

استخدام تقنيتي الشبكات العصبية الاصطناعية (ANN) و مقياس SPI للتنبؤ بمخاطر الجفاف في العراق و تأثيره على البيئة

ريناس ابوبكر احمد نادر¹ و ناراس جلال محمد كريم¹ و محمد محمود فقي¹

¹ كلية الإدارة والاقتصاد، جامعة السلبيانية، السلبيانية، كردستان، العراق

² كلية الإدارة والاقتصاد، جامعة التنمية البشرية، السلبيانية، كردستان، العراق

غير النظيفة، مما قد يؤدي إلى إزدياد حركات النزوح أو الهجرة الجماعية. يعاني العراق خلال السنوات الأخيرة من إرتفاع درجات الحرارة ونقص في كمية التساقطات المائية مقارنة مع المعدل العام، بالإضافة إلى سوء توزيع التساقطات المائية بين فصول السنة وأنحسارها في فترة قصيرة من الزمن، وانحسار الأمطار لمدة طويلة يؤدي إلى انخفاض في مخزون المياه في التربة وارتفاع معدل الملوحة فيها مما يؤدي إلى تلف المحاصيل الزراعية (منظمة الاغذية والزراعة للأمم المتحدة، 2014؛ منظمة الامم المتحدة للتربية و التعليم، 2014). ولغرض التنبؤ بمخاطر الجفاف في العراق و تأثيره على البيئة نستخدم احد الاساليب الاحصائية الواسعة التطبيق في المجالات الاقتصادية والانواء الجوية والتي هي الشبكات العصبية الاصطناعية (ANN). لذا تعد دراسة بمخاطر الجفاف غاية في الاهمية وما ستكون عليه في المستقبل، وكذلك معرفة المواسم او الفترات الرطبة والجافة وتحديدتها وامكانية توقعها ونسبتها مستقبلا لاستثمار كل الطاقات لحفاظ على هذا المورد الحيوي وتامين الامن البيئي، وان التنبؤ بفترات الزيادة او النقصان في الامطار يوفر لنا معينين بهذا المجال اتخاذ مايلزم لمواجهة فترات الجفاف القادمة، وتوفير اجراءات التكيف معها ما يمكن.

هدف البحث

تهدف الدراسة الى تحديد نسبة الجفاف في بيئة المدن العراق وفقاً لتصنيف دولية، مما يؤدي إلى تقليل في الموارد المائية في منطقة و مما يترك آثارا سلبية كبيرة على النظام البيئي والزراعة بشكل مباشر. و تم احتساب الفترة الزمنية للمواسم الجافة والرطبة، و التنبؤ بالمواسم المطرية الجافة والرطبة في المدن العراق.

المستخلص - يعاني العالم منذ القدم من الجفاف، والذي بدوره يؤثر سلباً على الإنسان، وجميع المجالات الاقتصادية، والاجتماعية، والثقافية، والسياحية، ومع تقدم العلم وتطوره وجدت عدة طرق للحد من ظاهرة الجفاف. و يطلق على ظاهرة عدد من المسميات؛ (كالقحط، والجذب، واحتباس الماء)، ويعني نقصاً شديداً في الموارد المائية بسبب قلة تساقط الأمطار وانخفاضها عن المعدل الطبيعي خلال فترة معينة من الزمن، مما يلحق خسائر فادحةً بالإنتاج الزراعي، وهو ما يجبر بعض السكان على الهجرة الجماعية، و حدوث الكوارث والمصائب الإنسانية كالجفاف. و استخدمت تقنيتي الشبكات العصبية الاصطناعية (ANN) ودليل المطر القياسي (SPI) في تحليل سجلات المطر لجميع المحافظات العراقية للفترة (1991-2016) شهريا و تبين من هذه الدراسة ان أفضل نموذج للشبكة العصبية وهي نموذج [1-3-19] حسب معيار AIC للتنبؤ بكميات الامطار و ان المحافظات العراقية خلال 10 السنوات القادمة تتعرض لمناخ متغير بين جاف معتدل و متوسط الرطوبة، وازدياد مساحة التصحر.

مفاتيح الكلمات- النماذج الاحصائية، انموذج السلسلة الزمنية، التنبؤ، تحليل الشبكات العصبية، دليل المطر القياسي

I. المقدمة

من أبرز مشكلات البيئة وآثرها تعقيداً وأصعبها حلاً مشكلة ظاهرة الجفاف، تعد ظاهرة الجفاف أحد المظاهر التي تؤثر على الانسان وانشطته المختلفة وفي مقدمتها النشاط الزراعي بشكل مباشر او غير مباشر بحيث اصبحت جزء من التحديات الكبيرة التي تواجه معظم دول العالم والتي يقع العراق في ضمنها، تعتبر ظاهرة الجفاف من المخاطر الطبيعية التي تحدث نتيجة انخفاض الأمطار او إندامها، مما يؤدي إلى شح في الموارد المائية في منطقة ما، مما يترك آثارا سلبية كبيرة على النظام البيئي والزراعات. وقد تصل فترات الجفاف إلى أشهر او سنوات، ومن المعروف ان فترة قصيرة من الجفاف قد تؤدي إلى خسائر إقتصادية محلية كبيرة، كما تساهم فترات الجفاف في إنتشار الامراض والايوية كالملاريا والكوليرا والجرب بسبب إستعمال المياه

II. الجانب النظري

1. المقدمة

المتوسط. وبسبب معيارية المؤشر المعياري للهطول، يمكن تمثيل حالات المناخ الماطرة والجافة بنفس الطريقة وبالتالي يمكن أيضاً رصد الفترات الماطرة باستخدام المؤشر المعياري للهطول. وقد استخدم نظام التصنيف المبين في جدول (1) قيم المؤشر SPI أذناه في تحديد مدى شدة الجفاف الناتجة عن المؤشر المعياري للهطول. كما حددوا المعايير الخاصة بأي ظاهرة جفاف على أي من النطاقات الزمنية. وتحدث ظاهرة الجفاف حيناً يكون المؤشر المعياري للهطول سلبياً بصفة مستمرة. وتصل شدته إلى 1 أو أقل وتنتهي الظاهرة حين يصبح المؤشر إيجابياً ولذلك فإن لكل ظاهرة جفاف مدة تحددها بدايته ونهايته، ومدى شدته في كل شهر يستمر فيه الجفاف. والمجموع الإيجابي للمؤشر المعياري للهطول لجميع الأشهر التي تستغرقها ظاهرة الجفاف، يمكن تسميته بـ "شدة" الجفاف (McKee وآخرون، 1993).

جدول 1

قيم المؤشر المعياري للهطول SPI

هطول مطرف	+2.0
هطول شديد	1.5 إلى 1.99
هطول متوسط	1.0 إلى 1.49
هطول قريب من المعتاد	-0.99 إلى 0.99
جفاف متوسط	-1.0 إلى -1.49
جفاف شديد	-1.5 إلى -1.99
جفاف مطرف	-2 أقل

ويتيح التوحيد القياسي للمؤشر أن يحدد قلة كثافة جفاف قائم (الجدول 2). واحتمال الهطول اللازم لإينائه (McKee وآخرون، 1993) "المطرقة". وعلى خلاف ذلك، يصل مؤشر بالمر لشدة الجفاف إلى فئته، كما يتيح للمستخدمين أن يقارنوا على نحو موثوق، حالات الجفاف التاريخية والحالية بين مختلف الأماكن المناخية والجغرافية عند تقييم مدى ندرة أو تواتر ظاهرة جفاف معينة.

جدول 2

احتمالات التكرار

المؤشر المعياري للهطول	الفترة	عدد مرات الحدوث في 100 عام	مدى شدة ظاهرة
صفر إلى -0.99	جفاف معتدل	33	مرة في 3 سنوات
-1.0 إلى -1.49	جفاف متوسط	10	مرة في 10 سنوات
-1.5 إلى -1.99	جفاف شديد	5	مرة في 20 سنة
2 فأكثر	جفاف مطرف	2.5	مرة في 50 سنة

4. الشبكات العصبية الاصطناعية Artificial Neural Network

تعد الشبكات العصبية من أهم الأساليب التي تستخدم في الكثير من التطبيقات التي يصعب إيجاد الحلول لها بالطرائق والحوارزميات المعروفة (الصقال، أدبية اسماعيل وطاهر، غادة محمد، 2006)، لذا فإن الشبكات العصبية الاصطناعية (ANN) تكون وسيلة فعالة لحل مسائل متنوعة تتضمن تصنيف الأنماط وتمييز الأنما (العبيدي، محمود خليل إبراهيم، 2006؛ Christopher, M. Fraser, 2000)، ويمكن استخدامها أيضاً في المالية والطب والبيولوجيا والهندسة لمسائل مثل التنبؤ والتصنيف والعنقدة (Andrescu, Andrea, 2004). تعرف الشبكة العصبية الاصطناعية (ANN) على أنها نظام حسابي مكون من عدد من وحدات المعالجة المترابطة مع بعضها (كل وحدة بمفردها أداة حسابية يمكن نمذجة سلوكها بمعادلات رياضية بسيطة) وتتصف بطبيعتها الديناميكية والمتوازية في معالجة البيانات الباخلة إليها (العبيدي، محمود خليل إبراهيم، 2000؛ Kumar et al, 2004). كذلك تعرف الشبكة العصبية الاصطناعية على إنها نظام معالجة يستند إلى نماذج رياضية بسيطة

الجفاف (Drought) ظاهرة طبيعية معقدة تحدث في معظم مناطق الكرة الأرضية، له علاقة مع الاقليم المناخي وحالة التوازن المحلية بين الطاقة والماء. وهو اهم المشاكل التي تعاني منها اغلب المناطق الجافة وشبه الجافة في العالم ومنها العراق. بدأت التحذيرات العالمية بشأن الجفاف منذ عام 1980. هناك اربعة أنواع من الجفاف من الناحية العملية، وهو (الجفاف الارصادي، الجفاف الزراعي، الجفاف المائي (الهيدرولوجي)، الجفاف الاقتصادي - الاجتماعي) (منظمة الاغذية والزراعة للامم المتحدة، 2014).

2. آثار الجفاف

يؤثر على النشاط الزراعي، فكثيراً من المناطق التي تتصف بشح المياه عانت من زيادة نسبة تركيز الأملاح الذائبة فيها، فحولتها إلى أراضٍ جدداء قاحلة تخلو من أي مظهر من مظاهر الحياة، وأيضاً لجوء بعض المزارعين للأساليب الزراعية القديمة، وأساليب الري غير المنتظمة، مما أدى إلى تصحرها وجفافها، وله تأثير كبير على المحاصيل الزراعية، والحقول، والأشجار المثمرة، ويؤثر سلباً على النباتات فتصبح قصيرة، وصغيرة الحجم، ويختلف تأثيره حسب شدته، وموعد حدوثه، وفترة مكوثه. الجفاف يؤثر على التربة بصورة سلبية، حيث إن جفافها يؤدي إلى جعلها أكثر تأثراً بالعوامل والمؤثرات الخارجية؛ كالانحراف بفعل السيول والمياه الجارية، وخصوصاً في المناطق الجبلية المنحدرة؛ مما يقلل من فرصة استغلالها، والاستفادة منها. ويمكن تلخيص اسباب الجفاف الى الى (منظمة الاغذية والزراعة للامم المتحدة، 2014؛ منظمة الامم المتحدة للتربية و التعليم، 2014):

1. انخفاض معدل تساقط الأمطار في منطقة ما عن المعدل الطبيعي، مما يؤثر على الإنتاج الزراعي بشكل عام، ويتسبب بالجفاف.
2. ارتفاع درجات الحرارة مما ينعكس سلباً على البيئة بارتفاع نسبة معدل التبخر.

3. المؤشر المعياري للهطول (Standardized Precipitation)

(Index) (SPI)

يستند المؤشر المعياري للهطول إلى احتمال حدوث الهطول في أي نطاق زمني. ثم يحول احتمال حدوث الهطول الذي رصد إلى مؤشر. صمم المؤشر المعياري للهطول (SPI) لتقدير كمية النقص في الهطول على نطاقات زمنية متعددة و تعكس هذه النطاقات الزمنية تأثير الجفاف على توافر موارد المياه المختلفة. فأحوال رطوبة التربة تستجيب للاختلافات في كمية الهطول على نطاق زمني قصير نسبياً. وتعكس المياه الجوفية، وتدفق المجاري المائية، ومستودعات التخزين بالمياه المخزونة فيها الاختلافات في الهطول في الأجل الأطول. ولهذه الأسباب (McKee وآخرون، 1993)، المؤشر المعياري للهطول في البداية (1993) على نطاقات زمنية تبلغ 3 أشهر، 6 أشهر، 12 شهراً، 24 شهراً، 48 شهراً.

ويستند حساب المؤشر المعياري للهطول الخاص بأي مكان إلى سجل الهطول الطويل الأجل لفترة مشنودة وهذا السجل الطويل الأجل مهيأ لتوزيع احتمالات. تحول بعدئذ إلى توزيع معتاد بحيث يكون متوسط المؤشر المعياري للهطول بالنسبة للمكان والفترة المشنودين، صفراً (McKee وآخرون، 1993)، وتدل القيم الإيجابية للمؤشر المعياري للهطول على هطول أعلى من المتوسط، أما القيم السلبية فتدل على هطول أقل من

عملية تحديث الأوزان من أجل تقليل نسبة الخطأ وتتوقف الشبكة في حالة تقارب الإخراج الفعلي مع الإخراج الهدف أو الحصول على أقل متوسط مربعات الأخطاء (MSE) (الصقال، أدبية أساعيل وطاهر، عادة محمد، 2006). هناك دوال التنشيط (Activation Function) شائعة وهي الدوال الزائدية (Hyperbolic) والخطية (Linear) ولوغاريتمية (log-activation) وسكمويد (Sigmoid) (العبيدي ، محمود خليل ابراهيم، 2000؛ Kumar et al, 2000؛ Christopher, M. Fraser, 2000) ودالة سكمويد تنتج القيم بين (1,0) لأي إدخال من خلال الدالة التوافقية وكما مبين بالمعادلة التالية :-

$$S(X) = (1 + e^{-X})^{-1} \quad \dots \dots \dots (2)$$

6. الأوزان في الشبكات العصبية الاصطناعية

إن عملية تحديد أوزان الشبكة العصبية الاصطناعية تسمى التعلم Learning أو التدريب Training. وتتدرب الشبكات العصبية الاصطناعية بمجموعة تدريب الإدخال وبيانات الإخراج الهدف. ويتم تدريب الأوزان الأولية إما بمجموعة القيم العشوائية أو مستندة على بعض التجارب السابقة بهدف تكيف الشبكة إلى أن يصل الخطأ إلى أقل ما يمكن (الخياط ، باسل يونس وزكي ، عزة حازم، 2005؛ KISI, ÖZGÜR, 2005). كذلك يمكن تقسيم طرائق تدريب الشبكات العصبية الاصطناعية المكيفة خلال مرحلة التدريب أو التعلم إلى التدريب بإشراف و التدريب بدون إشراف.

6.1. التدريب بإشراف (عن طريق مشرف أو معلم) Supervised Training

إن التدريب بإشراف يتضمن تجهيز الشبكة العصبية الاصطناعية بقيم مدخلات ومخرجات محددة والساح لها بالوصول إلى الحل تكرارياً (Christopher, M. Fraser, 2000).. وإن التدريب بإرشاد عادة ما يستخدم في التغذية شبكات الأمامية ويتطلب وجود زوج من متجه الإدخال ومتجه الإخراج والتي تمثل زوج التدريب ، حيث تدرب الشبكة العصبية على عدد من هذه الأزواج ويقارن الإخراج لمتجه الإدخال المطبق مع متجه الإخراج الهدف والاختلاف بينهما يمثل خطأ التدريب Training Error ويعاد هذه الخطأ خلال الشبكة كي تتغير الأوزان طبقاً للخوارزمية باتجاه تقليل الأخطاء (الكسو، ابتهاج عبد الحميد محمد علي، 2005). ويجري تعلم الشبكات العصبية بواسطة خوارزميات متخصصة تسمى خوارزميات التعلم Learning Algorithms (العبيدي ، محمود خليل ابراهيم، 2000). وبسط خوارزمية موجودة هناك خوارزمية Marquarddit و Neywton Raphson و ... الخ)، ومن الخوارزميات المشهورة في التعلم الموجه، خوارزمية

$$\Delta w_{ji}(k+1) = \eta \delta_j X_i + \rho \Delta w_{ji}(k) \quad \dots (3)$$

الانتشار الخلفي (للخطأ) Back- Propagation. وهذه الطريقة الشائعة تعمل على إقلال الخطأ وهي مربعات المتوسطات الصغرى القياسية وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ بقيم جديدة بعد المشاهدة الأخيرة للبيانات المدخلة (العبيدي ، محمود خليل ابراهيم، 2000؛ الكسو، ابتهاج عبد الحميد محمد علي، 2005؛ عيسى، علام زكي، 2000؛ Andreescu, 2000؛ Andrea, 2004؛ Nawzad M. Ahmed, 2007). وتكون الصيغة الرياضية لتعديل الأوزان كالتالي:

لها مميزات أداء معينة بأسلوب يحاكي الشبكات العصبية البيولوجية وتعد إحدى النماذج اللاخطية (الناصر، عبد الحميد حمزة والعبيدي، مروان عبد الحميد، 2003؛ عيسى، علام زكي، 2000؛ Moseley, N., Kaboudan, Mak, 2005). ولقد سميت بالشبكات العصبية الاصطناعية لكونها بنيت لمحاكاة الشبكة العصبية في الكائنات الحية بقدر المعرفة المتوفرة عنها (الصقال، أدبية أساعيل وطاهر، عادة محمد، 2006؛ العبيدي ، محمود خليل ابراهيم، 2000). وكذلك سميت بالدماغ الإلكتروني أو المنظومة العصبية ويطلق عليها أيضاً نماذج المعالجة (العبيدي ، محمود خليل ابراهيم، 2000؛ الكسو، ابتهاج عبد الحميد محمد علي، 2005).

5. مكونات الشبكة العصبية الاصطناعية


تتألف الشبكة العصبية اصطناعية عموماً من وحدات (عصبونات Neurons ، عقد Nodes، خلايا Cells) المعالجة المرتبطة والمرتبطة في طبقات Layers، وطبيعة هذه الارتباطات تحدد تركيب الشبكة (Allende, et al, 1999؛ Andreescu, Andrea, 2004؛ Moseley, N., 2003). وتعد الخلية العصبية الاصطناعية (العصبون ، العقدة) وحدة بناء الشبكات العصبية الاصطناعية وتنظم هذه الوحدات على شكل طبقات كل طبقة تضم عدد من الخلايا وترتبط كل خلية في طبقة معينة بجميع الخلايا في الطبقة التي تليها بأداة ربط مباشرة وكل أداة ربط ترفق بوزن معين وهذه الأوزان تمثل المعلمات (parameters) التي ستبدأ بها الشبكة حل المشكلة التي تكون مسؤولة عن التفاعل بمعنى أنها مسؤولة عن تدريب وتعلم الشبكة واستقراريتها (العبيدي ، محمود خليل ابراهيم، 2000؛ عيسى، علام زكي، 2000؛ Andreescu, Andrea, 2004؛ Kumar et al, 2004). وإن لكل عصبون حالة داخلية خاصة تدعى الفعالية (Efficiency) والتي يكون قد حصل عليها من تطبيق دالة رياضية معينة على معطيات الإدخال ونتيجته استقبلت من قبل العصبون (عيسى، علام زكي، 2000). تستقبل العصبونات الاصطناعية (Artificial Neurons) مدخلاتها من خلال عدد من العصبونات الاصطناعية أو من العالم الخارجي لنا تتكون الخلية العصبية الاصطناعية من وحدة حسابية متعددة المدخلات (X_1, X_2, \dots, X_n) وإشارة خارجة واحدة (y_i) ولكل إشارة داخلية هناك وزن (Weight) يعمل على تعديل (adjusting) الإشارة الداخلة وعلى تحفيز الخلية لإنتاج إشارة رد فعل عندما تكون قيمتها موجبة أو إخمادها وتقليل الإشارة الخارجة عندما تكون قيمته سالبة. ثم تضرب قيم الإدخال بالوزن المقابل لكل خلية ثم تجمع الإدخالات الموزونة عن طريق دالة توافقية (Σ) Combination Function التي غالباً تتألف من جمع مبسط ويعبر عنها رياضياً بالمعادلة التالية :

$$Net = \sum_{i=1}^n w_i x_i \quad \dots \dots \dots (1)$$

ثم يمر الناتج عبر دالة التحويل (Transfer Function) ($y=f(net)$) للحصول على الإخراج الحقيقي (Actual Output) لكل خلية، وهذا الإخراج المنفرد عادةً بين الصفر والواحد. وان الدالة التوافقية ودالة التحويل يشكلان معاً دالة التنشيط للعقدة (الصقال، أدبية أساعيل وطاهر، عادة محمد، 2006؛ العبيدي ، محمود خليل ابراهيم، 2000؛ Christopher, M. Andreescu, Andrea, 2004؛ Fraser, 2000).

وتستمر الشبكة بالعمل وفي كل مرة تتم مقارنه الإخراج الفعلي (Actual) مع الإخراج الهدف (Target Output) والفرق بينهما يسمى الخطأ (Error) ثم تجري

طبقة المدخلات إلى طبقة المخرجات عبر الطبقات المخفية كما يتضح من شكل (1) التالي (Gonzalez, J.M.B. & Desjandins, S.S.L.,2001; Zurada J. M., 1994):



الشكل 1. نموذج لشبكة عصبية ذات تغذية أمامية

7.2. الشبكات العصبية ذات التغذية الخلفية (Feed Back) (Recurrent) Neural Networks

في هذه الشبكات من الممكن ان يعاد تغذية (كل او بعض) الإشارات الخارجة من الشبكة وتحويل اتجاهها لتصبح إشارة داخلية أيضا (إعادة تغذية) ، وبذلك فان الإشارة الخارجة من أي خلية سوف تعتمد على الإشارات الداخلة إليها إضافة الى الإشارات الخارجة منها في وقت سابق ، ويطلق على هذه الشبكات بالشبكات التكرارية (العبيدي ، محمود خليل ابراهيم، 2000؛ Andreescu, Andrea, 2004; Ghodsian et al, 2003; Kumar et al., 2004). تمتلك الشبكات العصبية التكرارية (RNNs) ميزات مهمة ، وتعني بها إنه يتم الاحتفاظ بأحداث الماضي وتستخدم في الحسابات الحالية ، وكذلك تسمح للشبكة بإنتاج مخرجات معقدة تتغير مع الزمن في استجابتها لمدخلات ستاتيكية بسيطة (Kumar et al., 2004; Nawzad M. Ahmed, 2007).

8. الشبكات العصبية الاصطناعية من حيث جانب الرياضي

8.1. تحديد عدد المدخلات من خلال كشف أنماط الإدخال

يستخدم تحليل الارتباط الذاتي لتعريف أنماط الإدخال للسلسلة الزمنية لغرض التدريب ، إن كشف الاتجاهات والأنماط في البيانات له أهمية كبيرة في عالم الأعمال للمساعدة في عمليات اتخاذ القرار إذ استخدمت الأساليب الإحصائية. إن النماذج الرياضية المرتبطة بهذه الأساليب خطية ويمكن أن تفشل في التكهن بنقاط الانعطاف بسبب أنه في العديد من الحالات يكون نموذج البيانات غير خطي. يستخدم تحليل الارتباط الذاتي لتحديد أنماط الإدخال الصحيحة للتكهن بالسلاسل الزمنية غير الخطية من خلال الشبكات العصبية ، لأنه يعتقد بان أداء تكهن الشبكة العصبية يتأثر من خلال أنماط الإدخال (Lin, et al., 1995; Kumar et al., 2004).

8.2. تحديد عدد الطبقات المخفية والعصبونات فيها

إن تحديد عدد الوحدات المخفية الضرورية تواجه صعوبات كثيرة ، لكنها تكون جيدة عندما تبدأ مع طبقة مخفية واحدة تحتوي على عدد من الوحدات مساويا إلى نصف المجموع من عدد وحدات الإدخال والإخراج (Andreescu, Andrea, 2004). فإذا كانت عدد العقد في الطبقة المخفية قليلة فان الشبكة قد لا تحتوي على درجات كافية لتعلم العملية بشكل صحيح. وإذا كان عدد العقد في الطبقة المخفية كبير

حيث أن:

$$\delta_j = f(\text{net})(d_j - y_j) \quad \text{for Output Layer}$$

$$\delta_j = f(\text{net}) \sum \delta_i w_{ij} \quad \text{for Hidden Layer}$$

إذ أن ρ : هي معامل الزخم Momentum Term.

Δw_{ji} : مقدار التعديل على وزن الخليتين i, j .

η : معامل نسبة التعلم Learning Rate.

δ : معامل تعديل الأوزان (الفرق بين الإشارة الخارجة والقيمة المطلوبة).

d : القيمة المطلوبة Desired Value.

y : قيمة الإشارة الخارجة.

k : مؤشر التكرار Iteration Index.

6.2. التدريب بدون إشراف Unsupervised Training

هذا النوع من التدريب لا يستخدم المعلم الخارجي ويكون الاعتماد فقط على المعلومات الموقعية ، ويشار الى هذا النوع من التدريب بشبكات التنظيم الذاتي (Self-Organizing) أي تنظيم البيانات التي تقدم الى الشبكة ذاتياً . في هذا التدريب تمتلك الشبكة العصبية الاصطناعية بعض المعلومات خلال التدريب أي لها إدخالات فقط وليس لها معرفة عما سيكون عليه الجواب الصحيح ولا تعرف ما هو مخرجات الهدف أي عدم وجود إخراج مرغوب للشبكة يقارن مع النتائج (الكسو، ابتهاج عبد الحميد محمد علي، 2005؛ عيسى، علام زكي، 2000؛ Christopher, M. Fraser, 2000)، وتتألف فيه مجموعة التدريب من متجه الإدخال وخوارزمية التدريب لتغيير أوزان الشبكة لإنتاج متجه الإخراج الثابت، وتقوم هذه الخوارزمية بتعديل أوزان الشبكة بشكل آلي واستخلاص الخصائص الموجودة في الإشارات الداخلة وتجميعها على شكل مجموعات عن طريق تقوية أوزان الخلايا التي تستجيب تجاه خاصية معينة من الخصائص التي تحملها البيانات الداخلة وجعلها تخصص بتمييز هذه الخاصية أكثر من بقية الخلايا التي سوف يجري تقويتها وجعلها تستجيب لخاصية أخرى، والصيغة العامة لمعامل تعديل الأوزان تأخذ الشكل التالي (العبيدي ، محمود خليل ابراهيم، 2000):

$$\Delta w_{ij} = \eta (X_i - X w_{ij}) \quad \dots \dots \dots (4)$$

حيث أن:

X : تمثل مصفوفة المتجه للبيانات.

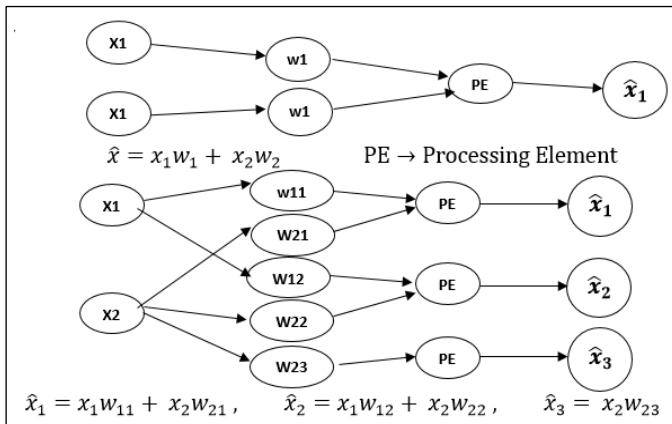
7. أنواع الشبكات العصبية الاصطناعية :-

7.1. الشبكات العصبية ذات التغذية الامامية (Feed Forward) Neural Networks

وهي الشبكات التي يخلو تركيبها من وجود حلقة مغلقة من الترابطات بين الوحدات المكونة لها . وتعد هذه الشبكات من أكثر الشبكات إستخداماً، حيث تتكون الشبكة من هذه النوع من طبقتين على الأقل، كما تتواجد في كثير من الأحيان طبقات مخفية (Hidden Layer) بين طبقة المدخلات وطبقة المخرجات، وتنتقل العمليات الحسابية في إتجاه واحد إلى الأمام من

التغذية الأمامية، و مرحلة للخطأ لإنتشار الخلفي)، مرحلة التغذية الأمامية لتدريب المدخلات تبدأ مرحلة التغذية الأمامية حيث تستقبل كل وحدة x_t إشارة الدخول، ومن ثم تنتقل هذه الإشارة إلى وحدة أو وحدات الطبقة المخفية حسب عددها (Mostafa, M. M., El-Refae, G.A., 2003)، وتقوم كل طبقة خفية بجمع قيم وإشارة دخولها المرجح بالوزن حسب المعادلة:

$$\hat{X}_t = \sum_{i=1}^n X_{ij} W_{ij} \quad , \quad \forall j \quad \dots \dots \dots (7)$$



شكل 2. كيفية حساب مرحلة التغذية الأمامية و المتعددة

ومن ثم حساب الدالة اللوجيستية التي تستخدم لتحويل الإشارة الى (1,0) لانها قيمة احتمالية، وبالتالي تنتقل القيمة التي تم الحصول عليها من المعادلات السابقة الى وحدة طبقة

نبدأ إنتشار الخلفي للخطأ بعد إنتقال القيم الى طبقة المخرجات التي تم حساب قيمتها من خلال الخطوات السابقة^[14]، يتم إجراء مقارنة بين القيم المحسوبة والقيم المرغوبة (حساب الخطأ) من خلال الفرق بين قيم تلك المخرجات وذلك من

$$W_i(Final) = W_i + \alpha \times \beta \times x_i \quad \dots \dots \dots (8)$$

خلال معادلة الخطأ التالية:

حيث: x_i : المخرجات المرغوبة من الشبكة.

\hat{x}_i : المخرجات المحسوبة من الشبكة. وبعد ذلك يتم تصحيح الوزن وتعديله من خلال عملية التعلم التي تتم على الشبكة، وذلك من خلال المعادلة التالية:

وتعبر α عن معدل التعلم والذي يتم وضعه عند أدنى مستوى تعلم، بينما تعبر β عن الفرق بين القيمة المحسوبة والقيمة المرغوبة ($\beta = x_i - \hat{x}_i$) وذلك لحساب الخطأ، وتسمى بالمرحلة التراجعية (Backward) (Hamilton, J. D., 1994)، وتكرر هذه الخطوات في الشبكة لعدة مرات بخطوة أمامية وخطوة تراجعية (مرحلة التغذية الأمامية- مرحلة الإنتشار الخلفي).

جدا فان التدريب سيستغرق وقتا طويلا والشبكة أحيانا قد تقع في مشكلة المطابقة المفرطة للبيانات (KISI, ÖZGÜR, 2005). يتم تحديد عدد عصبونات في الطبقة المخفية من خلال قواعد Baum-Haussler Rules إذ يتعلق عدد العصبونات في

$$N_{Hidden} \leq \frac{N_{Train} E_{Tolerance}}{N_{pts} + N_{Output}} \quad \dots \dots \dots (5)$$

الطبقة المخفية بتطبيق الشبكات العصبية للتكهن بالسلسلة الزمنية. إن قاعدة Thumb والمعروفة بقاعدة Baum Haussler تستخدم لتحديد عدد العصبونات في الطبقة المخفية وفق القانون التالي (Lin, et al., 1995):

حيث إن: N_{Hidden} : تمثل عدد العصبونات (العقد) المخفية

N_{Train} : تمثل عدد أمثلة التدريب Training Examples

$E_{Tolerance}$: تمثل الخطأ المسموح به او مقدار الخطأ المسموح

Error Tolerance (القدرة على الاحتمال)

N_{pts} : تمثل عدد نقاط البيانات لكل مثال تدريب.

N_{Output} : تمثل عدد عصبونات الإخراج Output Neurons.

وهذه العملية تعتمد على (المحاولة والخطأ) تزيد اعداد الطبقات والنودات في كل طبقة وتقارن للوصول الى اقل متوسط تربعات خطأ.

8.3. عدد العصبونات في طبقة الإخراج

إن الإخراج في الشبكة العصبية للسلسلة الزمنية تتطلب عصبونا واحدا فقط

في طبقة الإخراج (Kumar, et al., 2004).

9. التنبؤ باستخدام الشبكات العصبية الاصطناعية

يفرض وجود سلسلة زمنية تحتوى على المشاهدات $x_1, x_2, \dots, x_{n-1}, x_n$ وللتنبؤ بالقيم المستقبلية للمتغير بمعنى x_{n+1}, x_{n+2}, \dots ، وكان السلسلة محددة بمعنى وجود عدد حقيقي p الذى يدعى التخلف الزمني والدالة f بحيث تكون ($t > p$)

$$\hat{X}(t) = f(x_{t-1}, x_{t-2}, \dots, x_{t-p}) \quad \dots \dots (6)$$

وبالتالى يتكون التنبؤ من N ، قيمة لسلسلة زمنية معطاة، ولإيجاد قيم p, f ويفرض أن p معروفة ونرغب فى إيجاد f ومن المعروف أن الشبكات العصبية الاصطناعية مكونة من عدد كبير من عناصر بسيطة غير خطية مترابطة، فإن هناك ثلاثة أنواع من الوحدات (Everson, H., 1994; Johnson, R. A. and Wichern, W., 1996; Mostafa, M. M., El-Refae, G.A., 2003):

- 1- وحدات ادخال Input: والتي تهئ للقيم السابقة فى السلسلة الزمنية $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ حيث p تمثل البعد المطور.
- 2- وحدات مخفية Hidden: والتي تستخدم لحفظ التمثيل الداخلى للسلسلة الزمنية.
- 3- وحدات إخراج Output: والتي تعطى مخرجات الشبكة العصبية فى حالة

$$\hat{X}(t)$$

وحدة إخراج فقط لإرجاع $\hat{X}(t)$ يمكن استخدام طريقة الإنتشار الخلفي لهذا الغرض وهي طريقة الإنحدار التدريجي التي تستخدم لإيجاد قيمة المربعات الصغرى للخطأ وذلك لقيمة المخرجات المحسوبة من الشبكة. ويوجد مرحلتين للإنتشار الخلفي هما (مرحلة


III. جانب التطبيقي

1. وصف البيانات:

تم الحصول على بيانات هذا البحث من الصفحة (Climate Change Knowledge Portal) وكذلك من (شبكة الأرصاد الجوية الزراعية العراقية) وتمثل البيانات على شكل سلسلة زمنية شهريا لستة عشرة سنة يبدأ من السنة 1991 الى السنة 2016 .

يأخذ بيانات كمية الامطار الساقطة لكل شهر للمحافظات العراق ماعدى المحافظات الاقليم لمدة (1991-2016) وتوقع السلسلة بيانيا وحيث أن الخطوة الأولى في تحليل أية سلسلة زمنية هي التوقع البياني لمشاهدات السلسلة مع الزمن وهو ما يعرف Time Series Plot . وهي خطوة أساسية وهامة في التحليل، إذ يمكن من خلال الرسم الاطلاع على طبيعة التذبذب فيها.

ولقد تم استخدام نظام الشبكات العصبية الجاهز والذي يعرف Alyuda NeuroIntelligence وهو برمجية شبكات عصبية يستخدم لتطبيق الشبكات العصبية حل مسائل تكون العالم الحقيقي. وهذا البرنامج سريع الذكاء وسهل الاستخدام وان هذه البرمجية تمثل مجموعة (رزمة) كاملة بتقنيات مثبتة لتصميم الشبكة العصبية Neural Network Design.



شكل 3. الرسم الزمني لمشاهدات كمية الامطار للفترة (1991-2016)

يبين الشكل (3) أعلاه الرسم البياني لمشاهدات هذه السلسلة. إذ نلاحظ من خلال فحص الرسم البياني لهذه السلسلة بأن هناك تشتتاً نسبياً حول التباين بمعنى عدم وجود نمط التباينات الكبيرة والتباينات الصغيرة للسلسلة مما يدل على أن التباين المشاهدات ثابت نسبياً مع الزمن. لذا نستنتج بأن السلسلة مستقرة وأيضاً يمكن معرفة استقرارية هذه السلسلة من خلال طريقتين، أولاً من خلال استخدام رسم دالة الارتباط الذاتي لهذا السلسلة كما موضح في شكل (4)، وأخرى من خلال اختبارات ديكي - فولر (Dickey Fuller - ADF) و كواساكي فليب (Kwiatkowski - Phillips - Schmidt - Shin - KPSS) لتأكد الاستقرارية هذه السلسلة يمكن استخدام اختبار ديكي-فولر لاختبار الفرضية التي تنص على "ان سلسلة الزمنية غير مستقرة" و استخدام اختبار كواساكي لاختبار الفرضية التي تنص على "ان سلسلة الزمنية مستقرة" كما موضح في الجدول رقم (3).

الجدول 3

الاختبار	الاحصاء t-	مستوى المعنوي
ADF	3.370	0.013
KPSS	0.425	0.463


يتضح الجدول (3) ان مستوى المعنوي لاختبار ديكي-فولر يساوي

(0.013) والتي اصغر من قيمة ($\alpha = 0.05$). وهذا يعني ان هذه السلسلة مستقرة، وفي نفس الوقت ان مستوى المعنوي لاختبار كواساكي يساوي (0.463) والتي اكبر من قيمة ($\alpha = 0.05$). وايضا هذا يعني ان هذه السلسلة مستقرة. إن خطة التالية هو التمكن للسلسلة الزمنية لكمية الامطار في العراق اعتماداً على الشبكات العصبية ذات التغذية الأمامية تتكون متطلبات الادنى وهي

2. تحديد عدد المدخلات لتنبؤ الشبكة العصبية


يوضح الشكل (5) دالة الارتباط الذاتي الجزئي لسلسلة كمية الامطار، ويتضح من هذا الشكل وجود (9) ارتباطاً ذاتياً جزئياً معنوياً ، وبناءً على ذلك فان عدد المدخلات لتنبؤ الشبكة العصبية (9) ادخال.

Autocorrelations for series



شكل 4. معاملات الارتباط الذاتي لكمية الامطار

Partial Autocorrelations for series



شكل 5. معاملات الارتباط الذاتي الجزئي لكمية الامطار

3. تحديد عدد العصبونات في الطبقة المخفية

باستخدام قاعدة Baum-Haussler في تحديد عدد العصبونات في الطبقة المخفية على وفق القانون التالي:

$$N_{Hidden} \leq \frac{N_{Train} E_{Tolerance}}{N_{Pts} + N_{Output}}$$

لقد تم تثبيت مقدار الخطأ المسموح به $E_{Tolerance}$ كي يكون 0.01 وعدد مرات التدريب $N_{Train}=10000$ وعدد نقاط البيانات لكل مثال تدريب $N_{Pts}=9$ وعدد عصبونات الاخراج $N_{Output}=1$ وتطبيق المعادلة اعلاه نجد أن:

$$N_{Hidden} \leq \frac{10000 \times 0.01}{9 + 1} \rightarrow N_{Hidden} \leq 10$$

لذا فان عدد العصبونات في الطبقة المخفية هي اقل او تساوي 10، إذ تمثل الحد الاعلى لعدد العصبونات في الطبقة المخفية، إن البيانات المستخدمة في هذه


شكل 7. تدريب الشبكة العصبية [19-3-1]

4. بناء تنبؤ في الشبكة العصبية

لأجل الحصول على قيم تنبؤ الشبكة العصبية (التنبؤ خطوة واحدة للامام) لاشهر عام 2017 حتى نهاية عام 2026، تم تدريب واختبار الشبكة الأفضل وهي [19-3-1] التي عدت افضل شبكة من بين الشبكات الاخرى باستخدام خوارزمية الانتشار الخلفي التزايدى، وبعد تدريب الشبكة بالاعتماد على المعلمات تم الحصول على النتائج التالية:

جدول 5

نتائج المعلمات الشبكة باستخدام خوارزمية الانتشار الخلفي التزايدى		
التجربة	التدريب	الخطا المطلق
328.599457	23.692626	خطأ الشبكة
0.000	0.000522	خطأ المحسنة
	6.46E-08	تكرار
	10001	خوارزمية التدريب
	الانتشار الخلفي التزايدى	



شكل 8. رسومات تدريب الشبكة [19,3,1] باستخدام خوارزمية الانتشار الخلفي التزايدى يتبين من الشكل أعلاه بان مجموعة الشرعية سلكت تقريبا نفس سلوك مجموعة التدريب وأن الخطأ المطلق لمجموعة التدريب كان الاقل جدا. اما شكل منحني الخطا المطلق للشبكة فانه يأخذ بالتناقص مع زيادة عدد مرات التكرار تحسين الخطأ يسرع ويحسن من قدرة الشبكة العصبية على التنبؤ وانه مفيد لاكتشاف الحالة عندما تكون الشبكة غير محسنة. ومن خلال تدريب واختبار الشبكة العصبية تم التوصل أيضا إلى قيم التنبؤ، والشكل (9) ادناه يظهر رسم السلسلة الزمنية مع التنبؤ لاشهر عام 2017-2026 المستحصل عليها من خلال خوارزمية الانتشار الخلفي التزايدى:


الدراسة يبلغ عددها (312) مشاهدة عنه (68.3%) من المشاهدات كمجموعة التدريب و(15.85%) من المشاهدات كمجموعة شرعية، بينما عنه (15.85%) من المشاهدات كمجموعة اختبار. لقد تم استخدام دالة التنشيط في الطبقة المخفية وطبقة الاخراج. تم تدريب الشبكات باستخدام خوارزمية الانتشار العكسي الرزم (الدفع) وكان عدد التكرارات (1000) تكرار وعدد مرات اعادة التدريب = 1 باستخدام عدة عصبونات مخفية لاختبار أفضلها وكان عددها بين 10-2 وذلك من اجل الحصول على افضل معيارية للشبكة العصبية والنتائج موضحة في الجدول (4) ادناه:

جدول 4

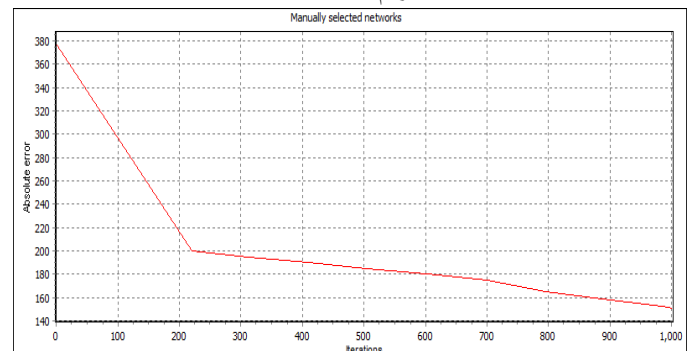
النتائج الاحصائية لمعيارية عدة شبكات عصبية

معيارية الشبكة	عدد الاوزان	المطابقة	خطا الاختبار	خطأ الشرعية	معيار AIC	معامل التحديد R ²
[19-3-1]	64	0.00509	196.41578	210.847	83.011631	0.751791
[19-9-1]	190	0.00523	198.59106	209.118	330.64075	0.772427
[19-6-1]	127	0.00472	211.55265	203.990	196.61446	0.802241
[19-7-1]	148	0.00523	190.90231	183.289	247.64162	0.756719
[19-8-1]	169	0.00461	216.76020	204.422	284.86477	0.78379

من الجدول أعلاه نلاحظ بان أفضل معيارية للشبكة العصبية هي [19-3-1] من بين المعاريات الاخرى وذلك حسب المعيار AIC مطابقة، كما مبين في الشكل التالي:



شكل 6. رسم أفضل شبكة عصبية



وهي [1-3-19] من بين المعاريات الاخرى وذلك حسب المعيار AIC مطابقة.

2. بعد الجفاف من أشد الظواهر الطبيعية المعقدة التي تؤثر بشكل كبير على حياة الانسان من جميع النواحي (الاقتصادية و الصحية ،....) و تبين من النتائج التحليل ان المحافظات العراقية خلال 10 السنوات القادمة تتعرض لمناخ متغير بين جاف معتدل و متوسط الرطوبة.
3. يتم تحديد ظاهرة الجفاف في المحافظات العراقية على أساس تأثيرات مواسم الجفاف السابقة و للتصدي لهذه الظاهرة لابد من دعم صياغة اطار وتخطيط لادارة مخاطر الجفاف
4. توصلت الدراسة الى ان متوسط الهطول السنوي للامطار في الفترة (1991-2016) بلغ نحو (440.66) اما متوسط هطول الامطار خلال السنوات العشر القادمة يساوي (307.51) و كمل لوحظ في هذه الدراسة ان ظروف المناخية في تغير مستمر مما يعرض البلد الى ندرة خلال عشر السنوات القادمة.
5. من خلال هذه الدراسة وجد ان السنوات (2017، 2018، و 2025، 2026) التي شهدت اقل معدلات هطول مما يوحي بان هذه السنوات أكثر عرضة للجفاف من غيرها حسب نتائج هذا البحث .


V. التوصيات

1. على الحكومة وضع خطة عمل شاملة للحد من مخاطر تأثيرات الجفاف حسب نتائج هذا البحث وخاصة لسنوات القادمة (2025، 2026).
2. تطوير نظام الانواء الجوية

VI. المصادر والمراجع References

المصادر العربية

- الخياط ، باسل ويونس وزكي ، عزة حازم .(2005). " استخدام الشبكات العصبية في التكهّن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في مدينة الموصل " ، المجلة العراقية للعلوم الإحصائية ، المجلد 5، العدد8 ، كلية علوم الحاسبات والرياضيات ، جامعة الموصل.
- الصقال ، أديبة اساعيل وطاهر، غادة محمد .(2006). " استخدام الشبكات العصبية الاصطناعية وشجرة القرار في تشخيص امراض الفم " ، مجلة الرافيدين لعلوم الحاسبات والرياضيات ، المجلد 3 ، العدد2، كلية علوم الحاسبات والرياضيات ، جامعة الموصل.
- العبيدي ، محمود خليل ابراهيم (2000). "الشبكات العصبية الاصطناعية"، مجلة ابجاث الحاسوب ، المجلد4، العدد1، الجامعة التكنولوجية ، بغداد .
- الكسو ، ايتاج عبد الحميد محمد علي .(2005): " استخدام الشبكات العصبية في تقدير رتب سلاسل ماركوف مع التطبيق على سلسلة جبل بطمة في محافظة نينوى " ، اطروحة دكتوراه غير منشورة كلية علوم الحاسبات والرياضيات ، جامعة الموصل ، العراق.
- الناصر، عبد الحميد حمزة والعبيدي ، مروان عبد المجيد . (2003). " استخدام الشبكات العصبية للتنبؤ المستقبلي بقم السلاسل الزمنية غير المنتظمة في طول الموسمية " ، المجلة العراقية للعلوم الإحصائية ، المجلد 3، العدد ، كلية علوم الحاسبات والرياضيات ، جامعة الموصل .
- عيسى، غلام زكي .(2000): "الشبكات العصبية، البنية الهندسية-الخوارزميات – التطبيقات"، الطبقة الاولى، شعاع للنشر والعلوم ، حلب، سوريا.
- منظمة الاغذية والزراعة للامم المتحدة (2014)، وزارة الزراعة "الاستراتيجية الوطنية وخطة



شكل 9. رسم السلسلة الزمنية بضمها قيم التنبؤ بعدها تم استخراج قيم دليل المطر القياسي باستخدام برنامج (SPI) لغرض تقييم الجفاف في العراق بالمستقبل حسب فترات المختلفة كما موضح في الجدول الادناه:

جدول 6

تصنيف حالات الجفاف في مستقبل جميع المحافظات العراق ماعدا الاقليم باستخدام خوارزمية الانتشار الخلفي التزايد

السنوات	شهر 1	3 اشهر	6 اشهر	9 اشهر	12 شهر
2017	م ج م	ج مت	ج مت	ج مت	م ج م
2018	م ج م	ج مت	م ج م	م ج م	ج مت
2019	م ج م	م ج م	م ج م	م ج م	م ج م
2020	م ر	م ر	م ر	م ر	م ر
2021	م ر	مت ر	مت ر	مت ر	مت ر
2022	مت ر	مت ر	مت ر	مت ر	مت ر
2023	م ر	مت ر	مت ر	مت ر	م ر
2024	م ر	م ج م	م ج م	م ج م	م ر
2025	ج مت	م ر	م ج م	م ج م	م ج م
2026	ش ج ج	ج مت	ج مت	ج مت	ج مت
	ج مت = معتدل جاف متوسط	ش ج ج = شديد جاف جدا	مت ر = متوسط الرطوبة	م ر = معتدل الرطوبة	م ج م = معتدل الرطوبة

جدول 7

يوضح النسبة المئوية لحالات الجفاف في مستقبل بالنسبة لجميع المحافظات العراق ماعدا الاقليم

السنوات	الحالة
2017	م ج م = 60 ، ج مت = 40
2018	م ج م = 60 ، ج مت = 40
2019	ج م = 100
2020	م ر = 100
2021	م ر = 20 ، مت ر = 80
2022	مت ر = 100
2023	م ر = 40 ، مت ر = 60
2024	م ر = 40 ، ج م = 60
2025	ج مت = 20 ، م ر = 20 ، ج م = 60
2026	ش ج ج = 20 ، ج مت = 80

IV. الاستنتاجات و التوصيات

الاستنتاجات

1. من خلال التحليل الاحصائي تم اختيار أفضل نموذج للشبكة العصبية

المصادر الانجليزية

- Johnson, R. A. and Wichern, W., (1996), Applied Multivariate Statistical Analysis (4th), New York: Patrice-Hell international.
- Kaboudan, Mak (2005)," Computational Forecasting of two Exchange Rates", School of Business, University of Redlands , 1200 East Colton Avenue, Redlands , CA92373, USA.
- KISI, ÖZGÜR (2005) , "Daily River Flow Forecasting using Artificial Neural Networks and Auto-Regressive Models", Turkish J. Eng. Env. Sci ., 9-20, © TÜBİTAK.
- Kumar, D. Negesh , Raju , K. Srinivasa and Sathish , T. (2004) , "River Flow Forecasting using Recurrent neural Networks", Water Resources Management 18:1431-161.
- Lin , Feng , Gregor , Shirley , Irons ,Richard and Yu ,Xing Huo . (1995) , "Time Series Forecasting with Neural Network", Complexity International (1995)2.
- McKee B Thomas., Doesken J Nolan. and Kleist John, 1993, The relationship of drought frequency and duration to time scales, Proceedings of ninth Conference on Applied Climatology, American Meteorological Society, Boston, 179-184.
- Moseley ,N. (2003) ,"Modeling Economic Time Series Using Afocused Time Lagged Feed Forward Neural Network", Proceeding of Student Research Day, CSIS,Pace University.
- Mostafa, M. M., El-Refae, G.A. 2003, Forecasting the Suez Canal Traffic: A Neural Network And analysis, Arab Journal of Administrative Sciences. Kuwait University. 10 (3) : 387- 409 .
- Nawzad M. Ahmed, (2007) "Forecasting Water Inflow and Electric Power Generation in Darbandi-khan Station By Using FFNN, and Adaptive Method In Time Series", Phd. Thesis of Philosophy in Statistics, University of Sulaimani, Kurdistan Region – Iraq.
- Zurada J. M., (1994) "Introduction to Artificial Neural Systems " , Jaico Publishing House, Mumbai.
- Allende, Hector , Moraga, Claudio and Salas, Rodrigo (1999), "Artificial Neural Network in time Series Forecasting : A comparative Analysis", German Academic Exchange Service (DAAD) .
- Andreescu ,Andrea.(2004)," Forecasting Corporate Earnings: A Data Mining Approach" , M.Sc. Thesis in Accounting The Swedish school of Economics and Business administration.
- Christopher, M. Fraser (2000), Neural Networks : Literature Review From a Statiatical Perspective, CSU, Hayward, Statistics Department.
- Everson, H. 1994, Using Artificial Neural Networks In Educational Research: some comparisons with statistical Models. Paper Presented At The Annual Meeting At The National Council On Measurement In Education. New Orleans, LA.
- Ghodsian, M., Khosronejad, A. and Montazer, G.A.(2003)," Estimation of Scour Hold Properties Around Vertical Pile using ANNs" , International Journal of Sediment Research ,Vol 18, No. 4, PP.290-300.
- Gilchrist, W. (1976). "Statistical Forecasting", Department of Mathematics and Statistics Sheffield City Polytechnic, John Wiley&Sons, UK.
- Gonzalez, J.M.B .& Desjandins, S.S.L. 2001 Artificial Neural Networks : Anew approach for Predicting Application Behavior. Paper presented At the Annual Meeting of The association For Institutional Research.
- Hamilton, J. D. (1994). "Time Series Analysis", Princeton University Press, New Jersey.