

التنبؤ بمعدلات درجات الحرارة الشهرية العظمى في مدينة الموصل باستخدام الشبكة العصبية
متعددة الطبقات

أ.م.د. أحلام عبد الجبار كاظم

قسم الجغرافية / كلية التربية / الجامعة المستنصرية

الملخص

ان التنبؤات بدرجات الحرارة تمثل اذارات مهمة لحماية حياة الانسان وممتلكاته ، لذا يتناول البحث استخدام الشبكة العصبية المتعددة الطبقات للتنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لمحطة الموصل الانوائية. وقد اثبتت هذه الشبكة قدرتها وكفاءتها على التنبؤ مقارنة مع الاساليب الاحصائية الاخرى كنموذج بوكس-جنكنز الموسمي . وقد تعامل البحث مع مشكلتين رئيسيتين في تحديد هيكلية الشبكة وهما تحديد عدد عقد الادخال ، وتحديد العقد المخفية في الطبقة، ولقد اوضحت النتائج المستخرجة اهمية وكفاءة الشبكة من خلال الاختيار المناسب لعدد عقد الادخال وعدد العقد المخفية في الطبقة باستخدام المقاييس الاحصائية AIC , BIC , AICc . وقد تم التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى لسنة 2013 باستخدام النماذج المختارة ومقارنتها بالقيم الحقيقية المقاسة في محطة الموصل وبالاعتماد على المقاييس MSE , MDE , PMC , ومن ثم تم اختيار النموذج الافضل لحساب التنبؤات المستقبلية لهذه الدرجات لسنة 2014 .

Prediction of Maximum Monthly Averages of Temperature in Mosel City Using Multi-layer Neural Network

Abstract

Temperatures forecasting are very important warnings to protect life and property ,the research deals with the multi-layered neural network to predict the averages of maximum temperatures for Mosel synoptic station . This network proved its capability and qualification in prediction by comparison with other statistical procedures like Box-Jenkins model (SARIMA) . The research deals with two major problems , First , determining the number of input nodes . second , determining the hidden nodes in the layer . The results show the importance and qualification of the network through the proper choosing for number of input nodes and number of hidden nodes in the layer, by using the statistical techniques AIC , BIC , and ALCC . The maximum temperature averages for Mosel station has predicted for 2013 by using the previous statistical procedures and compared its results with the real measured data for the station , by using the MSE , MDE , and PMC statistical techniques . then we choose the best model to calculate the future predictions of temperatures averages for 2014 .

المقدمة

يعد عنصر درجة الحرارة من العناصر الرئيسية في مناخ اي منطقة في العالم ، لما له من تأثير واسع وكبير على مختلف الانشطة البشرية عموما . كما وان اي تغير يحصل فيه مهما كان طفيفا فانه يؤدي الى تغييرات تكون كبيرة في معظم الاحيان في بقية العناصر المناخية . لذلك كان التركيز الكبير من قبل المهتمين بالشان المناخي والاضاع الجوية على مستوى باحثين اكاديميين او على مستوى مؤسسات مدنية او عسكرية تعنى بالجو والرصد الجوي على مسالة التوقعات والتنبؤات الجوية عموما ، وخاصة التنبؤ بدرجات الحرارة باعتبارها عنصرا رئيسيا وشديد الاهمية في مجمل ما يحدث من ذبذبات وتغيرات وتقلبات جوية يتعرض لها كوكب الارض حاليا .

يشهد العراق حاليا بجميع مناطقه ارتفاعا محسوسا وواضحا في درجات الحرارة لاسباب كثيرة بعضها محلي وبعضها الاخر عالمي الطابع . ويعد هذا الارتفاع مشكلة كبيرة تضاف الى مشاكل البيئة الحالية وتسبب ارهاقا ومشقة للسكان الى حد غير محتمل وخاصة في فصل الصيف الطويل والحار جدا في اغلب مناطق العراق . لذا جاء اهتمام البحث على التوقع او التنبؤ بما ستكون عليه درجات الحرارة في محطة الموصل للمساعدة في معرفة اتجاه درجات الحرارة المقبلة في المدينة كنوع من انواع المساعدة للتصدي لهذه الظاهرة على مستوى التنمية المستدامة في جميع القطاعات والتكيف لها ما امكن .

وقد اولى المناخيون والانوائيون في جميع مناطق العالم اهتماما واسعا بالتنبؤات الجوية وعملوا على دراستها او بناء نماذج او اساليب للتنبؤ بالمناخ عموما او باحد عناصره . وتوجد اساليب رياضية واحصائية كثيرة تستخدم لحساب التنبؤات المستقبلية لظاهرة معينة ، ومن بين هذه الاساليب ، نماذج بوكس-جنكنز المعروفة ، وكذلك نموذج الخلية العصبية الاصطناعية والتي تعد حاليا من التقنيات القوية للذكاء الاصطناعي Artificial Intelligence . وتعتبر الشبكة العصبية الاصطناعية محاكاة متواضعة بفعالها وشكلها ومضمونها للشبكة العصبية الحيوية الموجودة في الدماغ البشري ، وتتالف من الخلايا العصبية الحيوية المتصلة مع بعضها البعض بوصلات عصبية .

وقد شهدت السنوات القليلة الماضية توسعا ملحوظا في تطبيقات الشبكة العصبية في مجال التنبؤ باحوال عناصر المناخ كدرجات الحرارة العظمى والصغرى والامطار والضغط الجوي وغيرها . اذ اثبتت نماذج الشبكات العصبية قدرتها على التنبؤ ويمكن تطبيقها دون النظر الى فرضية معينة في طبيعة المتغيرات وعلاقتها ببعضها البعض ، فمن المعروف ان العناصر المناخية متداخلة ومترابطة فيما بينها ، وكل عنصر منها يؤثر ويتاثر بالعناصر الاخرى مما يعني وجود تداخل خطي عند استخدام اساليب كثيرة ومنها اسلوب الانحدار الخطي المستخدم بكثرة من الباحثين في الجغرافية والمناخ ، لذا فان استخدام الشبكة العصبية يعد اداة فعالة

ووسيلة مضمونة للبحث في تغيرات العنصر المدروس للوصول الى تنبؤات القيم المستقبلية له

وقد تناول عدد من الباحثين مسألة التنبؤ بدرجات الحرارة العظمى والصغرى منهم من استخدم اسلوب الشبكات العصبية كأنموذج انحدار غير خطي متعدد Multiple Non Linear Regression Model والآخر كأنموذج انحدار ذاتي غير خطي Non Linear Auto Regressive Model ، وكان اول من استخدم الخلية العصبية المتعددة الطبقات للتنبؤ بدرجات الحرارة العظمى والصغرى اليومية في البرتغال الباحثان Ricardo و Palutiko (Ricardo 1999, p45-59) . وفي عام ٢٠٠٤ استخدم Kihoro وآخرون (Kihoro 2004, p41-49) أنموذج الخلية العصبية المتعددة الطبقات للسلاسل الزمنية الموسمية للتنبؤ بدرجات الحرارة في Nottsyhom Cash مع المقارنة بأنموذج SARIMA اذ اثبت كفاءة وقدرة اسلوب الشبكة العصبية المتعددة الطبقات في عمليات التنبؤ. وفي عام ٢٠٠٧ استخدم الباحث Hayati (Hayati 2007, p613-620) اسلوب الشبكة العصبية للتنبؤ بدرجات الحرارة اليومية لمدينة كرمنشاه في ايران بالاعتماد على عناصر المناخ الاخرى المتمثلة (بالحرارة الجافة ، الحرارة الرطبة ، سرعة الرياح ، الرطوبة النسبية ، الضغط الجوي ، السطوع الشمسي ، الاشعاع) من الفترة ١٩٩٦ - ٢٠٠٦ ، وكذلك للتنبؤ بمعدلات الحرارة العظمى والصغرى لاشهر الرياح الموسمية في الهند (De,S.S. ، p34-44 ، ٢٠٠٩ ، و Baboo، p321-325، ٢٠١٠) و (Agrawal، p974-998، ٢٠١٢) وفي مدينة Changigarh (Kaur، p101-105، ٢٠١١) وفي مدينة كرمان ايضا (Mahbouben، p176-180، ٢٠١١) . وفي منطقة غرب الهملايا (Joshi، p283-290 ، ٢٠١٢) . وكذلك (Rahul ، p10-17 ، ٢٠١٣) .

واعتمد البحث على بيانات معدلات درجات الحرارة العظمى الشهرية لمحطة الموصل الانوائية للمدة من (١٩٨٠-٢٠١٣) ، وهذه المحطة تمثل مدينة الموصل الواقعة في المنطقة شبه الجبلية شمال العراق على دائرة عرض 36 19 شمالا وخط طول 09 ٤٣ شرقا

وعلى ارتفاع ٢٢٣ م عن مستوى سطح البحر . ويتبع البحث المنهج الاحصائي العلمي وكذلك الوصفي في الوصول الى الحقائق المرجوة بتطبيق النماذج الاحصائية المشار اليها سابقا وباستخدام برنامج SPSS 19 وكذلك برنامج Minitab 16 .

اهداف البحث

١- يهدف البحث الى ايجاد تنبؤات مستقبلية لمعدلات الحرارة العظمى الشهرية في محطة الموصل باستخدام نموذج الشبكة العصبية المتعددة الطبقات .

٢- مقارنة نتائج تنبؤات الشبكة العصبية مع تنبؤات نموذج بوكس-جنكنز الموسمي للحصول على تنبؤات اكثر دقة .

٣- التعرف على طبيعة درجات الحرارة للسنة المنتبا بها وهي ٢٠١٤ ، ان كانت تميل نحو الارتفاع ام هي مقاربة للمعدل العام لدرجات الحرارة .

ويتابع البحث فرضيتين هما :

١- تعد القيم المنتبا بها باستخدام الشبكة العصبية لمعدلات درجات الحرارة الشهرية في محطة الموصل ذات مصداقية كبيرة وقرية للواقع الفعلي .

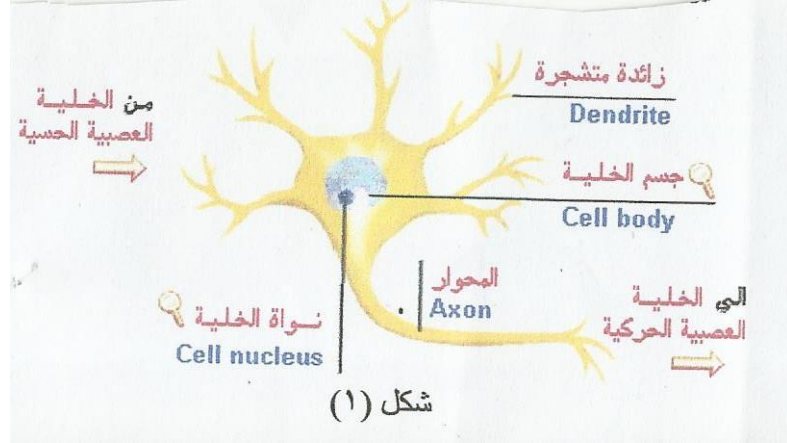
٢- ان درجات الحرارة الشهرية المنتبا بها لسنة ٢٠١٤ تمثل ارتفاعا عاما في قيمها عن السنوات السابقة .

الخلية العصبية الحيوية والخلية العصبية الاصطناعية

يتكون الدماغ البشري من خلايا عصبية وكل خلية عصبية تتألف من ثلاثة اقسام هي نهايات عصبية (زوائد شجرية Dendrites) ونواة Cell nucleus ومحور عصبي (غمد Axon) حيث تتلقى الاشارة من الخلايا الاخرى وتنتقل تلك الاشارة عبر نقاط التشابك

العصبي Synapses بواسطة معالجة كيميائية والتي بدورها تعدل من قيمة الإشارة ثم تجمع النواة الإشارة القادمة ثم تخرج الإشارة عبر الغمد فالنهايات العصبية كما في الشكل (1)

شكل (1) مكونات الخلية العصبية الحيوية

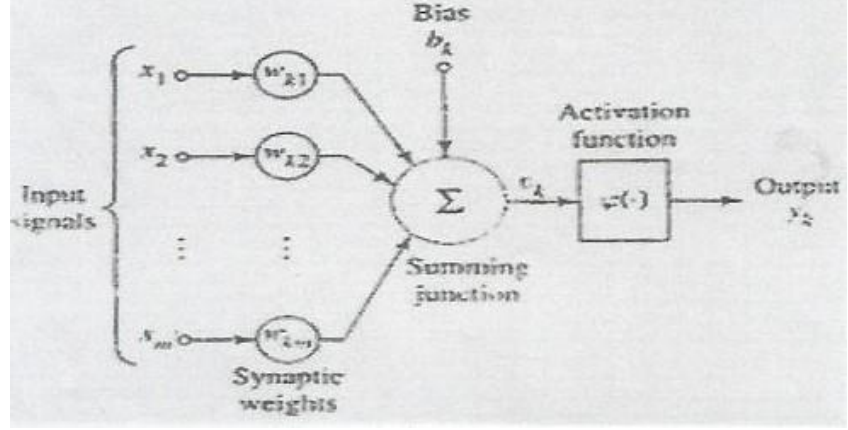


م : (الحسيني ٢٠١١ ، ص ٣) .

اما الخلية العصبية الاصطناعية فقد صممت لتحاكي خصائص الخلية العصبية الحيوية حيث استوحى العلماء الخطوط العريضة لبنية الشبكات العصبية من الدماغ البشري ، وهي بالمثل تحتوي على وحدات معالجة بسيطة تقابل النواة ووصلات ادخال تقابل الزوائد الشجرية ووصلات اخراج تقابل المحاور العصبية وتتصل هذه الوحدات ببعضها البعض عن طريق نقاط الاتصال تقابل التشابك العصبي ويخصص لكل نقطة اتصال وزن Weight ، كما في

شكل (٢)

شكل (٢) مكونات الخلية العصبية الاصطناعية



م : (الحسيني ٢٠١١، ص ٤) .

دوال التنشيط Activation Functions

" و تعرف بدوال التحويل Transfer Functions لانها تقوم بتحويل المدخلات عبر تفاعلها مع الاوزان من صيغة الى اخرى وتكون منها الخطية وغير الخطية ، ومنها الدوال الشائعة الاستخدام مثل الدالة اللوجستية ، والدالة اللوجستية ثنائية القطب ، والدالة الخطية . (Faraway ، p231 ، ١٩٩٨) ."

تعديل البيانات Data Normalization

هي عملية تهيئة البيانات قبل معالجتها (Pre – Processing) لاستخدامها في عملية تدريب الشبكة العصبية لذلك فأن مجال هذه البيانات لا بد ان يكون ضمن نطاق دالة التنشيط ، وقد وردت صيغ كثيرة لتعديل البيانات منها الصيغة المعيارية التي استخدمت في البحث .

الشبكات العصبية المتعددة الطبقات (Multi – Layer Networks ، Kaur) p101-105

(٢٠١١ ،

تتكون هذه الشبكات من طبقة واحدة او اكثر من الطبقات المخفية (Hidden Layer) التي بدورها تحتوي على عدد من العقد المخفية (Hidden Nodes) وهذه الشبكات تتألف من ثلاث مستويات .

١-مستوى المدخلات Inputs Level

يمثل المستوى الاول في الشبكة ويحتوي على عدد من العقد التي تمثل عدد المتغيرات المفسرة (المدخلات) ويتم فيه تلقي المعلومات المطلوب معالجتها ونود ان نشير عندما تكون وحدات الادخال متغيرات توضيحية فأن أنموذج الشبكات العصبية سيكون مشابه الى أنموذج الانحدار غير الخطي المتعدد وعندما تكون وحدات الادخال تمثل ازاحات المتغير المعتمد (Lags) فأن أنموذج الشبكة سيكون مشابه الى أنموذج الانحدار الذاتي غير الخطي .

٢-المستوى المخفي Hidden Level

يمثل المستوى الثاني من الشبكة وهذا المستوى قد يكون طبقة واحدة مخفية او عدة طبقات والتي بدورها تحتوي على عدد من العقد المخفية ولكل عقدة وزن يربطها مع المستوى السابق (المدخلات) ووزن يربطها مع المستوى اللاحق (مستوى المخرجات) اذ يتم فيه معالجة المعلومات.

٣-مستوى المخرجات Output Level

يمثل المستوى الاخير في الشبكة العصبية وهو عبارة عن مخرجات الشبكة حيث يتم اخراج نتائج المعالجة الى الوسط الخارجي.

عمل الشبكة العصبية

يمكن توضيح عمل الشبكة العصبية (Faraway ، p 232-235 ، ١٩٩٨) . اذا كانت مكونة من طبقة مخفية واحدة وعدد عقد المدخلات اثنان هما Y_{t-12}, Y_{t-1} وعدد العقد (٢) في الطبقة المخفية فأن

$$V_j = \sum W_{ij} \cdot Y_i \quad \dots\dots\dots(1)$$

وبأستخدام الدالة اللوجستية فأن

$$Z_j = 1/(1 + \exp(-V_j)) \quad \dots\dots\dots(2)$$

فأن الناتج النهائي سيكون

$$\hat{Y}_t = \varphi_0 \left\{ W_{05} + \sum_{h=3}^4 W_{h5} \varphi_h (W_{oh} + \sum_{i=1}^2 W_{ih} Y_{t-ji}) \right\} \quad \dots\dots\dots(3)$$

اذ ان :

W_{oh} : تمثل الاوزان التي تربط الثابت (Basie) وبين العقد المخفية والتي هي W_{04}, W_{03} .

W_{05} : الاوزان التي تربط الثابت (Basie) وبين الناتج Output .


W_{ih} : الاوزان بين المدخلات Input والعقد المخفية .

W_{h5} : الاوزان بين العقد المخفية والناتج Output.

φ_0 : دالة التنشيط (التفعيل) في مستوى المخرجات وعادة ما تكون خطية.

φ_h : دالة التنشيط في المستوى المخفي وعادة ما تكون لوجستية والشكل (3) يوضح ذلك

شكل (٣) يوضح كيفية عمل الشبكة العصبية الاصطناعية



م: (Faraway، ١٩٩٨، p231).

تدريب الشبكة العصبية

تستخدم خوارزمية الانتشار الخلفي في عملية تدريب او تعلم الشبكات العصبية المتعددة الطبقات وان ظاهرة التدريب في الشبكة يعني تغير اوزان الاتصال (ضبطها) بين الخلايا المتصلة مع بعضها . ونتيجة التدريب نحصل على الاوزان المثلى التي تعطي افضل تقدير لقيم المعيار وهي تمثل مخرجات الشبكة العصبية اذ يتم مقارنة هذه المخرجات المولدة بواسطة الشبكة مع مخرجات الهدف (المتغير المعتمد) لنحصل الخطأ (خطأ التدريب) Training Error الذي يمثل الفرق بين مخرجات الشبكة وقيم مخرجات الشبكة المرغوب فيها الذي يستخدم كأساس في عملية تعديل او تحديث الاوزان اذ ان هدف تدريب الشبكة على البيانات هو الحصول على اقل خطأ تدريب وبالتالي الحصول على الاوزان المثلى التي يتم اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتعلم.

ان عملية تحديث الاوزان تتم وفق خوارزمية الانتشار الخلفي Back Propagation Algorithm التي تحدث اوزان الطبقة الاولى (طبقة مستوى المدخلات الى المستوى المخفي)

عبر مرحلة الانتشار الامامي Feed Forward اما تحديث اوزان طبقة المستوى المخفي الى مستوى المخرجات فيكون عبر مرحلة الانتشار العكسي بالاعتماد على الخطأ والاوزان التي تم الحصول عليها عبر مرحلة الانتشار الامامي وان عملية التدريب بأستخدام هذه الخوارزمية يحتاج الى تحديد القيم الاولية للاوزان وان هذه القيم اما تختار عشوائياً او يتم توليدها من توزيعات احصائية او تؤخذ العينة $\frac{1}{\sqrt{Ni}}$ كقيمة اولية ولكل اوزان الشبكة اذ ان Ni : يمثل عدد عقد الادخال كذلك تحتاج عملية التدريب لمعرفة معدل التعلم او عامل الزحم اذ يستخدم في عملية تحديث الاوزان .

تحديد هيكلية الشبكة العصبية

لتحديد هيكلية الشبكة العصبية اذ يتطلب من مصمم الشبكة مهارة عالية وخبرة تجريبية في تحديد الخطوات الاتية (Faraway, 1998) :

اولاً : تحديد عدد عقد الادخال

ان المتغيرات في أنموذج السلسلة الزمنية تكون بدلالة المتغيرات المزاحة اي ان

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \dots\dots\dots (4)$$

ان تحديد هذه المتغيرات هي مشكلة كبيرة تواجه مصمم الشبكة العصبية وقد اقترحت عدة طرق منها :

١. الاعتماد على معاملات الارتباط الذاتي المعنوية للسلسلة الزمنية المستقرة.
٢. الاعتماد على طريقة تجميع البيانات فأذا كانت شهرية فأن عدد عقد الادخال هي

$$P = 12 \text{ واذ كانت فصلية فأن } P = 4$$

٣. اقترح Kihoro وآخرون عام ٢٠٠٤ طريقة (Automatic Relevance Determination Method) لتحديد عدد المتغيرات المزاحة زمنياً التي لها تأثير على المتغير المعتمد Y_t وذلك بالاعتماد على حساب المقدار

$$Inf(L) = \sum_{h=1}^{N_h} W_{ih} W_{ho} \dots\dots\dots(5)$$

حيث ان $Inf(L)$ مختصر لكلمة Influence الذي يمثل التأثير الكلي على الناتج Output من قبل المتغير Y_{t-L} وعلى فرض ان

$$r(L) = |inf(L)| \dots\dots\dots(6)$$

فإذا كانت قيمة $r(L)$ صغيرة فإنه يشير الى Y_{t-L} سوف لا يدخل في النموذج ويمكن تلخيص هذه القاعدة

١. تحديد عدد العقد المخفية.
٢. نختار قيمة P التي نعتقد بأن يكون لها تأثير على القيمة المتنبأ بها.
٣. ندرب الشبكة باستخدام كل الازاحات المختارة.
٤. نحسب المقدار Inf .
٥. نختار قيمة k فإذا

$$P(Y(t-L) \in Y) = \left\{ \begin{array}{l} 1 \quad \text{if } |r(L)| > k \\ 0 \quad \text{if } |r(L)| \leq k \end{array} \right. \quad L = 1, 2, \dots, P \dots\dots\dots(7)$$

مع مراعاة الاخذ بنظر الاعتبار مجموع مربعات الاخطاء لمجموعة التدريب SSE_t

ثانياً : تحديد عدد الطبقات المخفية

في اغلب تطبيقات التنبؤ باستخدام الشبكات العصبية المتعددة الطبقات يفضل استخدام طبقة مخفية واحدة.

ثالثاً : -تحديد عدد العقد في الطبقة المخفية

تواجه مصمم الشبكة العصبية مشكلة اخرى الا وهي تحديد عدد العقد في الطبقة المخفية فبعض الباحثين يختارها بعدد المتغيرات المزاحة زمنياً اي بعدد عقد الادخال في حين البعض الاخر يعتمد على مقياس AIC,BIC,AICC

$$AIC = N_t k \ln \hat{\sigma}^2 + 2 N_p \dots\dots\dots(8)$$

$$BIC = N_t \ln \hat{\sigma}^2 + N_p + N_p \ln(N) \dots\dots\dots(9)$$

$$AIC_C = AIC + \frac{2N_p(N_p + 1)}{N_t - N_p - 1} \dots\dots\dots(10)$$

اذ ان N_p : عدد المعلمات في الخلية العصبية N_t : حجم العينة لمجموعة التدريب

k : عدد عقد وحدة الاخراج

وان Kihoro واخرون قد اقترحوا طريقة لتحديد عدد العقد المخفية بموجب الصيغة الاتية

$$N_h \leq \frac{(N_t - 1) * \varepsilon}{(N_t + 2)} \dots\dots\dots(11)$$

أذ أن N_h : عدد العقد المخفية

N_t : عدد عقد المدخلات

ε : كمية موجبة فيها $\varepsilon \leq 0.125$

ان هذه الصيغة تعتمد على عدد عقد الادخال كلما قلت عددها زاد عدد العقد المخفية اذ ان العلاقة فيهما عكسية.

كما يمكن تدريب الشبكة على عدد من العقد قد تكون $1,2,3,\dots,t$ ويختار العدد الذي يكون فيه مجموع مربعات الاخطاء اقل ما يمكن .

رابعاً : تجزئة البيانات

تجزا البيانات في الخلية العصبية الاصطناعية الى(Faraway, 1998) :

❖ مجموعة التدريب او التعلم Training Set : وهي المجموعة التي تستخدم لتقدير الاوزان وتدريب الشبكة على التنبؤ.

❖ مجموعة الاختبار Test Set : هي المجموعة التي تقوم بأختبار قابلية الشبكة العصبية على التنبؤ بعد عملية التدريب.

❖ مجموعة التقويم Validation Set : مهمتها مراقبة وتقويم اداء تدريب الشبكة. لا توجد قاعدة عامة لتجزئة البيانات فأحياناً يكون 80% من البيانات لمجموعة التدريب 20% لمجموعة الاختبار او 70% للتدريب 30% للاختبار او 50% للتدريب و ٥٠% للاختبار.

وفي النهاية يمكن القول ان اسلوب الخلية العصبية يماثل ويشابه النماذج الاحصائية التقليدية شائعة الاستخدام غير ان هناك اختلاف فيما يتعلق ببعض المصطلحات فالمتغيرات المستقلة تسمى مدخلات والمتغير التابع يسمى قيم التدريب او قيم الهدف والقيم المتنبأ بها يسمى مخرجات والتقدير يسمى تدريب والمعلمات تسمى اوزان.

خامساً : تحديد عقد الاخراج

اتفق الباحثون على ان وجود عقدة اخراج واحدة تكفي لعملية التنبؤ بخطوة واحدة نحو الامام اما في حالة التنبؤ لعدة خطوات قادمة فأن عدد العقد يكون مساوياً الى عدد خطوات التنبؤ.

التنبؤ ————— Forecasting

ان الهدف الاساسي من استخدام أنموذج الشبكة العصبية هو حساب القيم المستقبلية للسلسلة الزمنية المدروسة.

ففي حالة التنبؤ لخطوة واحدة (One-Step-ahead) يكون باستخدام المعادلة باستخدام المشاهدات الفعلية لكل المتغيرات المزاحة كمدخلات.

أما في حالة التنبؤ لعدة خطوات ولتكن k (k-Step) يكون بالشكل الآتي (Faraway, 1998):

يستخرج التنبؤ لخطوة واحدة ثم تدخل هذه القيمة للتنبؤ لخطوة ثانية وهكذا إلى أن نحصل على k من التنبؤات وهي طريقة تكرارية مثل ما يحصل في تنبؤات بوكس-جنكز وهنا نود أن نشير إلى أن معمارية الشبكة لم تتغير وبوجود عقدة واحدة للنتائج كما موضح

$$\begin{aligned} \hat{Y}_{t+1} &= f(Y_t, Y_{t-1}, \dots, Y_{t-n}) \\ \hat{Y}_{t+2} &= f(\hat{Y}_{t+1}, Y_t, \dots, Y_{t-n+1}) \\ \hat{Y}_{t+3} &= f(\hat{Y}_{t+2}, \hat{Y}_{t+1}, \dots, Y_{t-n+2}) \dots\dots\dots (12) \\ \hat{Y}_{t+k} &= f(\hat{Y}_{t+k-1}, \hat{Y}_{t+k-2}, \dots, Y_{t-n+k-1}) \end{aligned}$$

وقد تم الاعتماد على معدلات درجات الحرارة الشهرية لمحطة الموصل للمدة من ١٩٨٠-٢٠١٣ وكما موضحة في ملحق (١)، لتشخيص نموذج الشبكة العصبية واستخدامه لحساب التنبؤات المستقبلية لدرجات الحرارة لسنة ٢٠١٤. وقبل البدء بتشخيص النموذج السابق سيتم استخدام أحد نماذج بوكس-جنكز كمقارنة لبيان مدى كفاءة وقوة التنبؤات المستخرجة بأسلوب الشبكة العصبية. ولتشخيص نموذج بوكس-جنكز تم الاعتماد على منهجية مراحل بناء النموذج والذي هو $SARIMA(0,0,1) \times (011)_{12}$ (Box, 1994, p327-371) حيث قدر النموذج واختبر كما في الملحق (٢).

وكان النموذج المقدر كالاتي :

$$(1-B^{12})Y_t = (1+0.30B)(1-0.94B^{12})a_t \dots\dots\dots (13)$$

وقد استخدم هذا النموذج لحساب التنبؤات المستقبلية لدرجات الحرارة للسنة ٢٠١٣ و ٢٠١٤ .

وكما ذكر سابقا من ان الباحث يواجه مشكلتين رئيسيتين هما تحديد عدد عقد الادخال Input Nodes وتحديد عدد العقد المخفية Hidden Nodes وهي :

اولاً : تحديد عقد الادخال Input Nodes

لتحديد عدد المتغيرات المزاحة نعتمد على الطرق الآتية:

١- الطريقة المقترحة من الباحثين Kihoro وآخرون اذ يتم أخذ كل متغير مزاح مع Y_t

وبيان مقدار تأثيره على Y_t من خلال حساب $|Inf(L)|$ بموجب المعادلة رقم (١٢)

واستخراج مجموع مربعات خطأ التدريب وعليه سيكون الانموذج هو:

$$NN(Y_{t-k};1) \quad k = 1,2,\dots,12$$

جدول (١) يوضح قيم $|Inf|$ ومجموع مربعات خطأ التدريب للازاحات (١٢.....١)

Lag	S.S.Ek	$ Inf $
١	37.597	0.939
٢	112.672	0.659
٣	132.553	0.202
٤	94.387	0.911
٥	44.974	1.292
٦	20.596	1.598
٧	49.680	1.312
٨	106.413	0.571
٩	140.483	0.193
١٠	111.554	0.733
١١	47.522	1.030
١٢	18.620	1.467

م : عمل الباحثة اعتمادا على نتائج برنامج SPSS

ومن خلال ملاحظة قيم $|Inf|$ ومجموع مربعات خطأ التدريب الاول جدول رقم (١) يمكن ان تحدد الازاحات المعنوية هي (1,6,12) اي ان نموذج الخلية العصبية هو $Y_t = f(Y_{t-1}, Y_{t-6}, Y_{t-12})$ للسلسلة .

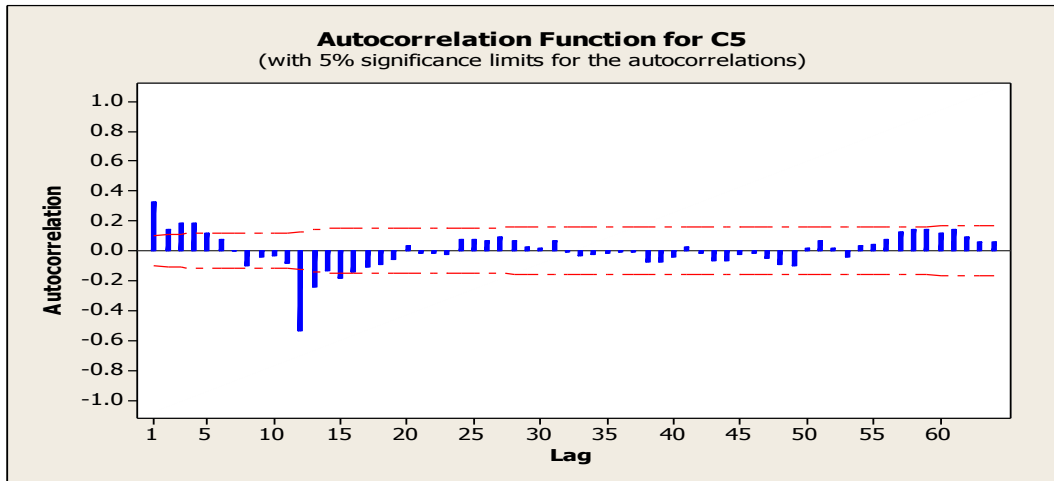
٢- الاعتماد على معاملات الارتباط الذاتي المعنوية لسلسلة درجات الحرارة العظمى المستقرة بعد ان اخذ لها الفرق الموسمي وقد وجد ان معاملات الارتباط الذاتي لدرجات الحرارة العظمى معنوية فقط عند الازاحة الاولى والثانية عشرة كما في الشكل (4) .

وعليه فانه ن نموذج الخلية العصبية سيكون:-
 $Y_t = f(Y_{t-1}, Y_{t-12})$

اي ان عدد عقد الادخال هي اثنان والمتغيرات المزاحة هي Y_{t-1}, Y_{t-12}

شكل (4) دالة الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة العظمى في

محطة الموصل



٣- ان بيانات السلسلة الزمنية المدروسة تمثل المعدلات الشهرية لدرجات الحرارة فأن المتغيرات المزاحة هي Y_{t-k} , $k=1,2,\dots,12$ اي ان نموذج الخلية العصبية يحوي على 12 عقدة ادخال .

ثانياً : تحديد عدد العقد المخفية (Hidden Nodes)

١- ان عدد العقد المخفية تعتمد على عدد عقد الادخال ولهذا فأن أنموذج الخلية العصبية سيكون حسب عدد عقد الادخال كما في الجدول (2)

جدول (2) يمثل عدد العقد المخفية حسب عدد عقد الادخال المستخرجة وانموذج

الخلية العصبية

الطريقة	عدد عقد الادخال	عدد العقد المخفية	النموذج
١	٣	٣	NN(1,6,12;3)
٢	٢	٢	NN(1,12;2)
٣	١٢	١٢	NN(1,2,.....,12;12)

اذ ان الرمز

$$NN(j_1, j_2, \dots, j_k; h)$$

تمثل الازاحة الزمنية h و j_1, j_2, \dots, j_k تمثل عدد العقد

المخفية

٢- استخدام الصيغة المقترحة من قبل الباحثين Kihoro واخرون بموجب المعادلة رقم

(١٧) لكل طريقة من طرق تحديد عدد عقد الادخال فكانت النتائج كما في الجدول

(3)

جدول (3) عدد العقد المخفية المستخرجة بموجب المعادلة (١1) والنموذج

النموذج	عدد العقد المخفية	عدد عقد الادخال	الطريقة
NN(1,6,12; 7)	٧	٣	١
NN(1,12; 8)	٨	٢	٢
NN(1,.....,12; 2)	٢	١٢	٣

الخاص

م : عمل الباحثة

نظراً لعدم تساوي الطريقتين في اختيار عدد العقد لذا سيتم اخذ عدد العقد (7-3) بالنسبة للنموذج الاول و(8-2) بالنسبة للثاني و (2-12) بالنسبة للنموذج الثالث وحساب المقاييس الاحصائية AIC, AIC_C, BIC وكما في الجدول (4) و(٥) و (٦) .

جدول (٤) المقاييس الاحصائية AIC, AIC_C, BIC و $\hat{\sigma}^2$ للنموذج الاول بعقد (7-3) لدرجات

الحرارة العظمى(م)

الانموذج	عدد المعالم	$\hat{\sigma}^2$	AIC	BIC	AIC_C
NN(1,6,12;3)	١٦	0.038	-816.959	-743.926	-814.747
NN(1,6,12;4)	٢١	0.018	-1060.446	-963.265	-1056.864
NN(1,6,12;5)	٢٦	0.022	-996.236	-876.200	-990.620
NN(1,6,12;6)	٣١	0.018	-1020.548	-877.883	-1012.314
NN(1,6,12;7)	٣٧	0.020	-975.242	-804.964	-963.174

م : عمل الباحثة اعتمادا على نتائج برنامج SPSS

جدول (٥) المقاييس الاحصائية AIC, AIC_c, BIC و $\hat{\sigma}^2$ للنموذج الثاني بعقد -)

(8 2) لدرجات

الحرارة العظمى

الانموذج	عدد المعالم	$\hat{\sigma}^2$	AIC	BIC	AIC_c
NN(1,12;2)	٩	0.027	-957.656	-916.237	-956.966
NN(1,12;3)	١٣	0.044	-816.156	-756.376	-814.734
NN(1,12;4)	١٧	0.023	-960.080	-882.161	-957.612
NN(1,12;5)	٢١	0.026	-1030.014	-931.516	-1026.641
NN(1,12;6)	٢٥	0.027	-941.318	-825.899	-936.097
NN(1,12;7)	٢٩	0.032	-884.477	-750.591	-877.375
NN(1,12;8)	٣٣	0.026	-939.309	-786.598	-930.113

م : عمل الباحثة اعتمادا على نتائج برنامج SPSS

جدول (٦) المقاييس الاحصائية AIC, AIC_C, BIC و $\hat{\sigma}^2$ للنموذج الثالث بعقد (12-2)

الانموذج	عدد المعالم	$\hat{\sigma}^2$	AIC	BIC	AIC_C
NN(1,2,...,12;2)	29	0.013	-111.311	-980.850	-1107.092
NN(1,2,...,12;3)	٤٣	0.015	-1161.111	-995.283	-1147.331
NN(1,2,...,12;4)	٥٧	0.022	-890.581	-629.752	-858.484
NN(1,2,...,12;5)	٧١	0.013	-998.692	-673.264	-945.991
NN(1,2,...,12;6)	٨٥	0.012	-1039.598	-646.557	-963.054
NN(1,2,...,12;7)	٩٩	0.016	-874.292	-422.405	-751.311
NN(1,2,...,12;8)	١١٣	0.016	-880.345	-360.305	-716.243
NN(1,2,...,12;9)	١٢٧	0.010	-1015.595	-427.431	-800.283
NN(1,2,...,12;10)	١٤١	0.031	-728.547	-69.608	-459.795
NN(1,2,...,12;11)	١٥٥	0.015	-841.478	-125.316	-438.478
NN(1,2,...,12;12)	١٦٧	0.012	-879.129	-107.522	-359.573

م : عمل الباحثة اعتمادا على نتائج برنامج SPSS

ومن خلال ملاحظة الجداول (6,5,4) نجد ان اقل قيماً للمقاييس الاحصائية كانت للنماذج

١-النموذج NN(1,6,12;4) الذي يضم ثلاثة متغيرات مزاحية هي $(y_{t-12}, y_{t-6}, y_{t-1})$ واربعة عقد مخفية.

٢-النموذج NN(1,12;5) الذي يضم متغيرين مزاحين هما (y_{t-12}, y_{t-1}) وخمسة عقد مخفية.

٣-النموذج NN(1,...,12;3) الذي يضم اثني عشرة متغير مزاح هي $(y_{t-1}, y_{t-2}, \dots, y_{t-12})$ وبثلاثة عقد مخفية.

لذا سنستخدم هذه النماذج لحساب التنبؤات المستقبلية للمعدلات الشهرية لدرجات الحرارة العظمى لسنة ٢٠١٣ ومقارنتها مع القيم الحقيقية لتلك السنة كما في الجدول (7) ومقارنتها مع القيم الحقيقية . وقد تم رسمها كما في الشكل (٥) .

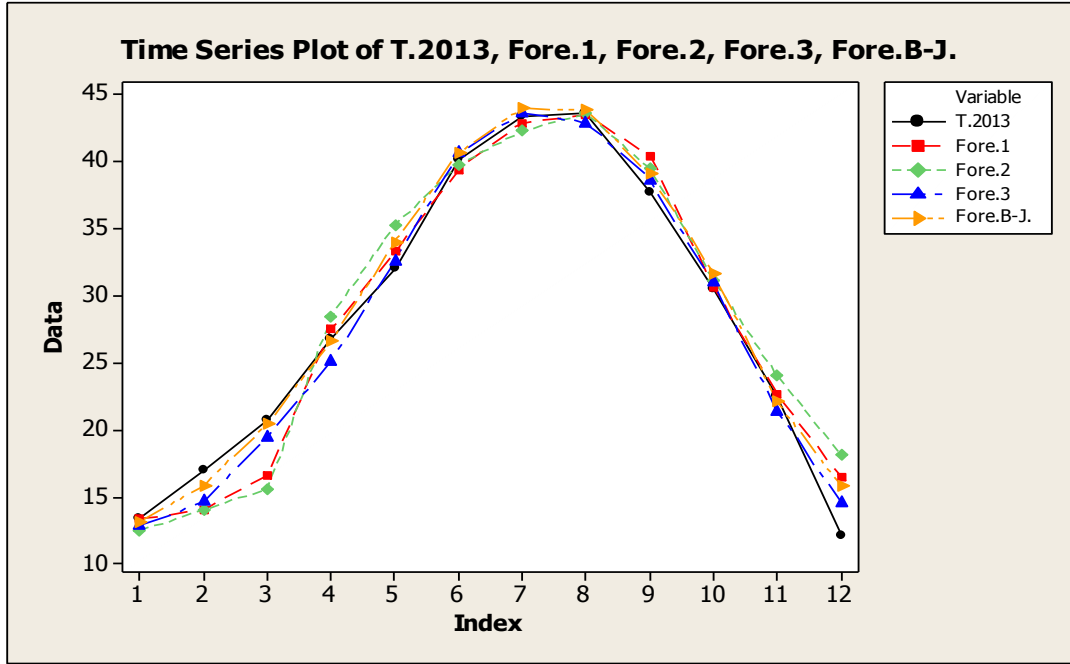
جدول (٧) القيم الحقيقية لمعدلات درجات الحرارة العظمى (م) لمحطة الموصل

مع القيم المتنبأ بها لسنة ٢٠١٣

الشهر	القيم الحقيقية	تنبؤات النموذج الاول	تنبؤات النموذج الثاني	تنبؤات النموذج الثالث	تنبؤات طريقة بوكس- جنكنز
١	13.3	13.3	12.4	12.8	13.1
٢	16.9	14.0	14.0	14.6	15.8
٣	20.7	16.6	15.6	19.5	20.4
٤	26.7	27.5	28.4	25.1	26.6
٥	32.0	33.3	35.2	32.6	34.0
٦	40.1	39.4	39.8	40.6	40.6
٧	43.3	42.9	42.3	43.6	44.0
٨	43.6	43.4	43.5	42.9	43.8
٩	37.7	40.4	39.5	38.6	39.0
١٠	30.4	30.6	31.2	30.9	31.7
١١	22.5	22.6	24.0	21.4	22.0
١٢	12.0	16.4	18.1	14.5	15.8

م: برنامج SPss وبرنامج MINITAB

شكل (٥) رسم المعدلات الشهرية لدرجات الحرارة العظمى لسنة ٢٠١٣ الفعلية مع التنبؤات المستخرجة



وكما هو واضح في الشكل السابق التطابق الكبير بين القيم الفعلية لدرجات الحرارة وبين القيم المتنبأ بها . وقد تم حساب المقاييس الاحصائية للنماذج الاربعة لدرجات الحرارة العظمى وكما موضحة في الجدول (٨) .

جدول (٨) المقاييس الاحصائية (MSE, Average وMED وPMC) لدرجات الحرارة العظمى

The Model	average	MSE	MED	PMC
NN(1,6,12;4)	28.36	4.59	0.618	7.68
NN(1,12;3)	28.66	7.81	0.807	11.11
NN(1,...,12;3)	28.09	1.64	0.369	5.43
SARIMA	28.90	1.98	0.406	5.50

م: عمل الباحثة

اذ ان (14)

$$MSe = \sum e_i^2 / 12, MED = \sqrt{\sum e_i^2} / 12, PMC = \sum |e_i / y_{t+i}| * 100\% / 12$$

ويظهر من خلال الجدول ٨ بان المعدلات السنوية العامة لدرجات الحرارة العظمى في محطة الموصل مقارنة جميعها للمعدل السنوي العام لعموم مدة الدراسة وهو (٢٧,٩ م) ، ومقارنة ايضا للمعدل السنوي الفعلي العام لسنة ٢٠١٣ وهو (٢٨,٢٧ م) ، وقد كانت اقرب قيمة للمعدل السنوي المتنبأ بها هي قيمة (٢٨,٠٩ م) للنموذج الثالث من نماذج الشبكة العصبية . وبالنظر لكون النموذج NN(1,...,12;3) يمتلك اقل قيمة للمقاييس الاربعة ، يليه نموذج بوكس-جنكنز لذا سيستخدم هذان النموذجان لحساب التنبؤات لدرجات الحرارة العظمى لسنة ٢٠١٤ كما في جدول(9) .

جدول (٩) التنبؤات الشهرية لدرجات الحرارة العظمى لسنة 2014 في محطة الموصل

الشهر	تنبؤات نموذج الشبكة العصبية	تنبؤات بوكس-جنكنز
١	13.2	12.4
٢	14.9	15.9
٣	18.9	20.3
٤	25.3	26.7
٥	32.7	33.9
٦	41.4	40.6
٧	42.7	44.0
٨	42.4	43.8
٩	38.8	39.1
١٠	30.7	31.6
١١	21.1	22.2
١٢	14.3	15.5
المعدل	٢٨,٠٣	٢٨,٨٣

م : برنامج SPss وبرنامج MINITAB

الاستنتاجات

١- استناداً الى المقاييس الاحصائية المستخدمة الاتية (AIC_C, AIC, BIC المصحح) لاختيار عدد العقد المخفية ، اذ كانت النماذج المختارة وهي ، $NN(1,6,12;4)$ ، ، $NN(1,12;5)$ ، $NN(1,...,12;2)$.

٢- اعطت الشبكة العصبية قيمة قريبة من الواقع الفعلي كلما ازداد عدد المتغيرات المزاحة زمنياً ، ويلاحظ ذلك من الشكل (٥) .

٣- عند استخدام المقاييس الاحصائية ($MSE, MED, MAPE$) لاختيار الانموذج الافضل للتنبؤات بدرجات الحرارة ، وجد ان الانموذج الافضل هو $NN(1....12;2)$ من بين نماذج الشبكة العصبية كونه اعطى اقل قيمة لهذه المقاييس ، يليه نموذج بوكس-جنكنز ، لذا فان الشبكة العصبية اثبتت كفاءتها وقدرتها على التنبؤ بدرجات الحرارة العظمى .

٤- ان المعدل السنوي العام لدرجات الحرارة العظمى المنتبأ بها لعام ٢٠١٤ اشر زيادة واضحة في درجة الحرارة ، وهذا مايتماشى مع الواقع الفعلي من ارتفاع لدرجات الحرارة في العراق عموماً وفي محطة الموصل خاصة .

التوصيات

١- يقترح البحث استخدام او اعتماد انموذج الشبكة العصبية $NN(1....12;2)$ للتنبؤ بدرجات الحرارة العظمى لمحطة الموصل من قبل دوائر الهيئة العامة للأنواء الجوية العراقية والرصد الزلزالي .

٢- اجراء المزيد من الدراسات والبحوث للتنبؤ بالمعدلات العامة لدرجات الحرارة وكذلك معدلات درجات الحرارة الصغرى في محطات اخرى في العراق .

٣- إجراء المزيد من الدراسات بتطبيق نماذج الشبكة العصبية للتنبؤ بالقيم المستقبلية لعناصر المناخ الأخرى مثل (كميات الامطار ، الرطوبة النسبية ، الضغط الجوي ، الرياح) ، وغيرها من العناصر ، وعلى وجه الخصوص التنبؤ بدرجات الحرارة اليومية لأهميتها الشديدة في الحياة

اليومية .

المصادر

١-الحسيني ، قصي حبيب واحمد عبد الامير الساعدي " مقدمة في الشبكات العصبية الاصطناعية " ، جامعة الامام جعفر الصادق ، ٢٠١١ .

٢-الهيئة العامة للانواء الجوية العراقية والرصد الزلزالي ، وزارة النقل والمواصلات ، المعدلات

العامة لدرجات الحرارة في محطة الموصل للمدة (١٩٨٠-٢٠١٣) ، قسم المناخ ، بيانات

غير منشورة .

3-Agrawal,A.and others, " AN Application of Time Series Analysis For weather Forecasting " , Engineering Research and Applications vol. 2,mar –Apr, 2012 .

4-Baboo, S.S. ,I.Shereef , " An Efficient Weather Forecasting Using Artificial Neural Network " , International Journal of Environmental Science and Development vol.1,No.4,October, 2010 .

5-Box, J. and others , " Time Series Analysis and Forecasting and Control " , 3^{ed}. Prentice-Hall International , Inc , 1994.

6-De,S.S. , " Artificial Neural Network Based Prediction of Maximum and Minimum Temperature in the Summer Monsoon Months over India" ,Applied Physics Research vol.1 ,No. 2, November 2009 .

7-Faraway , G. , Chris Chatfield , " Time Series Forecasting with neural networks : A comparative Study Using The Airline Data " Appl. Statist. 47, part 2,1998 .

8-Hayati,M. , Zahra M. , " Temperature Forecasting Based on Neural Network Approach "World Applied Sciences Journal 2(6) ,2007.

9-Joshi, P. , A. Ganju , " Maximum and Minimum Temperature Prediction over Western Himalaya using Artificial Neural Network ", MAUSAM,63,2, April , 2012.

10-Kaur, A., H.Singh , " Artificial Neural Networks in Forecasting Minimum Temperature", IUECT vol.2,ISSUE 3, Sept. 2011.

11-Kihoro, J.M. and others , " Seasonal Time Series Forecasting : A Comparative Study of ARIMA and ANN Models " , African Journal of Science and Technology (AJST) science and Engineering series vol.5, No. 2, December 2004 .

12-Mahbouben, A. and others , " Ambient Air Temperature Forecasting using Artificial Neural Network Approach", International Conference on Environmental and Computer Science IPCBEE vol.19,2011.

13-Rahul, G.K., and others , " Weather Forecasting using Soft Computing :Minimum Temperature , Maximum Temperature and Pressure", International Journal of Engineering Research and Development ,volume 7, Issue 11 July, 2013 .

14-Ricardo, M.T. , J..P.Palutikof , " Simulation of Daily Temperatures For Climate Change Scenarios Over Portugal Anural Network " Approach Climate Research 13",1999.

الملاحق

ملحق (١) المعدلات الشهرية لدرجات الحرارة العظمى (م) في محطة الموصل

(١٩٨٠-٢٠١٣)

Year	Jan.	Feb.	Mar.	Apr.	May.	Jun.	Jul.	Aug.	Sept.	Oct.	Nov.	Dec.
1980	11.3	14.0	18.1	23.5	32.4	39.6	44.2	42.0	36.7	29.6	19.5	14.2
1981	13.4	14.6	19.1	23.6	30.1	38.3	43.1	42.2	38.4	30.6	19.1	14.9
1982	11.3	12.6	17.4	24.6	31.8	38.5	41.0	40.6	37.2	26.8	16.4	11.9
1983	8.4	12.3	17.9	24.8	32.8	38.6	41.9	40.3	37.3	29.3	22.4	13.6
1984	14.1	16.6	19.7	25.6	30.9	40.3	43.7	40.5	38.8	29.7	18.1	11.9
1985	13.3	11.4	17.4	26.0	34.9	39.9	42.3	44.2	38.4	29.0	23.8	13.7
1986	13.2	15.3	19.3	26.2	31.6	38.5	44.8	44.3	41.0	31.3	17.6	12.8
1987	14.5	17.9	15.6	24.8	34.7	39.9	43.5	42.4	38.3	27.0	21.1	12.9
1988	10.5	14.4	16.9	23.3	32.5	37.7	34.2	42.0	37.8	29.2	18.7	14.6
1989	11.2	15.0	20.1	30.0	34.3	38.9	44.3	42.8	37.3	30.4	19.7	12.8
1990	10.7	13.0	20.3	23.4	33.6	39.7	43.8	41.9	38.3	31.2	24.4	15.9
1991	13.1	14.2	18.6	26.1	31.5	40.1	42.9	42.5	38.1	30.4	23.5	12.4
1992	8.3	9.7	16.0	23.6	29.0	37.0	41.2	42.1	37.2	31.6	19.0	11.1
1993	11.4	13.1	18.6	23.1	27.9	37.9	43.2	42.3	38.5	31.5	17.7	15.1

199 4	14. 9	14. 7	19. 5	27. 1	33. 8	39. 6	42. 9	42. 3	39. 3	30. 6	19. 0	10. 6
199 5	13. 6	16. 5	20. 2	23. 7	33. 9	38. 7	41. 6	42. 6	37. 5	30. 3	20. 5	15. 3
199 6	13. 1	16. 7	17. 7	23. 3	34. 5	38. 6	44. 8	43. 1	37. 0	29. 8	23. 5	16. 4
199 7	13. 6	13. 3	15. 6	23. 3	33. 7	39. 8	42. 1	40. 8	36. 5	30. 2	21. 9	14. 1
199 8	10. 8	14. 4	18. 9	26. 2	33. 8	41. 9	44. 3	44. 8	38. 1	32. 3	26. 4	19. 5
199 9	16. 1	17. 3	21. 2	27. 5	36. 1	40. 4	43. 2	43. 9	38. 0	31. 7	21. 8	16. 8
200 0	12. 0	15. 2	19. 3	28. 5	34. 1	40. 5	46. 4	43. 6	38. 2	29. 4	22. 2	13. 9
200 1	14. 1	15. 8	22. 2	26. 2	32. 3	40. 6	44. 1	44. 0	39. 2	31. 4	20. 6	15. 2
200 2	12. 1	17. 5	21. 9	22. 9	32. 6	39. 2	43. 3	41. 6	38. 5	32. 0	24. 1	12. 1
200 3	12. 6	14. 8	17. 1	25. 5	34. 7	40. 4	43. 3	44. 3	37. 9	32. 3	21. 2	13. 9
200 4	13. 5	14. 2	22. 4	25. 8	32. 5	39. 7	43. 6	42. 3	39. 6	32. 9	18. 9	13. 6
200 5	12. 6	14. 0	20. 0	27. 5	32. 7	38. 9	44. 1	43. 2	38. 1	31. 0	21. 6	18. 5
200 6	11. 1	15. 3	21. 4	25. 2	33. 2	39. 8	42. 1	45. 1	38. 2	30. 7	18. 9	14. 3
200 7	12. 5	15. 2	19. 3	22. 4	34. 7	40. 6	43. 7	43. 5	40. 0	32. 9	23. 1	16. 3
200 8	12. 0	15. 6	25. 2	30. 9	33. 3	40. 5	44. 0	44. 2	38. 6	30. 4	22. 3	15. 0
200 9	14. 3	17. 5	19. 7	25. 8	34. 2	40. 3	42. 2	41. 4	34. 4	32. 3	20. 4	16. 0
201 0	15. 4	16. 7	21. 5	27. 0	33. 4	41. 4	43. 0	45. 0	40. 7	32. 2	26. 7	18. 5
201 1	13. 2	14. 4	19. 8	25. 3	31. 9	39. 3	43. 4	42. 4	37. 3	29. 0	17. 9	15. 6

201 2	12. 4	14. 5	16. 9	28. 6	34. 6	41. 1	43. 4	43. 1	39. 3	31. 3	22. 3	14. 5
201 3	13. 3	16. 9	20. 7	26. 7	32. 0	40. 1	43. 3	43. 6	37. 7	30. 4	22. 5	12. 0

م : الهيئة العامة للأنواء الجوية العراقية والرصد الزلزالي ، المعدلات الشهرية لدرجة الحرارة العظمى في

محطة الموصل للمدة (١٩٨٠-٢٠١٣) ، قسم المناخ ، بيانات غير منشورة .

ملحق (٢) نتائج تقدير معلمات النموذج (SARIMA) واختباره

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	-0.3060	0.0489	-6.26	0.000
SMA 12	0.9431	0.0270	34.95	0.000
Constant	0.06366	0.01059	6.01	0.000

Differencing: 0 regular, 1 seasonal of order 12
 Number of observations: Original series 396,
 after differencing 384
 Residuals: SS = 1062.56 (backforecasts
 excluded)
 MS = 2.79 DF = 381

Modified Box-Pierce (Ljung-Box) Chi-Square
 statistic

Lag	12	24	36	48
Chi-Square	29.0	36.5	44.4	54.3
DF	9	21	33	45
P-Value	0.001	0.019	0.088	0.162

م: نتائج برنامج MINITAB

ملحق (٣) دالة الارتباط الذاتي لبواقي سلسلة درجات الحرارة العظمى وتبين ملائمة النموذج للبيانات

