

التنبؤ بالتصريف اليومي لنهر الزاب الكبير باستخدام نماذج الشبكات العصبية الاصطناعية

عبد الوهاب محمد يونس

gazzal@uomosul.edu.iq

قسم هندسة السدود والموارد المائية، كلية الهندسة، جامعة الموصل، الموصل، العراق

ريام يونس احمد حسن

Ryam.20enp150@student.uomosul.edu.iq

تاريخ القبول: 14 مارس 2023

استلم بصيغته المنقحة: 21 فبراير 2023

تاريخ الاستلام: 26 ديسمبر 2022

الخلاصة:

يعتبر التصريف اليومي للأنهار واحدا من اهم مكونات الدورة الهيدرولوجية في الطبيعة وله دورا اساسيا في التخطيط والادارة لمشاريع الموارد المائية المختلفة، حيث ان عملية التنبؤ بهذا التصريف ضرورية جدا في تشغيل الخزانات والتخطيط لدرء الفيضان وتقدير وفرة المياه او ندرتها. يهدف البحث الحالي الى استخدام نوعين من الشبكات العصبية الاصطناعية لبناء نماذج التنبؤ بالتصريف اليومي لنهر الزاب الكبير، النوع الاول هو الشبكة العصبية ذات التغذية الامامية والانتشار العكسي للخطأ (FFBP) Feed Forward Back Propagation، والثاني هي الشبكة العصبية متعددة الطبقات (متعددة البرسيبترون) Multilayer Perceptron (MLP). استخدمت بيانات السلسلة الزمنية للتصريف اليومية للفترة (2012-2021) لتدريب واختبار الشبكات العصبية الاصطناعية. وظهرت النتائج تفوق نموذج الشبكة المتعددة الطبقات (MLP) ذات الهيكلية (7-14-3) بالاعتماد على معامل التحديد (R^2) المستخدم في تقييم اداء النماذج من خلال ايجاد التوافق بين قيم التصريف الحقيقية والقيم المتنبى بها حيث ان قيمة هذا المعامل كانت (0.91) بينما كانت قيمته (0.86) لنموذج الشبكة (FFBP)، كذلك انخفض مقدار جذر متوسط مربع الخطأ (RMSE) من (69.9) للنموذج الاول (FFBP) الى (51.7) عند استخدام الشبكة متعددة الطبقات. كما تم التحري عن تأثير التصريف السابقة على كفاءة اداء النماذج من خلال استخدام انماط دخل مختلفة، حيث تبين ان افضل معامل تأخير زمني كان باستخدام ثلاثة ايام سابقة وقد اعطى اعلى قيمة لمعامل التحديد واقل قيمة لجذر معدل مربع الخطأ مقارنة بالتأخيرات الاخرى. اضافة الى ما سبق، قدمت الدراسة الحالية اختبار قدرة النماذج المقترحة على التنبؤ بالقيم العظمى والصغرى لتصريف نهر الزاب الكبير.

الكلمات المفتاحية:

التنبؤ بالتصريف، التصريف اليومي للنهر، الشبكات العصبية الاصطناعية، MLP، FFBP

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>).

<https://rengj.mosuljournals.com>

Email: alrafidain_engjournal1@uomosul.edu.iq

1. المقدمة:

كبير في فهم الخصائص الهيدرولوجية في احواض تلك الانهار كما تساهم في تحسين عملية نمذجة الانظمة الهيدرولوجية (Hydrologic Systems) ومن ابرزها احواض الانهار [2]، وبسبب طبيعة العلاقة غير الخطية بين المدخلات والمخرجات لتلك الانظمة التي تجعل من محاولات التنبؤ اكثر صعوبة واقل موثوقية ظهرت الحاجة الى بناء نماذج تنبؤ ذات دقة اداء عالية والتي تطلبت اجراء التحسينات على دراسات التنبؤ التقليدية تلك التي افترضت ان العلاقة التي تربط بين المتغيرات هي علاقة خطية [3]، [4].

اشهر تقنيات التنبؤ بتصريف الانهار واكثرها استخداما تندرج تحت مفهومين، اولها مفهوم النمذجة الفيزيائية (Physically based modeling) والتي تعمل على تمثيل الظاهرة الهيدرولوجية بنموذج فيزيائي محكوم بالقوانين الفيزيائية، اما الثاني فهو المفهوم الاحصائي او ما يسمى (data-driven) methods، ويقصد به استخدام البيانات المسجلة والتي تعطي وصف للظاهرة تحت الدراسة وتحليلها ومن ثم توليد بيانات جديدة من خلال نمذجة مباشرة للعلاقة بين المدخلات والمخرجات [5]. وتشمل نماذج تقنية التنبؤ القائمة على المفهوم الاحصائي: (نماذج الانحدار الخطي المتعدد (MLR) (Multiple Linear Regression)، نماذج المتوسط المتحرك الذاتي (Auto-Regressive Moving Average (ARMA)، نماذج

وجود المياه في الطبيعة هو أصل الحياة على الارض، ومن الضروريات الاساسية لحياة الكائنات البشرية والحيوانية وازدهار الزراعة وضمان البقاء على قيد الحياة. وتعد الانهار من اهم المصادر الاساسية للمياه على سطح الارض وعلى ضفافها شيدت اولى الحضارات الانسانية والمجتمعات البشرية، منها الحضارة السومرية، والبابلية والاشورية وغيرها، لذا بات من الضروري الاهتمام بدراسة كمية تصريف الانهار كونها أحد العوامل الاساسية لتحقيق التنمية المستدامة لقضايا الموارد المائية.

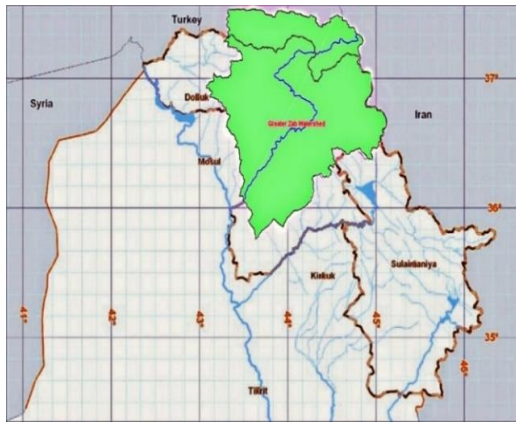
من اهم ادوات اتخاذ القرار في القضايا المتعلقة بإدارة الموارد المائية وتخطيط المشاريع هو التنبؤ المستقبلي بتدفق الانهار، ومن اجل اتخاذ القرار السليم لا بد من تحليل متغيرات الماضي والحاضر التي تصف الظاهرة الهيدرولوجية التي يراد دراستها وتقديم البدائل المتاحة لاختيار الافضل من بينها وتحديد الآثار الناتجة عند اتخاذ ذلك القرار. ويعود ظهور مصطلح التنبؤ (Prediction) الى الباحثين الأوائل الذين عملوا على ايجاد طرق لتحديد القيم المستقبلية لأحداث هيدرولوجية من خلال الاعتماد على البيانات المجمعة سابقا بوصفها تمثل عينة حقيقية من تلك الاحداث. [1] ان بحوث ودراسات التنبؤ الدقيق بتصريف الانهار تساعد بشكل

(MLP-ANN) وبقيمة معامل ارتباط (0.86) بين القيم الحقيقية المرصودة والقيم المتنبئ بها.

تسعى الدراسة الحالية الى تقديم اثنتين من النماذج الرياضية بهدف التنبؤ بالتصريف اليومي لنهر الزاب الكبير نظرا للاهمية البالغة لهذا النهر، حيث استخدمت تقنية الشبكات العصبية الاصطناعية (ANN) في بناء نموذجي التنبؤ وذلك لأهميتها ومواكبتها لتطور البرمجيات المستخدمة في العديد من البلدان المتقدمة، ومن ثم إجراء التقييم الاحصائي لأداء النماذج بغية الوصول الى افضلها واكثرها دقة تماشيا مع العديد من التوصيات التي تم اقتراحها في الكثير من البحوث والدراسات التي قدمت في مجال التنبؤ بالتصريف اليومي للأنهار.

2.منطقة الدراسة:

يقع حوض نهر الزاب الكبير بين خطي عرض (36°-38°) شمالاً وخطي طول (43.3°-44.3°) شرقاً، وتقدر مساحته الكلية بحوالي (26473 كم²) يقع 65% منها داخل الأراضي العراقية اي ما يعادل حوالي (17000 كم²) كما تبلغ كمية مياهه المغذية لنهر دجلة ما يقارب 40% من واردة السنوي. نهر الزاب الكبير هو واحدا من أهم الروافد الرئيسية لنهر دجلة، يدخل الأراضي العراقية في اقليم كوردستان قرب مدينة العمادية ويتابع جريانه باتجاه الجنوب الشرقي داخل محافظة دهوك حيث تصب العديد من الجداول والروافد فيه، اكبرها رافد (شمديان)، (حاجي بيك)، (راوندوز) ورافد (ريشين) عند مدخل قرية (كالي بلاندا)، اضافة الى الفروع الصغيرة والجداول الموسمية. يلتقي الزاب الكبير بنهر دجلة عند جنوب مدينة الموصل حيث يصب في الضفة الشرقية له. ويبلغ طوله الكلي من منابعه في تركيا حتى مصبه بحوالي (462 كم) (الشكل 1).



الشكل (1): خارطة توضح حوض نهر الزاب الكبير

3. البيانات المستخدمة في الدراسة، خصائصها الاحصائية وتهيئتها:

اعتمدت الدراسة سجلات التصريف لحوض نهر الزاب الكبير عند محطة قياس (اسكي كلك) لكونها من المحطات الرئيسية القديمة الواقعة على النهر والتي لازالت تسجل منها القراءات اليومية تباعا الى يومنا هذا والتي تم الحصول عليها من دائرة ري اربيل. حيث تضمنت بيانات السلسلة الزمنية للتصريف اليومية للفترة (2021-2012).


يوضح الجدول (1) بعض الخصائص الاحصائية لهذه البيانات عند محطة اسكي كلك بينما يوضح الشكل (2) السلسلة الزمنية للجريان. حيث كان أكبر قيمة للتصريف هي 1518 (متر مكعب/الثانية) في سنة 2013 واقل قيمة للتصريف بلغت 43 متر مكعب/الثانية وتم رصدها سنة 2021.

الشبكات العصبية الاصطناعية (Artificial Neural Network) (ANN) وغيرها من النماذج.


لقد أكد [6] ان نماذج الشبكات العصبية الاصطناعية (ANN) اثبتت قدرتها على محاكاة الظواهر المعقدة والعلاقات غير الخطية وحل المشاكل الهندسية المعقدة بوقت قصير، كما امتازت بمقدرتها على التنبؤ عندما تتوفر بيانات كافية للتدريب التي تتيح للشبكة التعلم منها والتنبؤ بمخرجات جديدة وهذه الخاصية جعلت من (ANN) أكثر استخداما مقارنة بالنماذج الاخرى. كما تم التحري عن إمكانية تطبيق وأدائية النماذج العصبية الاصطناعية لغرض التنبؤ القصير المدى بتصريف النهر [7] ، فقد استخدمت الشبكة العصبية الاصطناعية من النوع المتعدد الطبقات لبناء معمارية الشبكة واختبرت ثلاث نماذج في البداية لغرض معرفة تأثير التصريف السابقة على معدل التصريف في يوم محدد لاحق، بعدها تم اختيار النموذج لغرض إجراء التنبؤ ليوم ويومين لاحقين. كما كان لذلك النموذج القدرة على محاكاة قيم التصريف الواطنة والعالية على حد سواء. استخدم [8] نموذج الشبكات العصبية الاصطناعية (ANNs model) ونموذج النظام العصبي الضبابي التكيفي (Adaptive Neuro-Fuzzy Inference System, ANFIS)، لتخمين والتنبؤ بالجريان القادم من القطرلة المشيدة على نهر (Mahanadi , India) بهدف السيطرة على الفيضانات وبينت النتائج تقارب مخرجات نموذج (ANFIS) مع القيم الحقيقية المرصودة وبمعامل ارتباط قيمته (0.92) مقارنة بنتائج النموذج الأول (ANN model). اعتمد الباحثون [9] على تقنية (ANN) للتنبؤ بالتصريف الشهرية الواردة الى حوض نهر (Winooski River, USA) باستخدام الشبكات العصبية الاصطناعية المتكررة (Recurrent Artificial Neural Network, RNN)، واعتمدت الدراسة على البيانات المناخية المسجلة للأمطار ودرجات الحرارة اضافة الى اعادة استخدام قيم التصريف المتنبئ بها كمدخلات وفق مفهوم ما يعرف بالزمن المتأخر (Time-Lagged)، حيث اشارت النتائج الى ان استخدام تلك الطريقة في ترتيب بيانات الادخال ادت الى تحسن ملحوظ في اداء النموذج وزيادة دقة النتائج المستحصلة من نماذج (ANN Models). قارن الباحثان [10] بين كل من تقنية (ANN)، تقنية البرمجة الجينية (Genetic Programming, GP)، وتقنية اشجار النموذج (Model Trees, MT) للتنبؤ بتدفق النهر قبل يوم واحد في محطتين في مستجمعات نارمادا في الهند (Narmada catchment, India)، وتبين من النتائج ان اداء جميع النماذج كان مقبولا ووجد ان أداء تقنيات ANN و MT تعمل بشكل جيد جدا من حيث دقة التنبؤ مقارنة مع نتائج تقنية (GP). اضافة الى ذلك، اشار [11] ان تقنية (ANNs) هي أداة قوية لنمذجة السلاسل الزمنية المعقدة ومن الممكن استغلالها في العديد من التطبيقات الهيدرولوجية بسبب قدرتها العالية على تمثيل العلاقة بين التصريف المسجلة التاريخية (المدخلات المرصودة الحقيقية) والتصريف المستقبلية [12] بتطبيق ثلاثة نماذج (ANNs) للتنبؤ بالتصريف الشهرية لنهري الزاب الكبير والصغير في العراق، بينت نتائج الدراسة اهمية استخدام تقنية الشبكات العصبية الاصطناعية في التنبؤ و اشارت النتائج الى الدقة العالية في التنبؤ وتقدير القيم المستقبلية من خلال عملية المقارنة بين القيم الحقيقية المرصودة والقيم الناتجة كمخرجات للنماذج وتميزت النماذج بكفاءتها العالية والجيدة في تقدير قيم التصريف العليا لمجموعة البيانات التي تم اختيارها لغرض اختبار اداء النماذج. قدم [1] ثلاثة نماذج بهدف التنبؤ بالجريان الوارد الى حوض نهر الخازر شمال العراق، وهي نموذج الانحدار الذاتي المتكامل المتحرك (Autoregressive Integrated (ARIMA) Moving Average) اضافة الى اثنتين من نماذج (ANNs) هما نموذج (MLP) وشبكة العصبية ذات الاساس الاشعاعي (RBF). بينت نتائج المقارنة الاحصائية بين النماذج تفوق اداء نموذج

جدول (1): الخصائص الإحصائية لبيانات التصاريح اليومية لمنطقة الدراسة مقاسة بوحدة (m³/sec)

Statistics		Years	Max.	Min.	Mean	S.Deviation	Skewness
Discharge(m ³ /sec)	Whole data	-2012 2021	1518	43	270.9	178.26	1.73
	Training & Validation data set	-2012 2018	1518	68	269	153.21	1.65
	Testing data	-2019 2021	1227	43	274.43	226.13	1.6



شكل (2): السلسلة الزمنية لتصاريح النهر اليومية



الشكل (3): وجه التشابه بين الخلية العصبية البيولوجية والشبكة العصبية الاصطناعية.

بدأ تاريخ الشبكات العصبية الاصطناعية عام (1943م)، حيث قدم العالمان وارين ماكلوش ووالتر بيتس (Warren McCulloch & Walter Pitts) نموذجاً للشبكات العصبية الاصطناعية على الرغم من أنه لم يتم العمل بها حتى منتصف عام 1980 حيث بدأ تطوير واستخدام هذه التقنيات وأصبحت من أكثر الطرق اعتماداً في مختلف المجالات، أما في عام (1969م) نشر (Minsky) و(Papert) كتاباً حول الإمكانيات الحاسوبية للوحدة العصبية التي تسمى بالعصبونات أو بيرسيبترون (Perceptron) [13]. وتتكون الهيكلية الأساسية للشبكات العصبية الاصطناعية من ثلاثة أنواع من طبقات الخلايا العصبية: طبقة الإدخال (Input Layer)، الطبقات المخفية (Hidden Layer) وطبقة الإخراج (Output Layer) بالإضافة إلى الروابط البيئية الموزونة. أما أن ترتبط العصبونات في الطبقة الواحدة بشكل كلي (أي أن ترتبط كل العصبونات في طبقة الأولى مع جميع عصبونات

4. مفهوم الشبكات العصبية الاصطناعية (Artificial Neural Network)

(Network): تعد الشبكات العصبية الاصطناعية واحدة من أهم وأكثر تقنيات الذكاء الاصطناعي انتشاراً واستخداماً، وتمثل محاكاة لأصغر الوحدات العصبية في مخ الإنسان أو ما يعرف بالعصبون البيولوجي كما يمكن القول أنها محاكاة للطبيعة، حيث يتكون مخ الإنسان من عدد من الخلايا العصبية الحيوية المتصلة مع بعضها البعض بوصلات عصبية، والشبكات العصبية الاصطناعية بفرضياتها وخوارزمياتها ماهي إلا محاولة لفهم سلوك الشبكة العصبية الحيوية (البيولوجية)، كما هو موضح في الشكل (3).

وتتكون الشبكة العصبية من وحدات معالجة بسيطة، هذه الوحدات هي عناصر حسابية تسمى عصبونات أو عقد (Neurons) وترتبط مع بعضها بخطوط موزونة (تتأخر المحاور العصبية البيولوجية) حيث تقوم بنقل الإشارات (المدخلات) من عصبون إلى آخر، ويمكن للشبكة أن تحور سلوكها تبعاً للظروف والبيئة المحيطة بها من خلال اصلاح اوزانها (ارتباطاتها) كي تصبح المخرجات ملائمة قدر الامكان للمدخلات، وتتميز بسرعة المعالجة وكذلك قدرتها على التعلم والتعامل مع انماط مختلفة من البيانات لذا فهي ملائمة للعديد من التطبيقات والاستخدامات مثل تمييز الصوت والصور وعمليات التنبؤ المسبقة.. الخ.

المدخلات مهما كانت منخفضة ويطلق عليها تسمية دالة تنشيط سيغمويد الثنائي او (LOGSIG)، والمعادلة (1) توضح صيغة هذه الدالة:

$$f(x) = \frac{1}{1 + e^{-x}} \dots \dots \dots (1)$$

ودالة (Hyperbolic Tangent): وهي مشابهة للدالة الأولى وتتمتع بنفس المزايا من حيث الانسيابية إلا أن قيم الإخراج لها تكون ما بين [-1,1]، وتسمى أيضا بدالة سيغمويد ثنائية القطب (TANSIG)، ويمكن صياغتها رياضيا من خلال المعادلة التالية:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \dots \dots \dots (2)$$

بالإضافة الى دالة خطية (Linear): تكون فيها قيم الإخراج مساوية لقيم الإدخال الموزونة للعصبون وتسمى أيضا (Pureline) ويمكن التعبير عنها رياضيا بالصيغة التالية:

$$f(x) = x \dots \dots \dots (3)$$

يجري داخل هذه الوحدة او (العصبون) اولا حساب متوسط الاوزان لكل مدخلات وحدة المعالجة وذلك بضرب كل قيمة مدخلة في وزنها المرافق ومن ثم ايجاد مجموع نواتج الضرب مضافا اليها القيمة العددية لعامل الانحياز (Bias)، وتعتبر هذه العملية هي اولى عمليات المعالجة الحسابية داخل وحدة المعالجة. ويمكن التعبير عن هذه العملية رياضيا من خلال المعادلة التالية:

$$Net = b + \sum_{i=1}^n Xi * wi \dots \dots \dots (4)$$

حيث ان:

Net: ناتج جمع المدخلات المضروبة بأوزانها مضافا لها قيمة معامل الانحياز.

b: عامل الانحياز وله قيمة ابتدائية (b=1) يتم اضافته للحصول على قيمة موجبة للمرحلة الاولى من تدريب الشبكة واختيار الاوزان.

X_i : مدخلات الشبكة.

w: قيمة الوزن المرافق للمدخلات.

n: عدد المدخلات.

i, j : رمز يدل على رتبة العصبون.


تتم معالجة مخرجات الخطوة السابقة عن طريق دوال التنشيط (Activation Function) المذكورة آنفا، وتحتوي كل من طبقة الإخراج والطبقات المخفية على دالة تفعيل يمكن اختيارها بالاعتماد على طبيعة المسألة، ويتم الحصول على صافي المخرجات لعصبون (Y) من المعادلة ادناه:

$$Y = f(Net) = f\left(b + \sum_{i=1}^n Xi * wi\right) \dots \dots (5)$$

5- تطبيق نماذج الشبكات العصبية (ANNs):

اول الخطوات الرئيسية والعامية لتصميم وتطوير نموذج اي شبكة عصبية هي تهيئة البيانات والتحليل الاحصائي لها. تم اجراء عملية تحويل البيانات الى التوزيع الطبيعي (Normalization) لكل من قيم متجهات الادخال و الإخراج، وذلك بجعلها محصورة

الطبقة التي تليها) او جزئياً بالعصبونات الواقعة في الطبقة التي تليها. والشكل (4) يوضح مكونات هيكلية الشبكة العصبية الاصطناعية والتي يمكن تفصيلها كما يلي [14]:




شكل (4): هيكلية الشبكة العصبية الاصطناعية

يمكن ان تُصنف الشبكات العصبية الاصطناعية طبقا للمفاهيم التالية [15]:

1- عدد الطبقات المكونة للشبكة وشكل الترابط بين العصبونات وتشمل: شبكات احادية الطبقة (Single Layer Network) وشبكات متعددة الطبقات (Multilayer Network).

2- تبعا لطريقة تغذيتها بالبيانات وتحديد الاوزان للروابط (تشمل التدريب، التعلم، الخوارزميات) مثل الشبكات العصبية ذات التغذية الامامية (Feed Forward Neural Network (FFNN) وهي الشبكات التي يكون فيها انتشار الاشارات الداخلة الى الشبكة الى الامام دائما، الشبكات العصبية ذات التغذية الخلفية المتكررة (Recurrent Neural Network) (RNN) وهي الشبكات التي



تجد لمخرجاتها طريقا الى الوراء لتصبح مدخلات مرة اخرى لغرض الحصول على أفضل النتائج الممكنة، بالإضافة الى شبكات الترابط الذاتي (Auto Associative Network) هي الشبكات التي تلعب كافة العناصر المكونة لها دورا مزدوجاً، يتمثل في استقبال المدخلات و بث المخرجات في نفس الوقت (أي تعمل بتجاهين متعاكسين). لاحظ الشكل (5).

الشكل (5): مخطط توضيحي لأنواع الشبكات وفقا لانتشار البيانات فيها


يتألف العصبون الاصطناعي او ما يمثل وحدة المعالجة للشبكة من المكونات الأساسية التالية والموضحة في الموضع في الشكل (3) اعلاه:

1- معاملات الاوزان (Weighting Coefficients).

2- دالة الجمع (Summation Function).

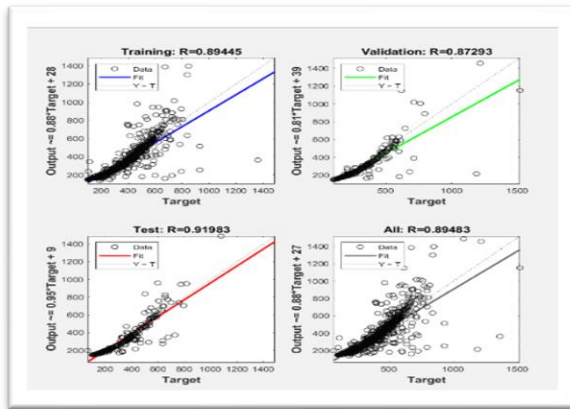
3- دالة التحويل (Transfer function) ودالة التنشيط (Activation Function). ومن اشهرها واكثرها شيوعا والمستخدمه ايضا في هذه الدراسة هي: دالة سيغمويد (Sigmoid): قيم الإخراج ما بين [0,1] بشكل انسيابي بحيث يوفر توزيعاً جيداً لهذه القيم ويساعد في تحقيق قيمة إخراج لكل قيم

1. نموذج الشبكة العصبية امامية التغذية وذات الانتشار الخلفي للخطأ (FFBP): في هذا النموذج تم تدريب الشبكة بالاعتماد على مجموعة بيانات للسنوات (2012-2018) اي ما يعادل 70% من بيانات السلسلة الزمنية الكلية بعد اجراء عملية التقييس لها، من خلال حزمة الادوات NN-Toolbox التي تعتبر قوالب جاهزة ضمن برنامج ماتلاب لبناء الشبكة امامية التغذية (FFBP)، ومن خلال عملية المحاولة والخطأ تم تحديد عدد العصبونات لكل من طبقة المدخلات حيث كانت ثلاثة عصبونات وبدون طبقة خفية وطبقة مخرجات واحدة و ب دالة التفعيل (TANSIG) لتكون معمارية الشبكة المختارة (3-1-1) كما هي موضحة بالشكل (6) ادناه:



الشكل(6):هيكلية الشبكة ذات التغذية الامامية والانتشار العكسي للخطأ(FFBP)

وقد تم اعتماد هذه الهيكلية لإعطائها اقل معدل للخطأ في مرحلة التدريب والمعايرة وقيمة معامل تحديد بلغت (R=0.876). لاحظ الشكلين (7) و(8)



الشكل (7): معامل التحديد (R) في مرحلة التدريب والمعايرة

2. نموذج الشبكة المتعددة الطبقات (Multilayer Perceptron):

من خلال تكرار عملية المحاولة والخطأ، كانت الهيكلية (1-7-14) الاقرب للهدف المطلوب من بين عدة محاولات وصلت الى 13 محاولة أجريت لتدريب الشبكة وكما موضح في الشكل (9). تكونت الهيكلية من طبقة مدخلات واحدة التي تحتوي على 3 عصبونات وهي عدد الصفوف في مصفوفة المدخلات المستخدمة للتدريب، بينما كان عدد الطبقات الخفية طبقتين تحتوي الاولى على 14 عصبونا والثانية 7 عصبونات وبدالة تحويل من نوع

ضمن مدى قصير نسبيا مثلا حصر تلك القيم بين [0-1] للتحقق من قيم الخطأ بين القيم المستحصلة من الشبكة والقيم المرصودة بهدف تحسين كفاءة العمليات الحسابية داخل العصبونات [16].

قسمت بيانات التصاريح اليومية المتوفرة الى مجموعتين (كما هو موضح بالجدول (1) اعلاه: الاولى مجموعة التدريب والمعايرة (Training & Validation) وتضمنت السنوات (2012-2018) (2920 يوم) وتمثل 70% من بيانات التصاريح اليومية للنهر. ان الغاية من عملية التدريب هي لتمكين الشبكة من اكتشاف العلاقة التي تربط بين المدخلات والمخرجات، بالإضافة الى اختيار الاوزان الضرورية بهدف تحقيق اقل معدل للخطأ ومن ثم التحقق من ضبط هذه الاوزان خلال عملية المعايرة (Validation) التي تلي عملية التدريب وبالإمكان تغييرها في حال عدم الوصول الى ذلك الهدف. تتم عملية التدريب والتعلم من خلال اختيار وفحص خوارزميات التعلم الملائمة، وتهيئ برمجيات (MATLAB) حزمة واسعة من خوارزميات التدريب، منها خوارزمية (Gradient Descent with Momentum) (GDM)، خوارزمية (Variable Learning Rate) (GDX,GDA) ومن اسرع تلك الخوارزميات لتدريب شبكة الانتشار العكسي للخطأ والتي ينصح باستخدامها ويمكن الاستفادة منها في التدريبات التي تتطلب بيانات ضخمة نسبيا هي خوارزمية تدريب (Levenbreg Marquardt) (LM)، فضلا عن ذلك استنتج [17] بأن هذه الخوارزمية هي افضل خوارزمية للتعليم لكونها تعطي اقل قيمة لمربع الخطأ مقارنة ببقية خوارزميات التعليم الاخرى كما تعد الأكثر تفضيلا لتدريب الشبكات امامية التغذية والشبكات المتعددة الطبقات حيث تمتاز بالموثوقية والسرعة في الاداء [18].

مرحلة المحاكاة (Simulate) تعتمد على المجموعة الثانية المتمثلة بـ30% المتبقية من البيانات، وتعتبر مجموعة اختبار قدرة النموذج على التنبؤ، تضمنت السنوات (2019-2021) اي (1095 يوم) حيث ان مرحلة الاختبار (Testing) يتم خلالها تقديم بيانات جديدة لم تتعرف عليها الشبكة اثناء التدريب والمعايرة هدفها التأكد من التوافق الادائي للنماذج وعدم حصول مبالغة في التدريب (Over fitting). ولا يمكن العودة مجددا الى تغيير الاوزان او المعلمات المختارة في فترة الاختبار او ما يليها من استخدام الشبكة في عملية المحاكاة.

ان تقييم اداء الشبكات العصبية الاصطناعية وكفاءة نماذج التنبؤ، حيث من خلال تطبيق هذه المعايير يتم اختيار النموذج الافضل ومن بين المعايير الاحصائية الأكثر شيوعا في اختبار الاداء الافضل والتي اعتمدت عليها الدراسة الحالية هي كالاتي [12], [2]:

* معامل التحديد (R^2) (Correlation Coefficient):

$$R^2 = \left[\frac{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})(Q_{pre} - \bar{Q}_{pre})}{\sqrt{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})^2 * \sum_{i=1}^n (Q_{pre} - \bar{Q}_{pre})^2}} \right]^2 \dots \dots (6)$$

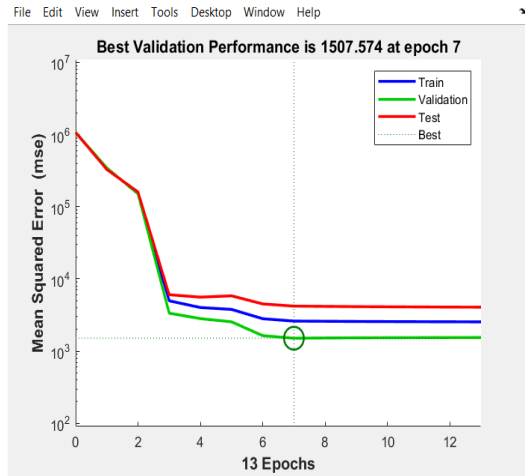
* معدل مربع الخطأ (Mean Square Error(MSE)):

$$MSE = \frac{\sum_{i=1}^n (Q_{obs} - Q_{pre})^2}{n} \dots \dots \dots (7)$$

* جذر معدل مربع الخطأ (Root Mean Square Error (RMSE)):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{obs} - Q_{pre})^2}{n}} \dots \dots (8)$$

من الواحد وذلك لان البيانات التي استخدمت كانت محصورة بين 0 و 1 في التدريب هي اقل من الواحد.



الشكل (11): مسار تدريب الشبكة متعددة الطبقات (MLP)

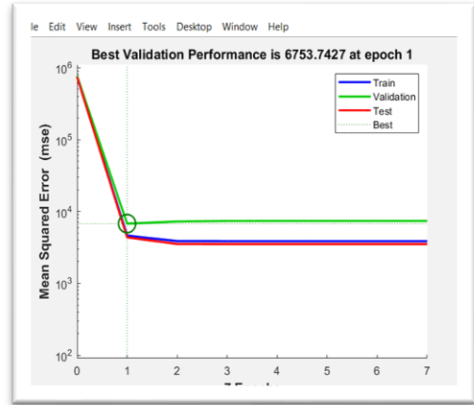
كما اعتمدت الشبكة العصبية الاصطناعية المتمثلة بالنموذجين ANN1(FFBP) و ANN2(MLP) انماط تدريب مختلفة من الدخل وكما موضح في الجدول (2) ادناه وذلك بهدف دراسة فحص تأثير استجابة التصاريح اليومية للقيم السابقة في التنبؤ بالقيم اللاحقة.

جدول (2): الانماط المختلفة لمداخلات الشبكات العصبية الاصطناعية التقليدية

NO. Cas	Network Inputs
1	Q_{t-1}
2	Q_{t-1}, Q_{t-2}
3	$Q_{t-1}, Q_{t-2}, \text{ and } Q_{t-3}$
4	$Q_{t-1}, Q_{t-2}, Q_{t-3} \text{ and } Q_{t-4}$
5	$Q_{t-1}, Q_{t-2}, Q_{t-3} \text{ and } Q_{t-4} \text{ and } Q_{t-5}$
6	$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5} \text{ and } Q_{t-6}$


6. النتائج ومناقشتها: تم اختيار بيانات التصاريح اليومية الخاصة بالسنوات الثلاثة 2019-2020-2021 من السلسلة الزمنية لإجراء عملية المحاكاة (Simulate) بالاعتماد على الهيكلية الافضل الخاصة بكل نموذج، حيث تم ادخال البيانات التي لم تتعرف عليها الشبكات سابقا. وبعد الحصول على مخرجات الشبكة اجريت المقارنة الاحصائية بينها وبين القيم الحقيقية المرصودة باستخدام المعايير الاحصائية المعتمدة.

يبين الجدول (3) ادناه تأثير التأخيرات الزمنية المختلفة لأنماط المدخلات المختلفة وتأثيرها على معامل الارتباط وقيمة جذر معدل مربع الخطأ، حيث يلاحظ ان النموذج ANN2 (MPL) هو الافضل في التنبؤ بالتصريف اليومي لليوم الرابع بتأخيرات زمنية لمدة ثلاثة ايام حيث تم الحصول على معامل ارتباط قدره 0.88 في



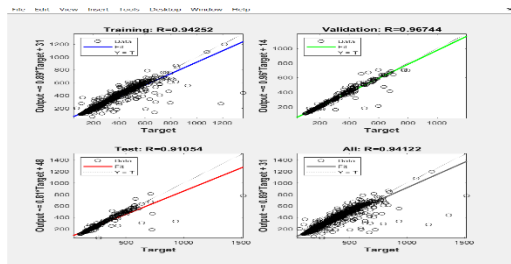
الشكل (8): يوضح مسار تدريب الشبكة امامية التغذية ذات الانتشار الخلفي للخطأ (FFBP) وقيم معدل مربع الخطأ

(TANSIG) في حين كانت الطبقة الاخيرة طبقة المخرجات تحتوي على عصبون واحد وبدالة تفعيل نوع (PURLINE).



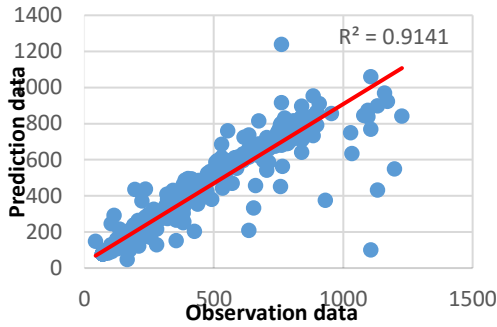
الشكل (9): هيكلية الشبكة متعددة الطبقات (MLP)

الهيكلية الموضحة اعلاه اعطت اداء افضل مقارنة بجميع المحاولات التي تم اجراؤه، حيث تم تغيير عدد العصبونات في كل محاولة ونوع دوال التفعيل المستخدمة مع تثبيت خوارزمية التعلم (LM) لحين الحصول على اقل قيمة (MSE) خلال فترة التدريب كما هو موضح بالشكل (11) التالي.



الشكل (10): قيم معدل مربع الخطأ ومعامل التحديد (R^2) في مرحلة التدريب والمعايرة

*يلاحظ من الشكل (11) اعلاه ان قيم معدل مربع الخطأ (MSE) هي قيم كبيرة مقارنة بالقيم المعتادة والسبب في ذلك ان البيانات استخدمت للتدريب من دون اجراء عملية التقييس (بيانات التصاريح اليومية)، وذلك لأنه قد تم تدريب احد الشبكات العصبية بالاعتماد على عملية التقييس التي اجريت ضمن فقرة تهيئة البيانات ولم يكن هناك فرق يذكر في الاداء فقط قيمة (MSE) كانت اقل



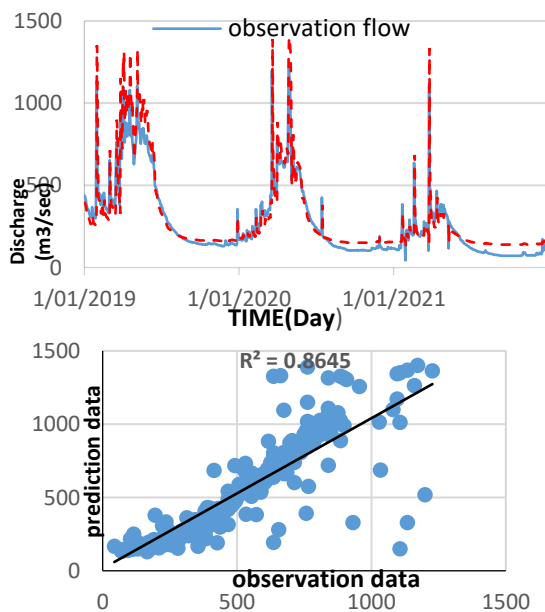
شكل (12): معامل التحديد والسلسلة الزمنية للبيانات المرصودة الحقيقية والمتنبأ بها باستخدام نموذج الشبكة $FFBP(ANN1)$

مرحلة تدريب البيانات و 0.91 في مرحلة التحقق فيما سجلت قيمة جذر معدل مربع الخطأ (RMSE) انخفاضا من 69.8 في مرحلة

التدريب الى 51.56 في مرحلة التحقق وهذا يدل على وجود استجابة قوية لفترة تأخير ثلاثة ايام مقارنة مع فترات التأخير الاخرى فيما نلاحظ في الحالات الاخرى انه كلما زادت فترات التأخير نتج عنه انخفاض في قيمة معامل التحديد وزيادة في قيمة (RMSE). حيث كانت اسوء الحالات بالنسبة لمرحلة التدريب هي الحالة الاولى بمعامل تحديده قدره 0.53 مقابل 89.8 ل (RMSE). فيما كانت الحالة الرابعة هي الأسوء بالنسبة لمرحلة التحقق بمعامل تحديده قدره 0.54 و (RMSE) بمقدار 79.

جدول (3): قيم R^2 , RMSE في مرحلة التدريب والتحقق لنموذجي $FFBP, MLP$ باستخدام انماط دخل مختلفة

Network input	ANN1(FFBP)				ANN2(MLP)			
	Training		Validation		Training		Validation	
	R^2	RMSE	R^2	RMSE	R^2	RMSE	R^2	RMSE
Q_{t-1}	0.792	69.13	0.76	69.9	0.53	89.8	0.73	77.6
Q_{t-1}, Q_{t-2}	0.81	64.72	0.75	79.85	0.78	60.54	0.82	69.78
$Q_{t-1}, Q_{t-2}, \text{ and } Q_{t-3}$	0.902	63.5	0.86	69.8	0.88	59.55	0.91	51.76
$Q_{t-1}, Q_{t-2}, Q_{t-3} \text{ and } Q_{t-4}$	0.77	77.46	0.82	70.65	0.82	62.34	0.54	79.15
$Q_{t-1}, Q_{t-2}, Q_{t-3} \text{ and } Q_{t-4} \text{ and } Q_{t-5}$	0.8	71.41	0.75	73.7	0.81	71.06	0.75	56.9
$Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, Q_{t-5} \text{ and } Q_{t-6}$	0.82	70.4	0.85	69.92	0.740	75.82	0.88	65.81



شكل (13): معامل التحديد والسلسلة الزمنية للبيانات المرصودة الحقيقية والمتنبأ بها باستخدام نموذج الشبكة

جرى تدريب الشبكات العصبية الاصطناعية التقليدية ومن ثم استخدام الامر (simulate) بهدف محاكاة النماذج من خلال مجموعة بيانات الاختبار الواقعة ضمن الفترة 2019-2021 حيث تم الحصول على قيم للبيانات المتوقعة كمخرجات للنماذج المقدمة في هذه الدراسة. ان الشكل (12) ادناه يبين العلاقة بين القيم الحقيقية المسجلة والقيم المتنبأ بها للفترة من 2019-2021 ومعامل تحديده قدره $R^2 = 0.864$ ، كما يوضح السلسلة الزمنية لبيانات المتوقعة باستخدام شبكة (FFBP) ومقارنتها مع القيم الحقيقية المرصودة لنفس الفترة الزمنية. اما الشكل (13) يوضح العلاقة بين مخرجات الشبكة العصبية متعددة البريسبترون (MLP) والقيم الحقيقية المرصودة ولنفس الفترة الزمنية ومعامل تحديده قدره 0.91.

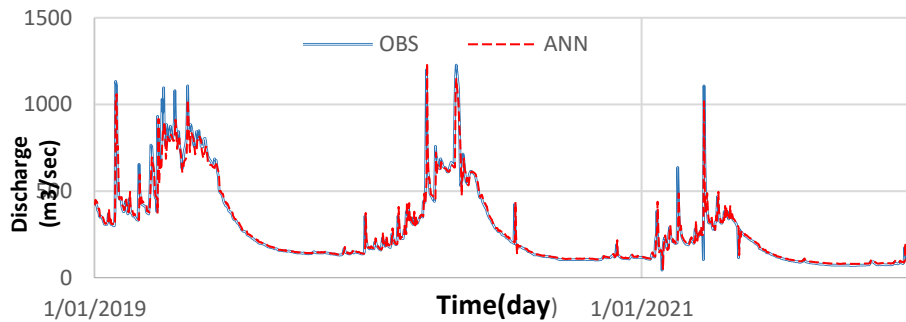
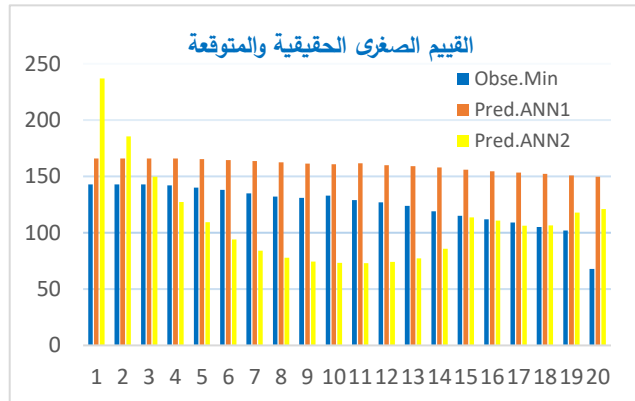
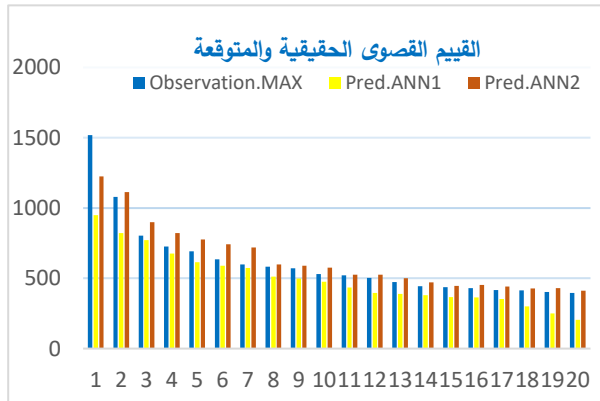
يلاحظ من مقارنة اداء النماذج من خلال الاشكال الموضحة في (شكل 13) تفوق نموذج الشبكة العصبية متعددة البريسبترون ذات الهيكلية (3-14-7).

ذلك يبين انه بزيادة عدد الطبقات للشبكات يودي الى كفاءة اداء افضل وتقليل معدل مربع الخطأ بسبب مرور المدخلات الى وحدات معالجة اكثر في الشبكات المتعددة الطبقات. الجدول (4) ادناه يبين اداء النماذج المقدمة في الدراسة الحالية

جدول (4) قيم المعايير الاحصائية للمقارنة بين اداء النماذج في مرحلتي التدريب والاختبار					
Models	Net. Archi.	MSE	RMSE	R(Training)	R ²
ANN1(FFBP)	3-1-1	4885.52	69.9	0.89	0.86
ANN2(MLP)	3-14-7-1	2676.95	51.7	0.94	0.91

احتماليتها (20%) و20 اخرى من التصاريح الدنيا التي لا تتجاوز قيمتها $43m^3/sec$ باحتمالية تجاوز (Exceedance) 80% من بيانات التدفقات اليومية الخاصة بمجموعة التحقق (Validation DataSet)، كما موضح في الشكل (14).

واحدة من اهم مميزات استخدام تقنية الشبكة العصبية الاصطناعية قدرتها على محاكاة القيم العظمى والصغرى للتصاريح، حيث تعتبر تلك القيم بالغة الاهمية في تخطيط وإدارة الموارد المائية مثل تصميم بوابات التحكم في السدود وكذلك في التخطيط لدرء الفيضانات، ولإثبات ذلك فقد تم اختيار تم اختيار 20 قيمة من التصاريح القصوى التي لا تتجاوز قيمتها $1518m^3/sec$ والتي لا تتجاوز



شكل (14) : القيم العظمى والصغرى الحقيقية والمتوقعة باستخدام نماذج الشبكات العصبية الاصطناعية

والدنيا المتنبأ بها مقارنة مع نضائرها في التصاريح الحقيقية المسجلة $11.92m^3/sec$ و $3.9m^3/sec$ وهي فروقات طفيفة جدا وكاد لا تذكر وهذا اقوى دليل على التقارب الكبير بين بيانات السلاسل الزمنية المسجلة والمتنبأ بها من خلال النموذج الافضل. وعلى ضوء ما تقدم كانت نسبة الخطأ النسبي لكل من معدل التصريف اليومي والتصاريح القصوى والدنيا المتنبأ بها مقارنة مع القيم الحقيقية هي 2%، 8%، و28% على التوالي

اما الجدول (5) التالي فيبين وجود تقارب قوي بين الخصائص الاحصائية لبيانات السلسلة الزمنية المسجلة والبيانات المتنبأ بها من خلال النموذج الافضل اداء والمتمثل بالنموذج ANN2(MPL) حيث كان معدل التصاريح للبيانات الحقيقية $274.43m^3/sec$ ، فيما كان معدل التصاريح المتنبأ بها بموجب النموذج الافضل هو $271.69m^3/sec$. اما الفرق بين التصاريح اليومية القصوى

جدول (5):-الخصائص الاحصائية لبيانات السلاسل الزمنية الحقيقية والمتنبأ بها

Statistics	Observation data	Pred.(ANN1)	Pred.(ANN2)
MAX	1227	1402	1238.92
MIN	43	130.60	46.90
MEAN	274.43	296.88	271.69
S.D	226.13	249.55	207.63
SEKW.	1.6	2.24	1.4

انه من الممكن استخدامها بدمجها مع تقنية من تقنيات الذكاء الاصطناعي الاخرى كتحويل الموجات المتقطع بهدف تحسين اداء نماذجها للتنبؤ المستقبلي للظواهر الهيدرولوجية الاخرى.

4. اشارت الدراسة الى قدرة نماذج الشبكات العصبية الاصطناعية في التنبؤ بالقيم العظمى والصغرى للتصارييف اليومية، حيث تبين ان قدرتها على التنبؤ بالتصارييف العظمى يكون بمعامل خطأ نسبي اقل بكثير مقارنة بالتنبؤ بتلك الصغرى.

5. بينت النتائج تأثير عامل التأخير الزمني والاعتماد على التصارييف السابقة في مدخلات نماذج (ANNs)، فقد تبين ان التأخير الزمني بثلاثة ايام سابقة كان هو الافضل ولكلا النموذجين.

6. وجود تقارب قوي بين الخصائص الاحصائية لبيانات السلسلة الزمنية المسجلة والبيانات المتنبئ بها من خلال النموذج الافضل اداء والمتمثل بالنموذج ANN2(MPL).

الاستنتاجات:

1. بينت الدراسة الحالية ان افضل نموذج للتنبؤ المستقبلي بالتصريف اليومي لنهر الزاب الكبير هو نموذج الشبكة العصبية متعددة البريسترون (MLP) وبهيكلية 1-7-14-3 المتكونة من طبقة مدخلات تحتوي على 3 عصبون خفية الاولى تحتوي 14 عصبون والثانية 7 عصبون وطبقة مخرجات واحدة.
2. اشارت نتائج المقارنة الاحصائية بين مخرجات النماذج الى وجود توافق خطي عالي بين القيم المتنبئ بها باستخدام نموذج (MLP) والقيم المرصودة حيث بلغ معامل التحديد $R^2 = 0.914$ وهو الافضل مقارنة بمعامل التحديد لنموذج (FFBP) الذي كانت قيمته $R^2 = 0.864$ والسبب في ذلك يعود الى زيادة الطبقات الخفية التي ساعدت على تدريب البيانات بشكل افضل.
3. سلطت هذه الدراسة الضوء على امكانية استخدام الشبكات العصبية الاصطناعية للتنبؤ بالتصارييف اليومية للأنهار كما

- 2009, doi: 10.1623/hysj.54.2.247.
- [9] L. E. Besaw, D. M. Rizzo, P. R. Bierman, and W. R. Hackett, "Advances in ungauged streamflow prediction using artificial neural networks," *J. Hydrol.*, vol. 386, no. 1–4, pp. 27–37, May 2010, doi: 10.1016/j.jhydrol.2010.02.037.
- [10] S. Londhe and S. Charhate, "Comparaison de techniques de modélisation conditionnée par les données pour la prévision des débits fluviaux," *Hydrol. Sci. J.*, vol. 55, no. 7, pp. 1163–1174, 2010, doi: 10.1080/02626667.2010.512867.
- [11] S. K. Patil and S. S. Valunekar, "PREDICTION OF DAILY RUNOFF USING," vol. 14, pp. 241–245.
- [12] T. A. Awchi, "River discharges forecasting in northern Iraq using different ANN techniques," *Water Resour. Manag.*, vol. 28, no. 3, pp. 801–814, 2014, doi: 10.1007/s11269-014-0516-3.
- [13] G. Ammar and B. Haidar, "Using Neural Networks models with Wavelet transform technology To Predict Flows Coming into Tishreen Lake", Tishreen University 16 Journal for Research ,39 .and Scientific Studies vol
- [14] A. P. Engelbrecht, "Comp_Intelligence.pdf." p. 630, 2007.
- [15] R. M. A. Q. Bashi, O. M. A. M. Agha, and A. W. M. Younes, "Forecasting the Reconnaissance Drought Index (RDI) Using Artificial Neural Networks (ANNs)," vol. 27, no. 2, pp. 140–155, 2022.
- [16] H. Y. Dalkiliç and S. A. Hashimi, "Prediction of daily streamflow using artificial neural networks (ANNs), wavelet neural networks (WNNs), and adaptive neuro-fuzzy inference system (ANFIS) models," *Water Sci. Technol. Water Supply*, vol. 20, no. 4, pp. 1396–1408, Jun. 2020, doi: 10.2166/ws.2020.062.
- [17] K. A. Abdulmuhsin and I. A. Al-Ani, "Using of Learning Vector Quantization Network for Pan Evaporation Estimation," *Tikrit J. Eng. Sci.*, vol. 16, no. 2, pp. 43–50,

Reference: -

- [1] A. A. Kassem, A. M. Raheem, and K. M. Khidir, "Daily Streamflow Prediction for Khazir River Basin Using ARIMA and ANN Models," *Zanco J. Pure Appl. Sci.*, vol. 32, no. 3, 2020, doi: 10.21271/zjpas.32.3.4.
- [2] M. Ş. Güneş, C. Parim, D. Yıldız, and A. H. Büyüklü, "Predicting monthly streamflow using a hybrid wavelet neural network: Case study of the Çoruh river basin," *Polish J. Environ. Stud.*, vol. 30, no. 4, pp. 3065–3075, 2021, doi: 10.15244/pjoes/130767.
- [3] H. Herawati, Suripin, and Suharyanto, "River flow modeling using artificial neural networks in Kapuas river, West Kalimantan, Indonesia," *AIP Conf. Proc.*, vol. 1903, no. November, 2017, doi: 10.1063/1.5011620.
- [4] P. Mittal, S. Chowdhury, S. Roy, N. Bhatia, and R. Srivastav, "Dual Artificial Neural Network for Rainfall-Runoff Forecasting," *J. Water Resour. Prot.*, vol. 04, no. 12, pp. 1024–1028, 2012, doi: 10.4236/jwarp.2012.412118.
- [5] T. A. Awchi, "River discharges forecasting in northern Iraq using different ANN techniques," *Water Resour. Manag.*, vol. 28, no. 3, pp. 801–814, Feb. 2014, doi: 10.1007/s11269-014-0516-3.
- [6] K. A. Al-Mohseen and A. R. M. Towfeeq, "Artificial Neural Network for Single Reservoir Operation," *AL-Rafidain Eng. J.*, vol. 22, no. 2, pp. 29–37, 2014, doi: 10.33899/rengj.2014.87313.
- [7] A. M. Atiaa, "PREDICTION OF RIVER DISCHARGE USING ARTIFICIAL NEURAL NETWORKS : AN EXAMPLE OF GHARRAF RIVER , SOUTH OF IRAQ Study area," vol. 50, no. 2, pp. 200–205, 2009.
- [8] N. Pramanik and R. K. Panda, "Application of neural network and adaptive neuro-fuzzy inference systems for river flow prediction," *Hydrol. Sci. J.*, vol. 54, no. 2, pp. 247–260,

Yangtze River,” *IEEE Access*, vol. 8, pp. 90069–90086, 2020, doi: 10.1109/ACCESS.2020.2993874.

[18] 2009, doi: 10.25130/tjes.16.2.07.
D. Liu, W. Jiang, L. Mu, and S. Wang, “Streamflow Prediction Using Deep Learning Neural Network: Case Study of

Prediction of Daily Flow to the Great Zab River Using Artificial Neural Network Models

Ryam Younus Ahmad Hassan
Ryam.20enp150@student.uomosul.edu.iq

Abdel Wahab Mohammad Younes
gazzal@uomosul.edu.iq

Dams and Water Resources Engineering Department, College of Engineering, University of Mosul, Mosul, Iraq

Received: December 26th 2022 Received in revised form: February 21th 2023 Accepted: March 14th 2023

ABSTRACT

The daily flow of rivers is one of the most important components of the hydrological cycle and plays an important role in the planning and management of various water resources projects, as the process of predicting such flow is very necessary in the operation of reservoirs, planning to prevent flooding and estimating water abundance or scarcity. This study aims to use two types of neural network models to predict the daily flow to the Great Zab river. The first type is the neural network of Feed Forward Back Propagation (FFBP) and the second one is the neural network of Multilayer Perceptron (MLP). Time series data of daily flow for the period (2012 – 2021) were used for training and testing the artificial neural networks. The results showed that the neural network of MLP of (3-14-7-1) structure better than FFBP based on the values of determination coefficient (R^2) which were 0.91 and 0.86 and the values of root mean square errors (RMSE) which were 69.9 and 51.7 for both models, respectively. The effect of including a time index within the inputs of the networks is also investigated by using different input patterns. It was found that there is a noticeable increase in R^2 and a decrease in RMSE values when using three previous days compared to other delays. In addition, the current study examined the ability of the proposed models to predict minimum and maximum flows of the Great Zab River.

Keywords:

flow prediction, daily flow of river, artificial neural networks, MLP, FFBP