

Integration of Artificial Neural Networks and Genetic Algorithms Models in Filling of Missing Precipitation Data

Dr. Ghaftan Abdalkareem Ammar^{*}
Alaa Ali Slieman^{**}
Amer Qusai Aldarweesh^{***}

(Received 23 / 4 / 2019. Accepted 28 / 10 / 2019)

□ ABSTRACT □

Accurate and reliable modeling of precipitation data is an important step in managing water and rivers, especially under the influence global climate change. This requires long time series of hydrological data, but these sequences often contain missing values. This research includes the using of artificial neural networks (ANNs) models with feed forward and back propagation of error with genetic algorithms (GAs) in the process of filling gaps in daily precipitation data, where genetic algorithms were used to determine the optimal structure of the artificial neural network, after that artificial neural networks were trained using the back propagation algorithm, in order to obtain the best performance of the artificial neural network models (ANNs) in predicting the lost values of daily precipitation, thus obtaining complete time series of daily precipitation in the study area.

The values of root mean square errors and correlation coefficients were used to evaluate the performance of the models and compare them according to the different input and output values of the meteostations (Satha -Ain Al-Krum-Al-Kareem-Al-Sakilibia) during the period (1994-2002), simulating the various possible losses of data from the meteostation. This study recommends the application of hybrid systems of artificial intelligence models to improve the efficiency of predicting models of weather factors and other water resources factors in different regions of Syria.

Keywords: Precipitation, Filling, genetic algorithms, Artificial neural networks, Back-propagation algorithm, predicting.

^{*}Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria, ghatfan62@gmail.com

^{**}Academic Assistant, Department of Water Resources Engineering and Management, Faculty of Civil Engineering, al-Baath University, Homs, Syria, alaa-slieman@hotmail.com.

^{***}Academic Assistant, Department of Water Resources Engineering and Management, Faculty of Civil Engineering, al-Baath University, Homs, Syria, aldarwesh92@gmail.com

تكامل نماذج الشبكات العصبية الاصطناعية والخوارزميات الجينية في استكمال بيانات الهطل المطري

د. غطفان عبد الكريم عمار*

علاء علي سليمان**

عامر قصي الدرويش***

تاريخ الإيداع 23 / 4 / 2019. قُبِلَ للنشر في 28 / 10 / 2019

□ ملخص □

لا شك أن نمذجة الأمطار بدقة وموثوقية هي خطوة هامة في إدارة المياه والأنهار، ومواجهة تغيرات المناخ العالمية، وهذا يتطلب سلاسل طويلة من البيانات الهيدرولوجية، غير أن هذه السلاسل في كثير من الأحيان تحوي على قيم مفقودة. يتضمن هذا البحث استخدام نماذج الشبكات العصبية الاصطناعية ذات التغذية الأمامية والانتشار العكسي للخطأ مع الخوارزميات الجينية (GAS) في عملية ملء الثغرات في بيانات الأمطار اليومية في منطقة سهل الغاب، حيث استخدمت الخوارزميات الجينية في تحديد الهيكلية المثلى للشبكة العصبية الاصطناعية، ثم دربت مجموعة من الشبكات العصبية الاصطناعية وفق الهيكلية الناتجة باستخدام خوارزمية الانتشار العكسي للخطأ، وذلك بهدف الحصول على أفضل أداء لنماذج الشبكات العصبية الاصطناعية (ANNS) في التنبؤ بالقيم المفقودة للأمطار اليومية، وبالتالي الحصول على سلاسل كاملة للهطل المطري اليومي في منطقة الدراسة. لقد استخدمت قيم جذر متوسط مربعات الأخطاء، ومعامل الارتباط لتقييم أداء النماذج والمقارنة فيما بينها وفق مختلف قيم المدخلات والمخرجات للمحطات المطرية (شطحة - عين الكروم - الكريم - السقيلية) خلال الفترة (2002-1994)، بحيث تحاكي مختلف حالات الفقد الممكنة للبيانات من المحطة الهدف أو المحطات المجاورة، وتوصلت هذه الدراسة إلى نتائج جيدة لجميع النماذج، وتوصي الدراسة بتطبيق الأنظمة الهجينة من نماذج الذكاء الاصطناعي لتحسين كفاءة نماذج التنبؤ بالعناصر المناخية وغيرها من العوامل المتعلقة بالموارد المائية في مناطق مختلفة من سورية.

الكلمات المفتاحية: الهطل المطري، ملء الثغرات، الخوارزميات الجينية، الشبكات العصبية الاصطناعية، الانتشار العكسي، التنبؤ.

* أستاذ، قسم الهندسة المائية والري، كلية الهندسة المدنية، جامعة تشرين، اللاذقية، سورية، ghatfan62@gmail.com
** قائم بالأعمال، قسم هندسة وإدارة الموارد المائية، كلية الهندسة المدنية، جامعة البعث، حمص، سورية
alaa-slieman@hotmail.com
*** قائم بالأعمال، قسم هندسة وإدارة الموارد المائية، كلية الهندسة المدنية، جامعة البعث، حمص، سورية
aldarwesh92@gmail.com

مقدمة:

يُعدّ الهطل المطري من أهم وأكثر المدخلات تأثيراً في مختلف الدراسات المتعلقة بهندسة وإدارة الموارد المائية، كما يُعتبر من أكثر العناصر الهيدرولوجية تأثيراً من ناحية التقدير والتنبؤ، ويُظهر ذلك أهمية الحصول على سلاسل كاملة للهطل المطري في مناطق الدراسة، ولهذا الأمر أُجريت العديد من الدراسات حول ايجاد نماذج قادرة على التقدير والتنبؤ وسد الثغرات في السلاسل المائية، وقد نالت نماذج الذكاء الاصطناعي النصيب الأكبر من مجالات البحث، وخاصةً ما يتعلّق منها بالشبكات العصبية الاصطناعية والخوارزميات الجينية، حيث وضع (El-Shafie et ali., 2001) أنموذجين من نماذج التنبؤ بهطول الأمطار في مدينة الإسكندرية في جمهورية مصر العربية، تتضمن نماذج الشبكات العصبية الاصطناعية (ANNs)، والانحدار الخطي المتعدّد (MLR)، حيث استخدم نموذج الشبكات العصبية أمامية التغذية (FFNN) مع خوارزمية الانتشار العكسي للخطأ (Backpropagation) للتنبؤ بالأمطار السنوية والشهرية (January, December)، واشتملت الدراسة على القياسات اليومية لهطول الأمطار ودرجة الحرارة في الفترة الممتدة من عام 1957 وحتى 2009، حيث بلغت النسبة المئوية للخطأ (RE) لنموذج (FFNN) وجذر متوسط مربعات الأخطاء (RMSE)، للتنبؤات السنوية (32.04،±20 mm) على الترتيب، كما بلغت لشهر كانون الثاني (2.82،±10 mm)، وشهر كانون الأول (10.04،±20 mm)، على الترتيب [1].

في حين استخدم (Zekai & Ahmet, 2001) الخوارزميات الجينية في عمليات التصنيف والتنبؤ بهطول الأمطار الشهرية بالاعتماد على قيم سرعة الرياح، نقطة الندى، درجة الحرارة والرطوبة النسبية، وأظهرت النتائج أنّ الخوارزميات الجينية قد أعطت نتائج أفضل من الطرائق التقليدية الأخرى مثل (discriminant analysis) [2]. واستخدم (Nasseri et ali., 2008) الخوارزميات الجينية في أمثلة الشبكات العصبية الاصطناعية للتنبؤ بالهطل المطري في المحطات المطرية غرب سيدني، وكانت نتائج هذا الدمج بين الشبكات العصبية الاصطناعية والخوارزميات الجينية أفضل من نتائج استخدام الشبكات العصبية بشكل منفرد [3].

في حين استخدم (Hung et ali., 2009) بيانات الأمطار الساعية، ومزيج من العناصر المناخية المختلفة، في بناء نموذج شبكة عصبية اصطناعية ذات تغذية أمامية للتنبؤ بالهطل المطري الساعي وإدارة الفيضان في بانكوك في تايلاند، وأظهرت النتائج بأنّ توقعات هطول الأمطار من 1-3 ساعات كانت مرضية للغاية بدقة $RMSE=(0.87-1.72 \text{ mm/hr})$ ، وأشار تحليل الحساسية إلى أنّ أهم مدخل إلى جانب الأمطار هو درجة حرارة الهواء الرطب [4].

وأجرى (Nkuna and Odiyo 2011) دراسة في حوض نهر Luvuvhu في جنوب أفريقيا، بهدف ملء بيانات الأمطار اليومية المفقودة خلال أزمّة مختلفة بالاعتماد على خمس محطات مجاورة، وقد تمّ ذلك باستخدام الشبكات العصبية الاصطناعية ((ANNs) المعتمدة على الأساس الشعاعي (Radial Basis Function) RBFNN وخوارزمية (Shuffled Complex Evolution) SCE)، كما حدّد تجانس قيم الهطول في المحطة الهدف مع المحطات الخمس المجاورة باستخدام منحنى التكامل المزدوج، ولم تُظهر كلّ المحطات علاقة جيّدة مع المحطة الهدف، ومع ذلك فإنّ البيانات المحددة للتدريب والاختبار أخذت من جميع المحطات، وقد أعطت نتائجاً جيّدة وفق المقاييس المعتمدة، حيث تراوح معامل الكفاءة بين (0.55-0.95)، وجذر متوسط مربع الخطأ RMSE بين (0.91-7.50 mm) [5].

وتنبأ (Terzi, O. & Cevik, E. 2012) بالأمطار الشهرية الكلية في مدينة إسبارطة اليونانية باعتماد نموذجين من الشبكات العصبية الاصطناعية هما: الشبكات ذات التغذية الأمامية والشبكات متعددة الطبقات (MLR Feed Forward ANNs & Forward ANNs)، ووضعت نماذج مختلفة باختلاف المدخلات (2،3،4 مدخلاً) المأخوذة من سجلات أربع

محطات مناخية منتشرة في المدينة، وأشارت النتائج إلى أن النموذج (ANN) مع هيكلية (4-3-1) أي مع أربعة مدخلات من المحطات الأربع يقدم أعلى قيمة لمعامل الارتباط (0.83) وأقل قيمة لجذر متوسط مربعات الأخطاء (RMSE=185.57mm) لمجموعة اختبار البيانات خلال الفترة (1997-2005) [6].

أما (Wambua et ali., 2016) فقد قاموا بصياغة نماذج مختلفة من الشبكات العصبية الاصطناعية باستخدام مزيج من التأخرات الزمنية لبيانات التدفق والهطول في حوض نهر تانا العلوي في كينيا، وأظهرت النتائج أن أفضل نموذج للتنبؤ ببيانات التدفق المفقودة كان مع معامل ارتباط (0.732)، في حين كان أفضل نموذج للتنبؤ بقيم الأمطار مع معامل ارتباط (0.79)، وعند تقييم الارتباط المكاني والزمني للبيانات المفقودة في دقة التنبؤات، أشارت النتائج إلى أفضل استخدام الارتباط المكاني مع نماذج الشبكات العصبية [7].

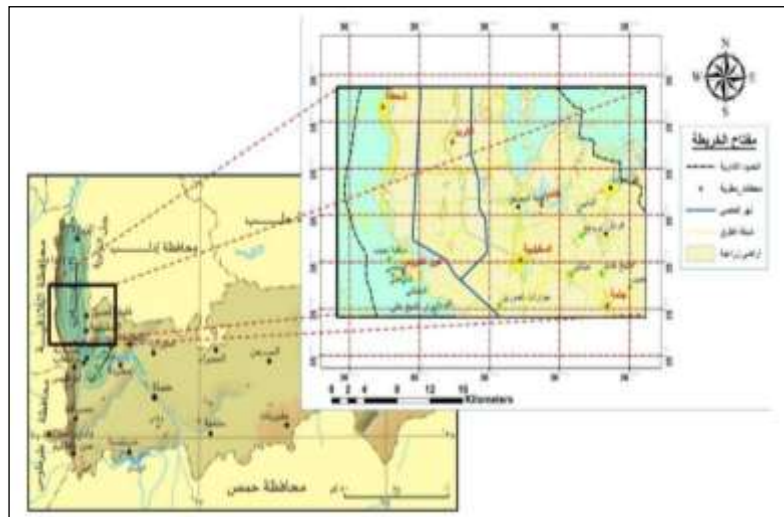
أهمية البحث وأهدافه:

تكمن أهمية البحث في الحاجة إلى إيجاد نماذج قادرة على استكمال بيانات الهطل المطري المفقودة في المحطات المناخية، حيث تعتبر بيانات الهطل المطري من البيانات الأساسية للبدء بمختلف أنواع الدراسات المتعلقة بهندسة وإدارة الموارد المائية.

ولذلك تهدف هذه الدراسة إلى استخدام نماذج الشبكات العصبية الاصطناعية ذات التغذية الأمامية والانتشار العكسي للخطأ (FFBP-ANN) مع الخوارزميات الجينية (GAs) في عملية ملء الثغرات في بيانات الأمطار اليومية في محطة عين الكروم في سهل الغاب.

موقع منطقة البحث:

جمعت البيانات من محطة مدينة حمص المناخية التي تقع في المنطقة الوسطى من الجمهورية العربية السورية، على ارتفاع 483 m عن مستوى سطح البحر، وعلى خط عرض (34° 45') شمالاً وخط طول (36° 43') شرقاً، ويبين الشكل (1) موقع المحطة المدروسة.



الشكل (1): موقع منطقة الدراسة.

طرائق البحث ومواده:

اعتمدت هذه الدراسة على استخدام الخوارزميات الجينية في عملية تدريب الشبكات العصبية الاصطناعية وأمثلة أوزانها، من أجل إعداد نماذج استكمال الهطل المطري اليومي في محطة عين الكروم، وفيما يلي شرح لأهم الطرائق المستخدمة في هذا البحث.

الشبكات العصبية الاصطناعية (ANNs)


تُعدّ الشبكات العصبية الاصطناعية من أهمّ مجالات الذكاء الاصطناعي، وهي عبارة عن أنموذج رياضي مبني على مفهوم الشبكات العصبية الحيويّة، حيث تتكون من مجموعة من العصبونات الاصطناعية التي تحاكي سير ومعالجة المعلومات في العقل البشري.

تختلف الشبكات العصبية من ناحية البنية الهندسية أي الطريقة التي ترتبط بها العصبونات في كل طبقة من طبقات الشبكة مع بعضها البعض لتشكل الشبكة العصبية حيث تؤثر هذه البنية على مخرجات الشبكة. وقد وُجد أن الشبكات العصبية متعددة الطبقات (Multiple Layer Neural Networks) تكون ذات فعالية أكبر في الحسابات لذا فهي واسعة الاستخدام، ويمكن لهذا النوع من الشبكات حل العديد من المشاكل المعقدة غير أن تدريبها يستغرق وقتاً أطول، ويتم تحديد عدد طبقات الدخل والخرج وعدد الطبقات المخفية وعدد العصبونات في كل طبقة من هذه الطبقات بحسب طبيعة المسألة المراد دراستها [8].

يقسم عمل العصبون الاصطناعي إلى مرحلتين أساسيتين:

المرحلة الأولى: ويتم فيها معالجة المدخلات حيث يقوم العصبون بضرب كل مدخل من المدخلات بوزن معين يتم تحديده عشوائياً كمرحلة أولية للتدريب، ومن ثم تتم عملية جمع المدخلات الموزونة ويضاف إليها عامل انحياز (b) وذلك للحصول على قيم موجبة للمرحلة الأولى.

المرحلة الثانية: تتولى معالجة مخرجات المرحلة السابقة وهي عبارة عن دوال رياضية تدعى بدوال التفعيل (Activation Function) حيث تحتوي كل من الطبقات المخفية وطبقة الخرج على دالة تفعيل يتم اختيارها تبعاً لطبيعة المسألة (الشكل 2).



الشكل (2): آلية عمل العصبون الاصطناعي.

وهناك العديد من دوال التفعيل التي تحدد ما هي قيمة المخرجات الممكن استنتاجها من قيم المدخلات، تصلح كل واحدة من هذه الدوال لنوع معين من التطبيقات بالاعتماد على المجال المحدد لها، وتعتبر دوال التفعيل (tan- sigmoid, log-sigmoid, pure Training) من أكثر دوال التفعيل المستخدمة في بناء الشبكات العصبية الاصطناعية [8]. إن الشبكات العصبية لا تُبرمج وإنما تُدرَّب، ويمكن أن يتم ذلك من خلال العديد من خوارزميات التدريب (Algorithms) التي تتولى تعديل أوزان الشبكة لتقليل الأخطاء فيها، وتعتبر خوارزمية الانتشار العكسي للخطأ (Back Propagation Algorithm) من أهم تلك الخوارزميات وأكثرها انتشاراً، وفيما يلي مراحل عمل هذه الخوارزمية [9]:


1. إدخال قيم معينة للدخل إلى الشبكة غير المدربة، حيث تقوم هذه الشبكة بإجراء الحسابات اللازمة للجمع الموزون وتطبيق دالة التفعيل وحساب قيمة الخرج، وتبعاً لذلك فإننا سنحصل على قيمة عشوائية للخرج من الشبكة .
2. حساب دالة الخطأ بين قيمة الخرج التي تم الحصول عليها في الخطوة الأولى وقيمة الخرج المطلوبة.
3. لتقليل قيمة دالة الخطأ يتم تعديل الأوزان في طبقة الخرج أولاً في اتجاه تقليل الخطأ ثم نشر أو نقل هذا الخطأ إلى الطبقة السابقة وتعديل الأوزان عند مداخل هذه الطبقة، وحساب قيم الخرج للشبكة مرة ثانية في الوضع الجديد وحساب دالة الخطأ باستخدام الخرج الجديد والخرج المطلوب، وتعديل الأوزان مرة أخرى في طبقة الخرج ثم نقل الخطأ الجديد إلى الطبقة التي قبلها وهكذا.

ويتم تكرار التعليم عدد من المرات حتى يصبح الخرج المحسوب مساوياً للخرج المطلوب وتتلاشى دالة الخطأ، أو تصبح قيمة هذا الخطأ ضمن الحدود المسموح بها والمحددة مسبقاً.

يعد عدد مرات التكرار هو المقياس لكي تتعلم الشبكة ويطلق على هذا النوع من تعليم الشبكة بالتعليم الموجه أو التعليم بإشراف (Supervised Learning).

تقسم الشبكات العصبية الاصطناعية ذات التغذية الأمامية من حيث اتجاه إجراء الحسابات المطلوبة إلى:

1. الشبكات العصبية الاصطناعية ذات التغذية الأمامية (Feedforward ANNs): الشكل (3).
 2. الشبكات العصبية الاصطناعية ذات التغذية الخلفية (Feedbackward ANNs):
- حيث يقصد بالتغذية الأمامية أن انتشار البيانات في الشبكة يكون دائماً باتجاه الأمام من طبقة الدخل إلى طبقة الخرج، أما في التغذية الخلفية فتعاد البيانات الخارجة من الشبكة لتصبح من المدخلات.



الشكل (3): شبكة عصبية اصطناعية ذات تغذية أمامية.

الخوارزميات الجينية (GAs) Genetic Algorithms

يعتمد أسلوب الخوارزمية الجينية في حل المسائل على أفكار مستنبطة من علم الوراثة، والتي تهتم بشكل عام بكيفية إنتاج أفراد جديدة تمتلك صفات معينة (مرغوبة أو غير مرغوبة) وذلك من خلال التداخل أو التعديل أو التبديل الذي يحصل على المجموعات الموروثة بهدف تكوين أفراد جديدة تختلف في صفاتها عن الآباء [10].

توجد ثلاث مراحل أساسية للخوارزميات الجينية [11]:

1. يجب ترميز الحلول المطروحة للمسألة بإحدى طرق الترميز (الكروموزوم) بما يناسب المسألة المطروحة، وهذا ما يسمى الخريطة الوراثية.

على سبيل الذكر، سنعدد بعض هذه الطرائق الشهيرة والناجحة المستخدمة في ترميز الحلول وهي: الترميز الثنائي Binary Encoding، ترميز التبادل permutation Encoding، ترميز القيمة Real Value Encoding، ترميز الشجرة Tree Encoding.

2. الانتقاء (Selection): نختار بشكل عشوائي المجتمع البدئي، ثم باستخدام تابع اللياقة أو الكفاءة (fitness) الذي يستخدم لاختيار الحلول ولتقييمها، نحدد الكروموزوم الذي يملك الكفاءة الأعلى ونهمل غيره.


توجد عدة طرائق لتحديد كيفية انتقاء الكروموزوم الأمثل، على سبيل المثال: عجلة الروليت Roulette wheel Selection، انتقاء بولتزمان Boltzman selection، tournament selection، انتقاء الحالة المستقرة Steady state selection.... الخ.

3. المؤثرات (العمليات) الجينية (التصالب Crossover، والطفرة Mutation): نقوم بإجراء التصالب بين الكروموزومات المختارة والتي تابع الأمثلة لها هو الأفضل، لتوليد جيل جديد مؤلف من كروموزومات جديدة بدلاً من التي تم استبعادها، تستخدم الطفرة على أحد كروموزومات الجيل الناتج لضمان عدم الوقوع في نهاية محلية. يمكن الجمع بين الشبكات العصبية والخوارزميات الجينية بعدة طرق، حيث استخدمت الخوارزميات الجينية في معظم الأحيان لتوليد الأوزان من الشبكة العصبية، ولتحدي هيكلية الشبكة العصبية، وكذلك في توليد كل من بينية وأوزان الشبكة العصبية في نفس الوقت [12].

أما بالنسبة للمقارنة بين النماذج وتحديد الأنموذج الأفضل ذو الدقة الأعلى فيوجد العديد من المعايير، وفي هذه الدراسة تم اعتماد قيم جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R.

النتائج والمناقشة:

جمعت البيانات اللازمة للدراسة من محطات (عين الكروم، الكريم، السقيلية، شطحة) والتي تقع جميعها ضمن منطقة الاستقرار الأولى في سهل الغاب ضمن محافظة حماه في الجمهورية العربية السورية، وتضمنت البيانات على القيم اليومية للهطل المطري خلال الفترة من 1994/1/1 وحتى 2003/11/30، ويبين الشكل (2) القيم اليومية المستخدمة التي تم الحصول عليها من محطة عين الكروم.



الشكل (2): بيانات الهطل المطري اليومي في محطة عين الكروم.

وبعد ذلك تم إنشاء مجموعة فقد عشوائية بنسبة 10% تم افتراضها لمحاكاة وجود مشكلة الفقد في المحطة الهدف (محطة عين الكروم) والمحطات المجاورة، وبعد ذلك قُسمت البيانات المتبقية إلى ثلاث مجموعات للتدريب والتحقق والاختبار بنسبة (15:15:70) على الترتيب. ثم اقترح 7 نماذج تحاكي مختلف حالات الفقد الممكنة في المحطات المجاورة للمحطة الهدف، فكانت المدخلات والخرجات للنماذج كما هو مبين في الجدول (1).

الجدول (1): مدخلات ومخرجات النماذج.

	Ein Alkroum	Alkriem	Alsqelbyeh	Shatha
Model 1	target	input	-	-
Model 2	target	-	input	-
Model 3	target	-	-	input
Model 4	target	input	input	-
Model 5	target	input	-	input
Model 6	target	-	input	input
Model 7	target	input	input	input

وبعد ذلك بُني عدد كبير جداً من النماذج مع التغيير في عدد العصبونات في الطبقة الخفية، وتوابع التفعيل في الطبقة الخفية وطبقة الخرج، ثم دُرِّبَت هذه النماذج باستخدام الشبكات العصبية الاصطناعية بالاعتماد على خوارزمية التدريب ذات التغذية الأمامية والانتشار العكسي للخطأ.

كما تم استخدام الخوارزميات الجينية في عملية أمثلة أوزان الشبكة العصبية الاصطناعية، الأمر الذي ساعد في تسريع الوصول إلى الهيكلية المثلى للشبكة وفق مختلف الحالات المقترحة، حيث اعتبرت مصفوفة أوزان الشبكة ممثلة للبروموسوم الذي ستعتمده الخوارزمية الجينية خلال النمذجة، فيكون الهدف هو الحصول على أقل قيمة لمتوسط مربعات الأخطاء (أي مسألة تصغير).

استُخدمت طريقة عجلة الروليت في اختيار الآباء، كما تم استخدام طريقة التصالب ذو النقطتين بنسبة عبور 0.8، أما بالنسبة للطفرات فقد أُخذت أيضاً بعين الاعتبار بنسبة 0.01، ويبين الجدول (2) البارامترات والمواصفات المعتمدة للتدريب سواء بالنسبة للخوارزميات الجينية أو للشبكات العصبية الاصطناعية.

الجدول (2): البارامترات والمواصفات المعتمدة لتدريب النماذج.

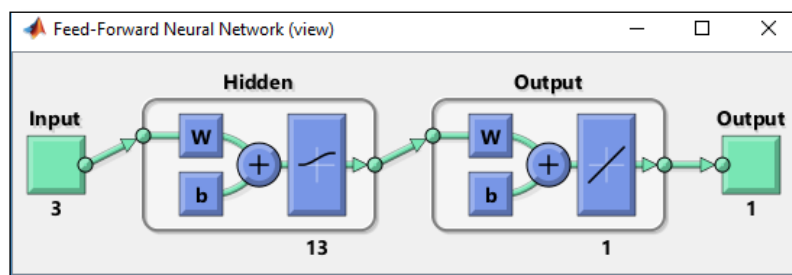
Network Parameters	Description
Neural Networks	Feed-Forward Back-Propagation
n. Neurons	From 2 to 20
Transfer function	tansig; logsig; purelin
Search method	GA
Population size	100
Fitness function	MSE
Probability of crossover	0.8
Probability of mutation	0.01
Crossover technique	Two point
Selection method	Roulette wheel selection

ويبين الجدول (3) الهيكلية المثلى للشبكة وتوابع التفعيل المستخدمة فيها، وقيم جذر متوسط مربعات الأخطاء فيها خلال مراحل التدريب والتحقق والاختبار، وذلك في كل حالة من الحالات السبع المقترحة.

الجدول (3): هيكلية النماذج المقترحة وقيم جذر متوسط مربعات الأخطاء لها.

Network Archi.	Activation Function		RMSE (mm/day)			
	Hidden Layer	Output Layer	Train Dataset	Validation Dataset	Test Dataset	
Model 1	1:14:1	Logsigmoid	Logsigmoid	4.18	4.57	3.60
Model 2	1:12:1	Logsigmoid	pureline	5.31	5.47	4.67
Model 3	1:12:1	Tansigmoid	pureline	3.79	3.49	4.56
Model 4	2:15:1	Tansigmoid	Logsigmoid	3.99	3.21	4.97
Model 5	2:15:1	Tansigmoid	pureline	3.46	2.60	2.66
Model 6	2:13:1	Tansigmoid	pureline	3.60	3.32	3.14
Model 7	3:13:1	Tansigmoid	pureline	2.51	3.80	4.60

ويُظهر الشكل (3) المخطط الهيكلية للشبكة المقترحة وفق النموذج رقم 7، حيث يحتوي على 3 عصبونات في طبقة الدخل يقابلها 13 عصبون في الطبقة الخفية وعصبون وحيد في طبقة الخرج، واستُخدم فيها تابع التفعيل Tansigmoid في الطبقة الخفية و pureline في طبقة الخرج.



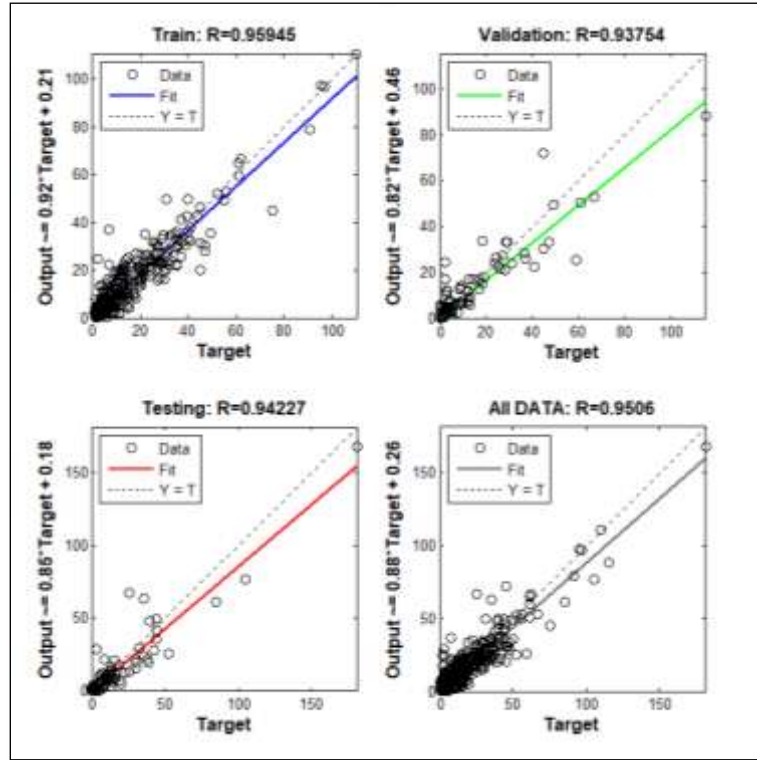
الشكل (3): المخطط الهيكلي للشبكة المقترحة وفق النموذج رقم 7.

أما الجدول (4) فيبين قيم معاملات الارتباط خلال مراحل التدريب والتحقق والاختبار وفق مختلف الحالات المقترحة.

الجدول (4): قيم معاملات الارتباط للنماذج المقترحة.

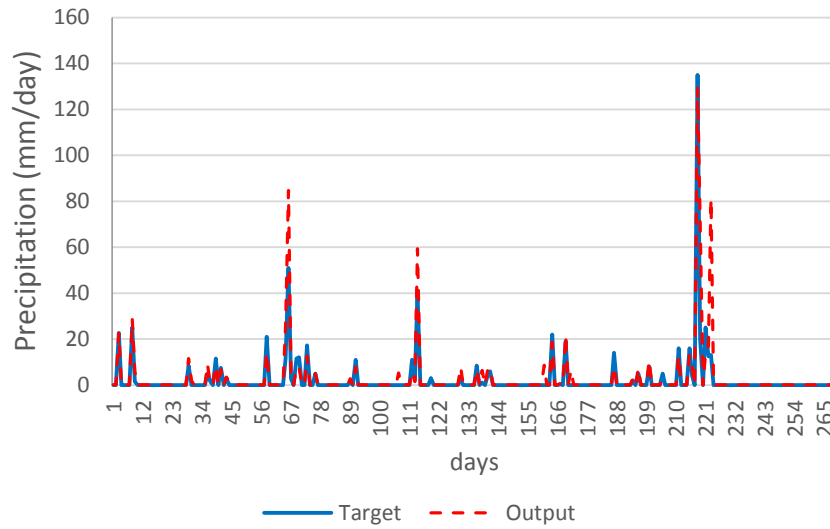
	R (%)		
	Train Dataset	Validation Dataset	Test Dataset
Model 1	90.97	85.65	93.08
Model 2	84.50	87.16	82.88
Model 3	93.79	88.80	85.00
Model 4	89.76	91.73	93.67
Model 5	94.68	95.17	94.28
Model 6	94.32	91.68	91.80
Model 7	95.94	93.75	94.23

حيث بلغت معاملات الارتباط في الأتمودج 7: 95.9% خلال مرحلة التدريب، و93.7% خلال مرحلة التحقق، و94.2% خلال مرحلة الاختبار (الشكل 4).



الشكل (4): قيم معاملات الارتباط للأنموذج رقم 7 خلال مختلف مراحل بناء الشبكة.

ويظهر الشكل (5) قيم الهطل المطري الحقيقية والمتنبأ بها وفق النموذج 7 خلال مجموعة فقد عشوائية تم افتراضها لمحاكاة وجود مشكلة الفقد في المحطة الهدف بحيث لم تدخل هذه القيم في مراحل تدريب وتحقق واختبار الشبكة.



الشكل (5): قيم الهطل المطري الحقيقية والمتنبأ بها وفق النموذج 7 خلال مجموعة فقد عشوائية تم افتراضها لمحاكاة وجود مشكلة الفقد في المحطة الهدف بحيث لم تدخل في مراحل تدريب وتحقق واختبار الشبكة.

الاستنتاجات والتوصيات

- أظهرت النتائج قدرة الشبكات العصبية الاصطناعية على استكمال قيم الهطل المطري اليومي في محطة عين الكروم في سهل الغاب بمعاملات ارتباط عالية تجاوزت 90% خلال مراحل التحقق لمختلف النماذج المقترحة.
- أظهرت النتائج أهمية استخدام الخوارزميات الجينية في عملية تدريب نماذج الشبكات العصبية الاصطناعية، وذلك من خلال تقليل الجهد والزمن المطلوبين في الوصول إلى الهيكلية المثلى للشبكة وفق مختلف النماذج.
- تسمح لنا النماذج المقترحة باستكمال بيانات الهطل المطري المفقودة في محطة عين الكروم في مختلف حالات توفر بيانات هطل مطري في المحطات المجاورة لها.
- توصي هذه الدراسة بإدخال نماذج المنطق الضبابي في الدراسات المتعلقة باستكمال البيانات المفقودة للهطل المطري.

المراجع:

1. EI-SHAFIE, A. H; EI-MAZOGHI, H. G; SHEHATA, A; TAHA, M. R. Artificial neural network technique for rainfall forecasting applied to Alexandria, Egypt. International Journal of the Physical Sciences, 2001, Vol. 6, NO.6, PP 1306-1316.
2. ZEKAİ ŞEN & AHMET ÖZTOPAL. Genetic algorithms for the classification and prediction of precipitation occurrence, Hydrological Sciences Journal, 2001, 46:2, 255-267, DOI: 10.1080/02626660109492820
3. NASSERI, M; ASGHARI, K; ABEDINI, M.J. Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network, Expert Systems with Applications, (2008) 1415–1421.
4. HUNG, N.Q; BABEL, M. S; WEESAKUL, S; TRIPATHI, N. K. An artificial neural network model for rainfall forecasting in Bangkok, Thailand. Hydrology and Earth System Sciences 13.8, 2009, 1413-1425.
5. Nkuna, T.R; Odiyo, J.O. Filling of missing rainfall data in Luvuvhu River Catchment using artificial neural networks. Physics and Chemistry of the Earth 36, 2011, PP 830:835.
6. TERZI, O; CEVIK, E. Rainfall estimation using artificial neural network method. International Journal of Technological Science, 2012, Vol.4, No.1, PP 10-19.
7. WAMBUA, R. M; MUTUA, M. M; RAUDE, J. M. Prediction of Missing Hydro-Meteorological Data Series Using Artificial Neural Networks (ANN) for Upper Tana River Basin, Kenya. American Journal of Water Resources, 2016, Vol. 4, No. 2, PP 35:43.
8. عبد المحسن، كامل علي؛ توفيق، أيمن رافع محمّد. شبكة عصبية اصطناعية لتشغيل نظام خزن منفرد . AL-Rafidain Engineering ، المجلد 22، العدد 2، 2013، 29-37.
9. الشراقوي، محمد علي. الذكاء الاصطناعي والشبكات الصناعية. الكتاب الأول ضمن سلسلة علوم وتكنولوجيا حاسبات المستقبل، مركز الذكاء الاصطناعي للحاسبات، 356.
10. PHILIP, A; TAOFIKI A. A, KEHINDE, O. A Genetic Algorithm for Solving Travelling Salesman Problem. (IJACSA) international journal of advanced computer science Applications, Vol. 2, No. 1, 2011.
11. KOEHN, P. Combining Genetic Algorithms and Neural Networks: The Encoding Problem. A Thesis Presented for the Master of Science Degree the University of Tennessee, Knoxville, 1994.

12. BLANCO, A; DELGADO, M; PEGALAJAR, M.C. A genetic algorithm to obtain the optimal recurrent neural network. International Journal of Approximate Reasoning 23, Spain, 2000, 67-83.