

## استخدام الشبكات العصبية الصناعية مع تقنية التحويل المويجي للتنبؤ بالتدفق اليومي الوارد إلى بحيرة سد 16 تشرين

د. غطفان عمّار\*

د. باديه حيدر\*\*

(تاريخ الإيداع 17 / 10 / 2016. قُبل للنشر في 20 / 2 / 2017)

### □ ملخص □

يُعدُّ تقييم موارد المياه السطحية من المدخلات الضرورية لحل قضايا إدارة المياه، والتي تتضمن إيجاد علاقة بين الأمطار والجريانات السطحية، وتعتبر هذه العلاقة على درجة عالية من التعقيد، حيث أن الأمطار من أهم العوامل التي تؤثر بشكل كبير على جريان الأنهار، وعملية التنبؤ بهذه الجريانات يجب أن تأخذ هذا العامل بعين الاعتبار، وبكثير من الاهتمام والدراسة، وتعتبر الشبكات العصبية الصناعية من أهم الطرائق الحديثة من حيث دقة نتائجها في الربط بين هذه العوامل المتعددة والبالغة التعقيد. ومن أجل التنبؤ بالجريان اليومي الوارد إلى بحيرة سد 16 تشرين في اللاذقية، موضوع بحثنا، تم تطبيق نماذج مختلفة من الشبكات العصبية الصناعية (ANN)، كانت مدخلاتها تدفقات سابقة للأمطار والجريانات.

قسمت مجموعة البيانات للفترة الممتدة بين عامي (2006-2012) إلى مجموعتين: تدريب واختبار، وقد تم معالجة البيانات قبل إدخالها إلى الشبكة العصبية باستخدام تقنية تحويل الموجات المتقطع، للتخلص من مشاكل القيم العظمى والقيم الصفرية، حيث حللت السلاسل الزمنية إلى ثلاثة مستويات من الدقة واستخدمت السلاسل الفرعية الناتجة كمدخلات للشبكة العصبية أمامية التغذية التي تعتمد على خوارزمية الانتشار العكسي لتدريبها. أشارت النتائج إلى أن الشبكة العصبية ذات الهيكلية (1-2-6) نموذج Wavelet-ANN، هي الأفضل في تمثيل الظاهرة المدروسة والأقدر على التنبؤ بالجريان اليومي الوارد إلى بحيرة سد 16 تشرين ليوم واحد قادم، حيث بلغ معامل الارتباط وجذر مربع متوسط الخطأ ( $RMSE=1.97m^3/sec, R^2=0.96$ )، على الترتيب.

**الكلمات المفتاحية:** التنبؤ بالتدفقات، الشبكات العصبية الاصطناعية، تحويل الموجات المتقطع.

\* أستاذ - قسم الهندسة المائية والري - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

\*\* مدرسة - قسم الهندسة الإنشائية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

## Using Neural Networks models with Wavelet transform technology To Predict Flows Coming into 16 Tishreen Lake

Dr. Ghatfan Ammar\*  
Dr. Badia Haidar\*\*

(Received 17 / 10 / 2016. Accepted 20 / 2 / 2017)

### □ ABSTRACT □

The evaluation of surface water resources is a necessary input to solving water management problems, which includes finding a relationship between precipitation and runoff, and this relationship is a high degree of complexity. The rain of the most important factors that greatly effect on rivers discharge, and process to prediction of these flows must take this factor into account, and much of the attention and study, artificial neural networks and is considered one of the most modern methods in terms of accuracy results in linking these multiple factors and highly complex. In order to predict the runoff contained daily to Lake Dam Tishreen 16 in Latakia, the subject of our research, the application of different models of artificial neural networks (ANN), was the previous input flows and rain.

Divided the data set for the period between (2006-2012) into two sets: training and test, has been processing the data before using them as inputs to the neural network using Discrete Wavelet Transform technique, to get rid of the maximum values and the values of zero, where t the analysis of time series at three levels of accuracy before they are used sub- series resulting as inputs to the Feed Forward ANN that depend back-propagation algorithm for training.

The results indicated that with the structural neural network (1-2-6) Wavelet-ANN model, are the best in the representation of the characteristics studied and best able to predict runoff daily contained to Lake Dam Tishreen 16 for a day in advance, where he reached the correlation coefficient the root of the mean of squared-errors ( $R^2 = 0.96$ ,  $RMSE = 1.97m^3 / sec$ ), respectively.

**Keywords:** Streamflow Prediction, Artificial Neural Network, Discrete Wavelet Transform

---

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

\*\* Associated Professor, Department of Structural Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

## مقدمة

يعتبر التقييم والتخطيط وإدارة المصادر المائية أحد المواضيع المهمة في الحياة البشرية، وبالأخص في المناطق التي تتميز فيها الأمطار بالندرة أو يكون فيها التوزيع المطري رديئاً وغير منتظم، وكذلك في حال الوجود المحدود للمياه الجوفية، وعليه تعتبر إقامة المنشآت الهيدروليكية كالسدود والخزانات من الأمور المهمة لغرض استخدامها في خزن الكميات الزائدة من المياه في مواسم الفيضان لاستخدامها لأغراض مختلفة، لذلك يعتبر التنبؤ بالجريان في النهر مع الأخذ بعين الاعتبار تأثير الأمطار عاملاً رئيسياً في مجال تصميم السدود، حيث يوفر رؤية واضحة عن أقصى فيضان محتمل حدوثه وبالتالي تفادي انهيار المنشأة.

يعدّ حوض نهر الكبير الشمالي (وتحديداً الجزء الأدنى منه)، من الأحواض المائية الأساسية الذي شهد في السنين الأخيرة تطوراً سريعاً، وشاملاً في مختلف المجالات، فقد انتشرت الزراعة المروية، والمعامل، والورشات الصناعية، كما شهدت المنطقة توسعاً سكانياً كبيراً، وقد أدت مجمل هذه التغيرات إلى ظهور مشكلات مائية تتلخص بمدى المحافظة على كمية ونوعية المياه.

معظم الأعمال السابقة القائمة على التنبؤ بتدفقات الأنهار والتي ذكرت في المراجع العلمية على نطاق واسع يمكن أن تقسم إلى مجموعتين رئيسيتين، نماذج فيزيائية مادية (نماذج اعتبارية) وأخرى قائمة على البيانات. بالرغم من وصف كافة العمليات الهيدرولوجية على أساس القوانين الفيزيائية في النماذج الاعتبارية، غير أن هذه النماذج لم تلق شعبية كبيرة لأنها تتطلب بيانات كثيرة والمعادلات التفاضلية الحاكمة معقدة التنفيذ، وعلى سبيل المقارنة، اكتسبت النماذج القائمة على البيانات، شعبية في الآونة الأخيرة في التطبيقات الهيدرولوجية بسبب تطورها السريع لارتباطها بالبرمجيات، واعتمادها على عدد أقل من البيانات وسهولة التنفيذ في الوقت الحالي [1]؛ وعموماً هذه النماذج تقوم على إيجاد علاقة بين المدخلات والمخرجات دون الاعتماد صراحة على القوانين الفيزيائية التي تحكم العمليات الهيدرولوجية .

النماذج الإحصائية والشبكة العصبية الاصطناعية وتقنيات التنبؤ الأخرى القائمة على أساس نهج نظري (نظام التشغيل) لاقت انتشاراً كبيراً على أساس البيانات؛ ومع ذلك، النماذج النظرية المعتادة مثل نماذج الانحدار الخطي وغيرها [2] المبنية على نظرية النظام الخطي والمرتبطة مباشرة بالزمن، ربما يكون من غير المناسب استخدامها للتعبير عن علاقة الهطل\_الجريان غير الخطية؛ المعقدة للغاية والمتغيرة ديناميكياً [3,4]، وخاصةً مع البيانات ذات الخصائص العابرة مثل الانحدارات والاتجاهات والتغيرات المفاجئة؛ وبالرغم من أن الشبكة العصبية الاصطناعية لديها القدرة على معرفة العلاقة بين المدخلات والمخرجات غير الثابتة [5]، فإن هيكلتها المثلى من الصعب تحديدها، وبالإضافة إلى ذلك، فإن سطح دالة الهدف من الشبكة العصبية هو غير محدب ويحتوي على نقاط مثلى محلية صغرى متعددة.

في العقود الأخيرة، أصبح تحويل الموجات تقنية مفيدة في مختلف البحوث المائية القائمة على أساس تحليل سلسلة البيانات في كل من مجالي التردد والزمن على عدة مستويات من الدقة، وينتج عن ذلك كشف الاختلافات والدوريات والاتجاهات المخبأة بشكل طبيعي في السلسلة الزمنية غير المستقرة كالأمطار والتدفقات مما يحسن من أداء النموذج [6]، وخاصةً إذا كان المقصود إيجاد علاقة معقدة للغاية كالهطل\_جريان، حيث هذا التعقيد يعود لعدم تجانس خصائص الحوض الهيدرولوجي وعدم انتظام الهطول، وكذلك العديد من العوامل الأخرى المشاركة في توليد الجريان منها التبخر ومعدل التسرب ورطوبة التربة والأمطار وتدفق المجرى نفسه [7].

اقترح **Wang & Ding** نموذج هجين WNN جمع بين الشبكات العصبية الاصطناعية أمامية التغذية (Feed Forward ANN) FF-ANN مع خوارزمية (back-propagation algorithm) PB لتدريبها، وكذلك تقنية تحويل الموجات Wavelet transform لمعالجة البيانات المدخلة للشبكة، وذلك بهدف التنبؤ بالتدفقات اليومية على المدى القصير والطويل بالاعتماد على بيانات التصاريح اليومية لنهر Yangtze في الصين على مدى 10 سنوات (8 سنوات للمعايرة، سنتين للتحقق من صحة النموذج)، وأشارت النتائج إلى أن تقنية تحويل الموجات تلعب دوراً مهماً في تحسين الدقة وإطالة الفترة الزمنية للتنبؤ [8].

درب **Cannas, B; et al.** نموذج شبكة عصبية اصطناعية (Multi-layer perceptron) MLP، للتنبؤ بالتدفقات الشهرية بالاعتماد على بيانات الأمطار قبل شهر على مدى 69 عاماً فوق حوض Tirso في إيطاليا، والتي تتميز بعدم الاستقرار وعدم انتظام الموسمية، وأشارت النتائج إلى أن الشبكة العصبية التي تستخدم تحويل الموجات المتقطع (Discrete Wavelet Transform) DWT في معالجة البيانات المدخلة للشبكة توفر أفضل أداء، حيث بلغت الدقة لمجموعة الاختبار ( $R^2=0.47$ ,  $RMSE=11.59$ )، بينما بلغت دقة تحويل الموجات المستمر ( $R^2=0.45$ ,  $RMSE=11.74$ )، وفي حال استخدام البيانات الخام ( $R^2=0.42$ ,  $RMSE=29$ )، في حين كان أداء كل من DWT و CWT ضعيف في تقدير القيم المنخفضة للتدفق وجيد في تقدير القيم العالية والمتوسطة للتدفق بكفاءة 90% [9].

تحرى **Atiaa; A.M** في إمكانية تطبيق وأداء النماذج العصبية لغرض التنبؤ قصير المدى بتصاريح نهر الغراف في الناصرة جنوب العرق بالاعتماد على البيانات التاريخية لتصاريح النهر في الموقع نفسه (333 شهر)، حيث استخدمت الشبكة العصبية متعددة الطبقات MLP مع خوارزمية PB، فأظهرت النتائج قدرة الشبكات العصبية على التنبؤ بالتصاريح الحالية  $Q_t$  بدقة ( $R^2=0.85$ ) ولشهر مقدماً  $Q_{t+1}$  بدقة ( $R^2=0.75$ ) ولشهرين  $Q_{t+2}$  بدقة ( $R^2=0.70$ ) [10].

تنبأ **Partala, T** بالتدفقات الشهرية لأنهار في تركيا باستخدام ثلاثة أنواع من الشبكات العصبية وهي: RBF, Generalized feed-forward back-propagation Neural Network) GRNN, FFBP (Radial Basis Function, Regression)، مع تقنية تحويل الموجات في معالجة السلاسل الزمنية للتدفقات قبل استخدامها كمدخلات للنماذج وذلك بتأخر زمني ( $Q_{t-1} \dots Q_{t-5}$ )، فتبين أن Wavelet-FFBP تقدم أفضل أداء من الشبكات الأخرى بدقة ( $R^2=0.91$ ,  $RMSE=4.83$ ) في محطة Rustumkoy [11].

استخدم **Mittal, P; et al.** نمطين من الشبكات العصبية للتنبؤ بالتدفقات الساعية لنهر في حوض Kolar في الهند، وذلك بالاعتماد على البيانات التاريخية للتدفق ومتوسط الهطول لثلاث محطات، وأشارت نتائج المقارنة إلى تفوق نموذج FF-ANN بدقة ( $R^2=0.98$ ,  $RMSE=23.24$ )، على الشبكة ذات النظام الثنائي (Dual-ANN) بدقة ( $R^2=0.98$ ,  $RMSE=27.16$ ) [12].

قام **Baojian & Chuntian** بالتنبؤ بتدفقات نهر لشهر مقدماً، باستخدام خوارزمية تعلم جديدة لتدريب الشبكة العصبية أمامية التغذية ذات الطبقة الواحدة SLFNS-ELM تدعى Extreme Learning Machine (ELM) كمنافس لأداء خوارزمية Support Vector Machine (SVM) لإيجاد المعاملات الأكثر ملائمة، وبالتالي الحصول على تنبؤ أكثر دقة في وقت قصير، واقترح للمقارنة نموذج WNN-ELM، فتبين أن أفضل أداء كان لنموذج WNN-ELM بدقة ( $R^2=0.883$ ,  $RMSE=62.78$ ) لمجموعة التحقيق بينما بلغت الدقة لنموذج SVM ( $86.57$ )

الزمنية للتحقق من صحة النموذج من خزانين في جنوب غرب الصين [13].  
 $(R^2=0.793, RMSE=)$  ولنموذج SLFNS-ELM  $(R^2=0.882, RMSE= 77.71)$  حيث تستمد السلاسل

بحث **Sahay, R. R** في إمكانية الجمع بين تقنية تحويل الموجات المتقطع DWT والانحدار الخطي AR (Auto Regression) في نموذج WR (Wavelet Regression) للتعويض بالتدفقات الموسمية في نهر Kosi في الهند، والتي تتميز بقيمتها العالية وغير المنتظمة ووجود اختلافات كبيرة فيما بينها، وأشارت النتائج إلى أن نموذج WR القائم على معدلات التدفق لثلاثة أيام سابقة كمدخلات، يوفر أفضل تقدير لقيم التدفق بدقة (90.4%)، بينما بلغ أفضل توقع لنموذج AR و ANN بدقة (82.2%-87.8%) على التوالي [14].

### موقع منطقة الدراسة والبيانات

ينبع نهر الكبير الشمالي من المنطقة الشمالية الغربية للجبال الساحلية، من المرتفع الواقع عند الحدود التركية على ارتفاع يتجاوز الـ (1100) م قاطعاً مسافة (89) كم، ليصب جنوب مدينة اللاذقية مباشرةً في البحر المتوسط .  
 يحد حوض نهر الكبير الشمالي من الشرق حوض نهر العاصي، ومن الجنوب الشرقي حوض نهر الصنوبر ومن الشمال الغربي عدة أحواض صغيرة.

تبلغ مساحة حوضه الصباب من المنبع حتى المصب (1097) كم<sup>2</sup>، ويقسم النهر إلى ثلاثة أقسام هي:

القسم الأول: يمتد من الحدود الدولية حتى التقائه بنهر السفكون ويبلغ طوله 18 كم .

القسم الثاني: يمتد من قرية السفكون وحتى قرية خان عطا الله ويبلغ طوله 17 كم، ويجري على ارتفاع

375م، ويقع في هذا القسم سد 16 تشرين.

القسم الثالث: يمتد 23 كم في الأراضي الساحلية ويستفاد منه في ري الأراضي الزراعية المجاورة عن طريق

أقنية محمولة، وعلى بعد 9 كم من مصبه يستقبل الكبير الشمالي أهم روافده على الجانب الأيسر نهر القش والذي تبلغ مساحة حوضه الصباب (150 كم<sup>2</sup>)، ويصب نهر الكبير الشمالي في البحر على بعد 4 كم جنوب مدينة اللاذقية.

يتميز حوض نهر الكبير الشمالي بشكل عام، بوجود غطاء نباتي كثيف، وتكثر النباتات والأعشاب الموسمية وغيرها. كما يتصف الحوض بالخصائص الآتية:

يصل طول الحوض إلى (65) كم والعرض الوسطي له (17) كم والعرض الأعظمي (25) كم، والارتفاع

الوسطي (680) م .

ميول المجرى من سد 16 تشرين وحتى المصب ليست كبيرة وهي بحدود (0.0012)، تتراوح كثافة المسيلات

في حوض نهر الكبير الشمالي بين (2 - 3.5) كم/كم<sup>2</sup>، وهي تتناقص من أعلى الحوض إلى أسفله وذلك بسبب تغير تضاريس الحوض من جبلية في الأعلى إلى سهلية تقريباً في الأسفل عند المصب.

متوسط الهطل المطري على الحوض للسنوات العشرين الأخيرة (900) ملم ، وقد أعطت الدراسات السابقة قيماً

لمعدل الأمطار يتراوح بين (800 - 1200) مم . حيث أن الأمطار في هذه المنطقة غزيرة نسبياً وخصوصاً في قسمه الأعلى.

توجد محطة لقياس التدفق على نهر الكبير الشمالي (محطة غمام)، تقع بالقرب من بحيرة سد 16 تشرين.

ويرتبط التدفق ارتباطاً وثيقاً بكميات الهطل المطري فوق الحوض الساكب للنهر.

البيانات المتوفرة هي البيانات اليومية للتصارييف والهطل المطري التي تم جمعها للفترة من شهر آذار لعام 2006 ولغاية شهر نيسان لعام 2012 والتي تتضمن 2253 يوماً. يتطلب استخدام تقنية الشبكات العصبية تقسيم مجموعة البيانات إلى مجموعتين؛ المجموعة الأولى تستخدم للتدريب ومعايرة النموذج Training data set والمجموعة الثانية تستخدم لتحقيق وتقييم نتائج النموذج Validation data set؛ يفضل عادةً أن تكون مجموعة بيانات التدريب حاوية على القيم العظمى والصغرى والتي تساعد الشبكة في عملية الاستيفاء interpolation وعملية التنبؤ ضمن هاتين القيمتين لأنه من المعروف أن الشبكات العصبية الاصطناعية ضعيفة في مجال التقدير الاستقرائي extrapolation؛ عند فحص البيانات تبين أن القيم العظمى والصغرى للتصارييف تتركز في الربع الأخير من البيانات، وعليه تقرر استخدام بيانات التصارييف (2006-2007) (671 يوماً) كمجموعة بيانات للتدريب (تمثل 40% من البيانات المتوفرة)، واستخدام بيانات التصارييف (2007-2012) (1582 يوم) كمجموعة بيانات للتحقق والتقييم (تمثل 60% من البيانات المتوفرة). يبين الجدول (1) المجموعات الإحصائية عن البيانات الكاملة وبيانات التدريب وبيانات التحقق والتقييم المستخدمة في بناء النموذج والتحقق من أداءه.

الجدول (1) المجموعات الإحصائية لقيم الأمطار والتدفقات في محطة 16 تشرين

Statistics		Minimum	Maximum	Mean	Median	S. deviation	Skewness
Flow (m <sup>3</sup> /sec)	Whole data set	0.1	388.8	7.5	1.0	19.4	7.6
	Training data set	0.1	388.8	9.1	1.2	22.2	6.9
	Validation data set	0.1	148.2	3.8	1.0	9.4	7.8
Rinfall (mm)	Whole data set	0.0	135.5	2.5	0.0	8.9	5.7
	Training data set	0.0	135.5	2.7	0.0	9.4	5.7
	Validation data set	0.0	75.0	2.0	0.0	7.6	5.4

### أهمية البحث وأهدافه:

يعد توقع تدفقات الأنهار من المعلومات الأساسية المدخلة في قضايا تخطيط وإدارة موارد المياه وتحويل المياه ومكافحة الفيضانات والاستدامة البيئية، ويكمن الجانب المستقبلي من هذه النماذج في الحد من مخاطر الفيضانات من خلال توفير نظام إنذار بالفيضان يتضمن إيجاد علاقة معقدة بين الأمطار والجريان السطحي، بالإضافة إلى إدارة نظام تشغيل السدود في حالة الجريانات المنخفضة.

تهدف هذه الدراسة إلى استخدام نموذج Wavelet-ANN الشبكة العصبية الاصطناعية أمامية التغذية ذات الانتشار العكسي للخطأ FFBP مع تقنية تحويل الموجات في معالجة السلاسل الزمنية اليومية للأمطار والتدفقات لنهر الكبير الشمالي لأزمة سابقة، بهدف التنبؤ بالتدفقات ليوم مقدماً على المدى الطويل، بالإضافة إلى فحص قدرة النموذج المقترح على تقدير القيم العظمى والصغرى باستخدام المؤشرات الإحصائية المناسبة.

### طرائق البحث ومواده

#### تحويل الموجات Wavelet Transform

نظرية الموجات (Wavelet) هي عبارة عن طريقة تحليلية رياضية تستخدم من أجل معالجة الإشارات للعديد من التطبيقات العملية كمعالجة الصور وضغط البيانات ومعالجة الإشارات الرقمية بأنواعها، وقد أصبح هذا التحويل

واحد من أهم وأقوى الأدوات لتمثيل الإشارة في الوقت الحاضر. إن أساس هذه النظرية هو نتاج عمل العالم فوربييه مع العلم أنه قد تم إجراء الكثير من التطوير على النظرية الأساسية.

بدايةً في تحويل فوربييه التقليدي نحن نستخدم الجيب كتابع أساسي، والذي يستطيع أن يوفر معلومات عن التردد فقط، وبالتالي يتم فقدان المعلومات الزمنية في هذه العملية للتحويل. في بعض التطبيقات نحن بحاجة إلى معرفة التردد والمعلومات الزمنية في نفس الوقت (خاصةً بالنسبة للإشارات غير ثابتة التردد)، مثل النوتات الموسيقية musical score، نحن نريد أن نعرف ليس فقط النوتة (الترددات) التي نريد عزفها بل أيضاً تمثيلها في نفس الوقت. على عكس تحويل فوربييه التقليدي فإن تحويل الموجات يعتمد على موجات صغيرة تدعى الموجات (wavelets) والتي يمكن أن تظهر معلومات التردد والزمن عن طريق هذه الموجات [15]، مما يزيد من قدرة الشبكات العصبية على استنتاج المعلومات الضرورية والموجودة بشكل طبيعي في البيانات. الشكل (1) بين آلية بناء النموذج بعد إجراء عملية التحويل الموجي للسلاسل الزمنية واستخدام السلاسل الزمنية الفرعية كمدخلات.

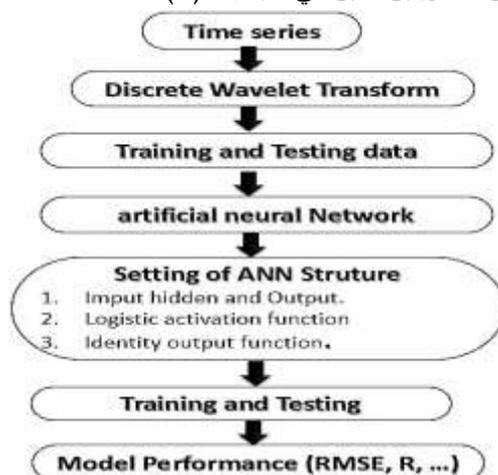
**الموجة:** هي إشارة محدودة الاستمرارية متوسطة صفر على العكس من الإشارة الجيبية التي تمتد نظرياً

من  $(-\infty, +\infty)$  والموجة لها بداية ونهاية كما هو موضح بالشكل (2).

هناك نوعان رئيسيان من تحويل الموجات: تحويل الموجات المستمر (Continuous Wavelet ) CWT

و تحويل الموجات المنقطع (Discrete Wavelet Transform) DWT الذي يستخدم في معالجة

الإشارة الرقمية المتقطعة، والفرق بين التحويلين مبين في الجدول (2).



الشكل (1) مخطط رسومي لعمليات بناء النموذج WNN



الشكل (2) موجة db5

الجدول (2) مقارنة بين تحويل الموجات المتقطع والمستمر

CWT	DWT
معلومات كثيرة وزائدة عن الحاجة	معلومات قليلة وكافية
موجات كثيرة وزائدة عن الحاجة	موجات قليلة وكافية
وقت حساب كبير	وقت حساب صغير
تستخدم للإشارات اللانهائية الطاقة	تستخدم لكل الإشارات

### تحويل الموجة المتقطعة Discrete Wavelet Transform

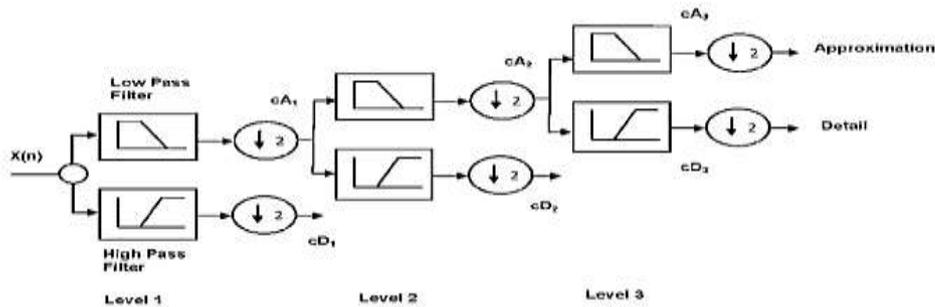
إن تحويل الموجة المتقطعة يحلل الإشارة إلى حزم ترددية مختلفة وكثافات مختلفة وذلك بتحليل الإشارة إلى معلومات مفصلة (Detail) ومعلومات تقريبية (Approximation) [16,17] كما هو موضح في المعادلتين:

$$c_{j+1}(k) = \sum_m L(z) \cdot (m - 2k) c_j(m)$$

$$d_{j+1}(k) = \sum_m H(z) \cdot (m - 2k) c_j(m)$$

يتم فصل تردد الإشارة المدخلة إلى حزم تردد مساوية لعرض الحزمة بواسطة المرشحين  $L(Z)$ ،  $H(Z)$ ، وهما مرشحي تمرير منخفض ومرتفع على التوالي، حيث يحتوي المُخَرَج من المرشحين على نصف التردد ولكن مساوياً لمجموع العينات لإشارة الإدخال، ويحتوي الإخراجان معاً على محتوى التردد نفسه للإشارة المدخلة، وبذلك تتم مضاعفة كمية البيانات. يتم تطبيق ذلك بأخذ نصف العينات في كل مرحلة إذ يشير الرمز  $(\downarrow 2)$  إلى النواتج من المرشحات، وهذا ما يسمى بشجرة مالات Mallat's Tree [18]، والشكل (3) يوضح آلية تحليل إشارة الدخل إلى معاملات التفصيلية والتقريبية على ثلاث مستويات من المرشحات.

يوجد العديد من الموجات التي يمكن استخدامها لإجراء تحويل الموجات المتقطع وعموماً اختيار الموجة الأم يعتمد على نوع البيانات التي سيتم تحليلها، وتحويل الموجات دوبيغيز Daubechies شائع الاستخدام كموجة أم، لما توفره من معلومات جيدة ليست بالكثيرة ولا بالقليلة، بالإضافة إلى كونها تنتج أحداثاً مماثلة للسلاسل الزمنية المرصودة [19]. في هذا السياق، تم اعتماد الموجة غير النظامية (Db5) من عائلة موجات Daubechies.



الشكل (3) تحليل إشارة الدخل على ثلاثة مستويات (multiresolution)

### الشبكات العصبية أمامية التغذية (Feed-Forward Back-Propagation Neural Network)

الشبكة العصبية الاصطناعية هي عبارة عن شبكة مكونة على غرار هيكل وسلوك الخلايا العصبية في الدماغ البشري، من خوارزميات حاسوبية قادرة على التكيف بالشكل المطلوب تبعاً للمعرفة المتكونة لها من خلال التجربة [20]، يمكن تدريب الشبكة للتعرف على الأنماط المعقدة وتصنيفها

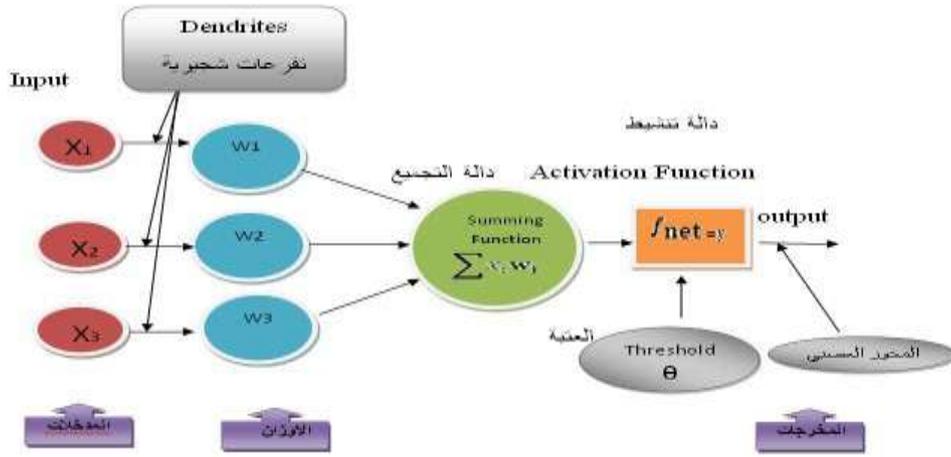
تتكون الشبكة العصبية الاصطناعية كما هو موضح في الشكل (4) من عدد من عناصر المعالجة البسيطة تدعى بالعصبونات Neurons وكل عصبون يرتبط مع العصبونات الأخرى بأداة ربط مباشرة وكل أداة ربط تفرق بوزن Weights، وهذه الأوزان تمثل المعلومات التي ستبدأ بها الشبكة بحل المشكلة. إن وحدات المدخلات لا تقوم بتطوير البيانات ولكنها ببساطة تقوم بتوزيع المعلومات إلى الوحدات الأخرى، حيث أن الطبقة المخفية تحوي عصبونات تسمى بالعصبونات المخفية، وطبقة الإخراج تحوي وحدات الإخراج والتي تقوم بتوجيه القيم الممكنة أو المقترحة التي يمكن تعيينها للحالة تحت الدراسة.

يعتبر تعيين القيم الابتدائية للأوزان عملية بالغة الأهمية، فالتخمين الأولي الأقرب إلى القيم المثلى للأوزان يساعد على تعميم أسرع للشبكة. مع هذا فلا توجد طريقة معينة لعمل تخمين أولي جيد للأوزان لذا فإنها تعتمد على تعيين قيم ابتدائية عشوائية. عندما تنتهي عملية التدريب يجب أن تثبت جميع الأوزان [21].

تدرب شبكة FFNN عادة باستخدام خوارزمية التدريب المسماة بطريقة الانتشار العكسي Back-propagation والتي هي نوع من تقنيات الهبوط اعتماداً على درجة الانحدار Gradient descent مع نشر الخطأ العكسي، وهي حالياً من أكثر الطرائق شيوعاً لتدريب الشبكات العصبية الاصطناعية من نوع FFNN، وهي طريقة نظامية لتدريب الشبكات العصبية متعددة الطبقات، وتستخدم في هذه الطريقة مجموعة أزواج بيانات إدخال وإخراج تسمى (Patterns). تغذى الشبكة بمجموعات بيانات الإدخال إلى الشبكة لإنتاج بيانات الإخراج والتي تقارن مع القيم الحقيقية للمخرجات، فإذا لم يكن هناك فروقات ملموسة بين القيم الحقيقية للمخرجات والقيم الناتجة عن الشبكة، عندها لا تحتاج الشبكة إلى تدريب إضافي، وفي حال وجود فروقات تستمر عملية التدريب وتنتشر الأوزان باتجاه الخلف ابتداءً من طبقة الإخراج ثم الطبقة المخفية وصولاً إلى طبقة المدخلات. بما أن التدريب يستخدم بيانات إخراج حقيقية، فإن طريقة الانتشار العكسي يشار إليها بطريقة تدريب بإشراف معلم Supervised. إن دالة الأداء المثالية المستخدمة لتدريب الشبكات العصبية ذات التغذية الأمامية هي معدل مجموع مربعات خطأ الشبكة:

$$MSE = \frac{1}{N} \sum_{j=1}^N (T_j - O_j)^2$$

حيث أن  $T_j$  هو الهدف المأمول و  $O_j$  هو الناتج الحقيقي عند وحدة الإخراج  $j$  [22]. استخدمت خوارزمية التدريب Levenberg-Marquardt [23] في هذه الدراسة لتدريب شبكة FFNN والتي هي واحدة من أسرع خوارزميات التدريب وينصح بها لتدريب الشبكات الصغيرة والمتوسطة الحجم والتي تحوي على عدة مئات من الروابط بين العصبونات.



الشكل (4) مكونات الخلية العصبية الاصطناعية

من أجل تحسين عملية التدريب وتحسين أداء الشبكات العصبية الاصطناعية يتم تحويل بيانات الإدخال والإخراج بحيث تكون محصورة ضمن نطاق معين، وفي هذه الدراسة تم حصر قيم البيانات بين 0 و 1 أي جعل القيم قياسية، ليتم فيما بعد ردها إلى القيمة الأصلية بعملية عكسية، وقد تم استخدام المعادلة الآتية من أجل تقييس البيانات:

$$P_{(norm)} = \frac{P - P_{(min)}}{P_{(max)} - P_{(min)}}$$

حيث: P: القيم الأصلية، P<sub>(norm)</sub>: القيم المعدلة، P<sub>(min)</sub>: أدنى قيمة مدخلة، P<sub>(max)</sub>: أقصى قيمة مدخلة. وضعت مجموعة من أنماط التدريب كمدخلات للشبكة العصبية أمامية التغذية وذلك بتأخرات زمنية لفترات سابقة، وتم اعتماد ثلاثة أنماط لمدخلات الشبكة لتقدير قيم التدفقات ليوم مقدماً. يبين **الجدول (3)** أنماط المدخلات الثلاثة المستخدمة في التدريب.

اعتمدت ثلاثة معايير لتقييم أداء الشبكات العصبية الاصطناعية وهي معامل الارتباط  $R^2$  (Correlation Coefficient) وجذر متوسط مربعات الأخطاء RMSE (Root Mean Squared Error)؛ والخطأ النسبي (Relative Error) RE وتعرف هذه المعايير رياضياً بالعلاقات الآتية:

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

$$R^2 = \frac{\sum_{t=1}^N (P_{obs} - \bar{P}_{obs})(P_{pre} - \bar{P}_{pre})}{\sqrt{\left[ \sum_{t=1}^N (P_{obs} - \bar{P}_{obs})^2 \right] \left[ \sum_{t=1}^N (P_{pre} - \bar{P}_{pre})^2 \right]}}$$

$$RE = \frac{1}{N} \sum_{t=1}^N \frac{|P_{obs} - P_{pre}|}{P_{obs}}$$

حيث: N: عدد البيانات، P<sub>obs</sub>: قيم المشاهدات الأصلية، P<sub>pre</sub>: قيم التنبؤ الناتجة عن المحاكاة،  $\bar{P}$  متوسط

القيم.

الجدول (3) أنماط المدخلات للشبكة

Model	Input Variables
I	$Q(t+1) = f(Q_t, R_t, R_{t-1}, R_{t-2})$
II	$Q(t+1) = f(Q_t, Q_{t-1}, R_t, R_{t-1}, R_{t-2})$
III	$Q(t+1) = f(Q_t, Q_{t-1}, Q_{t-2}, R_t, R_{t-1}, R_{t-2})$

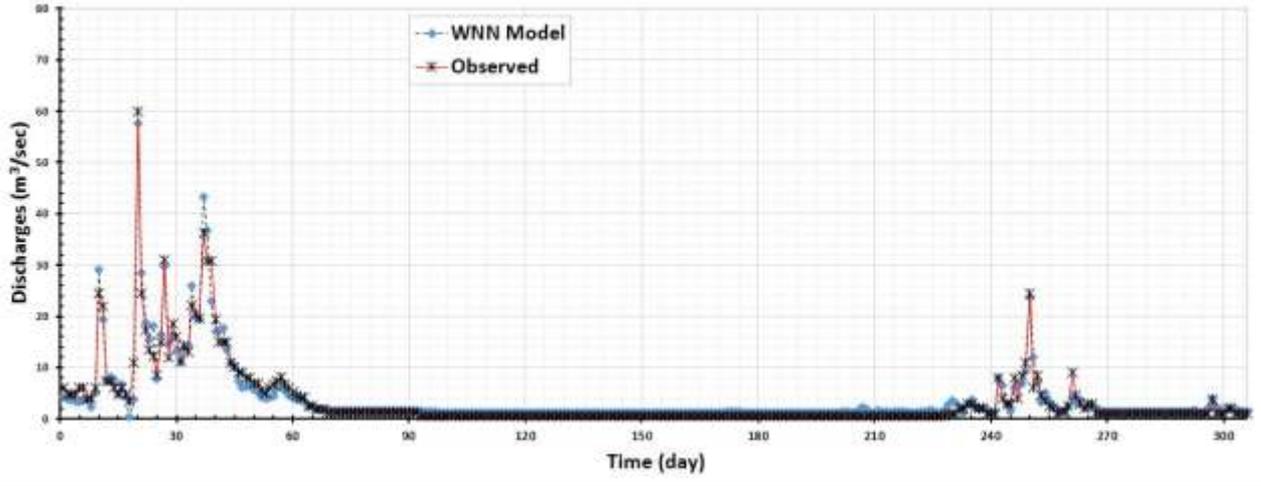
### النتائج والمناقشة

استخدمت السلاسل الزمنية الفرعية الناتجة عن عملية تحويل الموجات باستخدام الموجة db5، وذلك على ثلاثة مستويات، حيث دريت ANN باستخدام back propagation مع خوارزمية LM. بين الجدول (4) قيم RMSE و  $R^2$  لأنماط المدخلات الثلاث لمجموعة بيانات التدريب والاختبار؛ إن قيم RMSE للنموذج الثالث (III) تبين أن التصاريح لثلاثة أيام سابقة وقيم الهطل المطري ليومين سابقين بالإضافة إلى الوقت الحالي تؤثر بشكل كبير في التنبؤ بقيم التصاريح ليوم مقدماً. إن تحديد عدد العصبونات المخفية اللازمة لتدريب الشبكة يعتبر العملية الأصعب في التدريب والبناء بسبب عدم وجود طريقة عامة لإيجادها. لذا فإن هيكليّة نماذج ANN يتم استقراءها بعد عملية التجربة والخطأ ( trial and error) ومراقبة أداء الشبكة، حيث لوحظ أن أداء الشبكة يبدأ بالتراجع بعد زيادة عدد العصبونات عن 10، لذا تم التوقف عند هذا العدد، كما تبين أن أفضل هيكليّة للنموذج المقترح هي (1-2-6) (يتم ضرب كل سلسلة زمنية بـ 3 فيكون عدد المدخلات 18 عقدة (Neurons) لطبقة الإدخال (Input layer) واستخدام 3 طبقات خفية (Hidden layer) لكل منها عشرة عقد وعقدة إخراج واحدة (Output layer) تمثل قيم التدفقات ليوم مقدماً)، كما تبين أن استخدام دالة التنغيم (Logsigmoid) في الطبقة الخفية ودالة التنغيم (Tansigmoid) في طبقة الإخراج يوفر أفضل معايير تقييم الأداء للشبكة (معدل مربع الخطأ MSE)، واعتمد عدد تكرارات البيانات epochs في مرحلة التدريب 1000 تكرار، والجدير بالذكر أن النماذج الثلاث المعتمدة في البحث هي لأفضل حالات أداء الشبكة والتي اختيرت من بين عدد كبير من المحاولات.

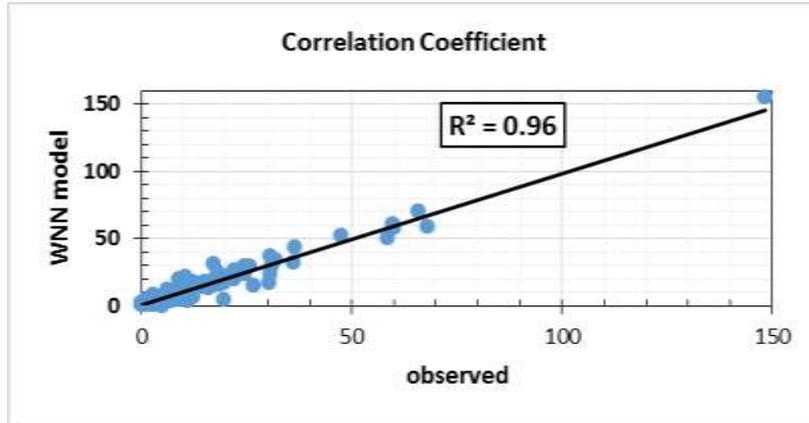
الجدول (4) المعايير الإحصائية للنماذج الثلاث في مرحلتي التدريب والاختبار

Model	Training Set		Validation Set	
	RMSE	R	RMSE	R
Wavelet-FFNN				
I	5.59	0.94	2.03	0.95
II	4.05	0.97	2.29	0.94
III	2.94	0.98	1.97	0.96

الشكلان (5) و (6) يعرضان توافراً جيداً بين القيم المرصودة والمتنبأ بها بما يتفق مع النتائج المبينة في الجدول ويعكسان جودة تدريب الشبكة واختبارها بمعامل ارتباط (0.96).

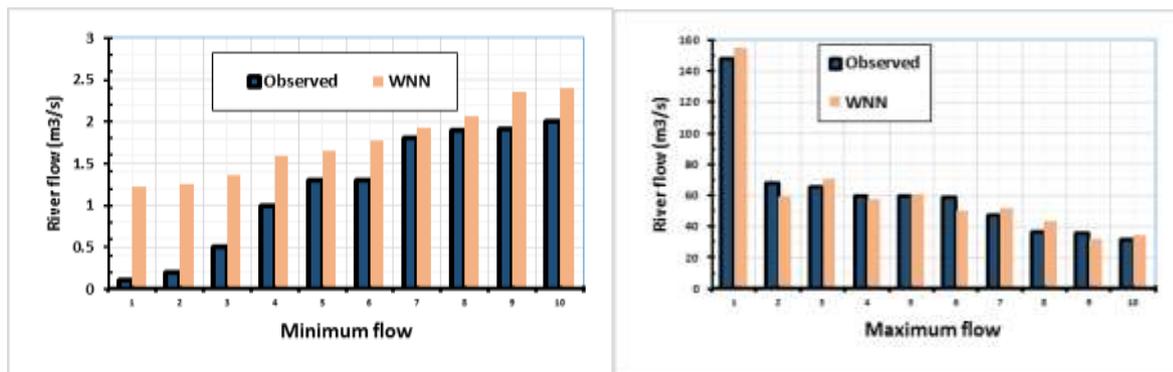


الشكل (5) مقارنة بين قيم المشاهدات والقيم المتنبأ بها



الشكل (6) مخطط مبعثر بين قيم المشاهدات والقيم المتنبأ بها

تبرز أهمية استخدام نموذج الشبكات العصبية في قدرتها على تحديد القيم العظمى والصغرى للتدفقات لأهميتها في التخطيط وإدارة المسائل المائية من تصميم وتشغيل بوابات التحكم في السدود وإدارة المياه في حالات الجفاف، ولتحقيق هذه الهدف تم اختيار 10 قيم من التصاريح الصغرى التي لا تتجاوز قيمها (  $2\text{m}^3/\text{sec}$  )، والتصاريح العظمى التي تتجاوز قيمها (  $30\text{m}^3/\text{sec}$  ) من مجموعة التحقيق، وتبين من النتائج أن التنبؤات هي أكثر تطابقاً مع القيم المرصودة في حالة التنبؤ بالقيم العظمى للتصاريح وذلك بخطأ نسبي كلي 9.4%، وعلى العكس فهي أضعف نسبياً في حالة التنبؤ بالقيم الصغرى للتصاريح وذلك بخطأ نسبي كلي 21.7%، الشكل (7) يوضح القيم المختارة من التصاريح العظمى والصغرى للمشاهدات مع القيم المتنبأ بها.



الشكل (7) التصاريح العظمى (a) والصغرى (b) والقيم المتنبأ بها باستخدام WNN

### الاستنتاجات والتوصيات

1. أظهرت الدراسة جدوى اعتماد تقنية تحويل الموجات Wavelet Transform مع الشبكة العصبية الاصطناعية FFBP (Feed-Forward Back-Propagation) كأداة للتنبؤ بقيم التدفقات الواردة ليوم مقدماً إلى بحيرة سد 16 تشرين بدقة ( $R^2=0.96$ ,  $RMSE=1.97m^3/sec$ ).
2. تعد الشبكة العصبية ذات الهيكلية (6-2-1) هي الأفضل في الأداء، حيث أظهرت الدراسة استجابة تصاريح النهر للتدفقات والهطولات المطرية خلال فترتين سابقتين، كما أن نتائج الشبكة العصبية كانت عالية الدقة في حال التنبؤ بالقيم العظمى للتصاريح بخطأ نسبي كلي 9.4%، وهذا هو المهم في موضوع هذا البحث، وأقل دقة في حال التنبؤ بالقيم الصغرى للتصاريح بخطأ نسبي كلي 21.7%.
3. يمكن استخدام نماذج عصبية أخرى مثل الشبكات العصبية التكرارية التي تتميز باحتفاظها بأحداث الماضي واستخدامها في الحسابات الحالية، مما يجعلها ملائمة لظواهر التي تتضمن تغذية عكسية في سلوكها، بالإضافة إلى دراسة مقدار استجابة النهر لعوامل مناخية وطبيعية أخرى.

### المراجع:

1. ADAMOWSKI, J, F. *River flow forecasting using wavelet and cross-wavelet transform models*. Hydrological Processes, 22, 2008, 4877-4891.
2. BOX, G, E, P; JENKINS, G. M. *Time Series Analysis: Forecasting and Control*. Holden Day Inc; San Francisco, 1976.
3. JAIN, A; SRINIVASULU, S. *Development of Effective and Efficient Rainfall-Runoff Models Using Integration of Deterministic, Real-Coded Genetic Algorithms and Artificial Neural Network Techniques*. Water Resources Research, Vol. 40, No. 4, 2004, Article ID: W04302. doi:10.1029/2003WR002355
4. SRIVASTAV, R. K; SUDHEER, K. P; CHAUBEY, I. *A Simplified Approach to Quantifying Predictive and Parametric Uncertainty in Artificial Neural Network Hydrologic Models*. Water Resources Research, Vol. 31, No. 10, 2007, pp. 2517-2530.
5. KISI, O; SHIRI, J. *Discussion on Precipitation Forecasting Using Wavelet-Genetic Programming and Wavelet-Neuro-Fuzzy Conjunction Models*. Water Resources Management, 2012, DOI 10.1007/s 11269-012-0060-y.

6. COULIBALY, P; BURN, H. D. *Wavelet analysis of variability in annual Canadian streamflows*. Water Resource Research, 40, 2004, W03105, doi.10.1029/2003WR002667.
7. BEVEN, K. J. *Rainfall-Runoff Modelling: The Primer*. John Wiley, Hoboken, 2000.
8. Wang, W; Ding, J. Wavelet network model and its application to the prediction of hydrology. *Nature and Science*, 2003, 1(1), 67-71.
9. CANNAS, B; FANNI, A; SEE, L; SIAS, G. *Data processing for river flow forecasting using neural networks: Wavelet transforms and data partitioning*. Physics and Chemistry of the Earth, 2006, Parts A/B/C 31((18)): 1164-1171 ISI.
10. ATIAA, A. M. *Prediction of River Discharge Using Artificial Neural Networks: An Example of Gharraf River, South of Iraq*. Iraqi Journal of Science, Vol.50, No.2, 2009, PP. 200-205
11. PARTALA, T. *River flow forecasting using different artificial neural network algorithms and wavelet transform*. Canadian Journal of Civil Engineering, 2009, 36(1): 26-38, 10.1139/L08-090
12. MITTAL, P; CHOWDHURY, S; ROY, S; BHATIA, N; SRIVASTAV, R. *Dual Artificial Neural Network for Rainfall-Runoff Forecasting*. Journal of Water Resource and Protection, 2012, 4, 1024-1028.
13. BAOJIAN, LI; CHUNTIAN, C. *Monthly discharge forecasting using wavelet neural networks with extreme learning machine*. China Technological Sciences, 2014, Vol.57 No.1: 1-10.
14. SAHAY, R. R. *Coupled wavelet-autoregression models for predicting monsoon flows for the Kosi River (India)*. IOSR Journal of Mechanical and Civil Engineering, 2014, 43-53. [e-ISSN: 2278-1684, p-ISSN: 2320-334X].
15. LIN, PAO-YEN. *An Introduction to Wavelet Transform*. Engineering National Taiwan University, Taipei, Taiwan, E-Mail: R97942117@Ntu.Edu.
16. KUMAR, B. M; LAVANYA, R. VIDHYA. Signal Denoising With Soft Threshold By Using Chui-Lian [CL] Multiwavelet. *International Journal of Electronics & Communication Technology IJECT* Vol. 2, Issue 1, 2011, 38-42.
17. AGGARWAL, R; SINGH, J. K. *Noise Reduction Of Speech Signal Using Wavelet Transform With Modified Universal Threshold*. *International Journal of Computer Applications*, Volume 20, No.5, 2011, 14-19.
18. MALLAT, S. *A Wavelet Tour of Signal Processing*, Academic Press. 1997.
19. DAUBECHIES, I. *Ten Lectures on Wavelets*, SLAM, 1992.
20. ZURADA, J. M. *Introduction to Artificial Neural Systems*. West Publishing Company, U.S.A, 1992.
21. JAIN, S. K; SINGH, V. P. *Applications of artificial neural networks to water resources*. Water and Environment International Conference (WE-2003), 2003, Bhopal, India.
22. AWCHI, T. A; SRIVASTAVA, D. K. *Artificial neural network model application in stochastic generation of monthly streamflows for Mula project*. Water resources system operation, Proceedings of the International Conference on Water and Environment (WE-2003), Bhopal, India, 2003.
23. DEMUTH, H; BEALE, M; HAGAN, M. *Neural Network Toolbox For Use With MATLAB*. User Guide, Version 6.0, The MathWorks, Inc; MA; 2003, <http://www.mathworks.com>.