

التنبؤ بالأمطار الشهرية في محطة حمص باستخدام تقنية تحويل الموجات والشبكات العصبية الاصطناعية

د. غطفان عبد الكريم عمّارⁱ

د. بادية يوسف حيدرⁱⁱ

عامر قصي الدرويشⁱⁱⁱ

(تاريخ الإيداع 13 / 7 / 2016. قُبِلَ للنشر في 20 / 11 / 2016)

□ ملخص □

التنبؤ بالطقس وخاصةً الأمطار، هي واحدة من المهام العملية الأكثر تحدياً وأهمية، والتي تقوم بها خدمات الأرصاد الجوية في جميع أنحاء العالم، علاوة على كونه إجراء معقد يتطلب مجالات متخصصة ومتعددة من الخبرات. في هذه الورقة، أُقترح نموذج الشبكات العصبية (ANNs) مع تحويل الموجات كأداة للتنبؤ بالأمطار الشهرية بشكل متتالي بالاعتماد على البيانات السابقة لهطول الأمطار (1933-2009)، المأخوذة من محطة حمص للأرصاد الجوية. حيث تم تحليل السلسلة الزمنية للأمطار إلى معالماتها التفصيلية والتقريبية على ثلاث مستويات باستخدام تحويل الموجات المتقطع (DWT) Discrete Wavelet Transform، واستخدمت الشبكة العصبية أمامية التغذية مع خوارزمية الانتشار العكسي في عملية التعلم والتنبؤ.

توصلت الدراسة إلى أن الشبكة العصبية WNN ذات الهيكلية (1-8-8-8-5)، قادرة على التنبؤ بالأمطار الشهرية في محطة حمص على المدى الطويل بمعامل تحديد وجذر متوسط مربعات الأخطاء (0.98, 7.74mm) على الترتيب.

تقدم تقنية تحويل الموجات ميزة مفيدة قائمة على تحليل البيانات، مما يحسن من أداء النموذج، وتطبق هذه التقنية في نماذج الشبكات العصبية الاصطناعية للأمطار لأنها بسيطة، كما يمكن تطبيق هذه التقنية لنماذج أخرى.

الكلمات المفتاحية: الهطل المطري، التنبؤ، الشبكات العصبية الصناعية، تحويل الموجات المتقطع.

ⁱأستاذ - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية

ⁱⁱمدرسة - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية

ⁱⁱⁱطالب ماجستير - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية

Predict monthly rainfall in Homs Station using a technique Wavelet Transform with Artificial Neural Network

Dr. Ghatfan Abd Alkarim Ammarⁱ
Dr. Badia Youssef Haidarⁱⁱ
Aamer Quse Aldarweshⁱⁱⁱ

(Received 13 / 7 / 2016. Accepted 20 / 11 / 2016)

□ ABSTRACT □

Weather forecasting (especially rainfall) is one of the most important and challenging operational tasks carried out by meteorological services all over the world. It is furthermore a complicated procedure that requires multiple specialized fields of expertise.

In this paper, a model based on artificial neural networks (ANNs) and wavelet Transform is proposed as a tool to predict consecutive monthly rainfalls (1933-2009) taken of Homs Meteorological Station on accounts of the preceding events of rainfall data.

The feed-forward neural network with back-propagation Algorithm is used in the learning and forecasting, where the time series of rain that detailed transactions and the approximate three levels of analysis using a Discrete wavelet transform (DWT).

The study found that the neural network WNN structured (5-8-8-8-1), able to predict the monthly rainfall in Homs station on the long-term correlation of determination and root mean squared-errors (0.98, 7.74mm), respectively.

Wavelet Transform technique provides a useful feature based on the analysis of the data, which improves the performance of the model and applied this technique in ANN models for rain because it is simple, as this technique can be applied to other models.

Keywords: Rainfall, Prediction, Artificial Neural Network, Discrete Wavelet Transform.

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

ⁱⁱAssistant Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

ⁱⁱⁱPostgraduate Student, Department of Irrigation and Drainage Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

مقدمة

يُعدُّ التنبؤ بكميات الأمطار المستقبلية عنصراً فاعلاً في مساعدة الإنسان على وضع الخطط المستقبلية لمختلف نواحي الحياة البشرية والنباتية والحيوانية، وخاصة في القطاع الزراعي المرتبط باقتصاد البلاد، وعلى الرغم من التطور الذي شهدته السنوات الأخيرة في مجال التنبؤ بالطقس، ظلَّ التنبؤ الدقيق بالهطل المطري واحداً من أكبر التحديات في الهيدرولوجيا التطبيقية [1]، بسبب تعقيد العمليات الجوية التي تولد الأمطار، بالإضافة إلى مجموعة هائلة من الاختلافات على نطاق واسع من المقاييس، سواء في المكان والزمان [2].

التقنيات الأكثر انتشاراً المستخدمة للتنبؤ بالأمطار هي الطرائق العددية والإحصائية، وبرغم من استمرار الأبحاث في هذه المجالات لفترات طويلة، غير أن النجاحات في هذه النماذج نادراً ما تكون ملموسة. هناك نجاح محدود للتنبؤ بمعلومات الطقس باستخدام النماذج العددية، حيث أن دقة النموذج تعتمد على الظروف الأولية للظاهرة التي هي غير مكتملة أصلاً، وهي غير قادرة على تحقيق نتائج مرضية في الحالات المحلية والقصيرة الأمد، وعلاوة على ذلك، فإن أدائها أيضاً ضعيف نسبياً للتنبؤ طويل الأمد بالأمطار حتى بالنسبة للأماكن واسعة المساحة [3]، وكبديل استخدمت الأساليب الإحصائية التي تتعامل مع السلاسل الزمنية للأمطار كظاهرة عشوائية منفردة وذلك للتنبؤ بالأمطار على المدى الطويل من خلال تحليل السلسلة الزمنية إلى مركباتها [4]، غير أن هذه النماذج عانت من اثنين من العوائق الرئيسية:

1. النماذج الإحصائية ليست مفيدة لدراسة العلاقات غير الخطية المعقدة للأمطار ومن ثم التنبؤ بها، حتى مع الأخذ بالاعتبار نماذج الانحدار الخطي (Power Regression)، بسبب متطلبات صياغة النموذج من حيث التوزيع الاحتمالي للبيانات، والقيود الأساسية لبناء النموذج فهي تفشل في وصف السلوك المتغير ديناميكياً مع الزمن [5,6].

2. لا توجد في نهاية المطاف، نهاية لإيجاد أفضل نموذج للتنبؤ، حيث أنه من غير الممكن الحصول على مجموعات تنبؤ إقليمية، أو عالمية لشرح الفروقات بين منطقتين متجاورتين، تمتلك كل منهما ميزات مطرية بارزة خاصة بها، حيث ان الارتباط بين الأمطار والقيم المنتبأ بها لا يمكن أبداً أن يكون مثالياً [7]. يرجع ذلك إلى وجود بارامترات جوية أخرى تؤثر على الأمطار ودقة التنبؤ بها، وكذلك التغيرات الداخلية للسلاسل الزمنية نفسها، وبالتالي فإن هناك تفاوت في السلاسل الزمنية التي لا يمكن تفسيرها، إلا إذا كنا قادرين على التنبؤ بالسلوك الديناميكي الداخلي للسلاسل الزمنية، وفي ضوء ذلك، فإن هذه التأثيرات الديناميكية المتعددة على السلسلة الزمنية ترتبط بالدورية والعوامل المناخية والطوبوغرافية وغيرها، لذلك فإن معظم النماذج للأمطار التقليدية عادة ما تأخذ بعين الاعتبار هذه العوامل [8,9].

ومع ظهور الشبكات العصبية عام 1986 والتي شغلت اهتمام الباحثين بسبب قدرتها على التعامل مع المشاكل المعقدة غير الخطية أفضل من الأساليب الإحصائية الأخرى، وخاصة تقنية ANN التي تعتمد على خوارزمية الانتشار العكسي (Back-Propagation Algorithm)، أمكن التعرف على الديناميكية الداخلية للسلاسل الزمنية للأمطار بنجاح، والتنبؤ بها أطول مدة، لأنه يمكن أن يتم قبل شهر أو عام، وهناك فائض من الأدلة في الأدبيات على تفوق استخدام الشبكات العصبية على غيرها من النماذج الإحصائية أو الأساليب الحاسوبية وخاصة في مجال التنبؤ بالأمطار [10,11,12,13,14,15]، ولا يوجد نموذج (باستثناء ANN) قادر على التنبؤ ببارامترات الطقس على المدى الطويل بهذه الدقة، وبالاعتماد فقط على البيانات التاريخية للأمطار بتأخر زمني.

في السنوات الأخيرة استخدمت تقنية الموجات Wavelet Techniques على نطاق واسع لمختلف بحوث الموارد المائية بسبب قدرتها على إنتاج تمثيل محلي جيد، للإشارة في كل من مجالي التردد والزمن من خلال تحليل إشارة الدخل إلى عدة مستويات من الدقة، بالإضافة إلى توفير معلومات هامة مخبأة بشكل طبيعي في البيانات مثل الدورية والتي تساهم في بناء هيكلية النموذج [16,17,18,19].

في محاولة من قبل دائرة الأرصاد الجوية الهندية (The India Meteorological Department) IMD للتعنبؤ بالأمطار الموسمية، والحصول على التنبؤات الطويلة المدى، فوق منطقتين متجانستين هما شمال غرب الهند وشبه الجزيرة الهندية، وذلك باستخدام ثلاثة نماذج، وجد أن النماذج الإحصائية كانت ناجحة في السنوات العادية للأمطار الموسمية، وفشلت بشكل ملحوظ خلال السنوات ذات الأمطار الموسمية الشديدة، في حين كان أداء الشبكات العصبية أفضل [20].

أجرى Tantane, s. et al. دراسة لمحاكاة تسلسل عدد الأيام الماطرة، وهطول الأمطار الشهرية من سجلات الأمطار لـ 52 عام في 4 محطات في الجزء الشمالي الشرقي في تايلاند، بهدف التعرف على عملية أدق لتوليد البيانات بحجم زمني أكبر، وذلك باستخدام نموذج الانحدار الذاتي (Autoregressive) AR، مع فلتر موجي (Wavelet Filter)، وبالمقارنة مع التسلسل الفعلي للأمطار لـ 30 عاماً، حصل على معامل تحديد R-square تراوح بين (0.60-0.47) وذلك للمحطات المدروسة، وعند تطبيق النموذج للتعنبؤ بالأمطار الشهرية لعام 2002 حصل على معامل تحديد تراوح بين {0.79-0.5} [21].

وضع Hung, N. et al. نموذج شبكة عصبية اصطناعية ذات تغذية أمامية (Feed Forward ANN) للتعنبؤ بالهطول المطري كل ساعة، وإدارة الفيضان في بانكوك، تايلاند، بالاعتماد على بيانات الأمطار الساعية لـ 4 سنوات، ومزيج من العناصر المناخية المختلفة، وأظهرت النتائج بأن توقعات هطول الأمطار من 1-3 ساعات كانت مرضية للغاية بدقة $RMSE = \{0.87-1.72\}$ mm/hr، وأشار تحليل الحساسية إلى أن أهم مدخل إلى جانب الأمطار هو درجة حرارة الهواء الرطب [8].

اقترح Phusakulkajorn, W. et al. نموذج (Back-Propagation ANN) مع تحويل الموجات المتقطع (Discrete Wavelet Transform) DWT للتعنبؤ بهطول الأمطار، بالاعتماد فقط على البيانات التاريخية للأمطار في خمس محطات في جنوب تايلاند، والشبكة المقترحة كانت قادرة على التنبؤ بالأمطار اليومية لمدة تصل إلى 4 أيام بدقة $(RMSE = 4.69 \text{ mm}, R^2 = 0.88)$ [22].

استخدم Partal, T. et al. نموذج يجمع بين تقنية الشبكات العصبية FFBP وتحويل الموجات المتقطع DWT، للتعنبؤ بالأمطار اليومية في محطات للأرصاد الجوية في تركيا، وذلك بالاعتماد على عناصر مناخية متعددة، وأشارت النتائج إلى أن نموذج Wavelet-ANN مناسب لتمثيل البيانات وخاصة في حالة وجود الأصفار في أشهر الصيف، وكذلك تقدير الذرى للأمطار في مرحلة الاختبار، مما يؤثر إيجابياً على معايير التقييم، بالمقارنة مع نموذج ANN التقليدي والانحدار الخطي المتعدد بدقة $MSE (2.86-9.37)$ و $R^2 (0.75-0.88)$ [23].

اقترح Moustiris, K. et al. نموذج (Multi-Layer Perceptron) MLP ANN مع خوارزمية Back Propagation، بالاعتماد على بيانات الأمطار العظمى والدنيا والوسطية والتراكمية لأربع أشهر متتالية في أربع محطات مناخية في اليونان (115 سنة)، وأظهرت النتائج أن النموذج المعتمد على المجاميع التراكمية للأمطار يوفر أفضل أداء بمعامل تحديد يتجاوز (0.603) للقيم المتنبأ بها في المحطات الأربعة المدروسة [24].

استخدم Ramana, R. V. et al. نموذج BPNN (The Back Propagation Neural Network) مع تقنية تحويل الموجات المتقطع DWT، للتنبؤ بالأمطار لشهر مقدماً باقتراح مجموعة نماذج تعتمد على بيانات الأمطار ودرجة الحرارة العظمى، والصغرى لـ 74 سنة مأخوذة من محطة Darjeeling، الهند، وأظهرت النتائج أن نموذج WNN المقترح أفضل من ANN التقليدية وخاصة بتمثيل الذرى والأصفار في مرحلة المعايرة والاختبار بدقة $[R^2=0.97, RMSE=63.01\text{mm/month}]$ [25].

أهمية البحث وأهدافه

نظراً لأهمية المياه وازدياد الحاجة إليها وخاصة في الوقت الحاضر، نتيجة تزايد أعداد السكان وارتفاع درجة حرارة الأرض الكونية، التي تؤدي إلى ازدياد مقدار التبخر من المسطحات المائية فقد باتت مسألة التنبؤ الدقيق بالأمطار محط أنظار الباحثين منذ عقود عديدة، بهدف الحصول على نظرة مستقبلية وذلك تحقيق إدارة متكاملة وفعالة للموارد المائية.


لذلك تقترح هذه الدراسة بناء نموذج يعتمد في هيكلته على الشبكات العصبية الصناعية، وتحويل الموجات، للتنبؤ بالأمطار الشهرية في محطة حمص للأرصاد الجوية، بالاعتماد على البيانات التاريخية للأمطار الشهرية المأخوذة من المحطة.

موقع منطقة البحث

محافظة حمص تقع على بعد 162 كم شمال العاصمة دمشق، جُمعت بيانات الأمطار الشهرية من محطة حمص للأرصاد الجوية الواقعة على خط عرض ($34^{\circ}4'$) شمالاً وعلى خط طول ($36^{\circ}4'$) شرقاً، وعلى ارتفاع 483 م عن مستوى سطح البحر؛ يبين الجدول (1) الخواص الإحصائية لبيانات الأمطار الشهرية المستخدمة في الدراسة، يتميز المناخ بأربعة فصول واضحة فهناك الصيف الحار والجاف ومن ثم ربيع وخريف معتدلان، وأخيراً شتاء بارد وممطر، مع هطول للثلوج على فترات متقطعة؛ تبلغ درجات الحرارة ذروتها في شهري تموز وآب، والأمر نفسه بالنسبة للرطوبة النسبية، أما شهري كانون الثاني وشباط فهما الأكثر برودة، ويبين الشكل (1) موقع منطقة الدراسة وتوزع الأمطار على كامل محافظة حمص.

الجدول (1) الخواص الإحصائية لبيانات الأمطار الشهرية

Variable	Data	فترة الدراسة	عدد السنوات	عدد الأشهر	Mean	Standard Deviation	Minimum	Maximum	Skewness
Rainfall (Mm)	Total	1933-2009	77	924	38.75	49.83	0	288	1.74
	Calibration	1933-2000	68	816	38.98	49.91	0	280.3	1.69
	Predicted	2001-2009	9	108	37.05	49.65	0	288	2.16



الشكل (1) موقع منطقة الدراسة

طرائق البحث ومواده

A. الشبكات العصبية الصناعية وخوارزمية الانتشار الخلفي (BPNN)

وهي تقنيات حسابية لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة، موزعة على التوازي، ومكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد (Nodes, Neurons)، والتي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية والمعلومات التجريبية، لتجعلها متاحة للمستخدم وذلك عن طريق ضبط الأوزان؛ إذاً الشبكات العصبية الصناعية (ANNs) تتشابه العقل البشري من ناحيتين [26]:

1. تكتسب المعرفة من قبل بيئة الشبكات العصبية من خلال عملية التعلم.
2. قوى وصل بين العصبونات، والتي تدعى أيضاً بالأوزان التشابكية، تستخدم لتخزين المعرفة.
3. تستند الشبكة العصبية إلى مفهوم تدريب الشبكة المعتمد على حجم الخطأ (متوسط مربع الخطأ)، حيث تحدث الأوزان بين الطبقات بقدر مساهمة الوزن في تكوين الخطأ، وتستمر الشبكة في تحديث الأوزان حتى الوصول

إلى الأوزان المثلى، التي تحقق أفضل توفيق للنموذج.

إن قدرة الشبكات العصبية على نمذجة العلاقة بين مجموعة متغيرات الدخل والخرج، يعطي دوراً هاماً للشبكات العصبية، حيث تعد الشبكات العصبية أداة النمذجة غير الخطية التي لا تحتاج إلى صيغة رياضية صريحة للعلاقة بين متغيرات الدخل والخرج، وبين مختلف أنواع ANNs، وخاصة (Backpropagation Feedforward) التي اكتسبت الكثير من الاهتمام في مجال التنبؤ بالطقس [27].

توجد ثلاث ميزات (مكونات) للشبكات العصبية الصناعية ANNs، يتم من خلالها تمييز شبكة عصبية عن

أخرى وهي [28]:

1. شكل الترابط بين العصبونات (المعمارية).

2. الطريقة التي تحدد الأوزان لهذه الترابطات (والتي تدعى التدريب، التعلم، الخوارزميات).

3. نوع دالة التنشيط (Activation Function) المستخدمة.

ويجري تعليم الشبكات بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم (Learning Algorithms)، تتولى تعديل أوزان الشبكة لتحسين أدائها، وتقليل إشارة الخطأ فيها (Error Signal)، استناداً إلى مقياس إحصائي معلوم. للوصول إلى النتيجة المثلى لهذه الأوزان التي تمكن الشبكة من تحقيق أفضل نتيجة مطابقة، أو قريبة من النتيجة المطلوبة، حيث يتم تعديل الأوزان جزئياً في كل دورة، وتؤخذ إشارة الخطأ دليلاً ومؤشراً على مدى القرب أو البعد عن القيم الصحيحة، إن الشكل (2) يوضح المخطط العام لتعديل (تكييف) الأوزان.

ومن الخوارزميات المشهورة في التعليم الموجه (Supervised Learning)، خوارزمية الانتشار الخلفي للخطأ (Error Back Propagation Algorithm)، التي تمثل الطريقة القياسية في تدريب الشبكة العصبية الصناعية، وهذه الطريقة الشائعة تعمل على تقليل الخطأ، لأنها وبكل بساطة عبارة عن طريقة الانحدار التدريجي (Gradient Descent)، وذلك لإيجاد القيمة الصغرى لمربع الخطأ الكلي لقيم الخرج المحسوب من قبل الشبكة، وبالتالي نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكة الصناعية، وتُعد هذه الخوارزمية الأكثر تفضيلاً لمجموعة البيانات الكبيرة [29].

تدريب الشبكة العصبية الصناعية باستخدام الانتشار العكسي تتضمن ثلاث مراحل هي:

• خطوة الانتشار الأمامي للخطأ (Error Forward propagation Step).

• خطوة الانتشار الخلفي للخطأ (Error Back propagation Step).

• خطوة توليف أوزان الشبكة (Network Weights Synthetic Step).

أكثر ما يميز الشبكات العصبية هو قدرتها على التمييز والتعميم (Generalize)، وللوصول إلى هذا الفائدة يتم تقسيم البيانات خلال فترة المعايرة إلى ثلاث مجاميع [30]، بنسبة 70% بناء، و 15% تحقيق، و 15% اختبار، والغرض من ذلك هو قياس كفاءة الشبكة العصبية الصناعية ولمعرفة ما إذا تم تدريب الشبكة الصناعية بشكل صحيح أم لا، وهذه المجموعات هي:

• مجموعة التدريب (Training)، وغايتها الوصول إلى شبكة مع أقل مستوى للخطأ.

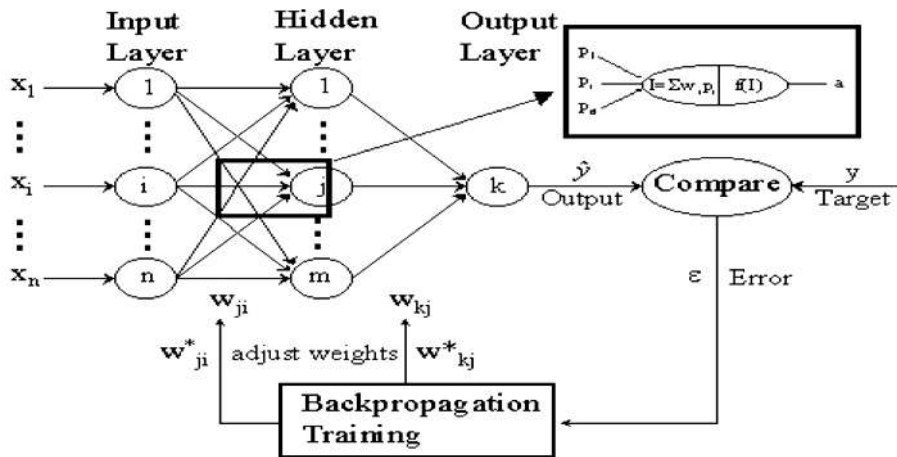
• مجموعة التحقق (Validation)، وتستخدم لتحقيق أفضل أداء للشبكة العصبية الاصطناعية على عينات

إدخال لم يتم التعرف عليها من قبل خلال مرحلة التدريب.

• مجموعة الاختبار (Testing)، وتستخدم لغرض التأكد من التوافق الأدائي لتدريب الشبكة.

إن إجراء عمليتي التحقق والاختبار هي لغرض التأكد من التوافق الأدائي للشبكة، ولمنع حدوث مبالغة بالتدريب (OverTraining) للشبكة المقترحة، بغية الوصول إلى الأوزان التي تربط مدخلات الشبكة بمخرجاتها بأمثل

شكل.



الشكل (2) نموذج الشبكة العصبية أمامية التغذية (FFNNs) مع خوارزمية الانتشار العكسي للخطأ [17].

B. تحويل الموجات Wavelet Transforms

قام العالم جوزيف فورييه في عام 1822 بإنتاج ما يعرف بتحليل فورييه (Fourier Transform)، وهو طريقة من أجل تمثيل الإشارات الدورية، باستخدام سلسلة من الجيب وجيب التمام، ثم تم تطويرها من أجل أي إشارة حتى لو لم تكن دورية، بإنهاء دورها إلى اللانهاية، عندها ينتج ما يعرف بتحويل فورييه، ويقوم تحويل بنقل السلسلة من مجال الزمن إلى مجال التردد وبالعكس [31].

إن تحويل الموجات يمثل تحليلاً متغيراً من ناحية تقسيم نافذة التردد بالنسبة إلى الزمن، مما يعطيه قوة في التحليل مقارنة مع تحويل فورييه، الذي يستخدم نافذة ثابتة العرض فهو غير فعال للإشارات غير الثابتة (متغيرة التردد)، لأنه لا يزودنا بمعلومات عن المحتوى الترددي خلال الزمن، كما هو موضح في الشكل (3)، فضلاً عن ميزته في اتخاذه أسلوب التحليل متعدد المستويات (Multiresolution Analysis)، حيث يتم التعامل مع السلسلة من خلال التفاصيل التي تنتج عند تحليلها إلى عدة مستويات، والممثلة بسلاسل فرعية (Sub-Series)، لها نفس طول السلسلة الأصلية، ويتم تحقيق ذلك بتمرير السلسلة الأصلية على مجموعات متتابعة من مرشحات التمرير المنخفض (Low Pass Filters) LPF، ومرشحات التمرير المرتفع (High Pass Filters) HPF، حيث ينتج عند كل مستوى تحليل معلومات ذات تردد منخفض، تدعى بالمعاملات التقريبية (Approximation, A)، ومعلومات ذات تردد مرتفع تدعى بالمعاملات التفصيلية (Detail, D)؛ وهذا ما يسمى بشجرة مالات [32] Mallat's Tree. كما أنها تتميز بملائمتها للتطبيق العملي على الحاسوب الرقمي وبشكل مباشر.

يمكن تمييز نوعان رئيسيان من تحويل الموجات المستخدم في معالجة الإشارة الرقمية وهما:

- تحويل الموجات المستمر (Continuous Wavelet Transform) CWT.
- وتحويل الموجات المتقطع (Discrete Wavelet Transform) DWT.

ويعرف تحويل الموجات (تحويل الموجات المستمر) رياضياً بالعلاقة (1) و(2):

$$\gamma(s, \tau) = \int f(t) \cdot \Psi_{s, \tau}(t) \cdot dt \quad \dots (1)$$

$$\Psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \cdot \Psi \left[\frac{t - \tau}{s} \right] \quad \dots (2)$$

حيث S هو عامل التدرج، والذي يمكن اعتباره معكوس التردد بالنسبة للموجة، ويتم ضغط الموجة عند التدرج المنخفض وتمديدها عند التدرج المرتفع، ولأنه يتم إجراء الحسابات للموجة بدلالة الزمن والتدرج فإنه يتم


تمثيلها (الموجة) على محوري الزمن والتدرج. ويسمى $\Psi_{s,\tau}(t)$ بالموجة الأم والذي نحصل من خلاله على بقية الموجات بتغيير قيم التدرج S والانتقال T.

يتم إجراء التحليل بإزاحة النافذة على طول الإشارة من أجل تدرج معينة (عرض معين للنافذة)، ثم يتم تكرار العملية لمختلف التدرجات (النوافذ)، لكن المشكلة هي العدد الهائل من الموجات الناتجة بسبب استخدام جميع التدرجات في عملية التحليل، والكم الهائل من المعلومات التي تنتج أيضاً لنفس السبب، وبالتالي فإن عملية المعالجة تتطلب زمناً طويلاً جداً، لذا تم حل هذه المشكلة بتطوير ما يعرف بتحويل الموجات المتقطع (DWT)؛ والاختلاف الرياضي بين معادلة CWT و DWT هو في الموجة الأم التي يعبر عنها في تحويل DWT بالعلاقة (3):

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{s_o}} \Psi \left[\frac{t - k \cdot \tau_o \cdot s_o}{s_o} \right] \dots (3)$$

حيث: k, j أعداد صحيحة و s_o هو درجة التأخر، و τ_o هو عامل الإزاحة. ويتم عادةً من أجل الإشارات في

الطبيعة وجعل s_o تساوي (2) و τ_o تساوي (1).



الشكل (3) يوضح تمثيل تحويل الموجات (تقسيم التردد إلى الزمن)

النتائج والمناقشة

A. إدخال البيانات ومعالجتها باستخدام تحويل الموجات Wavelet decomposition


الجانب التطبيقي يهدف إلى تطبيق نموذج الشبكات العصبية التقليدية ANN، والشبكات العصبية ذات تحويل الموجات WNN، على البيانات الزمنية للأمطار فقط، وذلك بتأخر زمنية للتنبؤ بهطول الأمطار لشهر مقدم في محطة حمص للأرصاء الجوية، وفق العلاقة (4):

$$R_{t+1} = f \{ R_t; R_{t-1}; R_{t-2}; \dots; R_{t-n} \} \dots (4)$$

حيث R: الأمطار الشهرية، t: الأشهر

ويهدف الحصول على أفضل هيكلية للشبكات العصبية، قسمت البيانات المتوافرة للأمطار إلى مجموعتين، المجموعة الأولى لبناء ومعايرة النموذج (1993-2000) (816 شهر)، والمجموعة الثانية للاختبار والتحقق من صحة النموذج (2001-2009) (108 أشهر).

من أجل إنجاز تحويل المتقطع DWT، استخدم البرنامج الجاهز Wavelet في لغة Matlab لتحليل السلاسل الزمنية للأمطار إلى معاملاتها التفصيلية والتقريبية إلى ثلاثة مستويات من الدقة، باستخدام الموجة Db5 من مجموعة الموجات دويغنز (Daubechies)، التي تتألف من 44 موجة، التي تتميز بملائمتها لطبيعة البيانات غير المنظمة في الدراسة الحالية [33]، حيث أن اختيار الموجة الأم لتحليل وفترة البيانات وعدد مستويات التحليل يتعلق بطبيعة البيانات، ومن خلال المحاولة والخطأ، حيث يتم فرض عدد من النماذج وزيادة عدد المدخلات بتأخر زمني واختيار النموذج الأفضل وفق المعايير الإحصائية المعتمدة؛ يبين الشكل (4) السلاسل الفرعية للمعاملات التفصيلية (d₁, d₂, d₃)، والتقريبية (a₃)، الناتجة عن تحليل سلسلة الأمطار إلى ثلاث مستويات من الدقة.



الشكل (4) تحليل السلاسل الزمنية للأمطار (2009-1933) إلى ثلاثة مستويات باستخدام تحويل الموجات

إن تحسين كفاءة الشبكة وسرعة العمليات الحسابية قبل استخدام السلاسل الزمنية الفرعية كمدخلات للشبكة، يتطلب إجراء عملية التقييس لقيم متجهات المدخلات والهدف، لجعل القيم محصورة بين مدى قصير نسبياً [0,1]، ولتقليل من قيمة الخطأ المحسوب بين قيم الهدف، والقيم الناتجة عن الشبكة، مما يمنع سيطرة المتغيرات ذات القيم الكبيرة أو الشاذة، وفي هذا السياق استخدمت الدالة اللوجستية (The Logistic Sigmoidal Function)، كتابع تنشيط (The Activation Function) لطبقة الخرج بحيث تكون المخرجات أرقاماً موجبة محصورة بين [0,1]، وتعرف معادلة التقييس المستخدمة رياضياً بالعلاقة (5):

$$p_{(nom)} = \frac{p - p_{(min)}}{p_{(max)} - p_{(min)}} \quad \dots\dots(5)$$

حيث: p: القيم الأصلية، p_(nom): القيم المعدلة، p_(min): أدنى قيمة مدخلة، p_(max): أقصى قيمة مدخلة.


ولغرض التحقق من الأداء الأفضل للشبكة تستخدم معايير مختلفة منها جذر متوسط مربعات الأخطاء RMSE (Root Mean Squared Error)، ومعامل التحديد R^2 (Coefficient Of Determination)، ومعامل الكفاءة COE (Coefficient Of Efficiency)، التي تعرف رياضياً بالعلاقة (6) و (7) و (8):

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (P_{obs} - P_{pre})^2}{N}} \quad \text{.....(6)}$$

$$R^2 = 1 - \frac{\sum_{t=1}^N (P_{obs} - P_{pre})}{\sum_{t=1}^N (P_{obs} - \bar{P}_{obs})^2} \quad \text{.....(7)}$$

$$COE = 1 - \frac{\left[\sum_{t=1}^N (P_{obs} - P_{pre})^2 \right]}{\left[\sum_{t=1}^N (P_{obs} - \bar{P}_{obs})^2 \right]} \quad \text{.....(8)}$$

حيث: P_{obs} : قيم المشاهدات الأصلية، P_{pre} : قيم التنبؤ الناتجة عن المحاكاة، متوسط القيم.



الشكل (5) الشبكة العصبية الصناعية بالاعتماد على تحليل الموجات

B. بناء الشبكة العصبية وطريقة تدريبها

بعد إجراء عملية التقييم استخدمت في هذه الدراسة حزمة الأدوات NN-Tool Box في برنامج Matlab لبناء الشبكة العصبية الصناعية أمامية التغذية ، التي تعتمد على خوارزمية Back Propagation Algorithm LM (Levenberg Marquardt)، للحصول على أوزان مثالية أثناء تدريب الشبكة، كما حدد عدد العصبونات، والطبقات الخفية من خلال المحاولة والخطأ، حيث يتم تغيير عدد عصبونات الطبقات الخفية مع تثبيت خوارزمية التدريب ودوال التنغيع للشبكات المشكلة، حتى الحصول على أقل قيمة لمتوسط مربعات الأخطاء MSE. وقد تم التوصل إلى هيكلية الشبكة العصبية الصناعية (1-8-8-8-5)] 5 عصبونات لطبقة المدخلات-3 عدد الطبقات الخفية (8 عصبونات في كل طبقة) - عصبون واحد لطبقة المخرجات] التي اعتبرت هي الأفضل في الأداء اعتماداً على قيمة مربعات الأخطاء المستنتجة لمجموعة التحقق (Validation)، والتي يتم انتقاءها عشوائياً من مجموعة بيانات المعايرة (15% من البيانات المعايرة)، ويمكن تعريف النموذج المختار لتمثيل بيانات الشبكة والتنبؤ رياضياً:

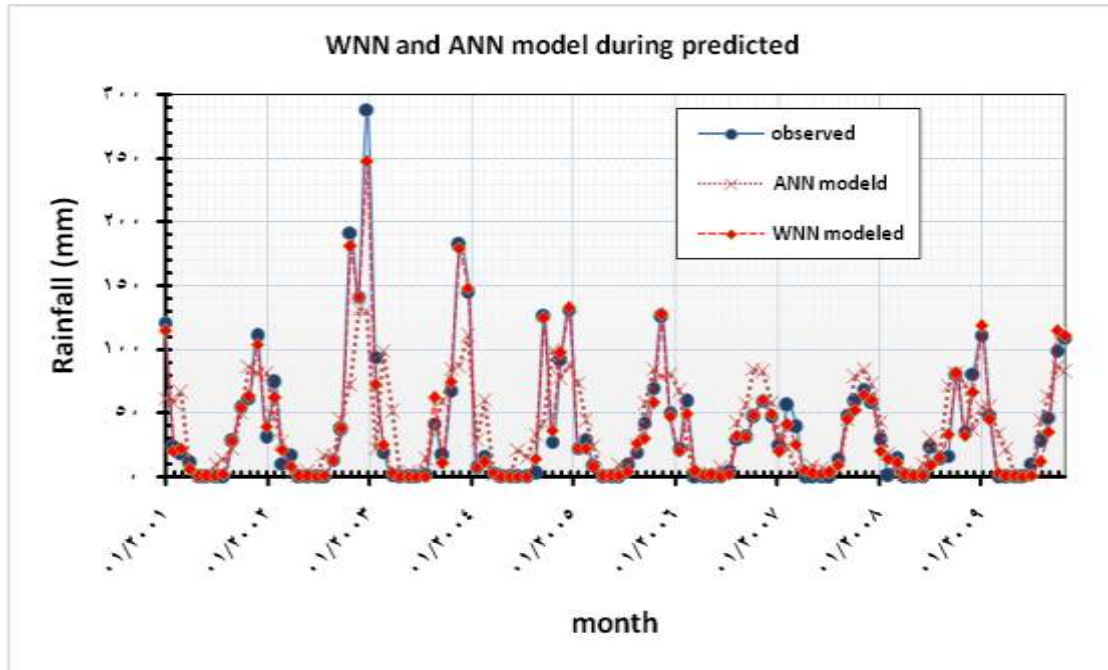
$$R_{t+1} = f\{R_t; R_{t-1}; R_{t-2}; R_{t-3}; R_{t-4}\}$$

في الجانب الآخر من التطبيق، استخدمت السلاسل الزمنية السابقة للأمطار الشهرية بعد إجراء عملية تحويل الموجات للبيانات كمدخلات للشبكة العصبية الاصطناعية، فكان الهيكل النهائي لنموذج WNN هو عدد المدخلات المستخدمة في ANN مضروب بـ 4 سلاسل فرعية لكل دخل فيصبح عدد عصبونات الدخل 20 عصبون و 3 عصبونات خفية، و 1 عصبون خرج.

يبين الجدول (2) مقارنة إحصائية لأداء نموذج ANN و WNN في مرحلتي المعايرة والاختبار، للتحقق من صحة النموذج؛ ويتضح من الجدول (2) و (3) والرسم البياني للقيم المتنبأ بها مع المشاهدات الأصلية في الشكل (6) لكلا النموذجين المقترحين، تفوق نموذج WNN بدقة على الشبكات العصبية التقليدية ANN، التي تفقد خاصية معالجة البيانات بتحويل الموجات المتقطع، وخاصة في تقدير الذرى، وقيم الأصفار في السلسلة الزمنية التي بلغت الحدود الدنيا المقبولة للخطأ بالنسبة لنموذج WNN؛ يبين المخطط المبعثر في الشكل (7) بين قيم المشاهدات والقيم المتنبأ بها باستخدام نموذج WNN مقدار تقارب القيم من بعضها البعض بمعامل تحديد ($R^2=0.98$)؛ وعليه يمكن استخدام النموذج المقترح WNN للتنبؤ بالأمطار الشهرية في محطة حمص لشهر مقدماً ولمدة طويلة نسبياً.

الجدول (2) مقارنة إحصائية للقيم الأمطار الشهرية في مرحلتي المعايرة (Calibration)، والتحقق من صحة النموذج (Predicted) من خلال أسلوب ANN و WNN.

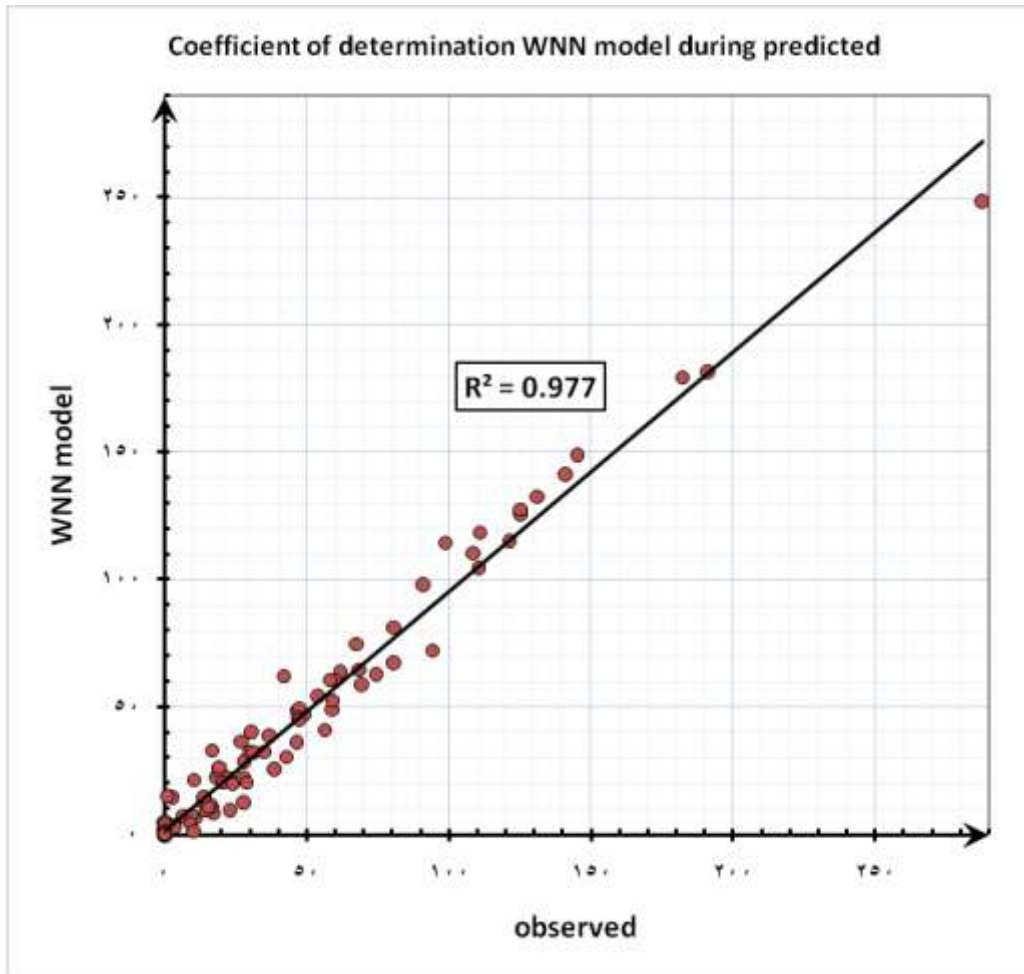
Model	Calibration			predicted		
	RMSE	R ²	COE(%)	RMSE	R ²	COE(%)
ANN	34.96	0.509	0.509	34.29	0.521	0.519
WNN	10.08	0.959	0.959	7.74	0.977	0.976



الشكل (6) قيم المشاهدات والقيم المتنبأ بها للأمطار الشهرية باستخدام ANN و WNN

الجدول (3) قيم الامطار الحقيقية والقيم المتنبأ بها وفق نموذجي ANN و WNN.

الاشهر	قيم الامطار الحقيقية	القيم الناتجة عن النموذج WNN	القيم الناتجة عن النموذج ANN	الاشهر	قيم الامطار الحقيقية	القيم الناتجة عن النموذج WNN	القيم الناتجة عن النموذج ANN
01/2001	121.4	61.5	114.8	07/2005	0	1.2	8.7
02/2001	24.6	58.7	20.3	08/2005	9.1	4.4	8.6
03/2001	18.1	66.3	22.5	09/2005	19.7	26.5	24.4
04/2001	11.1	4.7	6.3	10/2005	42.8	30.5	57.2
05/2001	0	1.6	0.7	11/2005	69.7	58.4	85.1
06/2001	0	1.2	0.7	12/2005	125.6	127.6	78.7
07/2001	0	8.8	1.0	01/2006	49.2	47.0	80.8
08/2001	0	13.1	2.3	02/2006	21	20.5	67.3
09/2001	28	22.0	28.3	03/2006	59.4	49.2	22.9
10/2001	54.4	51.0	54.0	04/2006	0.3	5.0	2.2
11/2001	61.7	86.9	63.4	05/2006	0	1.5	1.5
12/2001	110.6	80.2	104.3	06/2006	0	1.9	3.7
01/2002	30.9	82.1	39.8	07/2006	0	0.5	6.8
02/2002	74.4	46.0	62.4	08/2006	3.8	2.6	3.2
03/2002	10.4	26.9	21.5	09/2006	29.7	32.5	42.1
04/2002	17.2	3.6	8.4	10/2006	31.2	31.7	56.1
05/2002	0	1.6	1.0	11/2006	47.2	48.6	84.6
06/2002	0	3.9	0.7	12/2006	59.9	60.8	82.4
07/2002	0	2.1	0.3	01/2007	47.5	49.6	58.7
08/2002	0.3	17.6	1.6	02/2007	23.9	20.1	30.9
09/2002	13.6	15.9	12.9	03/2007	56.4	41.0	22.8
10/2002	37.3	45.6	38.3	04/2007	39.1	25.3	6.5
11/2002	191.5	73.0	181.2	05/2007	0	5.5	5.6
12/2002	141.4	132.0	141.0	06/2007	0	2.7	9.5
01/2003	288	129.8	248.2	07/2007	0	2.2	5.9
02/2003	94.2	22.7	72.3	08/2007	0	3.7	2.7
03/2003	19.7	99.1	24.9	09/2007	14.5	9.3	6.2
04/2003	1	51.1	3.5	10/2007	47	45.3	45.7
05/2003	0	1.4	0.1	11/2007	59.1	52.6	78.4
06/2003	0	2.9	0.1	12/2007	68.9	64.7	83.3
07/2003	0	1.5	0.1	01/2008	58.1	60.6	72.4
08/2003	1	13.9	0.5	02/2008	29	20.4	43.5
09/2003	41.9	39.8	62.3	03/2008	1	14.7	18.6
10/2003	16.8	59.5	10.8	04/2008	15.4	10.9	2.4
11/2003	68	85.0	74.6	05/2008	0	2.0	1.9
12/2003	182.2	86.6	179.5	06/2008	0	1.0	2.6
01/2004	145.4	110.6	148.5	07/2008	0	0.9	9.0
02/2004	7	29.5	7.5	08/2008	23	9.1	30.1
03/2004	16.5	60.7	11.8	09/2008	14.3	14.8	18.1
04/2004	3.6	2.1	3.1	10/2008	16.6	33.1	71.6
05/2004	0	1.2	0.2	11/2008	80.9	81.3	81.7
06/2004	0	1.1	0.5	12/2008	35.5	32.6	72.8
07/2004	0	21.4	0.3	01/2009	81	67.0	37.6
08/2004	0	15.7	0.2	02/2009	110.9	118.6	54.5
09/2004	2.8	33.8	14.2	03/2009	47.3	45.2	54.2
10/2004	125.6	42.6	125.3	04/2009	0	3.5	33.2
11/2004	27.4	98.4	36.6	05/2009	0	1.0	21.0
12/2004	91.3	77.5	97.6	06/2009	0	0.8	1.4
01/2005	131.5	87.4	132.6	07/2009	0	0.2	1.2
02/2005	22.2	73.8	22.5	08/2009	10.7	1.5	4.6
03/2005	28.2	44.1	22.4	09/2009	28.2	12.1	44.5
04/2005	9.5	23.2	7.9	10/2009	46.5	35.8	64.1
05/2005	0	1.4	0.7	11/2009	98.8	114.6	87.1
06/2005	0	1.2	0.7	12/2009	109	110.5	82.3



الشكل (7) معامل التحديد بين قيم المشاهدات والقيم المتنبأ بها للأمطار الشهرية لنموذج WNN

الاستنتاجات والتوصيات

- يُعدُّ نموذج الشبكة العصبية الصناعية أمامية التغذية ذات الانتشار العكسي للخطأ (بمعمارية 1-8-8-8-5)، والمعتمد على تحويل الموجات WNN أنموذجاً جيداً لتمثيل البيانات الشهرية للأمطار في محطة حمص، حيث قدّم هذا النموذج أفضل أداء من خلال المعايير الإحصائية، المستخدمة لتقييم أداء النماذج بالمقارنة مع الشبكات العصبية التقليدية، وعليه فإن تحويل الموجات يوفر أداة مفيدة في معالجة البيانات قبل تغذية الشبكة، ويمكن اعتباره جزءاً من بنية الشبكات العصبية.
- أشارت النتائج السابقة أن أنموذج WNN المقترح، هو الأفضل في التنبؤ بقيم الأمطار الشهرية في محطة حمص لشهر مقدماً بنتائج مرضية ($RMSE=7.74mm$ ، $R^2=0.98$)، وعليه يمكن استخدام النموذج المقترح للتنبؤ بالأمطار على المدى الطويل.
- يمكن استخدام تحويل الموجات لدراسة الظواهر المناخية الأخرى، والتعرف على الدورية فيها والتموجات ومعنوية الأخطاء العشوائية وتأثيرها، كما يمكن استحداث أسلوب ثنائي الموجة، ودراسة الظواهر من خلال التموج السطحي.

المراجع

1. GWANGSEOB, K; ANA, P. B. *Quantitative flood forecasting using multi sensor data and neural networks*. Journal of Hydrology, USA, 2001, 45–62.
2. FRENCH, M. N, KRAJEWSKI, W. F; CUYKENDALL, R. R. *Rainfall forecasting in space and time using neural network*. Journal of Hydrol, Amsterdam, Vol.137, 1992, 1–31.
3. SHRIVASTAVA, G; KARMAKAR, S; KOWAR, M, K; GUHATHAKURTA, P. *Application of Artificial Neural Networks in Weather Forecasting*. A Comprehensive Literature Review. International Journal of Computer Applications 51(18), 2012, 17-29.
4. الطائي، فاضل عباس. *التنبؤ والتمهيد للسلاسل الزمنية باستخدام تحويلات مع التطبيق*. المجلة العراقية للعلوم الإحصائية (17)، العراق، 2010، 293–308.
5. ROJAS, I; POMARES, H. *Soft-Computing Techniques for Time Series Forecasting*. ESANN 2004 Proceeding European Symposium on Artificial Neural Network-Bruges (Belgium), d-Side Publi, ISBN2-930307-04-8, 2004, 93-102.
6. THAPLIYAL, V. *Preliminary and Final Long Range Forecasts for Seasonal Monsoon Rainfall over India*. J. Arid Environ, 1997, 385–403.
7. GUHATHAKURTA, P; RAJEEVAN, M; THAPLIYAL, V. *Long Range Forecasting Indian Summer Monsoon Rainfall by Hybrid Principal Component Neural Network Model*. Meteorology and Atmospheric Physics, Springer-Verlag, Austria, 1999.
8. 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 Science, vol. 5, 2008, 183-218.
9. LEE, S; CHO, S; WONG, P. M. *Rainfall prediction using artificial neural networks*. Journal of Geographic Informaiton and Decision Analysis, vol. 2, 1998, 233-242
10. HSU, K; GAO, H; SOROSHIN, S; GUPTA, H. *Precipitation estimation from remotely sensed information using artificial neural networks*. J. Appl. Met. 36, 1997, 1176–1190.
11. KULLIGOWSKI, R. J; BARROS, A. P. *Localized precipitation from a numerical weather prediction model using artificial neural networks*. Weather and Forecasting 13, 1998, 1195–1205.
12. HALL, T. *Precipitation forecasting using a neural network*. Weather Forecasting 14, 1999, 338–345.
13. SILVERMAN, D; DRACUP, J. A. *Artificial neural networks and long-range precipitation prediction in California*. J. Appl. Met. 39(1), 2000, 57–66.
14. APPLEQUIST, S; GAHRS, G. E; PFEFFER, R. L. *Comparison of methodologies for probabilistic quantitative precipitation forecasting*. J. Am. Met. Soc. 17, 2002, 783–799
15. RAMIREZ, M. C. V; VELHO, H. F. C; FERREIRA, N. J. *Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region*. J. Hydrol. 301, 2005, 146–160.
16. ZHANG, B. L; DONG, Z. Y. *An adaptive neural-Wavelet model for short term load forecasting*. Chinese, Electric Power System Researches 59, 2001, 121–129.
17. KIM, T. W; VALDES, J. B. *Nonlinear model for drought forecasting based on a conjunction of Wavelet transforms and neural networks*. J. Hydrol. Engng ASCE 6, 2003, 319–328.

18. ANCTIL, F; TAPE, D. G. *An exploration of artificial neural network rainfall-runoff forecasting combined with Wavelet decomposition*. J. Environ. Engng Sci. 3, 2004, 121–128.
19. PARTAL, T; KISI, O. *Wavelet and neuro-fuzzy conjunction model for precipitation forecasting*. J Hydrol 342, 2007, 199–212.
20. 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.
21. TANTANEE, S; PATAMAKUL, S; OKI, T; SRIBOONLUE, V; PREMPREE, T. *Downscaled rainfall prediction model (DRPM) using a unit disaggregation curve (UDC)*. Hydrol. Earth Sys. Sci. Discuss, vol. 2, 2005, 543-568.
22. PHUSAKULKAJORN, W; LURSINSAP C. C; ASAVANANT, J. *Wavelet-Transform Based Artificial Neural Network for Daily Rainfall Prediction in Southern Thailand*, 2008.
23. PARTAL, T; CIGIZOGLU, H. K. *Prediction of daily precipitation using Wavelet-neural networks*. Hydrological Sciences–Journal–des Sciences Hydrologiques, Civil Engineering Department, Turkey, 2009.
24. MOUSTRIS, K; IOANNA K, L. *Precipitation forecast using artificial neural networks in specific regions of Greece*. Water Resour Manag 25, 2011, 1979–1993.
25. RAMANA, R. V; KRISHNA, B; KUMAR, S. R; PANDEY, N. G. *Monthly Rainfall Prediction Using Wavelet Neural Network Analysis*. Water Resour Manage 27, 2013, 3697–3711.
26. HAYKIN, S. *Neural Networks and Learning Machines*. Third Edition Prentice Hall International, 2009.
27. VANRULLEN, R. *The power of the feed-forward sweep*. Advances in Cognitive Psychology, vol. 3, no. 1-2, 2007, 167-176.
28. ALLENDE, H; MORAGA, C; SALAS, R. *Artificial Neural Networks in Time Series Forecasting: A Comparative Analysis*. Volume 88, Number 6, 2002, 685- 707.
29. ALYUDE, NouroIntelligence. *Neural Network Software*. 2003 <www.alyuda.com>.
30. SHAHIN, M. A; HOLGER, R. M; JAKSA, M. B. *Data Division for Developing Neural Networks Applied to Geotechnical Engineering*. Journal of Computing in Civil Engineering, Vol. 18(2), 2004, 105-114.
31. WALKER, J.S. *A Primer on Wavelets and Their Scientific Applications*. Second Edition, Taylor and Francis Group, LLC, 2008, PP.305.
32. MALLAT, S. A. *Wavelet Tour of Signal Processing*, Academic Press. 1997.
33. DAUBECHIES, I. *Ten Lectures on Wavelets*, SLAM, 1992.