

Filling of Missing Daily Precipitation Data in Tal-Kalakh Station Using Artificial Neural Networks

Dr. Ghatfan Abdalkareem Ammar ⁱ

Alaa Ali Slieman ⁱⁱ

Aamer Qusai Aldarwesh ⁱⁱⁱ

(Received 26 / 9 / 2018. Accepted 10 / 2 / 2019)

□ ABSTRACT □

Precipitation datasets are basic for all studies that related with the design of water structures and water balance studies. However, losses in these data or gaps in the time series is an obstacle to conducting these studies in the optimal manner, the aim of this study is to fill the Daily Precipitation data in Tal-Kalakh station using Artificial Neural Networks (ANNs), which Daily Precipitation in other meteostations around it as inputs. The network was trained and verified using a back-propagation algorithm with different learning methods, number of processing elements in the hidden layer(s), and the number of hidden layers. Results shown good ability of Artificial Neural Network models to estimate of the daily precipitation values with different inputs, the correlation coefficient was over 90 % for the validation data set in all models. This study recommends using the artificial neural networks approach to identify the most effective parameters to predict Precipitation.

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

ⁱ Professor, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria, ghatfan62@gmail.com.

ⁱⁱ Postgraduate student, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria, alaa-slieman@hotmail.com.

ⁱⁱⁱ Postgraduate student, Department of Water Engineering and Irrigation, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria, aldarwesh92@gmail.com.

استكمال قيم الهطل المطري اليومية المفقودة في محطة تكلخ

باستخدام الشبكات العصبية الاصطناعية

(هذا البحث ممول كلياً من قبل صندوق دعم البحث العلمي والتطوير التقاني في وزارة التعليم العالي)

د. غطفان عبد الكريم عمارةⁱ

علاء علي سليمانⁱⁱ

عامر قصي الدرويشⁱⁱⁱ

(تاريخ الإيداع 26 / 9 / 2018. قُبِلَ للنشر في 10 / 2 / 2019)

□ ملخص □

تعتبر بيانات الهطل المطري من البيانات الأساسية لكافة الدراسات المتعلقة بتصميم المنشآت المائية ودراسات الموازنة المائية للأحواض الساكبة، إلا أنّ وجود ضياعات في هذه البيانات أو ثغرات ضمن السلاسل الزمنية يشكّل عائقاً لإجراء هذه الدراسات بالشكل الأمثل، تهدف هذه الدراسة إلى استكمال قيم الهطل المطري اليومية في محطة تكلخ المناخية باستخدام الشبكات العصبية الاصطناعية، التي تستخدم القيم اليومية للهطل المطري في المحطات المجاورة كمدخلات، وقد استُخدمت خوارزمية الانتشار العكسي في عملية تدريب وتحقيق الشبكة مع تغيير طرائق التدريب وعدد الطبقات الخفية وعدد العصبونات في كل طبقة منها، وأظهرت النتائج قدرة نماذج الشبكات العصبية الاصطناعية على استكمال القيم اليومية المفقودة للهطل المطري، وبمعاملات ارتباط تزيد على 90% خلال مراحل التحقق لمختلف النماذج. وتوصي هذه الدراسة باستخدام أسلوب الشبكات العصبية الاصطناعية لتحديد العناصر الأكثر تأثيراً على استكمال بيانات الهطل المطري المفقودة.

الكلمات المفتاحية: الهطل المطري، الشبكات العصبية الاصطناعية، خوارزمية الانتشار العكسي، الاستكمال.

ⁱ أستاذ في قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية ghatfan62@gmail.com

ⁱⁱ قائم بالأعمال معاون في قسم هندسة وإدارة الموارد المائية - كلية الهندسة المدنية - جامعة البعث - حمص - سورية

alaa-slieman@hotmail.com

ⁱⁱⁱ قائم بالأعمال معاون في قسم هندسة وإدارة الموارد المائية - كلية الهندسة المدنية - جامعة البعث - حمص - سورية

aldarwesh92@gmail.com

مقدمة

تعتبر بيانات الهطل المطري من البيانات الأساسية لكافة الدراسات المتعلقة بتصميم المنشآت المائية ودراسات الموازنة المائية للأحواض الساكبة وغيرها من أنواع دراسات الموارد المائية، إلا أنّ وجود نقصان في هذه البيانات أو ثغرات ضمن السلاسل الزمنية يشكّل عائقاً لإجراء هذه الدراسات بالشكل الأمثل.

وقد شكّل ذلك دافعاً للعديد من الباحثين والمختصين للبحث عن أفضل التقانات الحديثة بهدف إيجاد نماذج تتيج إمكانية ملاءمة ومحاكاة سلوك الظاهرة واستكمال البيانات الناقصة فيها، بما يكفل حسن إدارتها وترشيد استخدامها في القطاعات المختلفة، فأجريت العديد من الدراسات في هذا المجال، حيث استخدم (Kuligowski and Barros, 1998) نماذج الشبكات العصبية الاصطناعية ذات الانتشار العكسي Backpropagation Neural Network، لإيجاد البيانات المكانية المفقودة للهطل المطري بالاعتماد على البيانات المأخوذة من أجهزة القياس المجاورة خلال الفترة (1978-1993)، واختبروا أداء النموذج للتنبؤ بهطول الأمطار لـ 6 ساعات قادمة، بربط نقطة القياس بست نقاط أخرى في الولايات المتحدة الأمريكية، كما قُسمت السنة إلى أربعة فصول ليتمّ تقييم أداء النموذج تحت ظروف جوية مختلفة، وبالمقارنة مع الطرائق التقليدية لاستيفاء البيانات مثل: (طريقة الجار الأقرب Earest-Neighbor، والمتوسط الحسابي لأقرب خمسة مقاييس، وطريقة مقلوب مربع المسافة Inverse Distance Squared Weighting، والانحدار الخطي Linear Regression)، أظهرت النتائج تفوق الشبكات العصبية في مختلف الظروف الجوية [1].

وحاول (Guhathakurta, 2000) التنبؤ بالأمطار الموسمية، والحصول على التنبؤات طويلة المدى، فوق منطقتين متجانستين شمال غرب الهند وشبه الجزيرة الهندية، ضمن دائرة الأرصاد الجوية الهندية (IMD (The India Meteorological Department)، ووُجد أنّ النماذج الإحصائية كانت ناجحة في السنوات العادية للأمطار الموسمية، وفشلت بشكل ملحوظ خلال السنوات ذات الأمطار الموسمية الشديدة، في حين كان أداء الشبكات العصبية الاصطناعية أفضل في جميع الظروف [2].

ووضع (Hung et ali., 2009) نموذج شبكة عصبية اصطناعية ذات تغذية أمامية (FeedForward ANN) للتنبؤ بالهطول المطري كل ساعة، وإدارة الفيضان في بانكوك في تايلاند، بالاعتماد على بيانات الأمطار الساعية لـ 4 سنوات، ومزيج من العناصر المناخية المختلفة، وأظهرت النتائج بأنّ توقّعات هطول الأمطار من 1-3 ساعات كانت مرضية للغاية بدقة $RMSE=\{0.87-1.72\}$ mm/hr، وأشار تحليل الحساسية إلى أنّ أهم مدخل إلى جانب الأمطار هو درجة حرارة الهواء الرطب [3].

واقترح (Moustris, K & Ioanna K, L. 2011) أحد أنواع الشبكات العصبية أمامية التغذية من النوع Perceptron متعدّدة الطبقات (MLP) مع خوارزمية (Back Propagation)، مع استخدام بيانات الأمطار الشهرية لأربع محطات مناخية (Alexandroupolis, Thessaloniki, Athens, Patras) في اليونان كمداخلات للنموذج، بغرض التنبؤ بقيم الهطول العظمى والصغرى والوسطية والتراكمية (Cumulative precipitation prediction) خلال أربعة أشهر متتالية مُقبلة، وأظهرت اختبارات التنبؤ في المواقع الأربعة، توافقاً جيداً بدلالة إحصائية ($P < 0.01$) في حين أنّ معامل الارتباط لم يتجاوز (0.603) في محطة (Patras) خلال الفترة بين عام (1980-1992) والذي صنّف كأفضل أداء للنماذج المقترحة [4].

أما (Nkuna and Odiyo 2011) فأجروا دراسة في حوض نهر Luvuvhu في جنوب أفريقيا، بهدف ملء بيانات الأمطار اليومية المفقودة خلال أزمدة مختلفة بالاعتماد على خمس محطات مجاورة، وقد تم ذلك باستخدام الشبكات العصبية (ANNS) المعتمدة على الأساس الشعاعي (Radial Basis Function (RBFNN) وخوارزمية Shuffled Complex Evolution (SCE)، كما حُددت تجانس قيم الهطول في المحطة الهدف مع المحطات الخمس المجاورة باستخدام منحنى التكامل المزدوج، ولم تُظهر كل المحطات علاقة جيدة مع المحطة الهدف، ومع ذلك فإن البيانات المحددة للتدريب والاختبار أُخذت من جميع المحطات، وقد أعطت نتائجاً جيدة وفق المقاييس المعتمدة، حيث تراوح معامل الكفاءة (Nash–Sutcliffe Efficiency (NSE) بين (0.55–0.95)، وجذر متوسط مربع الخطأ RMSE بين (0.91mm–7.50mm) [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 (Feed MLR Forward ANNS &)، ووضعت نماذج مختلفة باختلاف المدخلات (3,4,2 مدخلاً) المأخوذة من سجلات أربع محطات مناخية منتشرة في المدينة، وأشارت النتائج إلى أن النموذج (ANN) مع هيكلية (1–3–4) 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].

وطور (Al-hashimi, 2014) ثلاثة نماذج للتنبؤ بالهطل المطري في محطة كركوك في العراق، بالاعتماد على نماذج الانحدار الذاتي التكاملية مع المتوسطات المتحركة (ARIMA)، ونماذج الشبكات العصبية الاصطناعية (ANN)، والانحدار الخطي المتعدد (MLR)، بالاعتماد على القيم السابقة للهطول المطري ومتوسط درجات الحرارة، سرعة الرياح والرطوبة النسبية في الفترة من 1970 إلى 2008، وبيّنت النتائج أفضلية نموذج الشبكات العصبية الاصطناعية وذلك من خلال المقارنة بين معاملات الارتباط خلال مرحلة التحقق والتي بلغت (0.91، 0.85، 0.823) للنماذج الثلاثة على الترتيب [7].

وقام (Wambua et ali., 2016) بصياغة نماذج مختلفة من الشبكات العصبية الاصطناعية باستخدام مزيج من التأخرات الزمنية لبيانات التدفق والهطول في حوض نهر تانا الأعلى في كينيا، وأظهرت النتائج أن أفضل نموذج (ANN) للتنبؤ ببيانات التدفق المفقودة قد أعطى 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 أفضلية استخدام الارتباط المكاني مع نماذج الشبكات العصبية [8].

أهمية البحث وأهدافه

تعود أهمية البحث إلى ضرورة إيجاد طريقة قادرة على استكمال بيانات الهطل المطري اليومي المفقودة في المحطات المناخية والمطرية، حيث تعد هذه البيانات نقطة البداية في أغلب الدراسات والأبحاث المتعلقة بالموارد المائية، لأنه من الضروري أن تكون هذه البيانات كاملة وذات وثوقية عالية. يهدف البحث إلى وضع نموذج شبكة عصبية اصطناعية لاستكمال قيم الهطل المطري اليومي في محطة تلكلخ المناخية، بالاعتماد على بيانات الهطل المطري اليومي في المحطات المناخية والمطرية المجاورة والتي تقع ضمن نفس منطقة الاستقرار (منطقة الاستقرار الأولى).

موقع منطقة البحث

تتبع مدينة تالكخ إدارياً إلى محافظة حمص في المنطقة الوسطى من الجمهورية العربية السورية، وفيها تقع محطة تالكخ المناخية على ارتفاع 869 m عن مستوى سطح البحر، وهي تصنف ضمن منطقة الاستقرار الأولى بمعدل هطول سنوي 820.1 mm ، ويبيّن الشكل (1) توزّع المحطات المناخية والمطرية ضمن منطقة الدراسة.



الشكل (1) : توزّع المحطات المطرية في منطقة الدراسة.

طرائق البحث ومواده

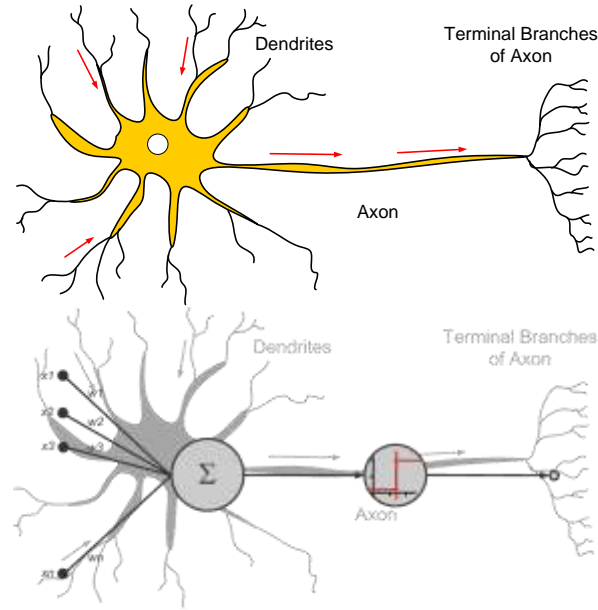
تعتمد الشبكات العصبية البيولوجية لدى الإنسان على الخلية العصبية Neuron كوحدة بنائية أساسية لها، والتي تتكوّن من جسم الخلية Soma والليف العصبي لمدخل الخلية Dendrites والذي يحمل الإشارات من مخارج خلايا عصبية أخرى إلى مداخل هذه الخلية عن طريق مشابك Synapses للتوصيل، ومن ثم الليفة العصبية الوحيدة للمخرج Axon والتي تحمل النبضة الخارجة من الخلية إلى الخلايا الأخرى [9].

في حين تعتمد الشبكات العصبية الاصطناعية على نموذج عنصر حسابي Processing Element مكافئ للخلية العصبية البيولوجية، حيث يقوم بمحاكاة لعمل النيرون الطبيعي من تجميع للإشارات الموزونة عند المدخل، ومن ثم مقارنة المجموع بقيمة حدية داخلية Threshold، ويبيّن الشكل (2) مقارنة بين الشبكات العصبية البيولوجية والاصطناعية.

مكونات الشبكات العصبية الاصطناعية

تعتمد الشبكات العصبية الاصطناعية في بنائها على، [10]:

- طبقة الدخل Input layer: وتحتوي هذه الطبقة على عدد من العصبونات تقابل المدخلات المطلوبة للشبكة.
- طبقة مخفية واحدة أو أكثر Hidden layer: تضيف المرونة إلى عمل الشبكة.
- طبقة الخرج Output layer: والتي تحتوي على عدد من العصبونات يقابل العناصر الهدف المطلوبة.



الشكل (2): مقارنة بين الشبكات العصبية البيولوجية والاصطناعية.

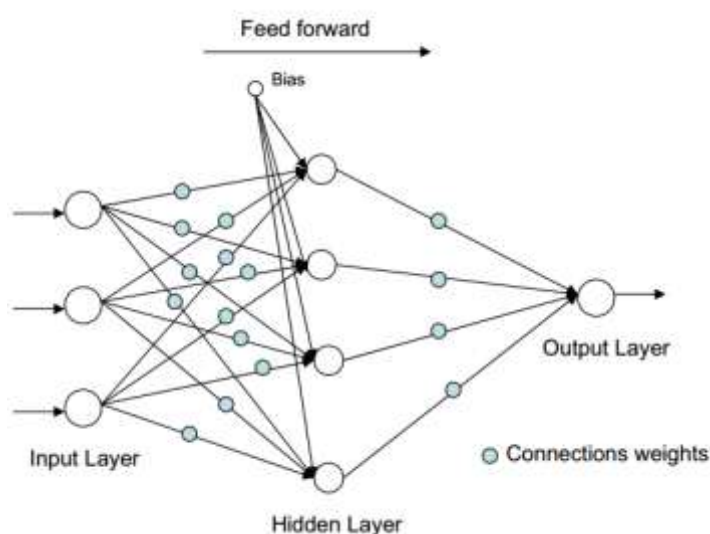
أنواع الشبكات العصبية الاصطناعية

يوجد العديد من أنواع الشبكات العصبية الاصطناعية التي تستخدم في معالجة الأنماط المختلفة للبيانات، ولكل نوع من هذه الأنواع خصوصية من ناحية الهيكلية وآلية معالجة المعلومات من خلال عدد ونوع العقد في كل طبقة، بالإضافة إلى نوع دوال التفعيل (Activation Function) المستخدمة وآلية تعديل الأوزان (Weights).

وتقسم الشبكات العصبية الاصطناعية من حيث اتجاه إجراء الحسابات المطلوبة إلى:

- الشبكات العصبية الاصطناعية ذات التغذية الأمامية (Feed forward ANNs)
- الشبكات العصبية الاصطناعية ذات التغذية الخلفية (Feed backward ANNs)

وتعدّ الشبكات العصبية الاصطناعية ذات التغذية الأمامية من أكثر أنواع الشبكات العصبية استخداماً، حيث يتكوّن هذا النوع من الشبكات من طبقتين على الأقل، كما توجد في غالب الأحيان طبقة مخفية أو أكثر بين طبقتي الدخل والخرج، وسُمّي هذا النوع من الشبكات بهذا الإسم لأنّ جهة انتقال البيانات وإجراء العمليات الحسابية يكون إلى الأمام من طبقة الدخل للشبكة إلى طبقة الخرج عبر الطبقات المخفية، (الشكل 3).



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

خوارزميات التدريب للشبكات العصبية الاصطناعية

يمكن أن تتم عملية التدريب للشبكات بشكل عام بإحدى الطريقتين الآتيتين:

▪ التدريب الموجّه Supervised Learning

▪ التدريب غير الموجّه Unsupervised Learning

وتعتبر خوارزمية الانتشار العكسي للخطأ Error Back-Propagation Algorithm من أفضل خوارزميات التدريب الموجّه للشبكات العصبية الاصطناعية ذات التغذية الأمامية، حيث أنّ هذه الخوارزمية تعتمد على عرض مجموعة بيانات التدريب على الشبكة العصبية على شكل أزواج لمدخلات ومخرجات الشبكة، ثم تستخدم الفرق بين مخرجات الشبكة والقيم الحقيقية في حساب الخطأ وتعديل الأوزان للعصبونات في الطبقات الأولى لتقليل الخطأ، ثم تكرار العملية عدد كبير من المرات حتى الوصول إلى الهيكلية المثلى [11].

تقييس البيانات

إنّ الهدف الرئيسي من عملية تقييس البيانات هو تثبيت مجالات تغير مُدخلات النماذج ضمن مجال واحد، وذلك قبل إدخالها إلى الشبكة، الأمر الذي يُسهل من تدريب النماذج، ويُمكن إجراء عملية التقييس بعدّة طرائق، وفي هذه الدراسة تمّ اعتماد المعادلة الآتية في عملية التقييس [12]:

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

وذلك حيث P : القيمة الأصلية. P_{norm} : القيمة بعد التقييس. P_{mean} : متوسط القيم. P_{max} : أعلى قيمة. P_{min} : أدنى قيمة.

معايير التقويم للنماذج

يوجد العديد من المعايير للمقارنة بين نماذج الشبكات العصبية وتحديد الشبكة ذات الدقة الأفضل، وفي هذه الدراسة تمّ اعتماد قيم جذر متوسط مربعات الأخطاء RMSE ومعامل الارتباط R، والتي تُعطى بالعلاقات كما يلي [13]:

$$RMSE = \left[\frac{\sum_{i=1}^n (p_i - o_i)^2}{N} \right]^{0.5} \quad (3)$$

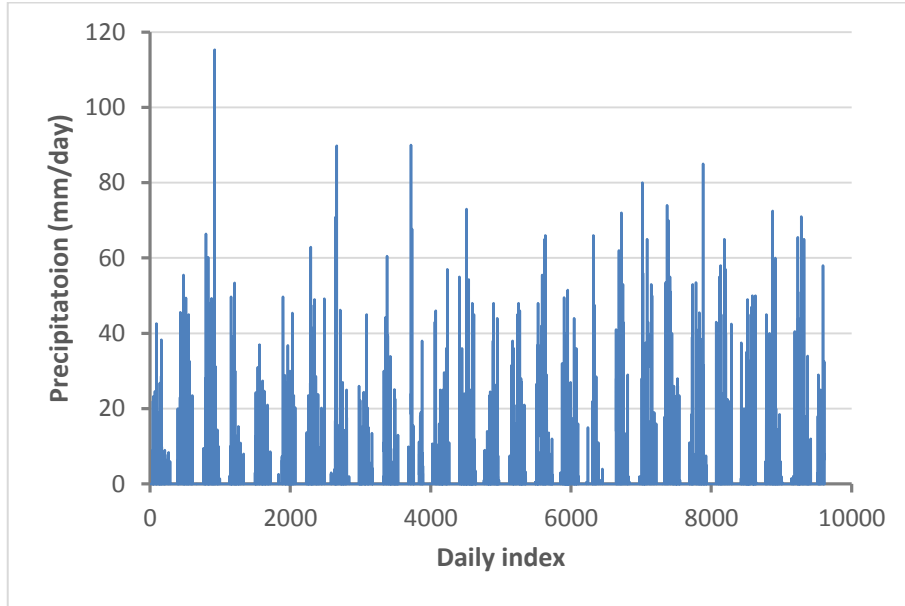
$$R = \frac{\sum_{i=1}^n (p_i - \bar{p})(o_i - \bar{o})}{\left[\sum_{i=1}^n (p_i - \bar{p})^2 \cdot \sum_{i=1}^n (o_i - \bar{o})^2 \right]^{\frac{1}{2}}} \quad (4)$$

حيث أن : p_i : القيمة المتنبأ بها. \bar{p} : المتوسط الحسابي للقيم المتنبأ بها. N : عدد البيانات .
 o_i : القيمة المقاسة. \bar{o} : المتوسط الحسابي للقيم المقاسة.

استُخدم برنامج Matlab 2014a في عملية بناء النماذج للشبكات العصبية، وبرنامج SPSS في الدراسة الإحصائية وإيجاد معاملات الارتباط.

النتائج والمناقشة

جُمعت في البداية بيانات الهطل المطري اليومية في محطة تلكلخ والمحطات المطرية والمناخية المجاورة لها والتي تقع ضمن منطقة الاستقرار الأولى [العريضة، مرميتا، الحصن، الناصرة، شين، المزينة]، ويبيّن الشكل (4) بيانات الهطل المطري التي تم الحصول عليها من محطة تلكلخ (9614 قيمة من 1985/9/1 وحتى 2011/12/31).



الشكل (4): بيانات الهطل المطري اليومي في محطة تلكلخ المناخية.

ويبيّن الجدول (1) الثوابت الإحصائية لبيانات الهطل المطري في محطة تلكلخ والمحطات المجاورة.

الجدول (1): الثوابت الإحصائية لبيانات الهطل المطري اليومي في المحطات المدروسة.

	المزينة	شين	الناصره	الحصن	مرمرينا	العريضة	تلكلخ
الارتفاع عن سطح البحر (m)	423	828	628	663	435	256	278
المعدل السنوي (mm/year)	1070.6	1053.8	1209.2	927.4	1189	857.7	820.1
المتوسط الحسابي (mm/day)	2.93	2.21	2.81	2.66	2.39	2.47	2.27
الانحراف المعياري	10.33	8.17	9.63	9.34	8.58	8.75	8.06
أكبر قيمة	91.6	146	129	108	150	125	85

أُجريت بعد ذلك دراسة معاملات الارتباط بين قيم الهطل المطري كقيم يومية في محطة تلكلخ والمحطات المطرية المجاورة، وبيّن الجدول (2) معاملات الارتباط الناتجة.

الجدول (2): معاملات الارتباط بين قيم الهطل المطري في محطة تلكلخ والمحطات المطرية المجاورة.

	المزينة	شين	الناصره	الحصن	مرمرينا	العريضة	تلكلخ
تلكلخ	0.286	0.806	0.793	0.778	0.83	0.883	1
العريضة	0.295	0.78	0.775	0.753	0.815	1	
الحصن	0.314	0.863	0.85	0.854	1		
مرمرينا	0.237	0.854	0.914	1			
الناصره	0.228	0.854	1				
شين	0.2	1					
المزينة	1						

ويظهر من هذا الجدول القيم العالية لمعاملات الارتباط بين قيم الهطل المطري في معظم المحطات والتي تتجاوز 75%، يُستثنى منها محطة المزينة والتي أعطت معاملات ارتباط منخفضة مع جميع المحطات المجاورة لها، ولذلك استثنيت بيانات هذه المحطة من الدراسة ولم تُستخدم ضمن مدخلات النماذج لاحقاً.

بعد ذلك تمت معالجة البيانات إحصائياً وتضمنت هذه المرحلة تقييس البيانات (Normalization) لتوحيد مجالات التغير للمدخلات ضمن مجال واحد واستخدم في ذلك المعادلة رقم (1) المذكورة سابقاً، ثم قُسمت البيانات الناتجة إلى ثلاث مجموعات للتدريب والتحقق والاختبار وفق النسب الآتية على التوالي: [70%، 20%، 10%]، حيث أنّ هذه النسب أعطت أفضل النتائج وفق اختبار أولي أُجري لتحديدها.


وأدخلت هذه البيانات كمدخلات ومخرجات لنماذج الشبكات العصبية، حيث بُني عدد كبير من النماذج مع التغيير في هيكلية الشبكة بما يتضمن عدد المدخلات في طبقة الدخل وعدد العصبونات في الطبقة الخفية، حيث تمّ الاعتماد على محطات الدخل وفقاً لارتباطها مع المحطة الهدف، وكذلك تمّ التغيير في توابع التفعيل في الطبقة الخفية وطبقة الخرج، وخوارزمية التدريب للشبكة، ويوضّح الجدول (3) معايير التقويم وآلية اختيار الأنموذج الأفضل من بين أفضل النماذج وذلك في حال اعتماد 5 عصبونات في طبقة الدخل.

الجدول (3): معايير التقويم لأفضل النماذج وفق حالة 5 عصبونات في طبقة الدخل.

الهيكلية	تابع التفعيل	RMSE (mm/day)				R (%)			
		Tr.	V.	Ts.	All	Tr.	V.	Ts.	All
5:6:1	Tan Sig.	3.19	3.71	4.24	3.41	89.8	91.4	85.4	89.8
5:6:1	Log Sig.	3.22	3.70	4.37	3.45	89.7	91.4	84.6	89.5
5:7:1	Tan Sig.	3.20	3.64	4.32	3.42	89.8	91.7	84.6	89.7
5:8:1	Tan Sig.	3.12	3.64	4.50	3.39	90.3	91.6	83.6	89.9

Tr. : Train Dataset V. : Validation Dataset Ts. : Test Dataset

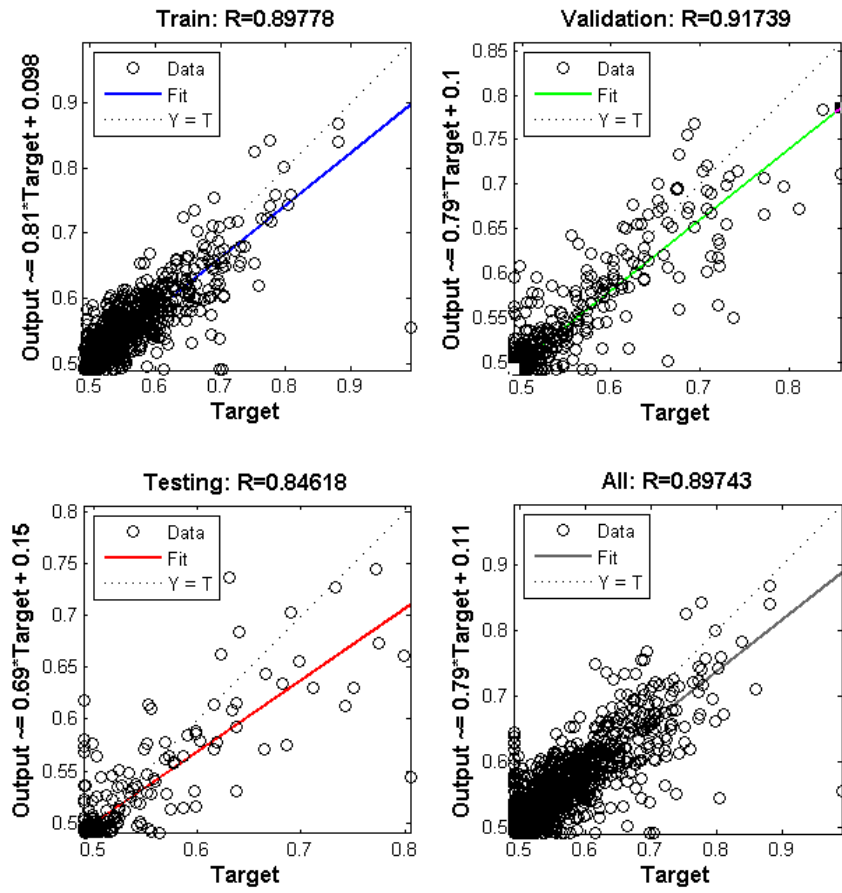
حيث يظهر من هذا الجدول التقارب الكبير بين معايير تقويم النماذج، مع الأفضلية البسيطة لأنموذج الشبكة العصبية الاصطناعية ذات الهيكلية 5:7:1 أي التي تحتوي على 7 عصبونات في طبقة الدخل (الشكل 5).



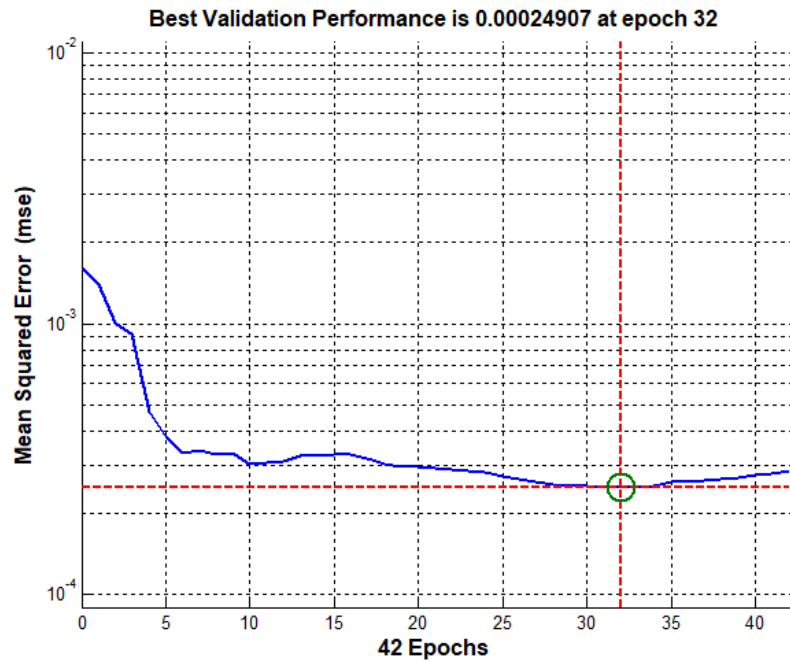
الشكل (5): معاملات الارتباط بين البيانات المقيسة ومخرجات النموذج المقترح.

وتم هذا الاختيار تبعاً للأفضلية في مرحلة التحقق والتي يتم على أساسها إيقاف التدريب، حيث بلغت قيمة جذر متوسط مربعات الأخطاء لهذا النموذج 3.20 mm/day خلال مرحلة التدريب، و 3.64 mm/day خلال مرحلة التحقق، و 4.32 mm/day خلال مرحلة الاختبار، في حين بلغت معاملات الارتباط 89.8% خلال مرحلة التدريب، و 91.7% خلال مرحلة التحقق، و 84.6% خلال مرحلة الاختبار (الشكل 6).

إن إيقاف التدريب لنماذج الشبكات اعتمد على أداء مجموعة التحقق، حيث يتم اعتماد الدورة التكرارية التي تُعطي أقل قيمة خطأ خلال مرحلة التحقق، وذلك كما هو مبين في الشكل (7)، الذي يُظهر أن أفضل أداء للشبكة 5:7:1 خلال مرحلة التحقق كان عند الدورة التكرارية 32، حيث كانت قيمة جذر متوسط مربع الخطأ المقيس تساوي 0.00024907.



الشكل (6): معاملات الارتباط بين البيانات المقاسة ومخرجات الأنموذج ذو الهيكلية (5:7:1).



الشكل (7): اعتماد الدورة التكرارية الأفضل وفق أداء مجموعة التحقق.

وينفس الطريقة أُجريت الدراسة وفق الأنماط الأخرى للمدخلات، حيث تم الاعتماد في كل حالة على المحطات الأكثر ارتباطاً مع المحطة الهدف، وهي كما في الجدول (2) محطات العريضة ثم مرميتا ثم شين ثم الناصرة ثم الحصن وفق ترتيب الأولوية، وذلك بعد استبعاد محطة المزينة.

وبعد إجراء عدد كبير جداً من التجارب تم تحديد أفضل النماذج وفق مختلف أنماط المدخلات، وبيّن الجدول (4) معايير التقويم لأفضل النماذج.

الجدول (4): معايير التقويم لأفضل النماذج وفق مختلف أنماط المدخلات.

رمز النموذج	عدد المدخلات	الهيكلية	RMSE (mm/day)				R (%)			
			Tr.	V.	Ts.	All	Tr.	V.	Ts.	All
A	5	5:7:1 *	3.20	3.64	4.32	3.42	89.8	91.7	84.6	89.7
B	4	4:10:1 *	3.27	3.88	4.54	3.54	89.9	91.2	82.8	89.0
C	3	3:6:1 **	3.54	3.93	4.22	3.69	87.3	91.0	85.5	87.9
D	2	2:6:1 *	3.83	3.90	3.80	3.84	85.0	90.8	88.3	86.8
A. المدخلات هي بيانات المحطات (العريضة، مرميتا، شين، الناصرة، الحصن).						دلالات الرموز				
B. المدخلات هي بيانات المحطات (العريضة، مرميتا، شين، الناصرة).										
C. المدخلات هي بيانات المحطات (العريضة، مرميتا، شين).										
D. المدخلات هي بيانات المحطات (العريضة، مرميتا).										

* النموذج يستخدم تابع التنعيل TanSigmoid في الطبقة الخفية.										
** النموذج يستخدم تابع التنعيل LogSigmoid في الطبقة الخفية.										

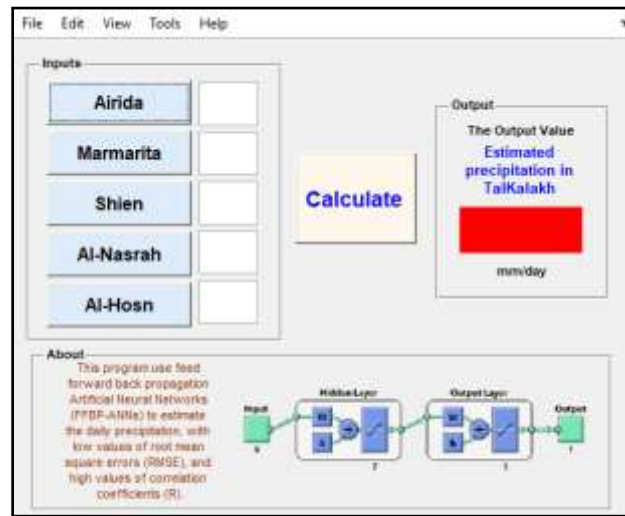
وقد أظهرت النتائج بشكل عام أفضلية خوارزمية الانتشار العكسي للخطأ، وكذلك تابع التنعيل Tan Sigmoid في مختلف النماذج.

أجري بعد ذلك عملية بناء لواجهة مستخدم وربط النموذج الأفضل بها، واعتمد في ذلك على بيئة البرمجة لواجهات المستخدم الرسومية Guide ضمن برنامج MATLAB، والتي تركز على البرمجة المقادة بالحدث في هيكليتها، وسمح ذلك بإمكانية الحصول على تطبيق منفصل يحتوي ضمناً على بنية وهيكلية وثوابت الشبكة العصبية الاصطناعية الناتجة، الأمر الذي يُسهّل من عملية استخدام هذه الشبكة في إجراء المحاكاة من قبل المستخدمين خارج بيئة عمل برنامج MATLAB، ويوضح الشكل (8) جزء من الكود البرمجي المستخدم في تصميم البرنامج النهائي، في حين يبيّن الشكل (9) الواجهة النهائية للبرنامج.

```

% hObject    handle to p7 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
A=get(handles.e1,'string'); %save the value of station 1
A=str2double(A);
B=get(handles.e2,'string');%save the value of station 2
B=str2double(B);
C=get(handles.e3,'string');%save the value of station 3
C=str2double(C);
D=get(handles.e4,'string');%save the value of station 4
D=str2double(D);
E=get(handles.e5,'string');%save the value of station 5
E=str2double(E);
    
```

الشكل (8): جزء من الكود البرمجي المستخدم في تصميم البرنامج النهائي.



الشكل (9): الواجهة النهائية للبرنامج.

الاستنتاجات والتوصيات:

- أظهرت النتائج قدرة الشبكات العصبية الاصطناعية على استكمال قيم الهطل المطري اليومي في محطة تلكلخ المناخية بمعاملات ارتباط عالية تجاوزت 90% خلال مراحل التحقق للنماذج.
- يسمح لنا البرنامج الذي توصلنا إليه باستكمال بيانات الهطل المطري المفقودة في محطة تلكلخ في حال توفر بيانات هطل مطري في المحطات المجاورة لها.
- توصي هذه الدراسة باستخدام أنظمة هجينة من الخوارزميات الجينية والشبكات العصبية الاصطناعية في استكمال البيانات المفقودة للهطل المطري.
- كما توصي بضرورة العمل على زيادة عدد المحطات المناخية في المنطقة الوسطى والحرص على جودة توزعها، الأمر الذي يُحسّن من إمكانية الربط بين المحطات وإعداد نماذج التنبؤ فيها.

المراجع:

1. KULIGOWSKI, R. J.; BARROS, A. P. *Using Artificial Neural Networks to Estimate Missing Rainfall Data*. Journal of the American water resources association. 1998, VOL. 34, NO.6, PP 1437: 1447.
2. GUHATHAKURTA, P. New Models for Long Range Forecasts of Summer Monsoon Rainfall over North West and Peninsular India. Meteor. & Atmos. Phys., 73 (3), 2000, 211-255.
3. 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.
4. MOUSTRIS, K; IOANNA K, L. Precipitation forecast using artificial neural networks in specific regions of Greece. Water Resour. Manag. 25, 2011, PP 1979–1993.
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. AL-HASHIMI, S.A. Prediction of Monthly Rainfall in Kirkuk Using Artificial Neural Network and Time Series Models, Journal of Engineering and Development, Vol. 18, No.1, January 2014, ISSN1813- 7822.
8. 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.
9. الشرفاوي، محمد علي. الذكاء الاصطناعي والشبكات العصبية. مركز الذكاء الاصطناعي للحاسبات، 1996.
10. راشد، صفوان ناظم؛ رشيد، خيرى بدل؛ زكي، عزة حازم. مقارنة بين اسلوبي الشبكات العصبية الاصطناعية والمربعات الصغرى للنماذج الخطية وغير الخطية مع التطبيق. المجلة العراقية للعلوم الإحصائية (21)، 2012، 265–246.
11. BASHEER, I, A; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. Journal of Microbiological Methods 43, 2000, 3–31.
12. KUMAR, M; RAGHUWANSI, N. S; SINGH, R; WALLENDER, W. W; PRUITT, W. O. *Estimating Evapotranspiration using Artificial Neural Network*. Journal of Irrigation and Drainage Engineering, 2002.
13. AL-ABOODI, A.H. *Evaporation Estimation Using Adaptive Neuro-Fuzzy Inference System and Linear Regression*. Eng. &Tech. Journal, Vol. 32, Part (A), No.10, 2014.