciences Discussions Belgium, 2005, 365–415.
- 2-Abbott, M. B.؛ Bathurst, J. C.؛ Cunge, J. A.؛ O’Connell, P. E.؛ Rasmussen, J. *An introduction to the european hydrological system – Systeme Hydrologique Europe’ en, “SHE”, 2: Structure of a physically-based, distributed modelling system*. 1986, 61–77.
- 3-Nash, J. E.؛ Sutcliffe, J. V. *River flow forecasting through conceptual models*. Journal of Hydrology 1970, 282–290.
- 4-Modarres, R. Multi-criteria validation of artificial neural network rainfall-runoff modeling. Hydrology & Earth System Science Iran, 2009, 411-421.
- 5-Viney, N. ؛Post, D. ؛Yang, A. ؛Willis, M. ؛Robinson, K. ؛Bennett, J. ؛Ling, F. ؛Marvanek, S. *Rainfall-runoff modelling for Tasmania*. CSIRO Australia, 2009, 1-47.
- 6-Nasri, M. *Application of Artificial Neural Networks (ANNs) in Prediction Models in Risk Management*. World Applied Sciences Journal Iran, Vol. 10, N^o .12, 2010, 1493-1500.
- 7-Jalal, J. ؛Hassan, S. *Monthly Runoff Estimation Using Artificial Neural Network*. Department of Civil Engineering, College of Engineering, Trivandrum, 2010, 1-14.
- 8-Arslan, C. *Rainfall-Runoff Modeling Based on Artificial Neural Networks (ANNs)*. European Journal of Scientific Research U. K. Vol. 65, N^o .4, 2011, 490-506.
- 9-Joshi, J. ؛Patel, V. *Rainfall-Runoff Modeling Using Artificial Neural Network*. National Conference on Recent Trends in Engineering & Technology India, 2011, 1-7.
- 10-Patil, S. ؛Valunjkar, S. *Study of Different Rainfall-Runoff Forecasting Algorithms for Better Water Consumption*. International Conference on Computational Techniques and Artificial Intelligence (ICCTAI) Malaysia, 2012, 327-329.
- 11-Dozier, A. *Influence of spatial variation in precipitation on artificial neural network rainfall-runoff model*. Hydrology Days U. S. A. 2012, 29-42.
- 12-Dhange, N. ؛Kadu, M. ؛Atmapoojya, S. *Rainfall Runoff Modelling Studies Using Artificial Neural Network*. International J. of Multidiscipl. Research & Advcs. in Engg. (IJMRAE) India, Vol. 4, N^o . I, 2012, 27-38.
- 13-Zijderveld, A. *Neural network design strategies and modelling in hydroinformatics*, Delft University of Technology Netherlands, 2003, 146.