



جمهورية العراق
وزارة التعليم العالي والبحث العلمي
جامعة كربلاء
كلية الادارة والاقتصاد
قسم الاحصاء

تشخيص وتقدير نماذج السلاسل الزمنية الموسمية مع تطبيق عملي

رسالة مقدمة الى مجلس كلية الادارة والاقتصاد في جامعة كربلاء

وهي جزء من متطلبات نيل درجة ماجستير في علوم الاحصاء

تقدم بها

كرار حمزة حسين علي المرشدي

باشرف

أ.م.د. ايناس عبد الحافظ محمد

2021 م

1443 هـ

كربلاء المقدسة

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

﴿ وَإِنْ تَعُدُّوا نِعْمَتَ اللَّهِ لَا تَحْصُوهَا ﴾

﴿ إبراهيم-٣٤ ﴾

الاهداء ...

بسم الله الرحمن الرحيم
(قل إعملوا فسيرى الله عملكم ورسوله والمؤمنون)
إلهي لا يطيب الليل إلا بشكرك ولا يطيب النهار إلا بطاعتك .. ولا تطيب اللحظات إلا بذكرك ..
ولا تطيب الآخرة إلا بعفوك ..
الله جل جلاله

إلى ...

رسول الامة وناصحها ومبلغ الرسالة.. نبي الرحمة ونور العالمين..
سيدنا محمد صلى الله عليه وعلى آله وصحبه وسلم

مَنْ كَلَّهَ اللهُ بِالْهَيْبَةِ وَالْوَقَارِ .. وَعَلَّمَنِي الْعِطَاءَ بَدُونَ انْتِظَارٍ .. إِمَّنْ أَحْمَلُ اسْمَهُ بِكُلِّ افْتِخَارٍ ..
أَرْجُو مِنْ اللهِ أَنْ يَرْحَمَكَ وَيَدْخُلَكَ فَسِيحَ جَنَاتِهِ وَسَتَبْقَى كَلِمَاتِكَ نَجْوَمًا أَهْتَدِي بِهَا الْيَوْمَ
وَفِي الْغَدِ وَإِلَى الْأَبَدِ..

(والدي العزيز رحمة الله تعالى)

معنى الحب ومعنى الحنان والتضحية .. بسمة الحياة وسر الوجود .. من بها أكبر وعليها
أعتمد .. شمعة متقدة تنير ظلمة حياتي..
(أمي الحبيبة)

رفقاء دربي من هم اقرب ألي من روعي وبهم استمد عزتي وإصراري

(اخوتي)

كل من يسعده نجاحي ... هؤلاء جميعاً ... أهدي هذا الجهد المتواضع سائلاً المولى عز وجل أن
يجعله شاهداً لنا لا علينا .

الباحث

شكر وإمتنان ...

الحمد لله رب العالمين، مستحقُّ الحمد، حمداً كثيراً طيباً طاهراً مباركاً ملءَ السَّمَوَاتِ والأَرْضِ وما بينهما، كما يَنْبَغِي لجلالِ وَجْهِهِ وعظيمِ سُلْطَانِهِ، والصلاة والسلامُ على سَيِّدِنَا وقَائِدِنَا مُحَمَّدٍ (صلى الله عليه وسلم) خاتمِ النبيين والمرسلين وعلى آلِهِ وأصحابه الطيبين الطاهرين وَمَنْ تَبِعَهُمْ بإِحْسَانٍ إلى يومِ الدِّينِ.

لا يسعني وأنا انهي عملي هذا إلا أن أتقدم بعظيم شكري وامتناني إلى أستاذتي الفاضلة الأستاذ المساعد الدكتور (إيناس عبد الحافظ محمد) لتفضلها بالإشراف على رسالتي ولما قدمته لي من آراء سديدة وبناءة طوال مدة الدراسة وكتابة الرسالة والتي كان لها الأثر الكبير في اغناء الرسالة، أسأل الله أن يحفظها ويوفقها وينعم عليها بالصحة والعافية لأكمال مشوارها العلمي .

كما أتقدم بالشكر الجزيل إلى السادة رئيس وأعضاء لجنة المناقشة المحترمين لتفضلهم بقبول مناقشة الرسالة ولما سيبدونه من ملاحظات قيّمة تسهم في اغناء الرسالة.

وأتقدم بوافر شكري وامتناني إلى جميع أستاذتي الفضلاء في قسم الإحصاء إذ كانوا لنا كالأضواء التي تنير لنا درب المظلم ففضلهم علينا لا يقدر بحجم ، لذلك نحن شاكرون وممتنون لتقانيهم وإخلاصهم في الجهد الذي بذلوه لكي يوصلونا إلى هذا المستوى .

والشكر والتقدير وأسمى جمل الأعتذار إلى كل من لم يسعنا ذكرهم وتذكرهم لتقديم شكرنا لهم سائلين المولى عز وجل دوام الموفقية للجميع ، إنه قريب مجيب .

الباحث

سعت هذه الرسالة تحليل سلسلة درجات الحرارة اليومية المسجلة في مركز قضاء الحلة / محافظة بابل لسنة (2020) والتي شملت احدى عشرشهر (334) مشاهدة والتي تم الحصول عليها من هيئة الانواء الجوية العراقية وباستعمل نماذج الانحدار الذاتي المتوسطات المتحركة الموسمية SARIMA ونماذج الانحدار الذاتي المتوسطات المتحركة المضاعفة الموسمية بالاعتماد على البرامج الجاهزة (Minitab 17, Matlab 2015, E-views 10) بهدف تشخيص افضل انموذج موسمي للسلسلة الزمنية من مجموعة نماذج تم توفيقها، ومن ثم اختيار افضل انموذج من هذه النماذج باستعمال معايير المقارنة بين النماذج وهي (AIC , BIC , SMAIC) ومن ثم تقدير الانموذج المشخص باستعمال ثلاثة طرائق في التقدير وهي طريقة الامكان الاعظم التقريبية وطريقة الامكان الاعظم المضبوطة وطريقة المربعات الصغرى اللاخطية ومن ثم المقارنة بين هذه الطرائق باستعمال المعيار الاحصائي متوسط مربعات الخطأ للتوصل الى افضلها. ومن ثم مقارنة اسلوب الشبكات العصبية الاصطناعية مع باقي الطرائق. وتم التوصل الى ان الانموذج الموسمي المضاعف $ARIMA(p,q,d) \times (P,Q,D)_2$ كأفضل انموذج ممثل للسلسلة الزمنية الموسمية محل الدراسة وكذلك تم تشخيص الانموذج الموسمي المضاعف من الرتبة $ARIMA(1,1,0) \times (1,2,0)_2$ كأفضل انموذج موسمي لسلسلة درجات الحرارة. وقد تفوقت طريقة الامكان الاعظم التقريبية على طريقة الامكان الاعظم المضبوطة وطريقة المربعات الصغرى اللاخطية في تقدير معاملات الانموذج الموسمي المضاعف $ARIMA(1,1,0) \times (1,2,0)_2$. قد تبين ان اسلوب الشبكات العصبية الاصطناعية افضل من باقي طرائق التقدير اعتماداً على معيار متوسط مربعات الخطأ MSE.

قائمة المحتويات

الموضوع	الصفحة
الآية	أ
الاهداء	ب
شكر وتقدير	ج
المستخلص	د
الفصل الأول : منهجية الرسالة	1-6
1-1 المقدمة	1-2
2-1 مشكلة الرسالة	2
3-1 هدف الرسالة	2
4-1 الاستعراض المرجعي	2-8
الفصل الثاني: الجاني النظري	8-51
2-1 تمهيد	8
2-2 الاستقرارية في السلاسل الزمنية	8-10
2-2-1 عدم الاستقرارية حول المتوسط	10-13
2-2-2 عدم الاستقرارية في التباين	13-15
2-2-3 اختبارات فحص استقرارية السلسلة الزمنية	15
2-2-3-1 اختبار جذر الوحدة	16-17
2-2-3-2 دالة الارتباط الذاتي	17-18
2-2-3-3 دالة الارتباط الذاتي الجزئي	18-20
2-3 السلاسل الزمنية الموسمية	20-21

21	2-4 نماذج السلاسل الزمنية الموسمية
21-22	2-4-1 نموذج الانحدار الذاتي الموسمي
23	2-4-2 نموذج الأوساط المتحركة الموسمي
23-24	2-4-3 الانموذج المختلط (الإنحدار الذاتي - الأوساط المتحركة) الموسمي
24	2-4-4 الانموذج المختلط التكاملي الموسمي
64-27	2-4-5 إنموذج ARIMA المضاعف Multiplicative
27	2-5 التشخيص Identification
27-28	2-5 تحديد رتبة الانموذج
28	2-5-1 معيار معلومة أكاي
28	2-5-2 معيار معلومة بيز
28-29	2-5-3 معيار اكاكي المعدل الموسمي
29	2-6 فحص الانموذج
29-30	2-6-1 اختبار Box and Pierce
30	2-6-2 اختبار حدي الثقة
30-31	2-6-3 إختبار Ljung-Box Test
31	2-7 تقدير معلمات الانموذج
31-34	2-7-1 طريقة المربعات الصغرى اللاخطية

34-35	2-7-2 طريقة الامكان الاعظم المضبوطة
35-36	2-7-3 طريقة الامكان الاعظم التقريبية:
36-37	2-8 الشبكات العصبية الاصطناعية
37-39	2-8-1 مراحل تطور شبكة الخلية العصبية الاصطناعية
39-41	2-8-1-1 الخلية العصبية البيولوجية والعصبونات الاصطناعية
41-43	2-8-3 تعريف الشبكة العصبية الاصطناعية وهدفها
43-45	2-8-4 معمارية (هيكلية) الشبكة العصبية الاصطناعية
45-50	2-8-5 معالجة المعلومات في الشبكة العصبية (التعلم والتدريب)
50-51	2-8-6 انواع الشبكات العصبية الاصطناعية
55-158	الفصل الثالث: الجانب التطبيقي
55	3-1 تمهيد
55	3-2 بيانات البحث
55	3-3 التحليل الأحصائي للبيانات
55-59	3-3-1 فحص استقرارية السلسلة
60-63	3-3-1-1 إزالة الاتجاه العام
63-67	3-3-1-2 إزالة المركبة الموسمية
67	3-3-2 تشخيص وتحديد الانموذج الموسمي الملائم
69	3-3-2-1 تحديد رتبة الانموذج
69-80	3-3-2-2 تقدير معلمات الانموذج واختبار معنويتها وملائمة الانموذج

80-91	1- باستعمال طريقة الامكان الاعظم التقريبية
91-103	2- التقدير باستعمال طريقة الامكان الاعظم المضبوطة
103-124	3- التقدير باستعمال طريقة المربعات الصغرى اللاخطية
157	3- التقدير باستعمال الشبكات العصبية الاصطناعية
157	الفصل الرابع : الاستنتاجات والتوصيات
158	5.1 الاستنتاجات Conclusions
158	2 - 5 التوصيات Recommendations
160-165	المصادر
160-162	1- المصادر العربية
162-165	2- المصادر الأجنبية
166-170	الملاحق
A	Abstract

قائمة الجداول

الصفحة	عنوان الجدول	رقم الجدول
14	لفروق الأولى للسلسلة الزمنية	2-1
15	لفروق الثاني للسلسلة الزمنية	2-2
26	طبيعة الانموذج وفقاً لمنحنى الارتباط الذاتي	2-3
58	قيم دالتى PACF , ACF لدرجات الحرارة في محافظة بابل	3-1

59	نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية	3-2
62-63	قيم دالتي PACF , ACF لدرجات الحرارة في محافظة بابل بعد اخذ الفرق الأول	3-3
63	نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الأول	3-4
65-67	قيم دالتي PACF , ACF لدرجات الحرارة في محافظة بابل بعد اخذ الفروق الموسمية	3-5
67	نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الموسمي	3-6
68	النماذج الموسمية المضاعفة المقترحة ذات التقديرات المعنوية	3-7
69	نتائج تقدير الانموذج المقترح بموجب طريقة الامكان الاعظم التقريبية	3-8
70-72	قيم دالتي PACF , ACF لدرجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية	3-9
73-80	القيم التقديرية والبواقي لسلسلة درجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية	3-10
80	نتائج تقدير الانموذج المقترح بموجب طريقة الامكان الاعظم المضبوطة	3-11
81	قيم دالتي PACF , ACF لدرجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة	3-12
81-83	القيم التقديرية بموجب طريقة الامكان الاعظم التقريبية والبواقي لسلسلة درجات الحرارة في محافظة بابل	3-13
91-93	نتائج تقدير الانموذج المقترح بموجب طريقة المربعات الصغرى اللاخطية	3-14

93-94	قيم دالتي PACF , ACF لدرجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة المربعات الصغرى اللاخطية	3-15
96-102	القيم التقديرية والبواقي لسلسلة درجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة المربعات الصغرى اللاخطية	3-16
104-111	القيم التقديرية والبواقي لسلسلة درجات الحرارة في محافظة بابل الانموذج المقدر بموجب طريقة الشبكات العصبية الاصطناعية	3-17
111-124	يبين نتائج مقارنة التقدير بين الطرائق المستعملة في تقدير سلسلة درجات الحرارة في محافظة بابل باستعمال معيار (MSE)	3-18

قائمة الاشكال

الصفحة	عنوان الشكل	رقم الشكل
38	خلية الشبكة العصبية الاصطناعية	2-1
41	مكونات الخلية العصبية الاصطناعية	2-2
45	معمارية الشبكة العصبية الاصطناعية	2-3
46	شبكة ايلمات العصبية الاصطناعية	2-4
50	معمارية شبكة (NARX) العصبية الاصطناعية	2-5
56	سلسلة درجات الحرارة اليومية في محافظة بابل Y_t	3-1
57	رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t	3-2
60	يوضح رسم سلسلة درجات الحرارة في محافظة بابل Y_t بعد اخذ الفرق الاول لها	3-3
61	رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF	3-4

	لدرجات الحرارة في محافظة بابل بعد اخذ الفرق الأول	
64	سلسلة درجات الحرارة اليومية في محافظة بابل Y_t بعد ازالة الموسمية	3-5
64-65	رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t بعد اخذ الفروق الموسمية	3-6
70	دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف	3-7
72-73	المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية	3-8
80	القيم التقديرية والحقيقية لسلسلة درجات الحرارة في محافظة بابل المقدر بموجب طريقة الامكان الاعظم التقريبية	3-9
81	دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف بموجب طريقة الامكان الاعظم المضبوطة	3-10
84	(a) المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة	3-11
91	القيم التقديرية بموجب طريقة الامكان الاعظم التقريبية والحقيقية لسلسلة درجات الحرارة في محافظة بابل بموجب طريقة الامكان الاعظم المضبوطة	3-12
92	دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف بموجب طريقة المربعات الصغرى اللاخطية	3-13
95	(a) المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي	3-14

	الطبيعي لسلسلة البواقي الانموذج المقدر بموجب طريقة المربعات الصغرى اللاخطية	
103	القيم التقديرية والحقيقية لسلسلة درجات الحرارة في محافظة بابل المقدر بموجب طريقة المربعات الصغرى اللاخطية	3-15
104	معمارية الشبكة العصبية الاصطناعية	3-16
111	القيم التقديرية والحقيقية لسلسلة درجات الحرارة في محافظة بابل المقدر بموجب الشبكة العصبية الاصطناعية NARX	3-17



الفصل الاول

منهجية الرسالة

1-1 مقدمة Introduction

تعد عملية التخطيط من أهم العمليات التي تؤدي الى تطور البلدان إذا اعتمدت فيه الاساليب الاحصائية التي تؤدي الى تخطيط قائم على اسس علمية متينة. ويُعد تحليل السلاسل الزمنية من ابرز الاساليب الاحصائية والتي تعد واحدة من الموضوعات المهمة والمستعملة في تفسير سلوك الظواهر عن طريق دراسة تطورها التاريخي عبر فترة زمنية قد تكون يومية او اسبوعية او فصلية او شهرية او يومية لإغراض تقديرها بأقل خطأ ممكن. فضلاً عن أنّ تحليل السلاسل الزمنية أصبح له دور مهم في عملية اتخاذ القرارات في المجالات التطبيقية. والغاية الاساسية من طرائق السلاسل الزمنية يتمثل بالحصول على نماذج يمكن استعماله لوصف المشكلة. ففي كثير من الظواهر الطبيعية وفي بعض مجالات الحياة العامة نرى ان بعض الظواهر تتغير بمرور الزمن وهذا التغير قد يحدث بصورة منتظمة وبعضها في مواسم معينة او في فترات متباعدة او تتغير بصورة فجائية تسمى احيانا بالتغيرات العرضية . ولغرض دراسة سلوك هذه الظواهر والوقوف على اسباب حدوثها لابد من بناء نماذج رياضية يمثلها ويجعلنا قادرين على تقديرها والتنبؤ بها مستقبلاً. ولقد شهدت العقود الأخيرة من القرن الماضي إستعمالاً واسعاً لنماذج السلاسل الزمنية ولاسيما نماذج الانحدار الذاتي - الأوساط المتحركة الموسمية التي يطلق عليها إختصاراً النماذج المختلطة الموسمية المستقرة $SARMA(p,q)$ والنماذج المختلطة المتكاملة الموسمية غير المستقرة $SARIMA(p,d,q)$ والنماذج المضاعفة $x(P,Q,D)_s$ عند الازاحة الموسمية S . وإن شرط الاستقرارية (Stationary) في المتوسط هو الأداة الرئيسية في بناء هذه النماذج . وهنا في هذه الرسالة سوف نتطرق الى اساليب التنبؤ بالسلاسل الزمنية الموسمية محاولين تحليل السلسلة الزمنية المتمثلة بكمية درجات الحرارة اليومية المسجلة في محافظة بابل-مركز قضاء الحلة لسنة 2020 وبناء نماذج رياضية مناسب يمثلها فقد اشتملت الرسالة على اربعة فصول.

تضمن الاول منهجية الرسالة من مشكلة البحث واهداف البحث والاستعراض المرجعي لبعض الدراسات والبحوث السابقة التي تناولت موضوع البحث.

اما الثاني فقد اشتمل على الجانب النظري إذ تضمن عرضاً لاهم المفاهيم الاساسية للسلاسل الزمنية وبالاخص السلاسل الزمنية الموسمية وعرضاً لاهم نماذج السلاسل الزمنية الموسمية وعرضاً لخطوات بناء نماذج لسلسلة زمنية موسمي وعرضاً لمفهوم الشبكات العصبية الاصطناعية وخطوات تنفيذها .

أما الفصل الثالث فقد تضمن الجانب التطبيقي وهو تحليل بيانات درجات الحرارة في محافظة بابل - مركز قضاء الحلة والتي تم الحصول عليها من هيئة الانواء الجوية العراقية .
واخيراً الفصل الرابع فقد اشتمل على الاستنتاجات والتوصيات التي توصل إليها الباحث من الجانب التطبيقي.

1-2 مشكلة الرسالة Problem of the study thesis

تتبنى غالبية الإدارات عند صياغة برامجها التخطيطية والتنموية تطبيقات واسعة في مجال السلاسل الزمنية وصولاً الى نتائج أكثر دقة وفاعلية، فالتقدم الذي تشهده الدول تعبير عن قدرتها في وضع الخطط السليمة لتنمية مواردها المادية والبشرية، من هنا يأتي دور السلاسل الزمنية للاسهام في بناء الخطط والبرامج المستقبلية، ولأن الكثير من الظواهر تتغير عبر الزمن عن طريق تغير خصائصها وسماتها ومنها ما يتضمن التغيرات الموسمية والتي كانت درجات الحرارة واحدة من تلك السلاسل الزمنية التي تطلب بناء نموذج احصائي يفسر سلوك تلك الظاهرة ويعمل على تفسيرها.

1-3 هدف الرسالة Aim of the study thesis

تهدف الرسالة الى تشخيص افضل نموذج موسمي للسلسلة الزمنية من مجموعة نماذج تم توفيقها والمتمثلة بدرجات الحرارة في مركز قضاء الحلة ، ومن ثم اختيار افضل نموذج مركز قضاء الحلة بالاعتماد على الانموذج المشخص باستعمال ثلاثة طرائق في التقدير هي طريقة الامكان الاعظم التقريبية وطريقة الامكان الاعظم المضبوطة وطريقة المربعات الصغرى اللاخطية ومقارنتها مع طريقة الشبكات العصبية الاصطناعية (NARX) عن طريق استعمال معيار المقارنة متوسط مربعات الخطأ (MSE).

1-4 الاستعراض المرجعي Literature Review

تتضمن هذه الفقرة استعراضاً مرجعياً لاهم الدراسات والبحوث ذات العلاقة بموضوع الرسالة وكالاتي:

- في عام (2005) قارن الباحثان (الخياط وزكي) منهجية بوكس وجنكز والشبكات العصبية الاصطناعية في التنبؤ باستهلاك الطاقة الكهربائية في مدينة الموصل باستعمال المعايير الاحصائية متوسط مربعات الخطأ (MSE) ومتوسط القيم المطلقة لنسب الاخطاء (MAPE)

- ومعدل القيم المطلقة للأخطاء (MAE) وتوصلا إلى أن أسلوب الشبكات العصبية الاصطناعية يتفوق على أسلوب بوكس وجنكز في التنبؤ . (الخياط وزكي، 2005)
- **في عام (2011) استعمل الباحثان (المحمدي و طعمة) نماذج السلاسل الزمنية الموسمية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة عن طريق دراسة وتحليل البيانات الشهرية عن استهلاك الطاقة الكهربائية في مدينة الفلوجة للفترة (2005-2010) وتوصلا إلى أن النموذج الملائم والكفوء لتمثيل بيانات السلسلة الزمنية هو النموذج الموسمي المضاعف من الدرجة $SARIMA(1,1,1) \times (0,1,1)_{12}$ وتم التنبؤ بكميات الاستهلاك الشهري للفترة من كانون الثاني 2011 ولغاية كانون الأول 2012 ، إذ أظهرت النتائج قيما تنبؤية متناسقة مع بيانات السلسلة الأصلية. (المحمدي و طعمة، 2011)**
 - **وفي العام نفسه (2011) هدفت دراسة (الجمال وآخرون) إلى اختيار أفضل نموذج موسمي مضاعف لبيانات السلسلة الزمنية باستعمال معايير تحديد الرتبة وهي معيار SMAIC, AICC, BIC, AIC ثم التنبؤ بالنماذج المختلفة وحساب خطأ التنبؤ لها للتأكد من دقة النموذج الذي تم اختياره . وتم اختيار أفضل نموذج سلسلة سرعة $SARIMA(0,1,1)(0,1,1)_{12}$ كأفضل نموذج لسلسلة سرعة الرياح والنموذج $ARIMA(0,1,1)(0,1,1)_{12}$ لسلسلة الغيمة . (الجمال وآخرون، 2011)**
 - **في عام (2012) استعمل الباحث (Moreno) وآخرون عدة أنواع من الشبكات العصبية الاصطناعية وتم تطبيقها على السلاسل الزمنية وهي السلاسل الزمنية متعددة الطبقات والدالة الشعاعية وانحدار الشبكة العصبية المعمم والشبكة العصبية المتكررة . واثبتوا أن أساليب الشبكات العصبية أكثر دقة في الحصول على تنبؤات حول السلاسل الزمنية . (Moreno& et al , 2012)**
 - **في عام (2013) درس الباحثان (Wang& et al) السلسلة الزمنية الممثلة لهطول الأمطار والتي تستند إلى مدينة Shouguang في الكتب السنوية الإحصائية لـ Shandong للفترة 1996 - 2009 والتي لها ارتباط ذاتي قوي بالخصائص الموسمية في السلاسل الزمنية. باستعمال منهجية الانحدار الذاتي والوساط المتحركة الموسمية (SARIMA) وتوصلا إلى أن النموذج المستعمل هو الأفضل والأكفء في تقدير ظاهرة هطول الأمطار. (Wang & et al, 2013)**

- استعمل الباحثان (Rajae and Guy) في العام نفسه طريقة الامكان الاعظم المضبوطة لتقدير إنموذج الانحدار الذاتي الاوساط المتحركة الموسمية الموسعة ESARIMA وطبقاه على سلسلة زمنية موسمية وتوصلا بان الإنموذج الموسع اكثر كفاءة من الانموذج الموسمي الاعتيادي. (Rajae and Guy, 2013)
- في عام (2014) قام الباحث (لقوي فاتح) باستعمل نماذج السلاسل الزمنية الموسمية المختلطة في تقدير سلسلة المبيعات الشهرية لمؤسسة مطاحن جديع من منتج الفرينة و النخالة في الفترة الممتدة من 2008 إلى 2012 ، و من ثم اختبار دقتها في التنبؤ بالمبيعات المستقبلية لتسع أشهر الأولى من سنة 2013 ، ليتم فيما بعد مقارنتها بالقيم الفعلية واستنتاج مدى دقة في مجال المبيعات SARIMA. إذ أظهرت النتائج تقارب بين القيم الفعلية للمبيعات والقيم التنبؤية. (لقوي فاتح، 2014)
- في العام نفسه (2014) قارن الباحثان (البدراي و صليو) دقة التنبؤ بين نماذج بوكس جنكز وإنموذج الشبكة العصبية الاصطناعية متمثلة بشبكة FFN(feed forward Neural Network) وشبكة ايلمان و الثالثة شبكة (NARX) لبيانات تمثل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة De Belt الهولندية للاعوام من 1983 الى 2009 لدقتها ، اذا بلغ عددها (324) مشاهدة والابقاء على 12 مشاهدة كعينة بعدية للمقارنة بقيم التنبؤ التي يتم الحصول عليها من الانموذج ، وقد توصلنا الى الشبكات العصبية الاصطناعية نوات التغذية العكسية افضل من غيرها ومن اداء بوكس وجنكز . (البدراي و صليو ، 2014)
- في عام (2016) درست الباحث (خلود) نماذج السلاسل الزمنية الموسمية SARIMA و Holt Winter وميز بين الموسمية المضافة والمضاعفة ، وتمت المقارنة بين الطريقتين وفقاً لمعيار RMSE MSE . وظهرت النتائج تقارب الطريقتين ولكن تفوق طريقة التمهيد الاسي الثلاثي Holt winter على نماذج الانحدار الذاتي والمتوسطات المتحركة المتكاملة الموسمية SARIMA وفقاً لمعيار RMSE. (خلود ، 2016)
- في عام (2018) استعملت الباحث (وفاء) منهجية Box-Jenkins لحساب الدليل الموسمي لأسعار اللحوم الحمراء الضاني، الجاموسي للتنبؤ بأسعار اللحوم ووضع السياسات الاقتصادية الزراعية وتبين أن الإنموذج الأمثل هو $S(1,1,1)$ $ARIMA(1,0,1)$ للحم الجاموس والانموذج $S(2,0,2)$ $ARIMA(0,1,2)$ لاسعار اللحوم الكندوز والانموذج $S(1,0,0)$ $ARIMA(0,1,2)$ لاسعار اللحوم الضأن كما تبين إقبال المستهلكين على

شراء اللحوم في شهري أكتوبر ونوفمبر في فترة الأعياد القومية وان هناك تقارباً إلي حد ما بين القيم التنبؤية والقيم الفعلية، واوصت الدراسة باستعمال هذه النماذج في التنبؤ بالأسعار الشهرية للحوم الحمراء الضاني، الجاموسي والكندور. (وفاء ، 2018)

- في عام (2019) قدم الباحث (Mengqing Qin) دراسة عن نماذج السلاسل الزمنية الموسمية مع تطبيقها على بيانات الطقس. اذ تضمنت الدراسة مفاهيم السلاسل الزمنية ، ونماذج المتوسط المتحرك الانحدار الذاتي المتكاملة (والمختصرة بـ ARIMA) ، وتقدير المعلومات ، وتشخيص النماذج ، والتنبؤ. تم تطبيق نماذج السلاسل الزمنية المدروسة على بيانات مستوى البحيرة اليومي في بحيرة بيغر (1988-2017) وبيانات درجة الحرارة القصوى اليومية في نيويورك سنترال بارك (1870-2017). نظراً لموسمية البيانات ، تم اقتراح ثلاث طراق مختلفة للنمذجة: إنموذج الانحدار ، إنموذج ARIMA الموسمي وإنموذج ARIMA الموسمي المضاعف. وتمت مقارنة القيم المتوقعة لعام 2018 مع البيانات الاصلية للسلسلة ؛ وبينت النتائج ان إنموذج الانحدار هو الأفضل للتنبؤ بالقيم اليومية ، وإنموذج ARIMA الموسمي المضاعف هو الأفضل بسبب الدقة العالية له. (Mengqing & Qin, 2019)
- وفي العام نفسه (2019) هدف الباحثان (طاهر ويوسف) الى نمذجة استهلاك الكهرباء في ولاية المدية باستعمال نماذج الانحدار الذاتي والايوساط المتحركة الموسمي SARMA للفترة من 2017-2019 لعينة شملت (80) مشاهدة وتوصلا الى ان الكهرباء المستهلكة لها إنموذج SARMA(4,0) في شكل إنموذج ضربى ذو اتجاه عام متزايد. (طاهر ويوسف ، 2019)
- وفي العام نفسه (2019) قارن الباحثان (صليو ومطر) دقة التنبؤ بين نماذج بوكس جنكز وإنموذج الشبكة العصبية الاصطناعية التي اختلفت فيما بينها من حيث وجود التغذية المتكررة في هيكلتها من عدمه متمثلة بـ شبكة FFN(feed forward Neural Network) وشبكة ايلمان و الثالثة شبكة (NARX) لبيانات تمثل المعدلات الشهرية لدرجات الحرارة العظمى لمدينة الموصل للاعوام من 1983 الى 2009 لدقتها ، اذا بلغ عددها (324) مشاهدة والابقاء على 12 مشاهدة كعينة بعدية للمقارنة بقيم التنبؤ التي يتم الحصول عليها من الانموذج ، وقد توصلا الى ان الشبكات العصبية الاصطناعية ذوات التغذية المتكررة افضل من غيرها ومن اداء بوكس وجنكز . (صليو ومطر ، 2019)

- في عام (2020) استعمل الباحثان (Chaurasia & Pal) استعمالاً نموذج الانحدار وإنموذج التمهيد الاسي وإنموذج Holt winter وإنموذج الانحدار الذاتي الاوساط المتحركة لغرض تقدير بيانات السلسلة الزمنية الممثلة لمرض COVID-19 المأخوذة من منظمة الصحة العالمية "بيانات منظمة الصحة العالمية حالات فيروس كورونا Covid-19 والوفيات WHO-COVID وقارنا بين النماذج باستعمال معيار متوسط مربعات الخطأ وتوصلا الى ان ARIMA هو الافضل في تقدير الظاهرة وان معدل الوفيات سيزداد الى 600 وفاة في يناير 2021. (Chaurasia & Pal, 2020).
- في العام نفسه (2020) استعمل الباحث (Ashour) أسلوب المحاكاة لدراسة وتحليل منهجية الشبكات العصبية الاصطناعية إذ تم توليد ثمانية سلاسل زمنية تمثل مختلف حالات السلاسل الزمنية (الموسمية، الاوساط المتحركة MA، الانحدار الذاتي AR، المختلطة ARMA، شبه الخطية) للوقوف على جودة تلك الشبكات في الواقع العملي والفعلي ومعرفة سلوكيتها في مختلف الحالات. وتم اعتماد بيانات النفط الخام للمملكة العربية السعودية في الجانب التطبيقي كونها من اهم الدول المنتجة واكثرها استقراراً وتعد إنموذجاً لدول المنطقة التي تتشابه الى حد كبير في سلوكيتها. وقد برهنت النتائج كفاءة ومقدرة اسلوب الشبكات العصبية في معالجة النماذج "السلاسل" شبه الخطية وغير الخطية وعجز "فشل" نماذج بوكس-جنكينز في معالجة تلك الحالات "السلاسل"، بالرغم من تطبيق "فرض" منهجية بوكس-جنكينز عليها. وكذلك كفاءة وفاعلية الكبيرة أسلوب بوكس-جنكينز في معالجة نماذج الانحدار الذاتي التامة (perfect) وعندما يتوزع الخطأ توزيعاً طبيعياً بمتوسط يساوي صفراً وتباين يساوي واحداً $[N \sim (0,1)]$ وأيضاً في نماذج الاوساط المتحركة والنماذج المختلطة (ARIMA) والنماذج الموسمية، وعدم كفاءتها في حالة تلوين البيانات وعندما تكون قيمة معلمة الانحدار الذاتي (Φ) تساوي (0.5) او اقل. وخلصت تجارب المحاكاة بعدم تأثير زيادة عدد العقد عن العدد الانسب للعقد في الطبقة المخفية على نتائج مخرجات الشبكة العصبية الاصطناعية.. (Ashour, 2020).



الفصل الثاني

الجانب النظري



2-1 تمهيد Preface

تعد السلاسل الزمنية بأساليبها المختلفة كافة أدواتاً علمية مهمة تستعمل في تقدير اتجاه وسلوك ظاهرة معينة أو ظواهر مختلفة خلال مدة من الزمن وبناء إنموذج احصائي لتلك الظاهرة ويمكن عن طريق استعمال اساليب السلاسل الزمنية السيطرة على سلوك تلك الظاهرة مستقبلاً . كما ان هذه الاساليب وتحليل السلسلة الزمنية يتطلب بناء نموذج رياضية تمثل السلسلة المعطاة وقد طور علماء الاحصاء عدة نماذج رياضية مختلفة والتي تربط بين قيم البيانات المشاهدة وقيم المركبات المختلفة للسلسلة الزمنية.

إن الكثير من الظواهر والتي تكون مرتبطة بالزمن تسجل على مدد زمنية محددة، وان هذه المدد غالباً ما تكون متساوية وتكون سنوية أو فصلية أو شهرية أو أسبوعية وحتى قد تكون يومية وهكذا، وهناك أمثلة كثيرة وواضحة مثل درجات الحرارة لمدينة معينة مسجلة يومياً، كمية المياه المستهلكة من نهر الفرات شهرياً. كمية النفقات الصلبة التي يتم جمعها من مشفى معين سنوياً أو شهرياً ... الخ .

2-2 الاستقرارية في السلاسل الزمنية: (Stationary in time series)

المقصود باستقرارية السلسلة الزمنية أن يكون المتوسط والتباين وتراكيب الارتباط الذاتي لا تتغير مع الزمن ويمكن القول أن السلسلة الزمنية مستقرة هي التي تكون متجانسة زمنياً أي أن رسم السلسلة في الفترة $(t, t+h)$ يكون مطابقاً لرسم السلسلة في فترة أخرى $(s, s+h)$ ، بمعنى اخر اننا لو قسمنا بيانات السلسلة الزمنية الى مجاميع من الفترات الزمنية فان المقاطع المختلفة لهذه المشاهدات تبدو متشابهة بمعنى تكون السلسلة في حالة خاصة من الإتزان الإحصائية أي امتلاكها وسطاً حسابياً وتبايناً ثابتين مع الزمن، عندها نقول أن السلسلة الزمنية مستقرة في الوسط والتباين. وتكون السلسلة الزمنية مستقرة إذا لم يكن هناك اتجاه إلى الأعلى أو إلى الأسفل في المعدل عبر الزمن (ليس فيها اتجاه عام) أو عدم ظهور اختلاف حول الوسط عبر الزمن. فهي تتغير مستوياتها مع الزمن من دون ان يتغير المتوسط فيها(اي لا يوجد نمو او اضمحلال في السلسلة). (Wei, W. W. S., 1990)

وتكون السلسلة الزمنية مستقرة بشكل تام (Strictly stationary) إذا كانت عزومها لا تتأثر بتغير الزمن وهذا يعني أن التوزيع المشترك لـ $(Y_{t_1}, Y_{t_2}, \dots, Y_{t_T})$ هو التوزيع المشترك نفسه

$\{Y_{(t_1+k)}, Y_{(t_2+k)}, \dots, Y_{(t_T+k)}\}$ لكل ثابت حقيقي مثل k وثابت صحيح موجب مثل T وقيم t_1, t_2, \dots, t_T اي انه يتحقق الآتي:

$$(F_{Y_{(t_1)}, Y_{(t_2)}, \dots, Y_{(t_T)}}(Y_1, Y_2, \dots, Y_T) = F_{Y_{(t_1+k)}, Y_{(t_2+k)}, \dots, Y_{(t_T+k)}}(Y_1, Y_2, \dots, Y_T) \text{ (Palma , W. 2007)}$$

ولكن في كثير من التطبيقات العملية من النادر الحصول على عملية مستقرة بشكل تام، فضلاً عن ان فروض الطريقة المستعملة للوصول إلى الهدف المرجو من التطبيق العملي قد لا تتطلب الاستقرار التامة للسلسلة الزمنية بل تتطلب استقرارية بدرجة أو بأخرى ويقال للسلسلة الزمنية بأنها مستقرة من الدرجة m ، إذا كانت العزوم المشتركة لغاية الدرجة m لـ $[Y_{(t_1)}, \dots, Y_{(t_T)}]$ موجودة وتساوي العزوم المشتركة لغاية الدرجة m لـ $[Y_{(t_1+k)}, \dots, Y_{(t_T+k)}]$ وذلك لكل ثابت حقيقي مثل k وثابت صحيح موجب مثل T والقيم t_1, t_2, \dots, t_T أي أنه:

$$E[\{Y_{(t_1)}\}^{m_1}, \{Y_{(t_2)}\}^{m_2}, \dots, \{Y_{(t_T)}\}^{m_T}] = E[\{Y_{(t_1+k)}\}^{m_1}, \{Y_{(t_2+k)}\}^{m_2}, \dots, \{Y_{(t_T+k)}\}^{m_T}]$$

وذلك لكل ثابت حقيقي مثل k وللأعداد الصحيحة الموجبة m_1, m_2, \dots, m_T والتي تحقق $\sum_{i=1}^T m_i \leq m$

(Box & Jenkins , 2008).

واستناداً إلى ما تقدم يمكننا وصف العملية $Y(t)$ بأنها مستقرة من الدرجة الأولى إذا كان متوسطها ثابتاً ومستقلاً عن الزمن ، وتكون مستقرة من الدرجة الثانية أو ضعيفة الاستقرارية (Weakly Stationary) إذا كان كل من متوسطها وتباينها ثابتين ومستقلين عن الزمن وكذلك دالة التباين المشترك الذاتي γ_k (Autocovariance function) أيضاً مستقلة عن الزمن إذ يمكن كتابة دالة التباين الذاتي المشترك للمتغيرين Y_t, Y_{t+k} كما في أدناه:

$$\gamma_k = \text{Cov}(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \quad \dots(2-1)$$

اما تباين السلسلة فيكون عبارة عن:

$$\text{Var}(Y_t) = \text{Var}(Y_{t+k}) = \gamma_0 \quad \dots(2-2)$$

ولتقدير دالة التباين الذاتي المشترك من سلسلة المشاهدات Y_1, Y_2, \dots, Y_T فتستعمل الصيغة:

$$\hat{\gamma}_k = \frac{1}{T} \sum_{t=1}^{T-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y}) \dots (2-3)$$

إذ ان

$$\bar{Y} = \sum_{t=1}^T Y_t / T \dots \quad (\text{Tsay , R.S. ,2005})$$

ويمكن عن طريق رسم السلسلة الزمنية واستعمال دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) الحكم على استقرارية او عدم استقرارية السلسلة . ويرجح عدم الاستقرارية في السلسلة الزمنية لوحداً من الأسباب الآتية:

2-2-1 عدم الاستقرارية حول المتوسط : (Non stationary around the mean)

ان عدم حدوث تذبذب في السلسلة الزمنية حول وسط ثابت يعني عدم سكون المتوسط ويمكن ازالة ذلك باخذ الفروق (Differences) المناسبة والتي تعد من الطرائق السهلة والكفوءة والتي تتناسب مع السلسلة الزمنية.

ويمكن توضيح عملية اخذ الفروق في السلسلة الزمنية كالاتي:

فاذا اظهرت السلسلة الزمنية المشاهدة Y_t اتجاهها سواء محدداً او عشوائياً، فان فروق السلسلة الاولى تتجح في تحويل هذه السلسلة الى سلسلة مستقرة ، فاذا رمزنا للسلسلة الجديدة بالرمز Z_t فإن:

$$Z_t = \Delta y_t = y_t - y_{t-1} , t=2,3,\dots,n \dots (2-4)$$

ويمثل n عدد المشاهدات المتاحة او مايعرف عادة بطول السلسلة او مجازا حجم العينة.

فاذا كانت مشاهدات السلسلة الاصلية غير مستقرة هي y_1, y_2, \dots, y_n فإن اخذ الفروق الاولى (First Difference) لهذه السلسلة يتطلب انشاء الجدول الآتي:

جدول (2-1) الفروق الأولى للسلسلة الزمنية

y_t	y_{t-1}	$Z_t=y_t- y_{t-1}$
y_1	-	-
y_2	y_1	$Z_2=y_2- y_1$
\vdots	y_2	$Z_3=y_3- y_2$
\vdots	\vdots	\vdots
y_n	y_{n-1}	$Z_n=y_n- y_{n-1}$

مع ملاحظة ان عدد المشاهدات الجديدة للسلسلة الجديدة Z_t هو $(n-1)$ فقط وليس (n) ، اي اننا نفقد مشاهدة واحدة عند اخذ الفرق الأول للسلسلة.

قد تظل سلسلة الفروق الأولى Z_t غير مستقرة ايضاً ، وفي هذه الحالة لابد من أخذ الفروق الثانية $\Delta^2 y_t$ او الفروق الأولى للسلسلة Z_t اي ΔZ_t . وهذا النوع من التحويلات مفيد في كثير من الاحيان . وفي مثل هذه الحالات قد يكون من المفيد عمل جدول كالتالي لايجاد الفروق الثانية w_t .

جدول (2-2) الفروق الثانية للسلسلة الزمنية

y_t	y_{t-1}	$Z_t=y_t- y_{t-1}$	Z_{t-1}	$w_t=Z_t- Z_{t-1}$
y_1	-	-	-	-
y_2	y_1	$Z_2=y_2- y_1$	-	-
y_3	y_2	$Z_3=y_3- y_2$	Z_2	$w_2=Z_3- Z_2$
\vdots	\vdots	\vdots	\vdots	$w_3=Z_4- Z_3$
\vdots	\vdots	\vdots	\vdots	$w_4=y_4- y_3$

	⋮	⋮	⋮	⋮
y_n	y_{n-1}	$Z_n = y_n - y_{n-1}$	Z_{n-1}	$w_n = Z_n - Z_{n-1}$

وعدد مشاهدات السلسلة الجديدة w_t هو $(n-2)$ اي اننا فقدنا مشاهدين فقط عند اخذ الفروق الثانية للسلسلة الاصلية y_t . (جاد الله أب ولبدة، 2017)

2-2-2 عدم الاستقرار في التباين : (Non stationary in variance)

من حيث عدم ثبات التباين فان مسألة عدم ثبات التباين تعد من المشاكل الرئيسة في عدم الحصول على إنموذج دقيق وأخذ التحويلات (اللوغاريتم أو اخذ الجذر التربيعي الخ) لبيانات السلسلة الزمنية تعالج ذلك.

وهناك أربعة من التحويلات المتوفرة وبالتحديد لسلسلة موجبة، وافرض أن $Y_t > 0$ هي السلسلة الاصلية وان X_t هي السلسلة المحولة وفيما يأتي التحويلات:

$$1- \text{التحويل اللوغاريتمي } X_t = \ln(Y_t)$$

$$2- \text{التحويل اللوجستي } X_t = (cY_t)/(1 - cY_t)$$

إذ ان:

$$C = (1 - e^{-6}10 - \text{ceil}(\log_{10}(\max(Y_t))))$$

وان $\text{ceil}(w)$ عدد صحيح وصغير أكبر من أو يساوي $w = (\log_{10}(\max(Y_t)))$

$$3- \text{تحويل الجذر التربيعي } X_t = \sqrt{y_t}$$

4- Box-Cox تحويل

$$X_t = \begin{cases} y_i^\lambda - 1/\lambda & \lambda \neq 0 \\ \ln y_i & \lambda = 0 \end{cases}$$

إذ يتم تطبيق هذه التحويلة باستعمال قيمة لمعلمة التحويل λ عادة ما تكون بين $[-2, 2]$.

(جاد الله أب ولبدة، 2017)

3-2-2 اختبارات فحص استقرارية السلسلة الزمنية:

هناك العديد من الاختبارات التي تستعمل للكشف عن استقرارية السلسلة الزمنية ونذكر منها.

1-3-2-2 اختبار جذر الوحدة Unit Root Test:

إن واحداً من الأساليب المعاصرة المستعملة لفحص استقرارية السلسلة الزمنية هو اختبار جذور الوحدة. ويتحقق شرط الاستقرار عندما تكون جذور الوحدة للسلسلة تقع داخل دائرة الوحدة. ومن أهم الطرائق المستعملة للكشف عن استقرارية السلسلة الزمنية هو اختبار ديكي-فولر ويعتمد على تقدير الانموذج الآتي.

$$Y_t = \gamma Y_{t-1} + \sum_{j=1}^k \phi_j \nabla Y_{t-j} + a_t \quad \dots(2-5)$$

إذ إن:-

Y_t : يمثل متغير السلسلة الزمنية.

a_t : تمثل متسلسلة الضوضاء الأبيض. (White Noise Process)

∇ : يمثل معامل الفرق الأول.

إن فرضية العدم في هذا الاختبار هي $H_0: \gamma = 0$ والتي تبين ان المتسلسلة الزمنية (Y_t) تمتلك جذور وحدة أي عدم الاستقرار. يتم اختبارها مقابل الفرضية البديلة $H_1: \gamma < 0$ تلك هي إحصاءة ديكي-فيلر وتعطى بالصيغة الآتية.

$$DF\tau = \frac{\hat{\gamma}}{SE(\hat{\gamma})} \quad \dots(2-6)$$

إذ إن $\hat{\gamma}$ هو تقدير المعلمة γ . وإن ($SE(\hat{\gamma})$) يمثل الانحراف المعياري. ويتم الاختبار ومعرفة القرار عن طريق مقارنة القيمة المحسوبة τ مع القيمة الجدولة للاختبار انفاً (Wei, 1989)

(Makridakis, 1998)

2-2-3-2 دالة الارتباط الذاتي: Auto correlation Function (ACF)

وهي مقياس لدرجة العلاقة بين قيم المتغير نفسه عند فترات ازاحة موسمية مختلفة وتعد دالة الارتباط الذاتي (Autocorrelation Function) والتي سيشار إليها اختصاراً (ACF) او معامل الارتباط الذاتي ، إذ يمكن تقدير دالة الارتباط الذاتي من سلسلة المشاهدات Y_1, Y_2, \dots, Y_T في حالة السلاسل الزمنية الموسمية عند الازاحة (التخلف) S حسب الصيغة الآتية:

$$\hat{\rho}_s = \frac{\text{cov}(y_t, y_{t+s})}{\sqrt{\text{var}(y_t) \text{var}(y_{t+s})}} = \frac{\sum_{t=1}^{n-s} (y_t - \bar{y})(y_{t+s} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad \dots(2-7)$$

إذ أن:

y_t : تمثل قيم مشاهدات السلسلة الزمنية .

S : الازاحة الموسمية عند الفترة الزمنية وتأخذ $1, 2, 3, \dots$.

\bar{y} : مقدر تقريبي لمتوسط السلسلة الزمنية التي حجمها n .

وتستعمل الصيغة (2-7) سواء للسلسلة الأصلية ام لسلسلة الفروق ام لسلسلة الاخطاء (البواقي) للنموذج المستعمل.

ومن شكل دالة الارتباط الذاتي (ACF) نجد انه يحتوي على خطوط تصف انحرافين للخطأ المعياري وعلى جانبي القيمة الصفرية للارتباط الذاتي ، وهي تمثل الحدود التي يختبر بها الارتباط الذاتي فإذا خرجت معاملات الارتباط الذاتي خارج هذه الحدود يكون معنوياً وعند الازاحة (S) ويبين حقيقة اخرى من ان النموذج لايفسر الارتباط الذاتي في البيانات فضلاً عن امكانية حساب الخطأ المعياري لمعاملات الارتباط الذاتي وعند الازاحة (S) بالاعتماد على معاملات الارتباط الذاتي (ACF) وفق العلاقة الآتية:

$$SE(\hat{\rho}_s) = \sqrt{\frac{1 + 2 \sum_{m=1}^s \hat{\rho}_m^2}{n}} \quad \dots (2-8)$$

وفي حالة السلاسل الزمنية الموسمية نلاحظ ان معاملات الارتباط الذاتي $\rho_1, \rho_2, \rho_3, \dots, \rho_{s-1}, \rho_{s+1}, \dots$ تكون قيمها قريبة او مساوية للصفر، وانه فقط عند الازاحات $s=0, s1, 2s, \dots$ توجد قيم معنوية لمعاملات الارتباط الذاتي .

ان دالة الارتباط الذاتي (ACF) تستعمل في تحليل السلاسل الزمنية الموسمية لانها تعطي معلومات عن سلوك السلسلة وعن مكوناتها الاساسية ، كما تساعد على تحديد استقرارية السلسلة وهل انها موسمية ام لا. كما تستعمل دالة الارتباط الذاتي للبواقي Residuals Autocorrelation Function (RACF) لفحص ملائمة الانموذج عن طريق اختبار عشوائية أخطاء التنبؤ . وبصفة عامة فان دالة الارتباط الذاتي للسلسلة المستقرة تتناقص بسرعة وتكون قريبة من الصفر كلما زادت درجات الابطاء. (طعمه و سعدي، 2012)

3-3-2-2 دالة الارتباط الذاتي الجزئي: Partial Auto correlation Function (PACF)

أن لدالة الارتباط الذاتي (ACF) أهمية كبيرة في عملية تحديد الانموذج، ولكنها لا تمكننا وحدها من تحديد الانموذج المناسب. أن هناك دالة أخرى تسهم في تشخيص الانموذج المناسب، تعرف هذه الدالة بدالة الارتباط الذاتي الجزئي (Partial Autocorrelation function) ويشار إليها اختصاراً (PACF)، وتكشف هذه الدالة الارتباط بين Y_t, Y_{t+k} بثبوت المتغيرات الأخرى اي انها مقياس لدرجة العلاقة بين مشاهدتين بثبوت بقية المشاهدات الأخرى (مزالة التأثير) . (Box , et al. 2013) إذ انه بضرب الصيغة الآتية:

$$Y_{t+k} = \phi_{k_1} Y_{t+k-1} + \phi_{k_2} Y_{t+k-2} + \dots + \phi_{kk} Y_t$$

في Y_{t+k-j} ومن ثم اخذ التوقع ينتج:

$$\gamma_j = \phi_{k_1} \gamma_{j-1} + \phi_{k_2} \gamma_{j-2} + \dots + \phi_{kk} \gamma_{j-k} \dots(2-9)$$

ويقسمه الدالة المذكورة انفاً (γ_0) ، نحصل على:

$$\rho_j = \phi_{k_1} \rho_{j-1} + \phi_{k_2} \rho_{j-2} + \dots + \phi_{k_n} \rho_{j-k}$$

$$j=1,2,\dots,k$$

$$\dots(2-10)$$

لقد تم افتراض المعادلة (8) في المذكورة انفاً معادلة انحدار، فيها y_{t+k} هو المتغير المعتمد و Y_t, \dots, Y_{t+k-1} كمتغيرات مستقلة، وان ϕ_{ki} ($i=1,2,3,\dots,k$) تمثل معالم انحدار .

أن بالإمكان تمثيل المعادلة (10) انفاً بمنظومة تتمثل كل معادلة فيها بإحدى قيم (j) ($j=1,2,3,\dots,k$) وعلى النحو الآتي:

$$\left. \begin{aligned} \rho_1 &= \phi_{k_1} \rho_0 + \phi_{k_2} \rho_1 + \dots + \phi_{k_k} \rho_{k-1} \\ \rho_2 &= \phi_{k_1} \rho_1 + \phi_{k_2} \rho_0 + \dots + \phi_{k_k} \rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k_1} \rho_{k-1} + \phi_{k_2} \rho_{k-2} + \dots + \phi_{k_k} \rho_0 \end{aligned} \right\} \dots(2-11)$$

وباستعمال قاعدة كرامير لـ $k=1,2,3,\dots$ لحل المعادلات في المذكورة انفاً سنحصل على:

$$\phi_{11} = \rho_1$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$$\vdots$$

$$\phi_{kk} = \begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & & & & & \\ \vdots & & & & & \\ \vdots & & & & & \\ \rho_{k-1} & \rho_{k-2} & \cdots & \cdots & \rho_1 & \rho_k \\ 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-3} & \rho_{k-2} \\ \vdots & & & & & \\ \vdots & & & & & \\ \rho_{k-1} & \rho_{k-2} & \cdots & \cdots & \rho_1 & 1 \end{vmatrix} \quad \dots(2-12)$$

2-3 السلاسل الزمنية الموسمية: (Seasonal time series)

تظهر بعض السلاسل الزمنية نمطا للموسمية بجانب الاتجاه العام. في حين هنالك تتضمن معدلا معيناً فضلاً عن تذبذبات عشوائية . وبناءً على هذه الاختلافات في تركيبات السلاسل الزمنية ظهرت عدة طرائق تنبؤية تلائم مختلف أنواع التذبذبات في السلاسل.

ان الكثير من المتغيرات البيئية والاقتصادية والسياسية... الخ تخضع لانماط الموسمية إذ انها تكرر نفسها عند فترات معينة قد تكون (يوم- شهر- سنة) ، ويؤدي تجاهل هذا النمط في السلسلة الى زيادة تباين السلسلة عند التنبؤ ويتم اكتشاف النزعة الموسمية عن طريق رسم البيانات (الشكل البياني) باستعمال دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) تظهر التباطأت ،...، 12,24,36 للبيانات الشهرية والتباطأت (4,8,12 ...) للبيانات ربع سنوية بشكل معنوي بدلا من التباطؤات 1,2 ... اللاموسمية . وفي هذه الحالة يتم إضافة عنصر انحدار ذاتي موسمي او عنصر (SAR) متوسط متحرك موسمي () او كلاهما عند الفترة الثانية عشرة اذا كانت معنوية للبيانات الشهرية $AR(1)_{12}$ $MA(1)_{12}$ في الإنموج .

ويتم معالجتها في طريقة (Box- Jenkins) باخذ الفروق الموسمية فضلا عن الى الفروق غير الموسمية. (رزمان ، 2015) .

2-4 نماذج السلاسل الزمنية الموسمية (Seasonal time series Models)

النماذج الموسمية (Seasonal) للسلاسل الزمنية هي النماذج اللاموسمية نفسها مضاعفاً إليها (S) للدلالة على أن السلسلة موسمية . ويقال للسلسلة الزمنية موسمية إذا كانت تعيد نفسها بفترة زمنية ثابتة ويمكن تمييز السلاسل الموسمية المستقرة عن طريق معاملات الارتباط الذاتي التي تكون معنوية لكل فترة زمنية ثابتة كأن تكون (2,4,,6,8,12,...) ولكن في حالة السلاسل غير المستقرة فالتمييز يكون صعباً لأنه يختلط مع الاتجاه العام للبيانات لذلك يجب تحويلها إلى سلاسل مستقرة أولاً ثم البحث عن الشكل الموسمي فيها. اما النماذج الملائمة لتمثيل السلاسل الزمنية الموسمية فهي : (المحمدي و طعمة، 2011) (فاندل، والتر، 1992).

2-4-1 إنموذج الانحدار الذاتي الموسمي (Seasonal Autoregressive Models)

يعد هذا الانموذج الأكثر شيوعاً في تحليل السلاسل الزمنية الموسمية ويرمز له بالشكل SAR(P) ويتمثل بالصيغة الآتية:

$$Y_t = \Phi_{1s} Y_{t-s} + \Phi_{2s} Y_{t-2s} + \dots + \Phi_{ps} Y_{t-ps} + a_t \quad \dots(2-13)$$

إذ أن:

Y_{t-ps} قيم مشاهدات السلسلة الزمنية الموسمية $t=0,1,2,\dots,p$

S طول الفترة الموسمية

Φ_{ps} معاملات الانحدار الذاتي الموسمي

P درجة الإنموذج الموسمي

a_t البواقي (الخطأ العشوائي) ، إذ أن $a_t \sim ND(0, \sigma_a^2)$

ولغرض تحقق الاستقرارية يشترط ان تكون جذور المعادلة :

$$\Phi_s(B^s) = 1 - \Phi_s(B^s) = 0 \quad \dots(2-14)$$

خارج دائرة الوحدة (Unit Circle) (دائرة نصف قطرها يساوي واحداً) ، أي لكي يكون النموذج مستقرًا يشترط ان تكون $-1 < \Phi_s < 1$. (Wei, 1990:161). إذ أن B هو عامل الارتداد الخلفي (Back Shift operator) ويعرف بالشكل الآتي:

$$B^s Y_t = Y_{t-s} \quad \forall s = 1, 2, \dots, K \quad \dots(2-15)$$

وإن الصيغة العامة لدالة الارتباط الذاتي (ACF) لإنموذج الانحدار الذاتي الموسمي من الدرجة الأولى SAR(1) تأخذ الشكل الآتي:

$$\rho = \begin{cases} 1 & K = 0 \\ \Phi_s & K = s \\ 0 & k = 1, 2, \dots, K, s - 1 \end{cases} \quad \dots(2-16)$$

أي ان دالة الارتباط الذاتي الانموذج الموسمي $AR(p)$ تتناقص أسياً ، في حين ان دالة الارتباط الذاتي الجزئي $PAR(P)$ تنقطع بعد الفاصلة P (Markidaki & McGee, 1983) (الطائي و الكوراني ، 2008)

2-4-2 إنموذج الأوساط المتحركة الموسمي

(Seasonal Moving Average Models) (SMA)

باستعمال عامل الازاحة (الارتداد) الخلفي (B) في الصيغة الآتية :

$$Y_t = \Theta_s B^s a_t \\ = (1 - \Theta_s B^s - \Theta_{2s} B^{2s} - \dots - \Theta_{Qs} B^{Qs}) a_t \quad \dots(2-17)$$

فان الصيغة العامة لإنموذج الوساط المتحركة الموسمي من الدرجة (Q) ستأخذ بالشكل الآتي:

$$Y_t = a_t - \Theta_s a_{t-s} - \Theta_{2s} a_{t-2s} - \dots - \Theta_{Qs} a_{t-Qs} \quad \dots(2-18)$$

إذ أن:

Θ_{Qs} معاملات إنموذج الأوساط المتحركة الموسمي ، $i=1,2,\Lambda,Q$ ، $-1 < \Theta < 1$

Q درجة إنموذج الأوساط المتحركة الموسمي

ان دالة الارتباط الذاتي الانموذج (SMA) متوسط الانحدار الموسمي تنقطع بعد الفترة Q_s (تؤول الى الصفر بعد الدرجة Q) . في حين دالة الارتباط الذاتي الجزئي (PACF) تتناقص اسـياً. (الطائي و الكوراني ، 2008) (WAFAA ,2017)

2-4-3 الانموذج المختلط (الإنحدار الذاتي -الأوساط المتحركة) الموسمي

(Seasonal Mixed (Autoregressive–Moving Average) Model (SARMA)

باستعمال عامل الازاحة (الارتداد) الخلفي (B) في الصيغة الآتية :

$$\Phi_s B^s Y_t = \Theta_s B^s a_t$$

$$(1 - \Phi_s B^s - \Phi_{2s} B^{2s} - \Lambda\Lambda - \Phi_{ps} B^{ps}) Y_t = (1 - \Theta_s B^s - \Theta_{2s} B^{2s} - \Lambda\Lambda - \Theta_{Qs} B^{Qs} a_t) a_t \quad \dots(2-19)$$

(ستأخذ الشكل الآتي (الخضيري، P,Q فان الصيغة العامة للإنموذج المختلط الموسمي من الدرجة) :1996و:13)

$$Y_t = \Phi_s Y_{t-s} + \Phi_{2s} Y_{t-2s} + \Lambda\Lambda + \Phi_{ps} Y_{t-ps} + a_t - \Theta_s a_{t-s} - \Theta_{2s} a_{t-2s} - \Lambda\Lambda - \Theta_{Qs} a_{t-Qs} \quad \dots(2-20)$$

والذي يرمز له بالرمز $ARMA(P,Q)_s$. (WAFAA ,2017)

2-4-4 الإنموذج المختلط التكاملية الموسمي

(Seasonal Autoregressive Integrated Moving Average Model)

ان النماذج الموسمية انفاً تنطبق على السلاسل الزمنية المستقرة، اما اذا كانت السلسلة Y_t غير مستقرة فانه يمكن ايجاد الانموذج بعد ايجاد الفروق الموسمية المطلوبة لانتاج سلسلة مستقرة ، إذ ان عامل الفرق الموسمي من الدرجة D هو :

$$\nabla_s^D = (1 - B^s)^D \quad \dots(2-21)$$

وهكذا يتكون لدينا إنموذج مختلط موسمي غير مستقر (Box&Jenkins, 1976, 154) والذي يمكن ان يكتب بالشكل الآتي:

$$\Phi_s B^s \nabla_s^D Y_t = \Theta_s B^s a_t \quad \dots(2-22)$$

إذ ان (P,D,Q) تحدد درجة الانموذج والذي يكتب اختصاراً $ARIMA(P,D,Q)_s$

(Box and Jenkins ,1976) (Reisen and Lopes , 2001)

2-4-5 إنموذج ARIMA المضاعف (Multiplicative ARIMA Model)

يعد الانموذج المضاعف من النماذج المحورة لإنموذج ARIMA وذلك عن طريق اضافة التأثير الموسمي وعدم الاستقرارية (Shumaw & Stoffey, 2006) فالنماذج المضاعفة تتكون من نماذج الانحدار الذاتي ونماذج الاوساط المتحركة عند الإزاحة (S). إن إنموذج ARIMA الموسمي يستعمل الفرق عندما تكون الإزاحة مساوية الى عدد شهور السنة فمثلاً لازالة التأثير المضاعف يمكن التعبير عن الانموذج $ARIMA(p,d,q)(P,D,Q)_s$ المضاعف بالشكل الآتي (Comwpertwait & Metcalf,) (2009) (Mengqing Qin, 2019) :

$$\phi_p(B)\Phi_P(B^s) \nabla^d \nabla_s^D Y_t = \theta_q(B)\Theta_Q(B^s)a_t \quad \dots(2-23)$$

$$\begin{aligned} \phi_p(B) &= 1 - \phi_1(B) - \phi_2(B^2) - \dots - \phi_p(B^p) \\ \Phi_P(B^s) &= 1 - \Phi_y(B^y) - \Phi_{2y}(B^{2y}) - \dots - \Phi_{Py}(B^{Py}) \\ \theta_q(B) &= 1 - \theta_1(B) - \theta_2(B^2) - \dots - \theta_q(B^q) \\ \Theta_Q(B^s) &= 1 - \Theta_y(B^y) - \Theta_{2y}(B^{2y}) - \dots - \Theta_{Qy}(B^{Qy}) \end{aligned} \quad \dots(2-24)$$

إذ أن:

p: درجة إنموذج الانحدار الذاتي غير الموسمي

d: درجة الفرق غير الموسمي

q: درجة نموذج الاوساط المتحركة غير الموسمي

$\phi_p(B)$ و $\Phi_p(B^s)$: معامل الانحدار الذاتي اللاموسمي والموسمي على الترتيب.

$\theta_q(B)$ و $\Theta_q(B^s)$: معامل الاوساط المتحركة اللاموسمي والموسمي على الترتيب.

a_t : الاخطاء العشوائية .

$\nabla^d \nabla_s^D$ عدد الفروق الموسمية $(1-B^s)$ عند الزمن D واللاموسمية $(1-B)$ عند الزمن d التي يمكننا للتوصل الى استقرار السلسلة

وان رتبة الانموذج هي $ARIMA(p,d,q)(P,D,Q)_s$

S الازاحة الموسمية الأنموذج. (ناظم وسعدية ، 2011) ، (الجمال وآخرون، 2011) (الخصيري، 1996) (Anderson , 1976)

2-5 التشخيص (Identification)

بعد ان يتم التحقق من الاستقرار في السلسلة الزمنية الموسمية ، تبدأ عملية تحديد الانموذج المناسب الذي يمثل السلسلة ودرجته باستعمال دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) . وتعتمد هذه الطريقة على دقة الرسوم البيانية لدالتي الارتباط الذاتي والارتباط الذاتي الجزئي بمطابقة معاملات الارتباط الذاتي والجزئي للسلسلة الزمنية الموسمية مع السلوك النظري لدالتي (ACF) و (PACF) . والجدول (1) يبين طبيعة الانموذج وفقاً لمنحنى الارتباط الذاتي (Box and et al. 2013).

الجدول (2-3) طبيعة الانموذج وفقاً لمنحنى الارتباط الذاتي

الانموذج	دالة الارتباط الذاتي (ACF)	دالة الارتباط الذاتي الجزئي (PACF)
SAR(PS)	تتناقص تدريجياً سالكة سلوك دالة الجيب (يتلاشى تدريجياً) (Decays)	قطع بعد الإزاحة الموسمية PS

(Cuts-off)	(Exponentially)	
قطع بعد الإزاحة الموسمية QS (Cuts-off)	تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	SMA(QS)
تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	تتناقص تدريجياً سالكة سلوكاً أسياً او سلوك دالة الجيب (يتلاشى تدريجياً) (Decays Exponentially)	SARMA(PS,QS)

ان عملية نموذج الانحدار الذاتي المستقرة (SAR) تمتلك ارتباطاً ذاتياً (ACF) تتناقص اسياً وتقرب من الصفر، وان معاملات الارتباط الذاتي قد تتبادل بالاشارة بصورة متعاقبة او تاخذ شكل الموجة بالارتفاع والانخفاض، ولكن في كل الحالات فان المعاملات تقرب من الصفر لذلك فان عملية الانحدار الذاتي الموسمي من الرتبة (P) والتي توصف SAR(P) تمتلك ارتباطاً ذاتياً جزئياً (PACF) ينقطع بعد الإزاحة (P) ، وان طول الإزاحة لآخر سنان بارز من (PACF) يساوي رتبة إنموذج SAR من الدرجة P. وان معاملات دالة الارتباط الذاتي لعملية تتبع إنموذج الاوساط المتحركة الموسمي SMA بالرتبة q تنقطع بعد الإزاحة (q) وان معاملات الارتباط الذاتي تضمحل اسياً باقترابها من الصفر. اما عن العملية المستقرة المختلطة الموسمية التي تجمع بين ميزات الانحدار الذاتي (SAR) والمتوسطات المتحركة (SMA) وهي عملية (SARIMA) فان كلاً من معاملات الارتباط الذاتي والارتباط الذاتي الجزئي تتناقص اسياً وتقرب من الصفر (Chaurasia & Pal, 2020).

2-6 تحديد رتبة الانموذج (Model Identification)

بعد التعرف على أنواع النماذج وخصائص ومميزات كل نوع لابد من معرفة رتبة الانموذج وهذا يتم عن طريق معايير إحصائية متعددة ، إن الاختيار الصحيحة لرتبة الانموذج تؤدي إلى دقة الانموذج الذي يتم التوصل إليه. يشير الباحث (Wei, 1989) إلى أن السلسلة الزمنية وعن طريق رسم دالة (A.C.F) إذا كانت تعاني من الاضمحلال وان رسم السلسلة لدالة (P.A.C.F) تعاني من وجود قطوعات فهذا دليل على إن الانموذج AR وان رتبة الانموذج تكون في منطقة القطع. لذلك لايمكن الاعتماد على سلوك

معاملات دالتي الارتباط ولكن يمكن الاستعانة في مثل هذه الحالات بمعايير إحصائية متعددة في تشخيص الإنموج الملائم وتحديد رتبته وكما يأتي:

2-6-1 معيار معلومة أكاكي (AIC) (Akaike Information Criterion):

اقترح هذا المعيار **Akaike** عام (1973) وهو أحد المعايير الإحصائية المهمة في تحديد رتبة الانموج وإن صيغته الرياضية. (محمد ، 2014)

$$AIC(M) = n \ln \sigma_a^2 + 2M \quad \dots(2-25)$$

إذ أن :

M : دالة (p,q) الرتبة الانموج.

n : عدد المشاهدات.

σ_a^2 : مقدر تباين الخطأ.

ويتم اختيار الانموج الملائم لبيانات السلسلة الذي يقابل القيمة الأقل لمعيار AIC .

2-6-2 معيار معلومة بيز (BIC) (Bayesian Information Criterion):

لقد أظهر توسيع معيار معلومة بيز الذي طوره العالم أكاكي عام (1978، 1979) لطريقة AIC نقلة أخرى ومعيار آخر يضاف لتحديد رتبة الانموج وهذا المعيار يحمل الصيغة الرياضية الآتية.

$$BIC(p) = n \ln \sigma_a^2 + p \ln n \quad \dots(2-26)$$

وهناك معايير أخرى نلاحظها ضمن طرائق الاختبار لتحديد رتبة الانموج مثل معيار دالة تحويل الانحدار الذاتي وغيرها. (الجبوري 2010)

2-6-3 معيار اكاكي المعدل الموسمي (The Seasonally modified Akaike;s)

(information criteria (SMAIC):

ان معيار اكاكي للإنموج الموسمي ذو اداء افضل وأكفاً من المعيار اكاكي التقليدي في تحديد رتبة الانموج الموسمي المضاعف (Kadilar & Erdemir , 2003) والصيغة الرياضية لهذا المعيار هي:

$$SMAIC = n \ln \sigma_a^2 + (2d^2k/T) + t_i \quad \dots(2-27)$$

اذ ان

d تمثل عدد السلاسل

T حجم العينة او السلسلة اذ ان $k=s, (s+1), (s+2), \dots$ ويفضل الازاحة لـ $k=1,2,\dots,7,\dots$ كافية لمعرفة افضل إنموذج موسمي والإنموذج المضاعف $t_{i=(k+1-s)kd}^2$ (الجمال واخرون ، 2011)

2-7 فحص الانموذج (Model Checking):

فحص الإنموذج أو مدى ملاءمة الإنموذج وهي المرحلة اللاحقة بعد تحديد رتبة الانموذج وتقدير المعلمات للإنموذج المشخص ويتم في هذه المرحلة إعادة احتساب السلسلة الزمنية باستعمال الانموذج الذي تم التوصل إليه سابقاً ومن ثم حساب البواقي وكذلك اختبار البواقي (تساوي الفرق بين القيم الفعلية والقيم التقديرية) وهي مرحلة التأكد من مدى ملاءمة الإنموذج المحدد أو الذي تم التوصل إليه وتعمل هذه المرحلة تحت الفرضية الآتية.

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0 \quad \dots(2-28)$$

$$H_1 : \rho_i \neq \rho_L ; i \neq L$$

هناك العديد من الاختبارات المستعملة للتأكد من مدى ملاءمة الانموذج المشخص وهنا سوف نذكر بعض هذه الاختبارات.

2-7-1 اختبار Box and Pierce :

ظهر هذا الاختبار في العام 1970 من الباحثين Pierce and Box يستعمل لاختبار عشوائية الأخطاء في الانموذج المشخص وهو اختبار للتحقق من مدى ملائمة الانموذج المشخص أيضاً. ويتم ذلك باختبار الفرضية الإحصائية الآتية.

$$Q_{B\&P} = (n-d) \sum_{k=1}^m r_k^2(a) \sim \chi^2_{m-j} , \alpha \quad \dots(2-29)$$

إذ أن :

d: يمثل عدد الفروقات المأخوذة بعد تحقق شرط الاستقرار حول متوسط البيانات للسلسلة الزمنية.

k: تمثل عدد الإزاحات وتساوي $k=1,2,3,\dots,m$

j: عدد المعلمات المقدرة (p,q) الانموذج المشخص وتقرن قيمة الاختبار المذكور انفاً مع قيمة X^2 الجدولية بدرجة حرية (m-p,q) ومستوى دلالة α .

إذا كانت القيمة المستخرجة من الاختبار أصغر من القيمة الجدولية عند مستوى الدلالة المحدد ودرجة الحرية فهذا يدل على ملائمة الانموذج المشخص لبيانات السلسلة الزمنية ونقبل فرضية العدم. وعلى غرار هذا الاختبار أوجد الباحثان Ljung و Box عام 1978 اختباراً معتمداً على توزيع الارتباطات الذاتية لبواقي الانموذج المشخص ويعتمد على قيم X^2 الجدولية في إجراء المقارنة وإعطاء القرار بحق ملائمة الانموذج من عدمه. (McElroy and Monsell, 2014)

2-7-2 اختبار حدي الثقة Confidence Interval Test :

في هذا الاختبار يتم أخذ سلسلة البواقي $\{a_t\}$ الخاصة بالانموذج المشخص سابقاً وهذه السلسلة تفترض بأنها تتوزع توزيعاً طبيعياً وإن $Ea_t a_{t+k} = 0$ واختبار السلسلة بعد

تقدير الارتباطات الذاتية لها $r_k(a_t)$. إن معادلات الارتباطات تتوزع توزيعاً طبيعياً تقاربياً وبوسط حسابي مقداره صفر وتباين مقداره $\frac{1}{n}$. أي إن

$$\hat{r}_k(a) \sim N(0, \frac{1}{n}) \quad \dots(2-30)$$

أما تقدير معامل الارتباط للبواقي يساوي.

$$\hat{r}_k(a) = \frac{\sum_{t=1}^{n-k} a_t a_{t+1}}{\sum_{t=1}^n a^2 t} \quad \dots(2-31)$$

إذا كانت معاملات الارتباط للبواقي في الانموذج المشخص تقع ضمن حدي الثقة وبمستوى ثقة 95% أي إن .

$$\text{pr}\{\hat{r}_k(a) | < 1.96 \frac{1}{\sqrt{n}}\} = 1 - \alpha \quad \dots(2-32)$$

ويدل ذلك على إن الانموذج المشخص ملائماً لبيانات السلسلة الزمنية قيد الدراسة. (Reza & Yeganegi, 2019)

2-7-3 إختبار Ljung-Box Test :

Ljung-Box إختبار إحصائي يستعمل لاختبار أي مجموعة من الارتباطات الذاتية في السلسلة الزمنية كونها تختلف معنويًا عن الصفر أم لا، ويمكن استعمال هذا الإختبار أيضاً للتحقق من عشوائية البيانات (إجمالاً) باستعمال مجموعة من الإزاحات . وفي الحقيقة إن صيغة إختبار (Ljung - Box) هي صيغة معدلة لصيغة (Q_{BP}) إذ قام كل من (Ljung,G.M&Box,G.E.P) بتعديل صيغة إختبار (Q_{BP}) الأصلية التي اقترحها كل من (Box & Pierce) بالشكل الآتي:

$$Q = m(m + 2) \sum_{i=1}^k \frac{r_i^2(u)}{(m-i)} \quad \dots(2-33)$$

اذ ان: $m=(n - d - SD)$

n : يمثل عدد مشاهدات السلسلة الزمنية.

d : عدد الفروق غير الموسمية.

D : عدد الفروق الموسمية

S : طول الموسم .

K : اكبر ازاحة

$r_i(u)$: يمثل الارتباط الذاتي للاخطاء عند الازاحة (i)

وهناك إختبارات متعددة يمكن استعمالها للتأكد من مدى ملاءمة الانموذج منها إختبار بارتلت (Bartlett Test) ، وإختبار مقدم (Mokkadem Test) ، وإختبار مونتي (Monti Test) . وغيرها من الإختبارات الأخرى . (Box & et al, 2013) (Reza & Yeganegi, 2019)

2-8 تقدير معاملات الانموذج Model Parameter Estimation

بعد مرحلة تحديد رتبة الانموذج يتم تقدير معالمه بأحدى طرائق التقدير الكفؤة منها طريقة المربعات الصغرى اللاخطية (Non-Linear least squares) وطريقة الامكان الاعظم المضبوطة (Exact Maximum Likelihood Method)، طريقة الإمكان الأعظم التقريبية .

2-8-1 طريقة المربعات الصغرى اللاخطية Nonlinear Least square method

ان تقدير معاملات إنموذج الانحدار الذاتي الموسمي ARMA(p,0) عندما $(p \geq 1)$ باستعمال طريقة المربعات الصغرى اللاخطية

بافتراض السلسلة الزمنية $\{y_t\}$ ، $(t = 0, 1, \dots)$ والتي تعطي على وفق إنموذج الانحدار الذاتي ARMA (p,0) .

$$y_t = \sum_{j=1}^p \Phi_j y_{t-j} + \varepsilon_t \quad \dots(2-34)$$

إذ ان Φ_j تمثل معاملات الانحدار الذاتي، ε_t تمثل حد الخطأ العشوائي بوسط صفر وتباين σ^2 ، ويجعل Φ و Y_t معرفة بصيغة المصفوفات.

$$\Phi = (\phi_1, \phi_2, \dots, \phi_p)'$$

$$Y_t = (y_{t-1}, y_{t-2}, \dots, y_{t-p})''$$

لذلك يمكن كتابة إنموذج الانحدار الذاتي ARMA(p,0) بالصيغة الآتية :

$$y_t = \Phi^T Y_t + \varepsilon_t \quad \dots(2-35)$$

وبافتراض ان فترة الإشارة Signal Interval هي (T) ، تحتوي على (I) من العينات وهذا يعني ان $T = I \Delta T$ ، إذ ΔT تمثل مجال العينة.

وعليه فان اول عينة في هذه الفترة تكون y_t ، في حين تكون العينة الاخيرة y_{t+r} . وفي هذه الفترة يتطلب تقدير $\hat{\phi}_r$ بحيث ان تكون دالة الكلفة (Cost Function) J_r اقل ما يمكن ، إذ ان

$$J_r = \sum (y_m - \hat{\phi}_r^T Y_m)^2 \quad \dots(2-36)$$

وعليه فان $\hat{\phi}_r$ يجب ان تحقق

$$(\partial J_r / \partial \hat{\phi}_r) = 0$$

بحيث ان

$$\left[\sum_{m=t}^{t+r} Y_m Y_m^T \right] \hat{\phi}_r = \sum_{m=t}^{t+r} y_m Y_m \quad \dots(2-37)$$

وبتحديد

$$P_r^{-1} = \sum_{m=t}^{t+r} Y_m Y_m^T \quad \dots(2-38)$$

فان P_r^{-1} تكون قابلة للعكس Invertible فقط اذا كانت $r > p$ والمتمثلة بدرجة الإنموذج وعليه فان المعادلة (2-38) ستكون

$$P_r^{-1} \hat{\phi}_r = \sum_{m=t}^{t+r} y_m Y_m^T \quad \dots(2-39)$$

$$\hat{\phi}_r = P_r \sum_{m=t}^{t+r} y_m Y_m^T \quad \dots(2-40)$$

ونلاحظ انه بالرغم من ان $(Y_m Y_m^T)$ تكون مصفوفة غير احادية non-singular فان المصفوفة P_r^{-1} تكون مصفوفة غير احادية non-singular وذلك لكون المجموع هو على مدى (m) . هذا ويمكن اعادة كتابة المعادلة (2-40) بالصيغة الاتية :

$$P^{-1}_r \hat{\phi}_r = \sum_{m=t}^{t+r-1} y_m Y_m + y_r Y_r \quad \dots(2-41)$$

ومن الصيغة (2-40) نلاحظ ان :

$$\sum_{m=t}^{t+r-1} y_m Y_m = \left[\sum_{m=t}^{t+r-1} Y_m Y_m^T \right] \hat{\phi}_{r-1} \quad \dots(2-42)$$

لذلك فان المعادلة (2-42) ستكون :

$$\hat{\phi}_r = P^{-1}_r \left[\sum_{m=t}^{t+r-1} Y_m \cdot Y_m^T \right] r Y_r + y \hat{\phi}_{r-1} \quad \dots(2-42)$$

باضافة وطرح $Y_r^T \hat{\phi}_{r-1}$ من الطرف الايمن من المعادلة (2-43) فان :

$$= \hat{\phi}_r P^{-1}_r \left[\sum_{m=t}^{t+r-1} Y_m \cdot Y_m^T \right] \hat{\phi}_{r-1} r^T Y_r + Y \hat{\phi}_{r-1}^T r Y - r (y_r + Y \hat{\phi}_{r-1})$$

$$\left[\sum_{m=t}^{t+r} Y_m \cdot Y_m^T \right] = \hat{\phi}_{r-1} + Y_r (y_r - Y_r^T \hat{\phi}_{r-1}) \quad \dots(2-44)$$

وبتعويض قيمة P^{-1}_r واجراء بعض التبسيطات نحصل على مقدر $\hat{\phi}_r$ بالصيغة الاتية :

$$\hat{\phi}_r = \hat{\phi}_{r-1} + P_r Y_r (y_r - Y_r^T \hat{\phi}_{r-1}) \quad \dots(2-45)$$

إذاً يتم الحصول عليها بالتتابع عن طريق المقدر السابق ($\hat{\phi}_{r-1}$)، ومن قياسات (y_r) و (Y_r) التي تشترط بان P_r يتم الحصول عليها بالتتابع ايضا .

وإن المقدار الأبتدائي لـ (p) يتم إختياره بطريقة إعتباطية و لكن لمقتضيات إنجاز عملية التقارب Convergence ، بشكل متسارع فإنه من الملائم باستعمال المقدر الأبتدائي المتمثل بالصورة الآتية :

$$P_0 = 1/\varepsilon \quad , \quad \varepsilon > 0$$

حيث أن (ε) عدد صغير إعتباطي ، إذ أن (1/ε) تكون بأي موقع بين العدد (10) وأعلى قيمة يمكن أن يحتوي عليها الحاسوب . (Harba , M.I.A. , 1981)

2-8-2 طريقة الامكان الاعظم المضبوطة Exact Maximum Likelihood Method

إن دالة الإمكان Likelihood function للسلسلة الزمنية Y_t تعتمد على تعظيم دالة الامكان وذلك بجعل مجموع مربعات الاخطاء أقل ما يمكن والصيغة على وفق المعادلة الآتية :

$$L(\emptyset, \theta, \sigma_a^2/W) = (2\pi\sigma_a^2)^{-\frac{n}{2}} |M_n^{(p,q)}|^{-\frac{1}{2}} \exp\left(-\frac{S(\emptyset, \theta)}{2\sigma_a^2}\right) \quad \dots(2-46)$$

$$\ln L(\emptyset, \theta, \sigma_a^2/W) = \left(\frac{-n}{2} \ln(2\pi\sigma_a^2)\right) - \frac{S(\emptyset, \theta)}{2\sigma_a^2} + \frac{1}{2} \ln [M_n^{(p,q)}]$$

عندما تكون العينة كبيرة يتم اهمال المقدار $|M_n^{(p,q)}|$ في الصيغة انفاً ومن ثم أخذ اللوغارتم لدالة الامكان فان المعادلة تصبح :

$$\ln L(\emptyset, \theta, \sigma_a^2/W) = \left(\frac{-n}{2} \ln(2\pi\sigma_a^2)\right) - \frac{S(\emptyset, \theta)}{2\sigma_a^2} \quad \dots(2-47)$$

وان $|M_n^{(p,q)}|$ مصفوفة التباين والتباين المشترك Var-Cov Matrix والتي تساوي :

$$M_n^{(p,q)} = \sigma_a^2 \begin{bmatrix} \gamma_0 & \gamma_1 & \dots & \gamma_{p-1} \\ \gamma_1 & \gamma_0 & \dots & \gamma_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{p-1} & \gamma_{p-2} & \dots & \gamma_0 \end{bmatrix}^{-1}$$

ان مصفوفة المعلومات والتي تساوي $(\emptyset, \theta)^{-1}$ والمتوفرة بعد ان يتم حساب مصفوفة المشتقات ذات الرتبة $n \times (p+q)$ ويكون

$$a = \theta^{-1}(B) \phi(B) \quad \dots(2-48)$$

ويتم الحصول على تقديرات الامكان الاعظم من المعادلة (2-48) انفاً بعد اخذ المشتقة الجزئية لها اي ان :

$$\left. \begin{aligned} \frac{\partial a_t}{\partial \theta_i} &= \theta^{-1}(B) B^i a_t \\ \frac{\partial a_t}{\partial \phi_j} &= \phi^{-1}(B) B^j a_t \end{aligned} \right\} \dots(2-49)$$

(الصراف، 2013)، (Rajae & Guy, 2013)

2-8-3 طريقة الامكان الاعظم التقريبية: Approximate Maximum Likelihood method

إن تقديرات الامكان الاعظم التقريبية المعتمدة على حساب المخطط الدوري تدعى تقريب Whittle الى لوغارتيم دالة الامكان . وللحصول على مقدر Whittle يتم استعمال صيغتان تقريبتان في صيغة لوغارتيم دالة الامكان كما في المعادلة الآتية:

$$L(\theta) = -\frac{1}{2} \text{Log det } \Gamma(\theta) - \frac{1}{2} y' \{ \Gamma(\theta) \}^{-1} y \quad \dots(2-50)$$

بعد قسمتها على حجم العينة نحصل على

$$\frac{1}{2n} \text{Log det } \Gamma(\theta) \approx \frac{1}{4\pi} \int_{-\pi}^{\pi} \text{Log} [2\pi f_{\theta}(\lambda)] d\lambda \quad \text{as } n \rightarrow \infty$$

$$\frac{1}{2n} y' \{ \Gamma(\theta) \}^{-1} y \approx \frac{1}{4\pi} \int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda$$

إذ أن :

$$I(\lambda) = \frac{1}{2n\pi} \left| \sum_{j=1}^n y_j e^{i\lambda_j} \right|^2$$

تمثل المخطط الدوري للسلسلة $\{y_t\}$.

وبذلك أن لوغاريتم دالة الإمكان التقريبي:

$$L(\theta) = - \frac{1}{4\pi} \left[\int_{-\pi}^{\pi} \text{Log} [f_{\theta}(\lambda)] d\lambda + \int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda \right] \dots(2-51)$$

ولتبسيط حساب التكامل يمكن الأستعاضة عنها بمجاميع (Riemann) :

$$\int_{-\pi}^{\pi} \text{Log} [f_{\theta}(\lambda)] d\lambda \approx \frac{2\pi}{n} \sum_{j=1}^n \text{Log} [f_{\theta}(\lambda_j)]$$

$$\int_{-\pi}^{\pi} \frac{I(\lambda)}{f_{\theta}(\lambda)} d\lambda \approx \frac{2\pi}{n} \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)}$$

وبذلك فإن الصيغة المتقطعة الى لوغاريتم دالة الامكان ستكون :

$$L(\theta) = - \frac{1}{2n} \left[\sum_{j=1}^n \text{Log} [f_{\theta}(\lambda_j)] + \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)} \right] \dots(2-53)$$

كما أن هناك صيغة أخرى مبسطة الى لوغاريتم دالة الامكان لـ(Whittle) وذلك بإهمال الحد الأول في صيغة (2-53) نحصل على :

$$L(\theta) = - \frac{1}{2\pi} \sum_{j=1}^n \frac{I(\lambda_j)}{f_{\theta}(\lambda_j)} \dots(2-54)$$

(Palma ,W. 2007) (Reisen , 2001)

2-9 الشبكات العصبية الاصطناعية : (Artificial Neural Network)

تبنى فكرة عمل الشبكات العصبية الاصطناعية على محاكاة وظائف الدماغ البيولوجية لإجراء عمليات حسابية متوازية لمعالجة البيانات واستخراج المعرفة للوصول إلى نموذج لهذه البيانات لغرض التحليل أو التصنيف أو التقدير أو التنبؤ أو أي معالجة أخرى دون الحاجة إلى نموذج مقترح لهذه البيانات، وبهذه الميزة فقد حازت الشبكات العصبية الاصطناعية اهتمام الكثير من الباحثين والعلماء إذ لها المرونة العالية بالمقارنة مع الأساليب الرياضية المستعملة (Cheng, 2014, 7). وتعد الشبكات العصبية الاصطناعية (ANN) هي حالة ذكية من نظرية الشبكات في عملية التعلم على نماذج للبيانات و تخزين و بث المعلومات في الشبكة العصبية الاصطناعية. وهي إحدى النماذج اللاخطية الذي يحاكي الشبكات العصبية الحيوية (النظام العصبي) ، وذلك عن طريق معالجة ضخمة موزعة على التوازي ومكونة من وحدات معالجة بسيطة تسمى هذه الوحدات بالعصبونات أو عقد أو خلايا (Nodes, cells , Neurons) والتي

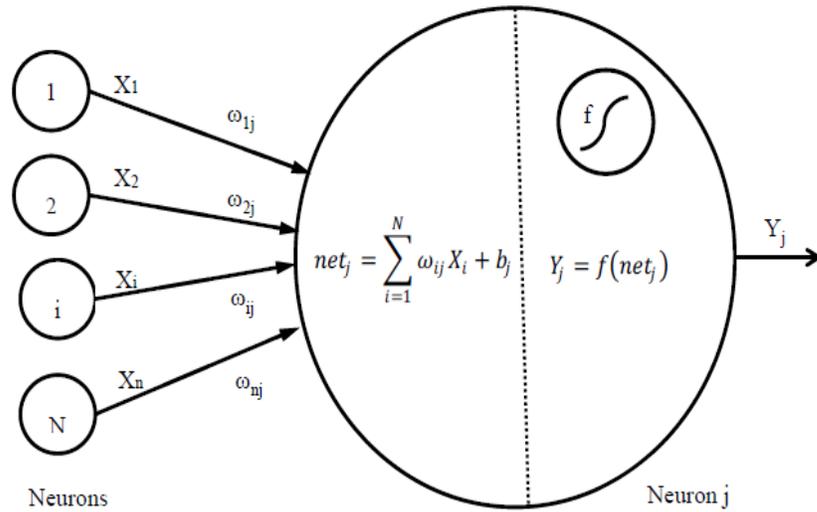
لها خاصية عصبية لأنها تقوم بتخزين المعرفة العلمية والمعلومات التجريبية لتجعلها متاحة عن طريق ضبط الأوزان (Negenvitsky, 2011, 286). وتستعمل الشبكات العصبية الاصطناعية في الكثير من المجالات والتطبيقات منها معالجة الإشارة (Signal processing) والسيطرة (control) ، تمييز الأنماط (Pattern recognizing) ، الطب (Medicine) ، إنتاج الكلام وتمييز الكلام (speech production and recognizing) وكذلك في تحليل السلاسل الزمنية (البدراني و صليو ، 2014 ، 1)

1-9-2 مراحل تطور شبكة الخلية العصبية الاصطناعية:

(Developing stages of Artificial Neural Network Cell)

ظهرت العديد من نظريات الشبكات العصبية الاصطناعية (ANN) ومن ابرز هذه النظريات، نظرية (Donald Hebb) عام (1949) ، إذ تنص هذه النظرية على إن عملية التعلم والذاكرة (Learning & Memory) هي ظاهرة تنتج عن تقوية الارتباط في عقد الشبكة العصبية، أي بمعنى آخر أن التحفيز المتكرر (repeated stimulation) لبعض العقد الفعالة في الشبكة العصبية يؤدي إلى حدوث زيادة في قوة الارتباط العصبي بين العقد الفعالة، وهذه العملية تؤدي إلى خزن (Encoding) التغيرات في قوة الارتباط العصبي بين العقد الفعالة في الشبكة لاختيار أفضل أوزان، وهذا معنى التعلم في الشبكة العصبية، وبذلك تتعلم الشبكة أنموذجاً للبيانات التي تدرت عليها. (Hajdu et al , 2019, 102)

افترض العالم (Frank Roseblatt, 1958) نظرية الإدراك الحسي عن طريق تمثيل الإدراك الحسي (Sensory perception) بشبكة الخلية العصبية الاصطناعية والذي يحاكي الخلية العصبية البايولوجية في طريقة عمله وقد افترضت هذه الطريقة إذ يتكون الإدراك الحسي من وحدات إدخال (Input units) ووحدة جمع (Summing unit) إذ ترتبط وحدات الإدخال مع وحدة الجمع بنقاط الارتباط العصبي والتي تمثل الأوزان في الخلية العصبية، وتضرب الأوزان بالمدخلات ثم تجمع لتكوّن وحدة الجمع (Summing Unit)، وتمرر مخرجات وحدة الجمع في دالة لخطية ذات قيمة معينة تسمى دالة العتبة (Threshold Function)، لكي نحصل على مخرجات الشبكة العصبية الاصطناعية. والشكل (2-5) يمثل مخطط شبكة الخلية العصبية الاصطناعية (Cheng, 2014, 8).



شكل (2-1) خلية الشبكة العصبية الاصطناعية

وكانت تلك هي النواة الأولى في عملية التعلم على مدخلات شبكة الخلية العصبية الاصطناعية المتكونة من طبقة واحدة (Single Layer) ولذلك فقد كانت عملية التعلم مقتصرة على النماذج الخطية للبيانات، لغرض التقدير أو التبويب أو التصنيف أو التنبؤ، ولهذا السبب فقد قل الاهتمام على البحوث و الدراسات في مجال الشبكات العصبية لسنوات عدة، إلى أن تم التوصل إلى شكل جديد للإدراك الحسي (Perceptron) ويتمثل بإضافة مستوى جديد يطلق عليه بالمستوى المخفي (Hidden Level) و بذلك أصبحت عملية الربط بين المدخلات (Input) و المخرجات (Output) لا تتم بشكل مباشر و إنما عن طريق المستوى المخفي إذ اكتسب الإدراك الحسي القدرة على حساب الدوال والعلاقات للبيانات ذات النماذج الخطية واللاخطية، وبعد ذلك فقد تطور هذا المستوى المخفي بإضافة أوزان تربط بين مستوى المدخلات (Input Level) والمستوى المخفي من قبل العالم (Paul Werbos) عام (1974). ولم يثير هذا التطور أي اهتمام من قبل الباحثين والعلماء إلا بعد استعمال خوارزمية الانتشار العكسي للخطأ (Error Back-Propagation) في منتصف الثمانينات في عملية التدريب والتعلم على البيانات لغرض بناء نماذج أو تقدير أو تصنيف أو تنبؤ (الكسو، 2005، 46-45).

2-9-2 هيكليّة الشبكة العصبية (التعريف والهدف)

(Aim-Definition and Artificial Neural Network Structure)

قبل التعرف على بنية الشبكة العصبية الاصطناعية وتعريفها لابد من ذكر اوجه التشابه بين الجهاز العصبي البشري (الخلية العصبية البيولوجية) والعصبونات الاصطناعية.

2-9-2-1 الخلية العصبية البيولوجية والعصبونات الاصطناعية

يتألف الدماغ البشري من كم هائل ومعقد من الخلايا العصبية تزيد على (10) بليون خلية لها ارتباطات داخلية معقدة مكونة شبكة كبيرة من الأعصاب (Neurons) تشترك مع بعضها ببعض بالصفات مع خلايا الجسم الأخرى لكنه وحيد في قابليته في استقبال ومعالجة نقل الإشارة الكهروكيميائية على طول العصب والتي تشكل نظام الارتباط للدماغ.

يحتوي العصب على ثلاثة أجزاء هي جسم الخلية (Cell Body) والتفرعات الشجيرية (Dendrites) والمحور العصبي (Axon). وتمتد التفرعات الشجيرية (Dendrites) من جسم الخلية إلى الأعصاب الأخرى لتشكل شبكة عصبية، وتمثل العقدة العصبية (Synapse) ممراً أو بوابة لربط التفرع الشجيري القادم من عصب آخر، فهي نقاط الربط التي يستلم عضو الحس أو المستقبل الإشارات الكهربائية وتقوم بتحميل المعلومات بالوقت والسرعة كليهما. تصل الإدخالات إلى جسم الخلية فبعضها يثير الخلية ويحفزها والأخرى تكبحها وتثبطها وتعمل العقدة (العصب) على دمج أو تراكم الإشارات في جسم الخلية، وعندما تتجاوز المستوى المطلوب (Threshold) للخلية سوف تكبح وتمرر إلى الخلية الأخرى على طول المحور العصبي (Axon)، ويقوم التفرع الشجيري بتعديل (تغيير) سعة الإشارة المنقولة خلاله وهذا التعديل يتغير مع الزمن كما في عملية التعلم (Learning) للشبكة العصبية الاصطناعية (خليل، 17، 2001) (الجراح، 10، 2003) (العمرى، 2004، 11) (Idwo et al, 2012, 68).

أما الخلية العصبية الاصطناعية فقد صممت لتحاكي الخصائص الأساسية للخلية العصبية البيولوجية، إذ تمثل ترابطات الإدخال بخطوط تقابل التفرعات الشجيرية والتي بدورها تمثل الإخراج لعصب آخر، فعندما

تأتي الإشارة متمثلة بالمتجه X (الإدخال) من ترابط معين تضرب برقم يسمى وزن الترابط (Weight of Connection) ومجموعة الأوزان تُمثل بالمتجه W الذي يقابل اتساع التفرع الشجيري البيولوجي، وتجمع الإشارات أو الإدخالات الموزونة (Weighted Inputs) في صندوق الجمع الذي يقابل جسم الخلية العصبية لتحديد مستوى التأثير (الفاعلية) (Level activation) لها لتنتج إشارة الإخراج ممثلة الإدخال لخلايا أخرى مرتبطة معها، وهكذا تجمع جميع الإدخالات الموزونة جبرياً لانتاج الإخراج المتحقق المسمى بمصطلح نيت (Net) محسوباً بالصيغة الآتية:

$$\text{Net} = \underline{W} \underline{X} + b \quad \dots (2-55)$$

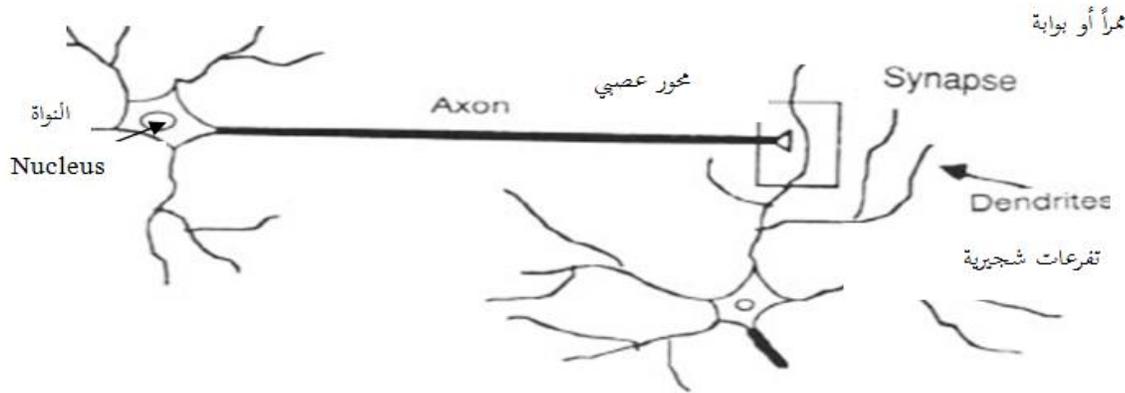
إذ أن:

X : متجه الإدخال الذي يضم مجموعة الإدخال وهي X_1, X_2, \dots, X_n .

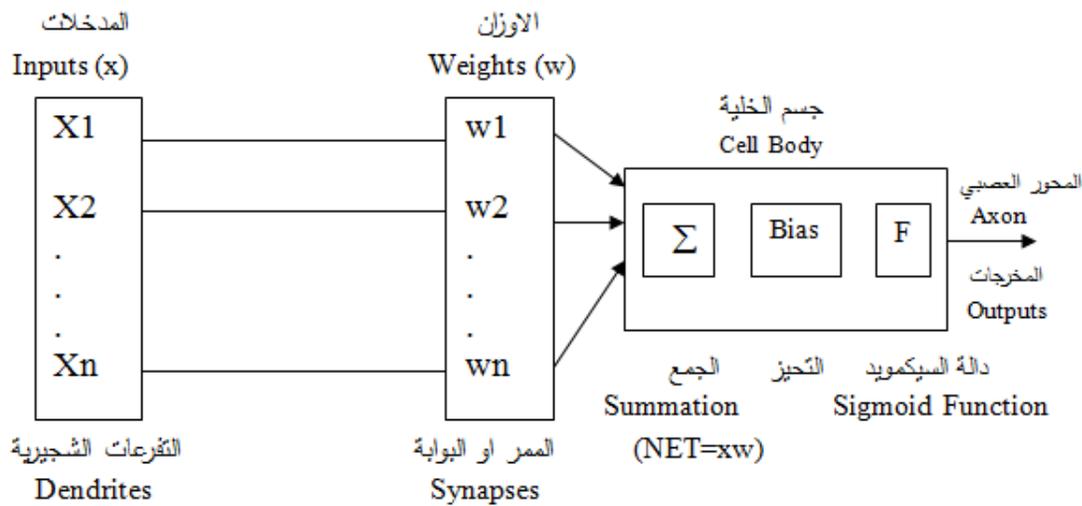
W : متجه الأوزان الذي يضم مجموعة الأوزان W_1, W_2, \dots, W_n .

مُشكلةً بذلك العصب الاصطناعي (Artificial Neuron) والشكل (2-2) يوضح مكونات الخلية العصبية البيولوجية وما يناظرها في الخلية العصبية الاصطناعية.

(et al, 2012, 69&ldwo)



الشكل (2-2-a): مكونات الخلية العصبية البيولوجية



الشكل (b-2-2) مكونات الخلية العصبية الاصطناعية

الشكل (2-2): (a) مكونات الخلية العصبية البيولوجية (b) مكونات الخلية العصبية الاصطناعية

3-9-2 تعريف الشبكة العصبية الاصطناعية وهدفها

(Aim and Definition of Artificial Neural Network)

سميت الشبكات العصبية الاصطناعية بعدة تسميات جميعها مبنية على فكرة محاكاة الشبكة العصبية في الكائنات الحية، فقد سميت بالحاسوب الحي (Biological Computer) والدماغ الالكتروني (Electronic Brain) والمنظومة العصبية (Neuromorphic System) ونماذج الترابط (Connection Models) والتوزيع المتوازي (Parallelism Distribution) ونماذج المعالجة (Processing Models) (خليل، 2001) (بني خالد، 2003).

وهناك تعريف عدة للشبكات العصبية منها ما يختص بالجانب الحاسوبي والآخر بالجانب الرياضي والآخر بالجانب الهندسي هدفها جميعاً محاولة تقليد القدرة الإدراكية للدماغ بالتعلم والتجربة والخطأ، لتحقيق أداء يشبه أداء الإنسان في حل المسائل ذوات الحلول غير الخوارزمية والمسائل غير التامة (الناقصة) وللبينات المشوشة (الضجيج) ومن هذه التعاريف ما يأتي:

1- إن الشبكة العصبية الاصطناعية هي عبارة عن نظام حاسوبي لمعالجة المعلومات، مكون من عدد كبير جداً من عناصر المعالجة (Processing Elements) المترابطة فيما بينها ذات طبيعة ديناميكية وظيفتها هي التقسيم المتوازي لحسابات الشبكة، وتتكون الشبكة العصبية من عدد من وحدات المعالجة المتداخلة والمتجانسة، كل وحدة بمفردها أداة حسابية يمكن نمذجة سلوكها بمعادلات رياضية بسيطة.

2- أما التعريف الرياضي للشبكة العصبية الاصطناعية فهي بشكل أساس نماذج رياضية لمعالجة المعلومات، أو هي أسلوب رياضي يقوم بمحاكاة شبكة عصبية بيولوجية للحصول على شبكة عصبية اصطناعية، فهي تستعمل بعض الطرائق الرياضية للحصول على الأوزان مثل المشتقات، ولا تزال تعرف على أنها مكملة لطرائق الحساب التقليدية (عيسى، 2000، 22).

3- هندسياً تعرف الشبكة العصبية الاصطناعية بأنها تشكيل لدائرة كهربائية لها اتصالات داخلية عناصرها البسيطة تسمى العصبونات، كل عصبون يمثل خريطة إنموزجية للعديد من الإدخالات مُمثلةً بالفولتية وإخراج واحد ممثلاً بالتيار، فالإدخال لكل عصبون هو الإخراج الموزون للعصبونات الأخرى، والاتصالات (الارتباطات) الداخلية تسمح بنقل واستبدال البيانات والمعلومات بين العصبونات (Chong & Zak, 2001, 88).

ومن وجهة نظر النظم الديناميكية فإن الشبكات العصبية الاصطناعية عبارة عن أنظمة معلمية (Parametric System)، إذ تستعمل البيانات الخارجية لمعلمات مجموعة من الإدخالات ويكون إدراك المخرجات عن طريق إنجاز التغذية العكسية (Feed Backward) لدالة الكلفة (Cost Function) التي تستعمل بشكل مباشر في تغيير المعلمات خلال التدريب والتعلم (اختيار الأوزان) يؤدي إلى تحسين مخرجات النظام، أي تقليل الخطأ عن التدريب، فالأوزان هي معلمات التعلم، وبهذا تعرف الشبكة العصبية الاصطناعية احصائياً. (Principe et al., 2000, 78)

2-9-4 معمارية (هيكلية) الشبكة العصبية الاصطناعية

(Artificial Neural Network Architecture (Structure))

يقصد بمعمارية (هيكلية أو بنية) الشبكة العصبية الاصطناعية ترتيب العقد في المستويات أو الطبقات وشكل الترابط ضمن المستويات (الطبقات) أو فيما بينها، فهي من أهم خصائص الشبكة العصبية والتي توصف على أساسها الشبكة.

تصنف الشبكات بحسب عدد مستوياتها (طبقاتها) إلى صنفين رئيسيين:

- أ- شبكات وحيدة المستوى أو الطبقة (Single-level or layer): وهي لا تمتلك طبقة (مستوى) مخفية.
- ب- شبكات متعددة المستويات (الطبقات) (Multi-level or layers): لها مستوى (طبقة) مخفي واحد أو أكثر وهي نوعان أيضا شبكة أمامية التغذية (Feed Forward N.) وشبكة عكسية التغذية (Feed Backward N.).
- وبشكل عام، فان معمارية الشبكة العصبية الاصطناعية الانموذجية مكونة من ثلاث مستويات (طبقات) هي:

- 1- مستوى (طبقة) الإدخال (Input level (layer)): هو المستوى الأول في الشبكة العصبية، يحتوي على عدد من العقد تمثل عدد المتغيرات المستقلة (الإدخالات).
- 2- المستوى (الطبقة) المخفي (Hidden Level): وهو المستوى الأوسط الذي يقع بين المستوى الأول (الإدخال) والمستوى الأخير (الإخراج)، فهو يأتي المستوى الأول.
- 3- مستوى (طبقة) الإخراج (Output Level): وهو المستوى الأخير في الشبكة العصبية الاصطناعية الذي يمثل اخراجات الشبكة العصبية.
- ويتكون كل مستوى من المستويات الثلاثة انفاً من:

أ. العقد أو الخلايا (Nodes): تشكل نقاط الترابط العصبي بين مستويات (طبقات) الشبكة العصبية.

ب. المستوى (Level): يمثل مجموعة العقد أو الخلايا التي تستلم الإدخال ولها إخراج.

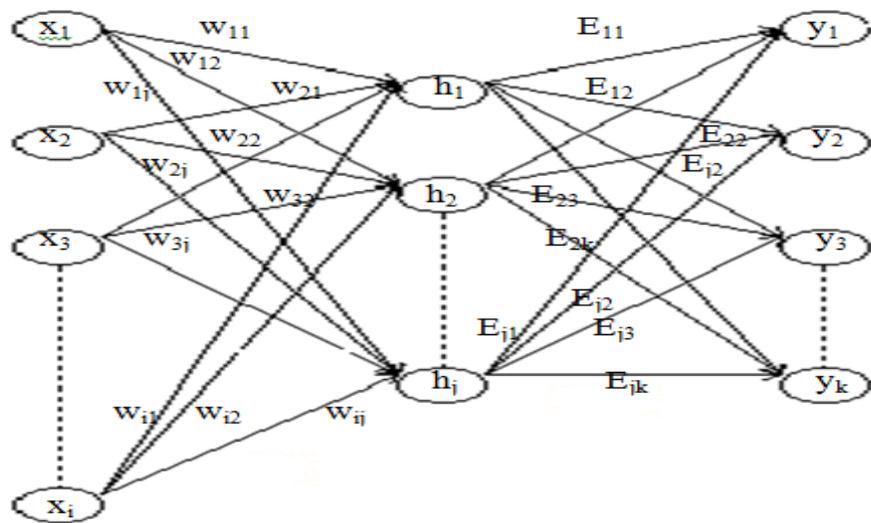
ج. الأوزان (Weights): تشير الأوزان إلى مدى قوة الارتباط العصبي بين مستويات (طبقات) الشبكة العصبية فلكل عقدة (خلية) وزن يربطها مع المستوى السابق، ووزن يربطها مع المستوى اللاحق. إن القيم الأولية للأوزان (Initial Weights) في بداية تدريب الشبكة (Network Training) قيم عددية عشوائية يتم توليدها من توزيعات إحصائية.

(الشيخلي، 2003، 22). (Cheng, 2014, 9)

وفي الشبكة العصبية ثلاث طبقات من الأوزان هي:

- 1- طبقة أوزان مستوى الإدخال والمستوى المخفي (Input to Hidden Weights)
- 2- طبقة أوزان بين المستويات المخفية (Hidden Weights)
- 3- طبقة أوزان المستوى المخفي ومستوى الإخراج (Hidden to Output Weights).

والشكل (2-3) مخطط يوضح معمارية الشبكة العصبية الاصطناعية الإنموجية.



الشكل (2-3) : معمارية الشبكة العصبية الاصطناعية الإنموجية

ولأهمية الشبكات العصبية ولصعوبة توسيع طبقات (مستويات) الشبكة العصبية لتشتمل على طبقات عدة ولعدم وجود وسيلة واضحة أو مفهوم محدد لكيفية التعامل مع هذه الطبقات لجعلها تتعلم أي شيء، بات لازماً تحديد الحجم الأمثل (Optimal Size) للشبكة العصبية أي تحديد العدد الأمثل للعقد (الخلايا) والحلقات (الترايطات) الموجودة في الشبكة، علماً أن حساب عدد طبقات الشبكة العصبية لا يشتمل على طبقة الإدخال (Input Layer) لعدم إنجازها أية عملية حسابية (الجراح، و 11,2003) (الكسو، 2005، 50-52).

5-9-2 معالجة المعلومات في الشبكة العصبية (التعلم والتدريب):

Information Process in Neural Network (Learning and Training)

إن الشبكات العصبية الاصطناعية تكون على نوعين هما الشبكات الثابتة (Fixed N Nets) وهي التي لا تتغير أوزانها عند التدريب أو التعلم، والشبكات المكيفة (Adaptive N. Nets) والتي لها القابلية على تغيير أوزانها. ويقصد بمعالجة المعلومات في الشبكات العصبية مرور البيانات في الشبكات العصبية المكيفة بمرحلتين أساسيتين هما:

1- مرحلة التدريب أو التعلم (Learning or Training Step).

2- مرحلة العمل (الاسترجاع) (Doing or Recall Step).

أولاً: مرحلة التدريب أو التعلم : (Training or Learning)

يعرّف التعلم عموماً على انه تغير دائم ومستمر نسبياً في السلوك الذي يحدث بواسطة التجربة والاختبار. والتعلم في الشبكات العصبية هو تطبيق معطى لعمليات (الإدخال-الإخراج) عن طريق مجموعة من الأمثلة، ويكون التعلم ضرورة ملحة عندما يكون هناك نقص في فهم العلاقة بين الإدخال والإخراج بحيث تكون صعبة الوصف. وفي هذه المرحلة تنتج معلومات (بيانات) جديدة في الشبكة نتيجة لتغير الوزن (Weight) للشبكة (Idwo et al, 2012, 70-71).

تبدأ عملية تدريب الشبكة العصبية الاصطناعية على التطبيق المعطى بإدخال البيانات إلى الشبكة فتتعلم على خصائص ومزايا هذه البيانات التي تُمثل بشكل متجهات (Vectors) كل متجه يتكون من جزآن، الجزء الأول يمثل مجموعة المتغيرات المستقلة مثلاً (الإدخال) أما الجزء الثاني فيمثل قيم المعيار (المتغيرات المعتمدة) (الإخراج المطلوب)، إذ يكون الجزءان معاً المتجه الذي يعد الإدخال إلى الشبكة وكل عقدة من عقد الإدخال تمثل إحدى قيم الجزء الأول من المتجه (المتغيرات المستقلة). ويتم إدخال المتجه إلى الشبكة على شكل مصفوفة، وتدريب الشبكة على البيانات أي تتغير أوزانها وفقاً لقوانين محددة وبشكل متسلسل، وبذلك تقترب الأوزان تدريجاً إلى القيم المثالية التي تعطي أفضل تقدير لقيم المعيار والتي تمثل الإخراج المطلوب للشبكة [الشيخلي، 2003]. وبناءً على ذلك فإن للتدريب في الشبكات

العصبية الاصطناعية المكيفة (تكيف معلمات النظام) طريقتين أساسيتين هما التدريب بإشراف والتدريب بدون إشراف.

(Shen & Chang, 2013, 12002)

1) التدريب بإشراف (عن طريق مشرف أو معلم): Supervised Training

وهو التدريب بإرشاد وعادة ما يستعمل في شبكات التغذية الأمامية (Feed Forward Networks) ويتطلب وجود زوج من متجه الإدخال (Input) ومتجه الإخراج المتوقع (Target Output) والتي تمثل زوج التدريب، تدرب الشبكة العصبية على عدد من هذه الأزواج ويقارن الإخراج (Output) لمتجه الإدخال المطبق مع متجه الإخراج المتوقع والاختلاف بينهما يمثل خطأ التدريب (Training Error) يرجع خلال الشبكة كي تتغير الأوزان وفقاً للخوارزمية باتجاه تقليل الخطأ. تطبق جميع متجهات مجموعة التدريب وتتغير الأوزان ويحسب الخطأ إلى أن يصل لمجموعة التدريب المدخلة إلى أقل خطأ تدريب (Minimum Training Error) باستعمال إحدى الطرائق الشائعة في إقلال الخطأ وهي مربعات المتوسطات الصغرى التقاربية (LMS) وبالنتيجة نحصل على الأوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب أو التعلم، وهذا هو الهدف من تدريب الشبكة العصبية الاصطناعية.

(Negnevitsky, M. , 2011, 111)

2) التدريب بدون إشراف Unsupervised Training

هذا النوع من التدريب لا يستعمل المعلم الخارجي ويكون الاعتماد فقط على المعلومات الموقعية، ويشار إلى هذا النوع من التدريب بشبكات التنظيم الذاتي (Self-Organizing) أي تنظيم البيانات التي تقدم إلى الشبكة ذاتياً. في هذا التدريب تمتلك الشبكة العصبية بعض المعلومات في التدريب أي لها إدخلات فقط وليس لها معرفة عما سيكون عليه الجواب الصحيح ولا تعرف ما هو الإخراج المطلوب أي عدم وجود (Desired Output) للشبكة يقارن مع النتائج. اكتشف هذا التدريب الباحث كوهين وآخرون،

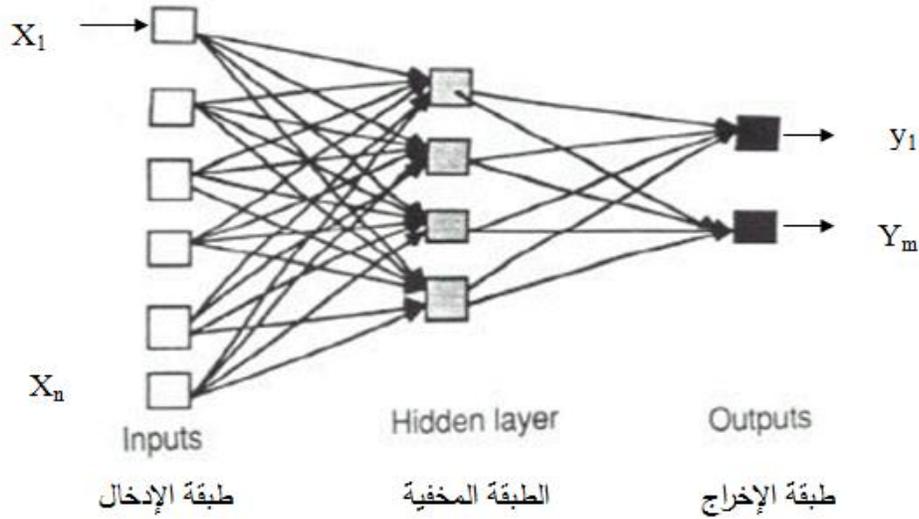
تتألف فيه مجموعة التدريب من متجه الإدخال وخوارزمية التدريب لتغيير أوزان الشبكة لانتاج متجه الإخراج الثابت، يطبق الإدخال لانتاج الإخراج المحدد. (Moreno & Gracia , 2011, 330).

ثانياً: مرحلة العمل (الاسترجاع)

وهي المرحلة الثانية لمعالجة معلومات (بيانات) الشبكة العصبية الاصطناعية، وفيها يطبق الإدخال المعطى مع الأوزان الناتجة عن المرحلة الأولى (مرحلة التدريب) وبخطوة واحدة نحصل على الإخراج المطلوب (Desired Output).

إن مرحلة العمل (الاسترجاع) هي تغذية أمامية فقط (Feed Forward)، إذ تكون العصبونات مرتبطة مع الطبقات يؤدي إلى انسيابية البيانات باتجاه واحد فقط، أي أن كل عصبون يستلم المعلومات فقط من العصبونات في الطبقة السابقة، والإدخال لكل عصبون يمثل الإخراج الموزون للعصبونات في الطبقة السابقة (Chong and Zak, 2001, 90).

والشكل (2-4) يوضح هيكله الشبكة العصبية ذات التغذية الأمامية.

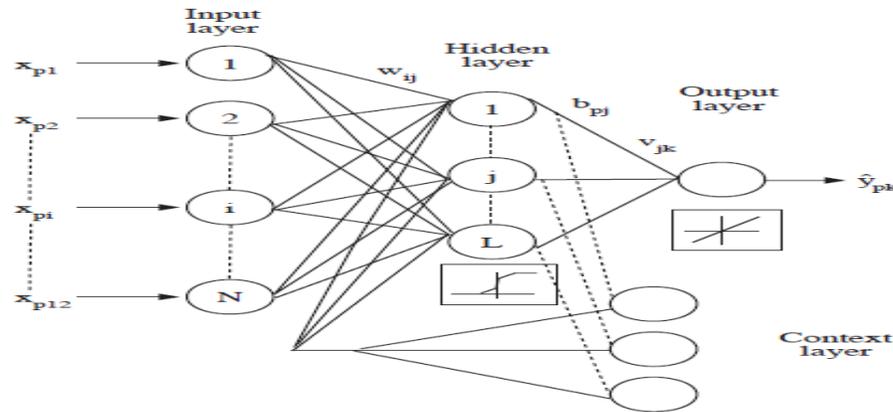


الشكل (2-4) هيكله الشبكة العصبية ذات التغذية الأمامية

وفي شبكات التغذية العكسية (الاسترجاعية) يعاد تغذية (كل أو بعض) الاشارات الخارجة من الشبكة وتحويل اتجاهها لتصبح اشارات داخلة ايضاً (اعادة تغذية) وذلك فان الاشارة الخارجة من اية خلية تعتمد على الاشارات الداخلة اليها فضلاً عن الاشارات الخارجة منها في وقت سابق. ومن انواع شبكات التغذية الاسترجاعية:

1. الشبكة العصبية إيلمان (Elman Neural Network):

تتألف هذه الشبكة على الأقل من أربع طبقات من الخلايا : طبقة الإدخال (Input Layer) وطبقة وسطى تسمى الطبقة المخفية (Hidden Layer) إذ ترتبط كل طبقة بالطبقة التي تليها ارتباطاً أمامياً (feed forward) وفضلاً عن هذا الارتباط فان خلايا الطبقة المخفية ليست مرتبطة بطبقة المخرجات فقط ولكن أيضاً مرتبطة بطبقة اخرى تسمى طبقة السياق (Context Layer) لتشكل اتصالات متكررة ، ومخرجات طبقة السياق هي أيضاً مدخلات الطبقة المخفية (Moreno et al , 2011,55). والشكل (9-2) يبين شبكة إيلمان العصبية الاصطناعية .

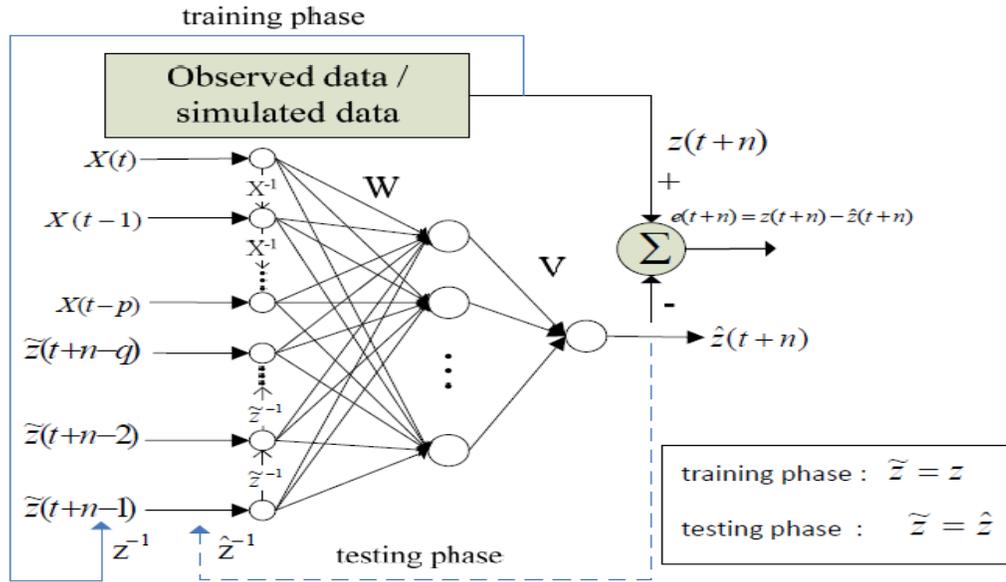


شكل (9-2) شبكة إيلمان العصبية الاصطناعية

2. شبكة الانحدار الذاتي اللاخطية بمدخلات خارجية (NARX)

(Non-Linear Autoregressive with Exogenous Inputs)

وهي من الشبكات العصبية الحركية المتركرة القوية التي تستعمل للتنبؤ بالسلاسل الزمنية فيكون لها تأخر زمني (Delay Time) ومعماريته مبنية على أساس الشبكة العصبية متعددة الطبقات فهي تتألف من ثلاث طبقات من الخلايا : طبقة ادخل والطبقة المخفية وطبقة الاخراج ، وترتبط كل طبقة في السبطة بالطبقة التي تليها ارتباطاً أمامياً (feed forward) فضلاً عن هذا الترابط فان الشارة الخارجة من خلايا طبقة الاخراج تعد كمدخلات اضافية (External) باتصالات تغذية عكسية (Feed Back) لخلايا طبقة الادخال وهذا سيؤدي الى سرعة وصول الشبكة الى الاستقرار ، كما انها تستعمل خوارزمية الانتشار الخلفي (Back Propagation) لتصحيح الخطأ (البدراني وصليبة ، 2014 ، 11) والشكل (5-2) يبين معمارية (NARX)



شكل (2-5) معمارية شبكة (NARX) العصبية الاصطناعية

(Shen & chang, 2013, 12023)

2-9-6 أنواع الشبكات العصبية الاصطناعية (Types of Neural Networks)

تقسم الشبكات العصبية الى نوعين هما :

1- شبكات عصبية ثابتة (Static Networks) : وهي الشبكات التي ليس لها عنصر تغذية عكسية (Feedback) ولا تمتلك تخلف زمنياً (Delay time) اي ان مخرجاتها تحتسب مباشرة من المدخلات مروراً باتصالات التغذية الأمامية (M.Gupta et al, 2006, 17)

2- الشبكات الحركية (Dynamic Networks) : فهي تحتوي على الأقل طبقة واحدة ذات تغذية عكسية ، ففي هذا النوع من الشبكات فان المخرجات الحالية لاتعتمد فقط على المدخلات الحالية للشبكة ونما تعتمد ايضاً على المدخلات والمخرجات السابقة ، ومن ثم فان الاشارة في هذا النمط من الشبكات العصبية تتجه اماماً اي نحو الاخراج وايضاً بالاتجاه العكسي لتكون ادخالاً في الوقت ذاته ويطلق عليها بالشبكات الحركية (الديناميكية) ، اذ انها تمتلك ذاكرة (Shen & chang, 2013, 1999).

ويوجد نوعان من التغذية في الشبكات العصبية كالآتي:

- 1- شبكة التغذية الأمامية (Feed forward Networks): وتكون الاشارات الداخلة الى الشبكة الى الامام دائماً وتتجه جميع خطوط الربط باتجاه واحد من طبقة الادخال حتى طبقة الاخراج وبذلك تكون الاشارة الخارجة من اية خلية تعتمد على الاشارات الداخلة فقط (M.Gupta et al, 2006, 18) .
 - 2- شبكة الانتشار العكسي للخطأ (Error Back propagation Network): وهي من اكثر الشبكات العصبية استعمالاً وهي مشتقة من عملية المربعات الصغرى (Least mean Square) والتي تسعى الى تقليل مربع الخطأ الكلي عند التدريب وبالنتيجة نحصل على الاوزان المثلى التي يمكن اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتدريب او التعلم (Idown, 2012, 73).
- ان تدريب الشبكة العصبية الاصطناعية باستعمال الانتشار العكسي للخطأ يمر بثلاثة مراحل هي :
- 1- مرحلة الانتشار الامامي للخطأ .
 - 2- مرحلة الانتشار الخلفي للخطأ .
 - 3- مرحلة توليف اوزان الشبكة . (البدراني و صليو ، 2014 ، 9-10)



الفصل الثالث

الجانب التطبيقي

3-1 تمهيد

يتناول هذا الفصل بناء نموذج سلسلة زمنية موسمية والمقارنة بين هذه النماذج باستعمال معايير المفاضلة بين النماذج واختيار افضل نموذج يشمل درجات الحرارة في مركز قضاء الحلة / محافظة بابل.

3-2 بيانات الرسالة

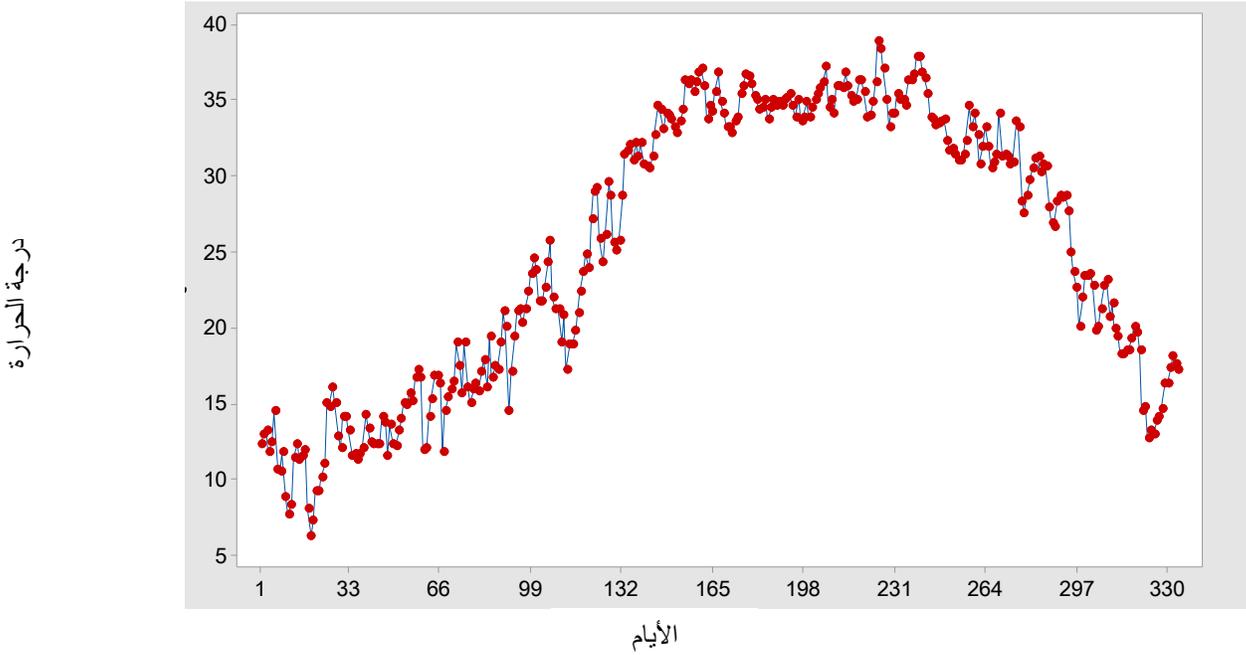
تم الحصول على البيانات الخاصة بالدراسة من هيئة الانواء الجوية العراقية ، التي تمثل درجات الحرارة اليومية المسجلة في محافظة بابل لسنة (2020) والتي شملت (334) مشاهدة . والتي تم الحصول عليها من هيئة الانواء الجوية العراقية والمبينة في ملحق (A). وتم اختبار اعتدالية البيانات وفقاً لاختبار Goodness of fit وتم تحليل البيانات وبالاعتماد على البرامج الجاهزة (Minitab 17, (Matlab 2015, E-views 10

3-3 التحليل الأحصائي للبيانات:

لغرض تحديد الإنموذج الافضل في تقدير درجات الحرارة اليومية في مركز قضاء الحلة / محافظة بابل سيتم اتباع خطوات التحليل الاتية على السلسلة وكما يأتي:

3-3-1 فحص استقرارية السلسلة

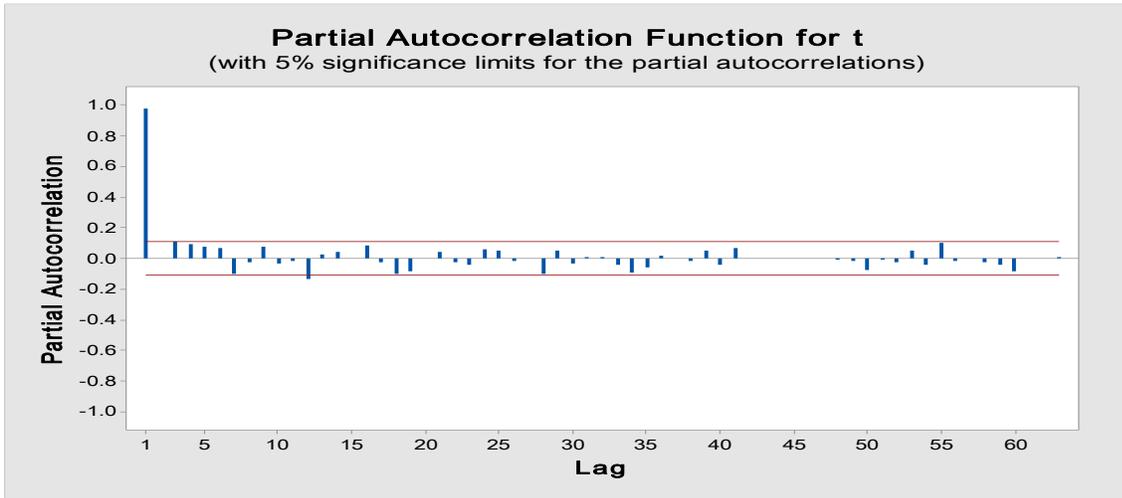
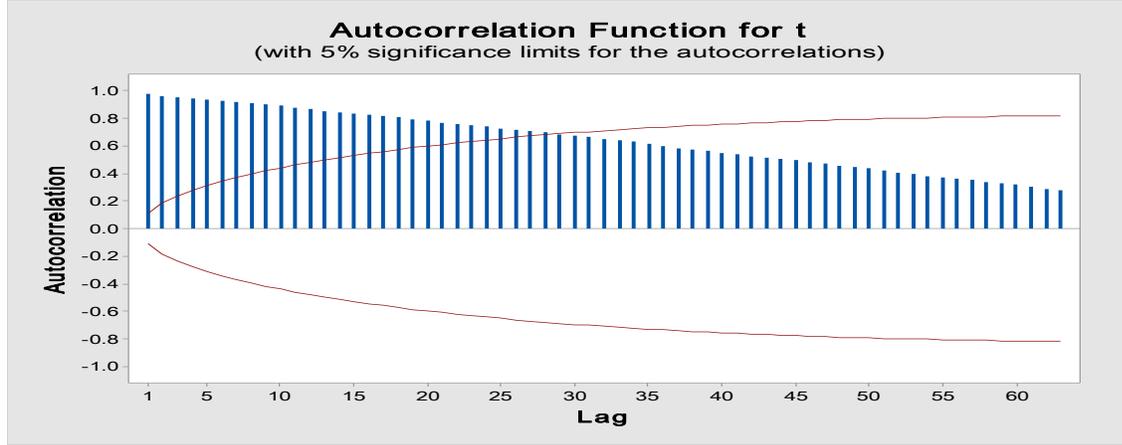
بعد جمع البيانات والتي تعد المرحلة الاولى من مراحل عملية تحليل البيانات، وقبل عملية التحليل لابد من ان نقوم برسم سلسلة البيانات التي تمثل درجات الحرارة اليومية المسجلة في محافظة بابل للتعرف على سلوك السلسلة وخصائصها الأولية والشكل (3-1) يمثل رسم السلسلة :



الشكل (3-1) يبين سلسلة درجات الحرارة اليومية في محافظة بابل Y_t

من الشكل (3-1) نلاحظ ان المحور العمودي يمثل قيم درجات الحرارة اليومية والمحور الافقي يمثل الأيام، ونلاحظ عدم استقرار السلسلة الزمنية اذ تعبر عن الاتجاه العام مع الزمن فضلاً عن وجود تذبذبات متمثلة في تقعات ونبوءات ، وهذه التذبذبات تتكرر بانتظام بوتيرة متشابهة كل يوم مع اختلافها والتي تزداد بها من يوم لآخر الى آخر ، وهذه التغييرات تؤثر لنا على وجود مركبة اتجاه عام ومركبة موسمية وان السلسلة غير مستقرة.

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) وكما في الشكل (3-2) :



الشكل (3-2) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t

نلاحظ من الشكل (3-2) أن الكثير من معاملات دالة الارتباط الذاتي ACF خارج حدود الثقة بمستوى 95% وكذلك بعض معاملات الارتباط الذاتي الجزئي وهذا مؤشر على عدم استقرار السلسلة .

والجدول (3-1) يوضح قيم دالة الارتباط الذاتي Auto Correlation Function ودالة الارتباط الذاتي الجزئي Partial Auto correlation function لسلسلة درجات الحرارة في محافظة بابل .

الجدول (3-1) يبين قيم دالتي ACF , PACF لدرجات الحرارة في محافظة بابل

Lag	ACF	PACF	Lag	ACF	PACF
1	0.983088	0.983088	34	0.730977	0.050734
2	0.966353	0.003242-	35	0.721607	0.019613-
3	0.953603	0.110326	36	0.712925	0.007112-
4	0.944076	0.091859	37	0.700241	0.103607-
5	0.936698	0.076440	38	0.687383	0.047324
6	0.930698	0.064316	39	0.674349	0.035033-
7	0.920572	0.099535-	40	0.663595	0.010258
8	0.909085	0.023786-	41	0.654089	0.011261
9	0.900782	0.079547	42	0.644069	0.038337-
10	0.892118	0.033583-	43	0.630329	0.090004-
11	0.882942	0.017706-	44	0.614722	0.055753-
12	0.869774	0.133888-	45	0.600382	0.015533
13	0.857351	0.024392	46	0.586522	0.008074-
14	0.846902	0.038743	47	0.574279	0.012733-
15	0.837668	0.005922-	48	0.562977	0.047612
16	0.831343	0.086251	49	0.549553	0.038478-

17	0.823733	0.026619-	50	0.435734	0.072543-
18	0.811327	0.098746-	51	0.421758	0.011725-
19	0.796078	0.082451-	52	0.407400	0.024777-
20	0.783142	0.008108	53	0.395634	0.052487
21	0.772608	0.044631	54	0.383764	0.041752-
22	0.762420	0.027827-	55	0.374662	0.098390
23	0.750817	0.044061-	56	0.364568	0.017993-
24	0.740188	0.062151	57	0.353413	0.007170-
25	0.730977	0.050734	58	0.342262	0.025718-

26	0.721607	0.730977	59	0.331141	0.040475-
27	0.712925	0.721607	60	0.317759	0.082456-
28	0.700241	0.712925	61	0.303865	0.007254-
29	0.687383	0.700241	62	0.290389	0.002896
30	0.674349	0.687383	63	0.277468	0.011572
31	0.663595	0.674349			
32	0.654089	0.663595			
33	0.644069	0.654089			

وكانت عدد المشاهدات (63) لوجود قيم مكرر ونلاحظ من الجدول (3-1) ان اغلب قيم دالتي الارتباط الذاتي والارتباط الذاتي الجزئي متباطئة بعد الازاحة الاولى بمعنى ان $|ACF| > \left| \frac{1.96}{\sqrt{n}} \right|$ و $|PACF| > \left| \frac{1.96}{\sqrt{n}} \right|$

وللتأكد اكثر من عدم استقرارية سلسلة درجات الحرارة في محافظة بابل نلجأ إلى اختبار ديكي- فولر الموسع ويبين الجدول (3-2) نتائج الاختبار.

جدول (3-2) يبين نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية

Test	Test Statistic	Table Statistic	P-value
Augmented Dickey – Fuller	-1.66945	-3.4498	0.4459

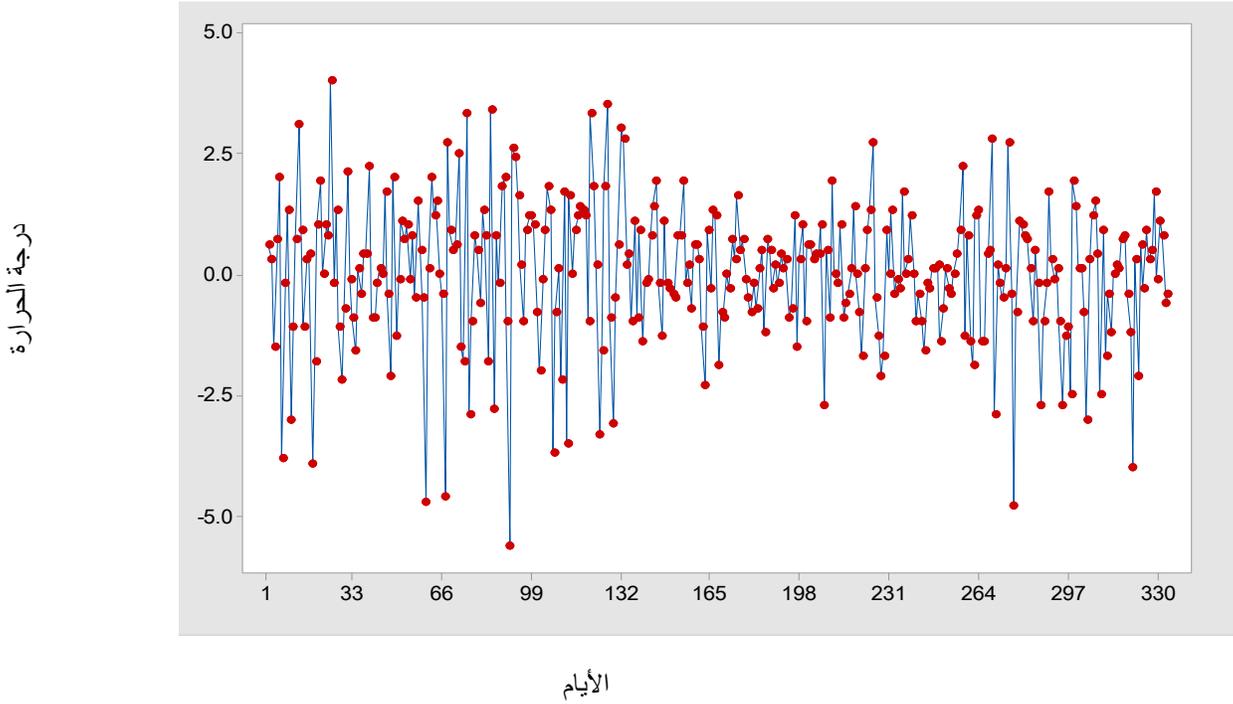
تبين نتائج الاختبار في الجدول (3-2) إن القيمة المطلقة لاحصاء الاختبار هي اقل من القيمة الجدولية الخاصة باختبار ديكي - فولر الموسع عند مستوى معنوية (0.05) . وهذا يدعونا الى عدم رفض فرضية عدم ورفض الفرضية البديلة التي تشير إلى استقرارية السلسلة الزمنية اي ان السلسلة غير مستقرة.

H_0 : السلسلة غير مستقرة

H_1 : السلسلة مستقرة

3-3-1-1 إزالة الاتجاه العام

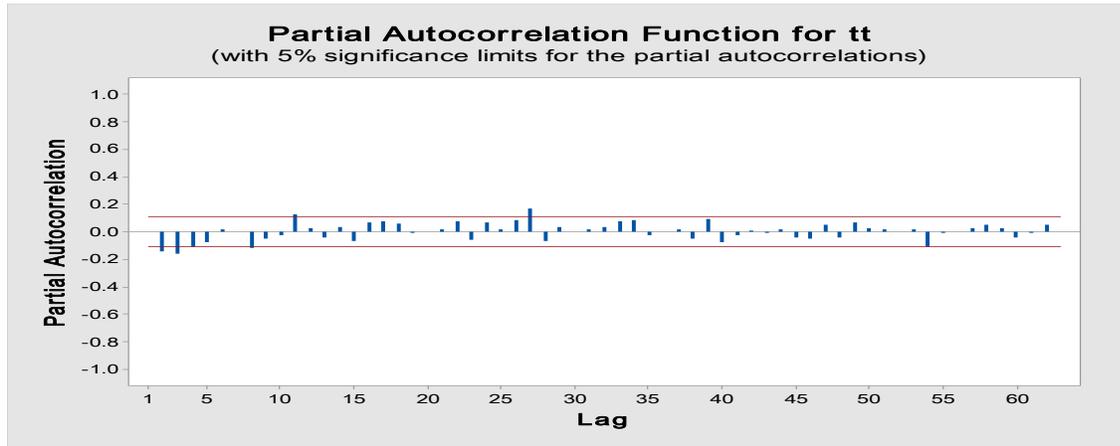
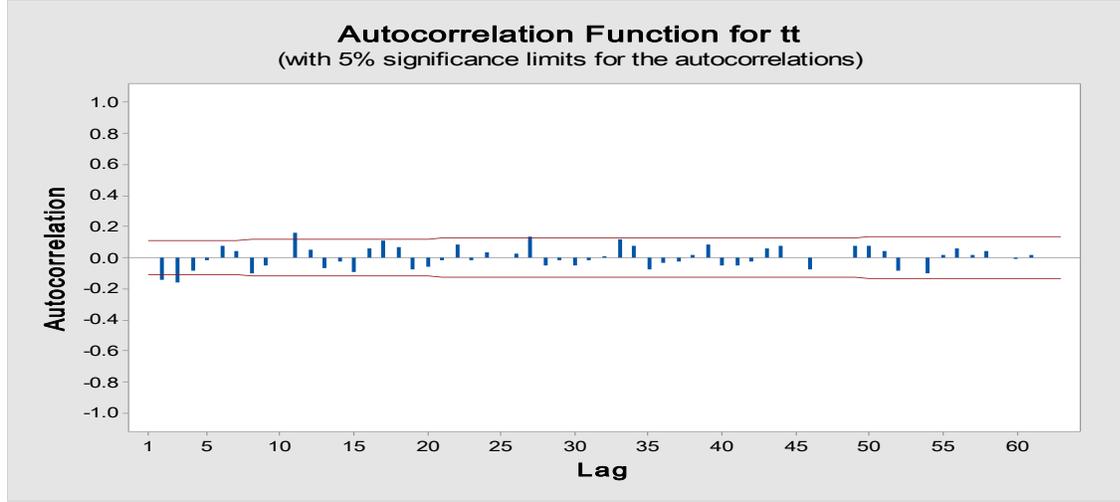
لازالة الاتجاه العام من السلسلة الزمنية تم اخذ الفرق الاول لقيم السلسلة الزمنية Y_t اذ نلاحظ انه تم تحقيق الاستقرار حول المتوسط في السلسلة وكما مبين في الشكل (3-3) .



الشكل (3-3) يوضح رسم سلسلة درجات الحرارة في محاطه بابل Y_t بعد اخذ الفرق الاول لها عن طريق الشكل (3-3) نلاحظ استقرار السلسلة الزمنية حيث انعدام الاتجاه العام مع الزمن اذ ان المنحنى يوازي محور الفواصل يدل على غياب الاتجاه العام في السلسلة مع بقاء المركبة الموسمية اي ان السلسلة غير مستقرة وهذا ماتؤكدده لنا احصاءة Ljung-Box :

$$Q.stat = LBQ = 89.4217 > \chi^2_{(62,0.05)} = 88.38$$

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) بعد اخذ الفرق الأول وكما في الشكل (3-4) :



الشكل (3-4) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في محافظة بابل Y_t بعد اخذ الفرق الأول

نلاحظ من الشكل (3-4) أن اغلبية معاملات دالة الارتباط الذاتي ACF داخل حدود الثقة بمستوى 95% وكذلك معاملات الارتباط الذاتي الجزئي وهذا مؤشر على استقرار السلسلة وانها تخلصت من الاتجاه العام مع بقاء المركبة الموسمية.

والجدول (3-3) يوضح قيم دالة الارتباط الذاتي Auto Correlation Function ودالة الارتباط الذاتي الجزئي Partial Auto correlation function لسلسلة درجات الحرارة في محافظة بابل بعد اخذ الفرق الأول .

الجدول (3-3) يبين قيم دالتي ACF , PACF لدرجات الحرارة في مركز قضاء الحلة / محافظة بابل بعد اخذ الفرق الأول

Lag	ACF	PACF	Lag	ACF	PACF
1	0.577001	0.008395	34	0.106345	0.087557
2	0.065321	0.143883-	35	0.017706-	0.023427-
3	0.346059-	0.163368-	36	0.079714-	0.005794
4	0.246285-	0.110529-	37	0.045173-	0.019685
5	0.066351-	0.071939-	38	0.019951	0.048852-
6	0.034843	0.014943	39	0.030111	0.094184
7	0.003773	0.001064	40	0.041061-	0.073967-
8	0.088607-	0.119601-	41	0.062051-	0.028159-
9	0.050799-	0.047829-	42	0.014294-	0.009969
10	0.064528	0.022442-	43	0.085490	0.009613-
11	0.170927	0.129022	44	0.094162	0.020502
12	0.113891	0.027531	45	0.026714	0.043042-
13	0.029881-	0.042796-	46	0.059862-	0.053238-
14	0.103308-	0.037632	47	0.038286-	0.049728
15	0.059226-	0.067578-	48	0.043301	0.040605-
16	0.098292	0.065202	49	0.145966	0.066335

17	0.157535	0.075753	50	0.131137	0.022462
18	0.103499	0.060121	51	0.059118	0.019802
19	0.041560-	0.009002-	52	0.079944-	0.003163
20	0.076885-	0.000598	53	0.121916-	0.015220

21	0.033499-	0.015681	54	0.113368-	0.109380-
22	0.056417	0.077418	55	0.010250-	0.011596-
23	0.055765	0.061057-	56	0.062561	0.006275-
24	0.055030	0.064038	57	0.099045	0.023305
25	0.074316	0.019297	58	0.084462	0.048606
26	0.113007	0.088059	59	0.049936	0.023902
27	0.119765	0.166125	60	0.027718	0.039470-
28	0.019857	0.071228-	61	0.015985	0.009768-
29	0.056510-	0.032898	62	0.002878-	0.049254
30	0.103135-	0.000191-	63	0.027401-	0.006298
31	0.016031-	0.014978			
32	0.093209	0.031803			
33	0.158374	0.078221			

وللتأكد أكثر من استقرارية سلسلة درجات الحرارة في محافظة بابل بعد اخذ الفرق الأول نلجأ إلى اختبار ديكي- فولر ويبين الجدول (3-4) نتائج الاختبار.

جدول (3-4) يبين نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الاول

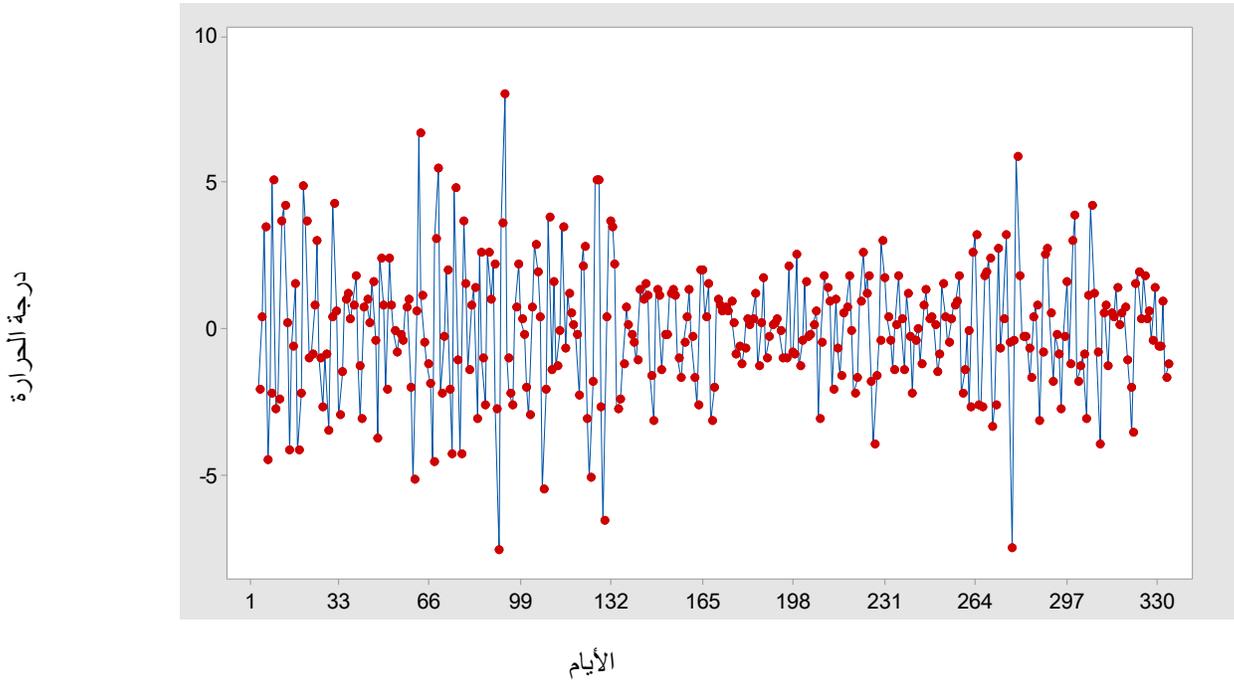
Test	Test Statistic	Table Statistic	P-value
Augmented Dickey – Fuller	-12.2505	-3.42384	0.000

تبين نتائج الاختبار في الجدول (3-4) إن القيمة المطلقة لاحصاء الاختبار هي اكبر من القيمة الجدولية الخاصة باختبار ديكي - فولر عند مستوى معنوية (0.05) . وهذا يدعونا الى رفض فرضية العدم وقبول الفرضية البديلة التي تشير إلى استقرارية السلسلة الزمنية اي ان السلسلة مستقرة بعد الفرق الأول.

3-3-1-2 إزالة المركبة الموسمية (Remove the seasonal vehicle)

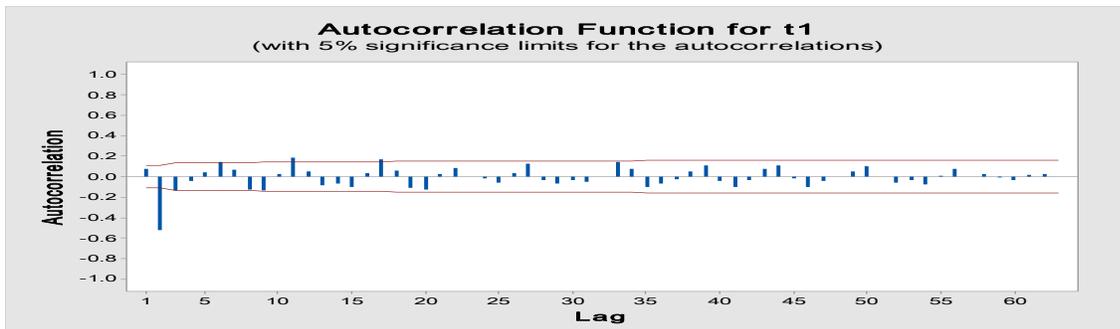
لغرض ازالة المركبة الموسمية ومن ملاحظة قيم الارتباطات الذاتية للسلسلة المعدلة (بعد اخذ الفرق الأول) تبين ان هذه القيم معنوية في فترات معينة وغير معنوية في فترات اخرى فهي تعيد نفسها كل

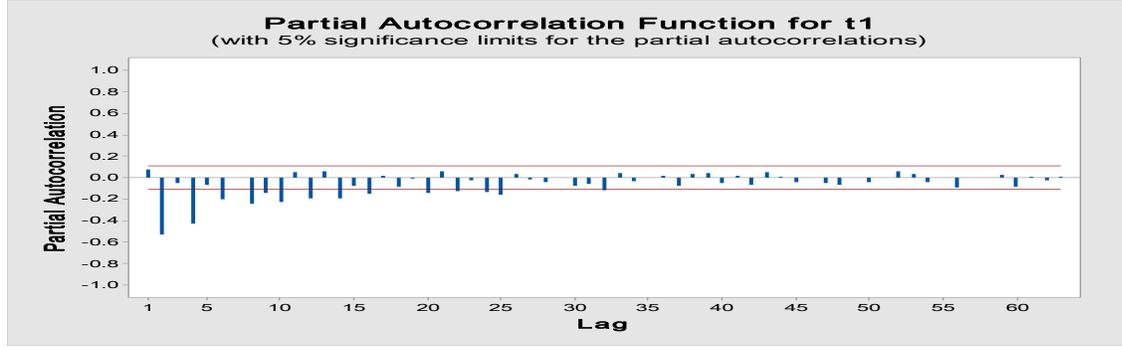
فترتين زمنتين مما يدل على وجود الموسمية فيها ، لذلك لغرض التخلص من الموسمية تم اخذ الفروق الموسمية من الدرجة الثانية لنحصل على السلسلة المعدلة والمخلصة من الاثر الموسمي والشكل (3-5) يبين السلسلة الزمنية المعدلة بعد اخذ لفروق الموسمية لها وانها معنوية فقط عند الازاحة الثانية يدل على استقرارية السلسلة الزمنية.



الشكل (3-5) يبين سلسلة درجات الحرارة اليومية في مركز قضاء الحلة / محافظة بابل Y_t بعد ازالة الموسمية

ولمزيد من الدقة نقوم برسم كل من دالة الارتباط الذاتي (Auto Correlation Function) ودالة الارتباط الذاتي الجزئي (Partial Auto correlation function) وكما في الشكل (3-6) :





الشكل (3-6) يبين رسم دالة الارتباط الذاتي ACF والارتباط الذاتي الجزئي PACF لدرجات الحرارة في مركز قضاء الحلة/ محافظة بابل Y_t بعد اخذ الفروق الموسمية

نلاحظ من الشكل رقم (3-6) بأن معاملات دالة الارتباط الذاتي ACF داخل حدود الثقة بمستوى 95% وكذلك الكثير معاملات الارتباط الذاتي الجزئي وهذا مؤشر على استقرار السلسلة الزمنية بعد الفرق الموسمي الأول.

والجدول (3-5) يوضح قيم دالة الارتباط الذاتي Auto Correlation Function ودالة الارتباط الذاتي الجزئي Partial Auto correlation function لسلسلة درجات الحرارة في محافظة بابل بعد اخذ الفروق الموسمية.

الجدول (3-5) يبين قيم دالتي PACF , ACF لدرجات الحرارة فيمركز قضاء الحلة / محافظة بابل بعد اخذ الفروق الموسمية

Lag	ACF	PACF	Lag	ACF	PACF
1	0.075349	0.075349	34	0.073895	0.033200-
2	0.524813-	0.533519-	35	0.103315-	0.003256-
3	0.139314-	0.054087-	36	0.070750-	0.019388
4	0.043059-	0.428113-	37	0.028734-	0.076238-
5	0.039863	0.067252-	38	0.051720	0.033887
6	0.145984	0.198857-	39	0.106047	0.045743
7	0.066183	0.006553-	40	0.040606-	0.054011-
8	0.123542-	0.246905-	41	0.105520-	0.020771

9	0.134392-	0.139521-	42	0.032489-	0.063660-
10	0.023528	0.230291-	43	0.072016	0.049341
11	0.189939	0.052512	44	0.111789	0.010690
12	0.052608	0.196898-	45	0.018056-	0.043316-
13	0.085162-	0.057201	46	0.100894-	0.006468-
14	0.067852-	0.192959-	47	0.042007-	0.051017-
15	0.100072-	0.079795-	48	0.001761-	0.067049-
16	0.035943	0.153029-	49	0.053112	0.000834-

17	0.167935	0.016816	50	0.103968	0.045863-
18	0.058811	0.080902-	51	0.002994	0.003241
19	0.106924-	0.009960-	52	0.060453-	0.062930
20	0.123102-	0.144515-	53	0.029632-	0.029884
21	0.028287	0.062625	54	0.077532-	0.043368-
22	0.086236	0.123416-	55	0.009665	0.006204-
23	0.008012-	0.023282-	56	0.072260	0.094918-
24	0.016391-	0.136204-	57	0.004646	0.004409-
25	0.055327-	0.159342-	58	0.022685	0.001168
26	0.030286	0.029761	59	0.008693-	0.029496
27	0.129976	0.016061-	60	0.033363-	0.086906-
28	0.032149-	0.044913-	61	0.013050	0.011836
29	0.071153-	0.001666-	62	0.025595	0.023627-
30	0.032531-	0.074579-	63	0.005412-	0.010505
31	0.054199-	0.060952-			

32	0.004306	0.122225-		
33	0.140161	0.042623		

وللتأكد أكثر من استقرارية سلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل نلجأ إلى اختبار ديكي- فولر الموسع ويبين الجدول (3-6) نتائج الاختبار.

جدول (3-6) يبين نتائج اختبار ديكي - فولر الموسع للسلسلة الزمنية بعد اخذ الفرق الموسمي

Test	Test Statistic	Table Statistic	P-value
Augmented Dickey – Fuller	-9.01859	-2.87044	0.000

تبين نتائج الاختبار في الجدول (3-6) إن القيمة المطلقة لاحصاء الاختبار هي اقل من القيمة الجدولية الخاصة باختبار ديكي - فولر الموسع عند مستوى معنوية (0.05) . وهذا يدعونا الى رفض فرضية العدم وقبول الفرضية البديلة التي تشير إلى استقرارية السلسلة الزمنية وتكون خالية من الاتجاه العام والمركبة الموسمية.

3-3-2 تشخيص وتحديد الانموذج الموسمي الملائم:

3-3-2-1 تحديد رتبة الانموذج

بعد تحقيق الاستقرارية في السلسلة الخاصة بدرجات الحرارة في محافظة بابل نقوم بتشخيص الانموذج الملائم لتمثيل السلسلة الزمنية عن طريق دراسة ومقارنة السلوك النظري لدالتي (ACF),(PACF) والجدول (3-7) يبين سلوك دالتي الارتباط الذاتي والارتباط الذاتي الجزئي في تحديد الأنموذج اذ نلاحظ ان الانموذج الملائم هو الانموذج المضاعف $ARIMA(p,q,d)(P,Q,D)_2$ اذ يتضح ان دالة الارتباط الذاتي ودالة الارتباط الذاتي الجزئي للعينة تتناقص تدريجاً مع زيادة فترات التخلف الزمني سالكة سلوك دالة الجيب، وبشكل أدق في تحديد رتبة الإنموذج تم توفيق عدد من النماذج المعنوية واختيار الانموذج

الأفضل بالاعتماد على احصاءة (Ljung-BoxChi-Square) والمعايير (AIC) و (BIC) و (SMAIC) ، والنماذج المقترحة هي كما موضحة في الجدول (6-7) الجدول (3-7) يبين النماذج الموسمية المضاعفة المقترحة ذات التقديرات المعنوية

No.	الانموذج	AIC	BIC	SMAIC	Ljung-Box Chi-Square	P-Value
1	ARIMA(1,1,0) (1,1,0) ₂	-36.76	-288.91	-130.77	165.7	0.000
2	ARIMA(1,2,0) (1,1,0) ₂	-33.45	-202.34	-37.77	195.5	0.000
3	ARIMA(2,1,0) (1,1,0) ₂	-35.81	-233.63	-35.54	184.6	0.000
4	ARIMA(2,2,0) (1,1,0) ₂	-35.81	-233.63	-35.54	184.6	0.000
5	ARIMA(1,1,0) (1,2,0) ₂	-146.81	-288.91	-130.77	378.78	0.000
6	ARIMA(1,1,0) (2,1,0) ₂	-43.41	-222.56	-56.76	212.6	0.000
7	ARIMA(1,1,0) (2,2,0) ₂	-120.61	-210.53	-45.45	128.9	0.000
8	ARIMA(2,1,0) (1,2,0) ₂	-47.41	-237.56	-66.76	234.3	0.000
9	ARIMA(1,1,0) (0,1,0) ₂	-31.48	-199.36	-31.74	192.7	0.000
10	ARIMA(1,1,0) (0,2,0) ₂	-47.41	-237.56	-66.76	234.0	0.000
11	ARIMA(0,1,0) (0,2,0) ₂	-137.45	-188.76	-128.39	85.2	0.000
12	ARIMA(1,0,0) (0,2,0) ₂	-43.77	-246.55	-61.42	239.0	0.000

إذا يتضح من جدول (3-7) ان افضل انموذج موسمي مضاعف من الدرجة ARIMA(1,1,0) (1,2,0)₂ لان امتلك اقل قيم لمعايير المقارنة (AIC, BIX, SMAIC) واعتمادا على ذلك سيتم تقدير معلمات هذا الانموذج واختيار افضل طريقة بالتقدير .

2-2-3-3 تقدير معلمات الانموذج واختبار معنويتها وملائمة الانموذج :

بعد تحديد الانموذج الموسمي ورتبته تأتي الخطوة اللاحقة من مراحل بناء انموذج السلاسل الزمنية وهي تقدير معلمات الانموذج واختبار معنويتها وباستعمال برنامج (Gretl 1.9.11) و برنامج (MiniTab Ver 17) و (E-Views 10) و (NCSS 2007) تم تطبيق ثلاث طرائق لتقدير معالم الانموذج المقترح وكما يأتي:

1- باستخدام طريقة الامكان الاعظم التقريبية (AMLE)

بتطبيق طريقة الامكان الاعظم التقريبية على بيانات السلسلة الزمنية قيد الدراسة تم الحصول على تقدير الانموذج الموسمي المضاعف $ARIMA(1,1,0) \times (1,2,0)_2$ كما يأتي:

جدول (3-8) نتائج تقدير الانموذج المقترح بموجب طريقة الامكان الاعظم التقريبية AMLE

Type	Coef.	SE Coef.	T	P-Value
AR 1	-0.1507	0.0560	-2.69	0.008
SAR 2	-0.7656	0.0366	-20.92	0.000
Differencing: 1 regular, 2 seasonal of order 2				
MSE = 11.65				

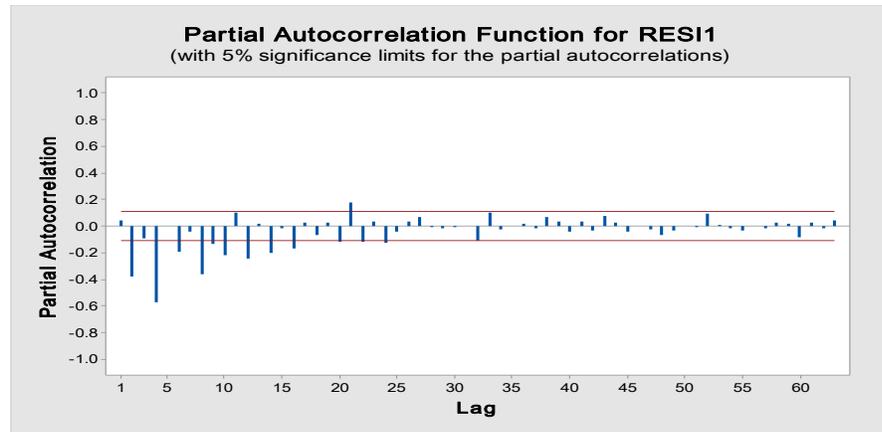
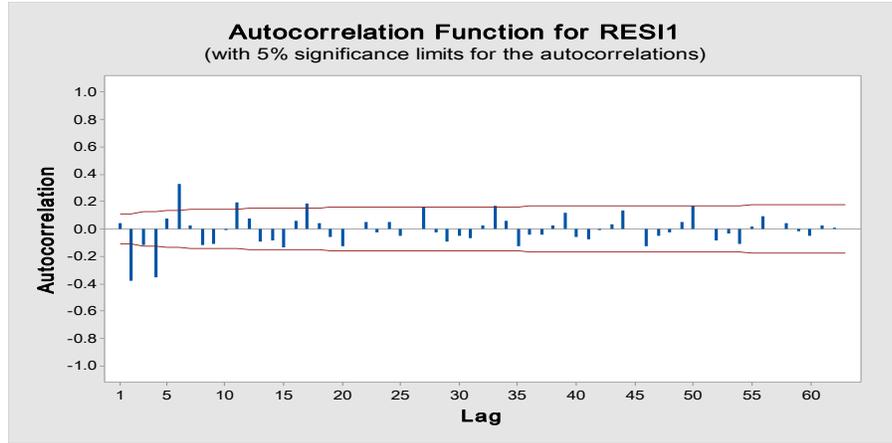
اذ نلاحظ من جدول (3-8) ان الانموذج معنوي من الناحية الاحصائية لان قيمة P-Value اقل من مستوى المعنوية (0.05)

1-1 فحص ملائمة الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE:

بعد تشخيص الانموذج وتحديد درجته وتقديره لابد من التأكد من صحة ملائمة الانموذج وكفاءته وتم ذلك عن طريق ما يأتي:

أ- إختبار معاملات الارتباط الذاتي المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE:

تم استخراج معاملات الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي (الخطأ العشوائية) الانموذج المقدر كما في جدول (3-9) وتم رسمها كما في شكل (3-7) اذ تبين ان اغلبية قيم معاملات الارتباط الذاتي والارتباط الذاتي الجزئي ضمن ضمن حدود الثقة يعني بان سلسلة البواقي عشوائية وان الانموذج المستعمل جيد وملائم.



شكل (3-7) دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف

الجدول (3-9) يبين قيم دالتي ACF , PACF لدرجات الحرارة في مركز قضاء الحلة /محافظة بابل

الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE

Lag	ACF	PACF	Lag	ACF	PACF
1	0.045411	0.045411	34	0.061980	0.027797-
2	0.381557-	0.384412-	35	0.122841-	0.005255
3	0.118943-	0.091125-	36	0.041237-	0.020706
4	0.351264-	0.578965-	37	0.041468-	0.017865-
5	0.079292	0.005190-	38	0.028954	0.070570

6	0.329556	0.193354-	39	0.119745	0.031211
7	0.022530	0.041242-	40	0.062119-	0.038558-
8	0.120070-	0.367215-	41	0.077067-	0.037048
9	0.108245-	0.137917-	42	0.009622-	0.035811-
10	0.011314-	0.217678-	43	0.031612	0.076744
11	0.191052	0.100249	44	0.132013	0.024261
12	0.072197	0.249081-	45	0.001410	0.042101-
13	0.092686-	0.018808	46	0.127693-	0.002157
14	0.080358-	0.203306-	47	0.050259-	0.026716-
15	0.131557-	0.014497-	48	0.024778-	0.067812-
16	0.061416	0.167497-	49	0.051612	0.036351-

17	0.182249	0.027769	50	0.165741	0.005258
18	0.042716	0.068400-	51	0.005364	0.009511-
19	0.061434-	0.024894	52	0.084384-	0.090831
20	0.127360-	0.119222-	53	0.029981-	0.009213
21	0.000265-	0.179567	54	0.113705-	0.020044-
22	0.052159	0.121832-	55	0.020583	0.032477-
23	0.024114-	0.032789	56	0.096054	0.000204-
24	0.048983	0.127478-	57	0.007428-	0.017144-
25	0.054454-	0.044619-	58	0.043880	0.027973
26	0.003127-	0.031053	59	0.013499-	0.017586
27	0.161274	0.067936	60	0.052187-	0.081685-
28	0.027512-	0.011671-	61	0.029407	0.021952

29	0.095625-	0.017744-	62	0.011419	0.012909-
30	0.052377-	0.008907-	63	0.007672-	0.043953
31	0.063832-	0.006556-			
32	0.027960	0.110732-			
33	0.170023	0.101130			

ب- إختبار Portmanteau للاخطاء العشوائية المقدرة بموجب طريقة الامكان الاعظم التقريبية :AMLE

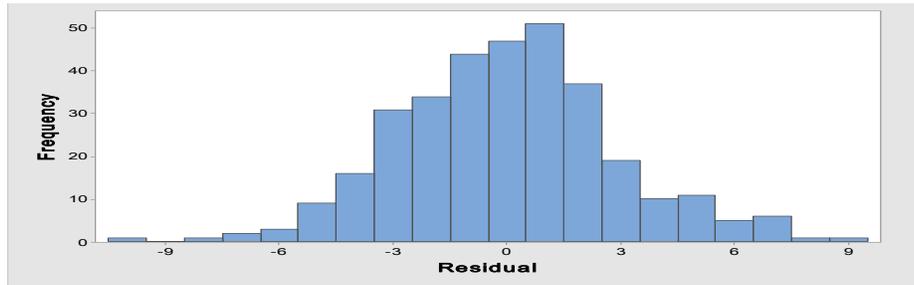
بما ان الاخطاء تعد (White Noise) اي ان $a_t \sim NID(0, \sigma_a^2)$ وان معاملات الارتباط للبواقي $r_k(\hat{a})$ تتوزع طبيعياً بوسط حسابي يساوي صفر وتباين مقداره $(1/N)$ فقد تم تطبيق احصاءة (Ljung-Box) لفحص ملائمة الانموذج وظهر بان:

$$Q.stat = LBQ = 428.875 > \chi^2_{(61,0.05)} = 88.38$$

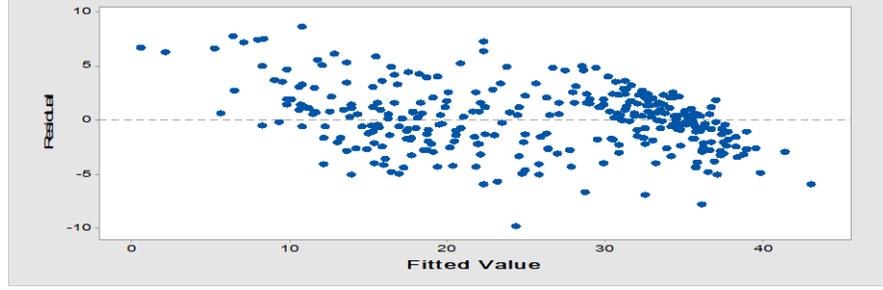
ومن ذلك نستنتج أن سلسلة البواقي غير معنوية (عشوائية) ومن ثم فان توفيق الانموذج جيد وملائماً وكفوءاً

ب- اختبارالتوزيع الطبيعي للبواقي المقدرة بموجب طريقة الامكان الاعظم التقريبية AMLE :

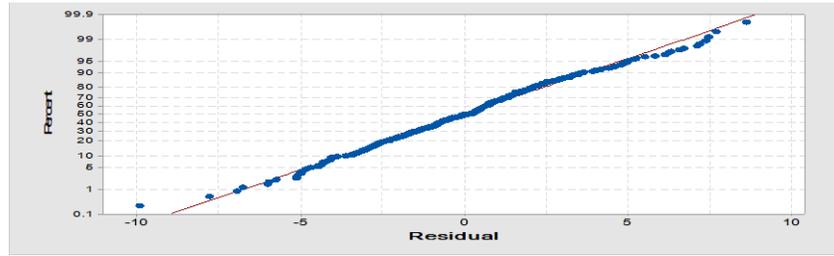
يوضح الشكل (3-8) اختبار التناظر والتسطح الطبيعي لسلسلة البواقي الانموذج المقدر وهو يدل على ان سلسلة البواقي تحمل خصائص التوزيع الطبيعي يؤكد على دقة وكفاءة وملائمة الانموذج المقدر .



(a)



(b)



(c)

شكل (3-8) (a) المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE

ج- القيم التقديرية للإنموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE:

نلاحظ من الجدول (3-10) والشكل (3-9) ان القيم التقديرية لسلسلة درجات الحرارة اليومية في محافظة بابل متناسقة مع القيم الاصلية للسلسلة وهذا يدل على دقة وكفاءة جيدة الانموذج المقدر.

جدول (3-10) القيم التقديرية والبواقي لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل الانموذج المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE .

NO	Residuals	Fits	NO	Residuals	Fits
1	*	*	168	0.5736	34.23
2	*	*	169	-5.7638	39.76
3	*	*	170	-4.1971	37.30
4	*	*	171	2.236	30.86

5	*	*	172	-0.0437	32.84
6	*	*	173	3.0535	30.45
7	-0.9048	11.50	174	1.7949	32.01
8	-3.1332	13.53	175	1.1301	34.27
9	-0.3623	12.06	176	0.6645	35.24
10	3.5521	5.15	177	0.2854	36.31
11	-6.2339	13.83	178	-1.7198	38.22
12	0.1204	8.18	179	-1.3752	37.38
13	9.3246	2.08	180	-2.1793	37.38
14	1.7896	10.51	181	-0.6612	35.66
15	-0.4395	11.64	182	0.6731	33.63
16	-3.7869	15.29	183	0.6846	33.72
17	-2.2792	14.18	184	1.4185	33.48
18	-3.4507	11.45	185	0.32	33.38
19	-5.9439	12.14	186	-1.0871	35.49
20	1.5835	5.62	187	0.4193	34.48
21	8.5832	0.52	188	1.6622	32.94
22	2.6599	6.44	189	-1.8892	36.69
23	0.7863	9.31	190	0.0194	34.58
24	0.1216	10.78	191	0.6985	34.30
25	1.9347	12.97	192	-0.7697	35.87
26	0.8735	13.83	193	1.3316	34.07
27	0.6082	15.39	194	-0.9727	35.47
28	-4.1253	19.03	195	-1.8696	35.67
29	-2.9465	15.65	196	0.2342	34.77
30	-5.1807	17.18	197	0.8585	32.64
31	3.9967	10.10	198	-0.3569	34.16

32	7.0092	6.99	199	0.1177	34.68
33	-0.6653	13.77	200	2.541	31.26
34	-3.8111	15.31	201	-2.1979	36.60
35	-1.6258	13.23	202	0.1814	34.82
36	-1.0504	12.25	203	3.0133	32.29
37	1.7984	9.80	204	-1.7391	37.44
38	2.224	9.78	205	0.7491	35.35
39	3.3779	10.82	206	1.4517	35.65
40	-0.0282	13.33	207	-3.1555	37.56
41	-3.3851	15.79	208	-2.3859	37.29
42	-3.8254	16.03	209	-1.1281	35.13
43	1.1454	11.15	210	4.7278	31.17
44	0.7585	11.54	211	0.8485	35.05
45	2.4419	11.56	212	2.0404	33.66
46	2.8437	10.76	213	-1.5026	38.20
47	-3.4169	14.92	214	-1.1444	36.94
48	-2.8912	16.39	215	-1.48	36.68
49	1.674	10.53	216	-2.8248	37.62
50	0.6175	11.48	217	2.5269	32.37
51	-1.6427	14.84	218	1.7184	34.58
52	5.6758	8.22	219	2.0377	34.26
53	0.3576	14.54	220	-0.3042	35.80
54	-1.5182	16.32	221	-4.9155	38.72
55	1.3024	14.30	222	-1.6741	35.57
56	-2.3083	17.41	223	1.5735	33.23
57	1.0351	15.56	224	4.4826	31.62
58	1.4107	15.69	225	4.7006	34.10

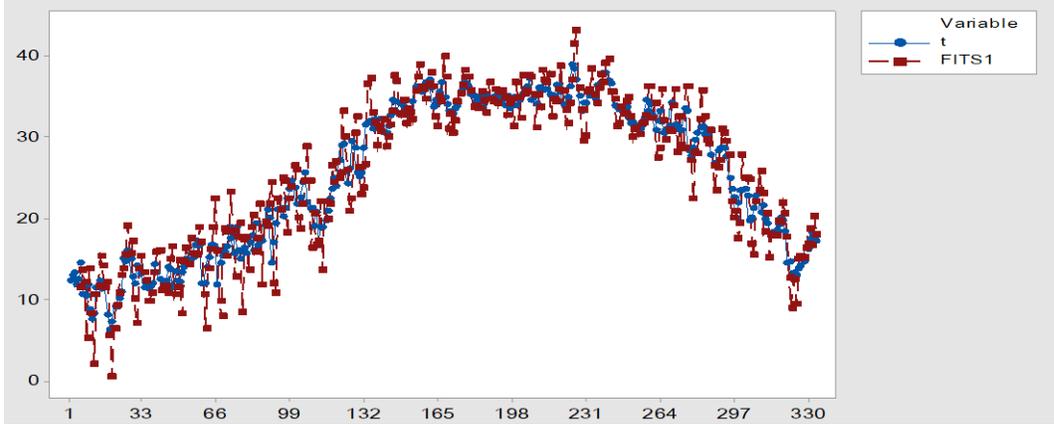
59	1.0722	15.53	226	1.301	37.00
60	-6.9896	18.89	227	-4.337	41.34
61	-4.923	16.92	228	-8.1123	43.01
62	3.4015	10.60	229	-2.776	35.98
63	8.8672	6.33	230	0.8331	33.27
64	2.8466	13.85	231	4.7658	29.33
65	0.4937	16.21	232	5.262	30.14
66	-2.4515	18.75	233	-0.4437	35.44
67	-10.5836	22.28	234	-0.8507	35.75
68	-1.5227	15.92	235	-3.7563	38.36
69	5.5323	9.77	236	1.2039	35.10
70	7.8624	7.94	237	2.1018	34.20
71	-2.2581	18.66	238	0.6053	35.99
72	3.6732	15.23	239	0.0771	37.72
73	-0.9489	18.35	240	1.1563	36.64
74	-7.5499	23.15	241	-2.1559	38.96
75	0.4583	18.44	242	-3.0789	39.48
76	3.1994	12.80	243	-0.043	35.44
77	-2.6625	17.66	244	-1.7437	35.54
78	-3.5738	19.37	245	-1.058	34.66
79	7.9542	8.35	246	2.07	31.23
80	-1.6756	17.38	247	1.8055	31.59
81	-0.5605	17.56	248	-0.0906	33.59
82	4.1929	13.61	249	0.9669	32.73
83	-2.7711	18.77	250	-2.0218	34.32
84	-0.8973	20.30	251	-3.1393	34.74
85	0.7729	15.83	252	-0.7457	32.45

86	-0.0575	17.46	253	1.5615	29.84
87	-4.5396	21.74	254	0.0338	30.97
88	7.3088	11.69	255	-0.0677	31.07
89	1.5521	19.45	256	1.1687	30.23
90	0.9912	19.01	257	0.7763	31.52
91	-7.2246	21.62	258	2.738	31.76
92	-7.3064	24.31	259	0.5079	32.69
93	7.4182	11.98	260	-2.1131	36.11
94	10.2101	10.79	261	-3.6213	36.22
95	-1.1635	22.36	262	-1.5796	32.28
96	-0.7402	20.94	263	-2.2405	34.14
97	-3.7979	24.90	264	5.7984	27.40
98	-2.1769	24.48	265	3.1609	28.64
99	5.3813	18.12	266	-5.3734	35.77
100	2.1095	22.39	267	-1.1677	31.97
101	-0.1692	23.87	268	1.6516	29.65
102	-4.6592	26.36	269	3.3527	30.75
103	-4.2079	25.81	270	0.5645	30.64
104	2.5698	19.93	271	-2.4328	33.83
105	5.6964	18.60	272	-4.5427	35.74
106	3.8416	21.76	273	2.5881	28.11
107	-2.6027	24.50	274	-1.6336	32.43
108	-7.5632	28.66	275	4.5413	28.96
109	-3.3117	24.51	276	4.5776	28.52
110	2.6359	16.36	277	-7.7964	36.10
111	0.2302	20.47	278	-8.6179	36.12
112	0.6251	16.57	279	1.5959	27.00

113	1.7074	17.09	280	7.3022	22.30
114	-3.2343	22.03	281	2.3494	28.05
115	6.1315	13.57	282	3.1924	27.91
116	-1.094	21.99	283	-0.8457	32.05
117	2.5067	19.79	284	-5.469	35.67
118	1.9957	21.60	285	-1.7806	32.48
119	-1.5277	26.33	286	0.9553	29.54
120	-0.5949	24.39	287	-1.2303	29.03
121	0.1541	26.95	288	-4.0442	30.84
122	3.9931	24.91	289	0.1999	26.40
123	3.4868	25.61	290	4.9875	23.31
124	-7.3644	33.16	291	2.3533	26.25
125	-5.6714	29.87	292	1.4294	27.07
126	0.1427	25.86	293	-2.2688	30.87
127	8.6726	20.83	294	-2.7872	30.39
128	6.3038	22.30	295	-4.5718	29.47
129	-4.9773	30.48	296	-4.1251	27.73
130	-7.4765	32.48	297	0.4542	22.05
131	-0.6959	26.30	298	0.0257	19.97
132	5.7267	22.87	299	1.0956	20.80
133	7.6864	23.71	300	5.7975	17.50
134	4.9878	26.61	301	4.101	19.30
135	-4.4464	36.45	302	-4.2807	27.78
136	-6.1157	37.12	303	-2.1483	24.85
137	-0.8648	32.96	304	-5.1002	24.80
138	-0.5728	31.77	305	-4.7084	24.71
139	3.2665	28.83	306	4.4076	16.79

140	-0.5004	31.20	307	7.2994	15.40
141	-0.0654	30.57	308	1.1365	21.96
142	-1.6314	32.03	309	-2.7874	23.39
143	2.3722	28.83	310	-4.2184	25.72
144	2.7387	29.86	311	-3.1501	22.95
145	3.131	31.37	312	1.161	18.24
146	1.1425	33.16	313	-2.2832	20.48
147	-4.4384	37.44	314	3.0144	15.19
148	-2.7918	36.89	315	0.3643	18.04
149	1.1158	32.78	316	0.7431	17.76
150	1.0327	32.57	317	1.456	17.74
151	-1.3259	34.53	318	0.4059	19.59
152	1.1609	31.54	319	0.0345	19.57
153	0.0162	33.48	320	-3.4465	21.85
154	1.4015	32.90	321	-6.0457	20.45
155	4.1413	32.06	322	-3.0042	17.70
156	0.3716	35.63	323	0.0068	12.59
157	-1.1932	37.39	324	4.2357	8.96
158	-3.4171	38.92	325	0.399	12.50
159	-0.1066	36.21	326	4.3443	9.46
160	0.9491	35.75	327	-0.9116	15.01
161	2.4083	34.59	328	-0.6741	15.27
162	-0.6415	36.54	329	1.1461	15.15
163	-4.1776	37.78	330	-0.0206	16.22
164	-1.6606	36.16	331	0.4332	16.87
165	1.7143	32.49	332	-0.5882	18.69
166	4.1693	31.33	333	0.9354	16.56

167	1.7207	34.98	334	0.5736	20.09
-----	--------	-------	-----	--------	-------



شكل (9-3) القيم التقديرية والحقيقية لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل المقدر بموجب طريقة الامكان الاعظم التقريبية AMLE

2- التقدير باستعمال طريقة الامكان الاعظم المضبوطة EMLE:

بتطبيق طريقة الامكان الاعظم المضبوطة على بيانات السلسلة الزمنية قيد الدراسة تم الحصول على تقدير الانموذج الموسمي المضاعف كما يأتي:

جدول (11-3) نتائج تقدير الانموذج المقترح بموجب طريقة الامكان الاعظم المضبوطة EMLE

Type	Coef.	SE Coef.	T	P-Value
AR 1	0.1141832	5.552756E-02	2.0563	0.039750
SAR 1	-0.6672221	0.041214	-16.1892	0.000000
MSE = 13.68				

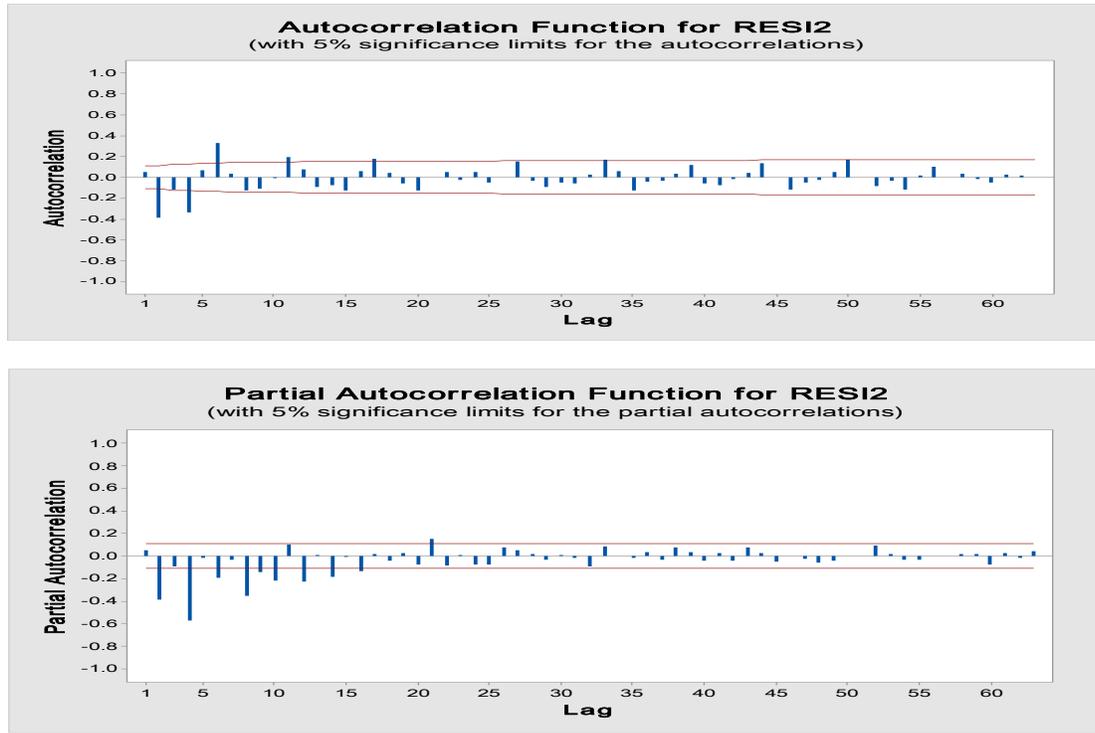
اذ نلاحظ من جدول (11-3) ان الانموذج معنوي من الناحية الاحصائية لان قيمة P-Value اقل من مستوى المعنوية (0.05)

1-1 فحص ملائمة الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة EMLE :

بعد تشخيص الانموذج وتحديد درجته وتقديره لابد من التأكد من صحة ملائمة الانموذج وكفاءته وتم ذلك عن طريق ما يأتي:

أ- إختبار معاملات الارتباط الذاتي المقدر بموجب طريقة الامكان الاعظم المضبوطة **EMLE** :

تم استخراج معاملات الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي (الاحطاء العشوائية) للإنموذج المقدر كما في جدول (3-12) وتم رسمها كما في شكل (3-10) اذ تبين ان اغلبية قيم معاملات الارتباط الذاتي والارتباط الذاتي الجزئي ضمن ضمن حدود الثقة يعني ان سلسلة البواقي عشوائية وان الانموذج المستعمل جيد وملئم.



شكل (3-10) دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف

بموجب طريقة الامكان الاعظم المضبوطة **EMLE**

الجدول (3-12) يبين قيم دالتي **ACF** , **PACF** لدرجات الحرارة في مركز قضاء الحلة /محافظة

بابل الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة **EMLE**

Lag	ACF	PACF	Lag	ACF	PACF
1	0.047136	0.047136	33	0.167241	0.082322
2	0.386982-	0.390070-	34	0.061047	0.000377-

3	0.119224-	0.089227-	35	0.124071-	0.016924-
4	0.339077-	0.571831-	36	0.041586-	0.035145
5	0.070725	0.015832-	37	0.035773-	0.033363-
6	0.325648	0.190894-	38	0.029832	0.075821
7	0.033098	0.036613-	39	0.116094	0.031964
8	0.122947-	0.354845-	40	0.060896-	0.039339-
9	0.113322-	0.145729-	41	0.079770-	0.025958
10	0.012624-	0.216404-	42	0.013674-	0.039397-
11	0.193157	0.104973	43	0.039812	0.074993
12	0.076860	0.230645-	44	0.132955	0.028132
13	0.096081-	0.008648	45	0.005587-	0.054594-
14	0.079644-	0.184299-	46	0.121947-	0.006947
15	0.124558-	0.009281-	47	0.051235-	0.028458-
16	0.056469	0.132441-	48	0.028938-	0.063382-
17	0.174696	0.015432	49	0.054508	0.040261-
18	0.044127	0.040527-	50	0.165301	0.007397
19	0.058726-	0.026459	51	0.005121	0.006735-
20	0.123298-	0.078499-	52	0.082217-	0.091893
21	0.000848-	0.155170	53	0.029759-	0.018810
22	0.048283	0.081331-	54	0.117338-	0.030406-
23	0.022257-	0.010417	55	0.017511	0.030372-
24	0.047220	0.076141-	56	0.102433	0.003849
25	0.050812-	0.075715-	57	0.000083-	0.004338-
26	0.002239	0.074559	58	0.035459	0.016940
27	0.152321	0.047981	59	0.019132-	0.019635

28	0.033693-	0.016411	60	0.050525-	0.078315-
29	0.091163-	0.030225-	61	0.028978	0.024584
30	0.047698-	0.009862	62	0.014018	0.017315-
31	0.062008-	0.015961-	63	0.001356	0.046431
32	0.027062	0.096365-			

ب- إختبار Portmanteau للاخطاء العشوائية المقدرة بموجب طريقة الامكان الاعظم المضبوطة EMLE:

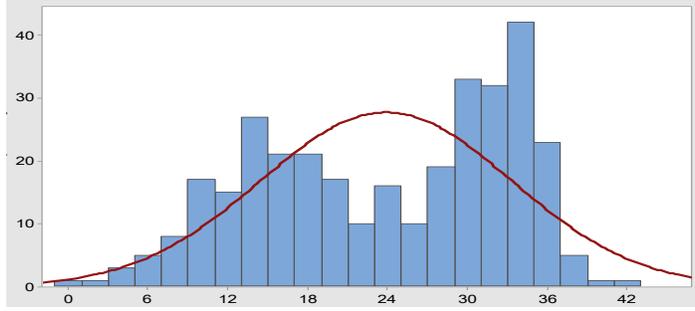
بما ان الاخطاء تعد (White Noise) اي ان $a_t \sim NID(0, \sigma_a^2)$ وان معاملات الارتباط للبواقي $r_k(\hat{a})$ تتوزع طبيعياً بوسط حسابي يساوي صفراً وتباين مقداره $(1/N)$ فقد تم تطبيق احصاءة (Ljung-Box) لفحص ملائمة الانموذج وظهر بان:

$$Q.stat = LBQ = 557.587 > \chi^2_{(61, 0.05)} = 88.38$$

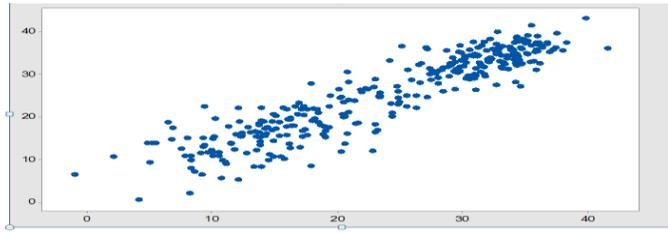
ومن ذلك نستنتج أن سلسلة البواقي غير معنوية (عشوائية) ومن ثم فان توفيق الانموذج جيد وملائماً وكفوء

ب- اختبار التوزيع الطبيعي للبواقي المقدرة بموجب طريقة الامكان الاعظم المضبوطة EMLE:

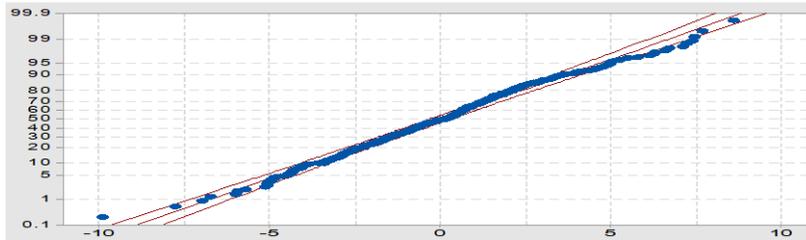
يوضح الشكل (3-11) اختبار التناظر والتسطح الطبيعي لسلسلة البواقي الانموذج المقدر وهو يدل على ان سلسلة البواقي تحمل خصائص التوزيع الطبيعي يؤكد على دقة وكفاءة وملائمة الانموذج المقدر .



(a)



(b)



(c)

شكل (3-11) (a) المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة EMLE

ج- القيم التقديرية الانموذج المقدر بموجب طريقة الامكان الاعظم المضبوطة EMLE

نلاحظ من الجدول (3-13) والشكل (3-12) ان القيم التقديرية لسلسلة درجات الحرارة اليومية في مركز قضاء الحلة / محافظة بابل متناسقة مع القيم الاصلية للسلسلة وهذا يدل على دقة وكفاءة جيدة الانموذج المقدر

جدول (13-3) القيم التقديرية بموجب طريقة الامكان الاعظم المضبوطة والبواقي لسلسلة درجات الحرارة في مركز قضاء الحلة/ محافظة بابل

NO	Residuals	Fits	NO	Residuals	Fits
1	*	*	168	2.07	32.73
2	*	*	169	-4.26	38.26
3	*	*	170	-2.70	35.80
4	*	*	171	3.74	29.36
5	*	*	172	1.46	31.34
6	*	*	173	4.55	28.95
7	-0.90	11.50	174	3.29	30.51
8	-3.13	13.53	175	2.63	32.77
9	-0.36	12.06	176	2.16	33.74
10	3.55	5.15	177	1.79	34.81
11	-6.23	13.83	178	-0.22	36.72
12	0.12	8.18	179	0.12	35.88
13	9.32	2.08	180	-0.68	35.88
14	1.79	10.51	181	0.84	34.16
15	1.06	10.14	182	2.17	32.13
16	-2.29	13.79	183	2.18	32.22
17	-0.78	12.68	184	2.92	31.98
18	-1.95	9.95	185	1.82	31.88
19	-4.44	10.64	186	0.41	33.99
20	3.08	4.12	187	1.92	32.98
21	10.08	-0.98	188	3.16	31.44
22	4.16	4.94	189	-0.39	35.19
23	2.29	7.81	190	1.52	33.08

24	1.62	9.28	191	2.20	32.80
25	3.43	11.47	192	0.73	34.37
26	2.37	12.33	193	2.83	32.57
27	2.11	13.89	194	0.53	33.97
28	-2.63	17.53	195	-0.37	34.17
29	-1.45	14.15	196	1.73	33.27
30	-3.68	15.68	197	2.36	31.14
31	5.50	8.60	198	1.14	32.66
32	8.51	5.49	199	1.62	33.18
33	0.83	12.27	200	4.04	29.76
34	-2.31	13.81	201	-0.70	35.10
35	-0.13	11.73	202	1.68	33.32
36	0.45	10.75	203	4.51	30.79
37	3.30	8.30	204	-0.24	35.94
38	3.72	8.28	205	2.25	33.85
39	4.88	9.32	206	2.95	34.15
40	1.47	11.83	207	-1.66	36.06
41	-1.89	14.29	208	-0.89	35.79
42	-2.33	14.53	209	0.37	33.63
43	2.65	9.65	210	6.23	29.67
44	2.26	10.04	211	2.35	33.55
45	3.94	10.06	212	3.54	32.16
46	4.34	9.26	213	0.00	36.70
47	-1.92	13.42	214	0.36	35.44
48	-1.39	14.89	215	0.02	35.18
49	3.17	9.03	216	-1.32	36.12
50	2.12	9.98	217	4.03	30.87

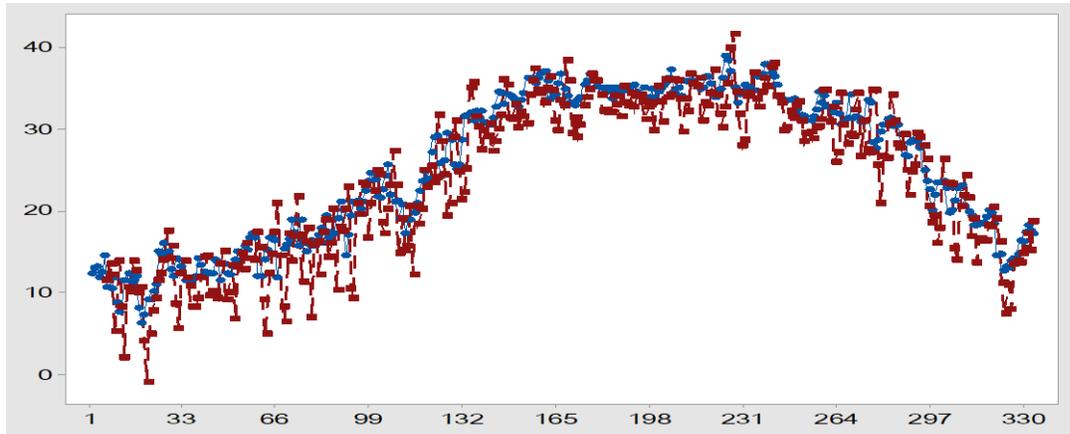
51	-0.14	13.34	218	3.22	33.08
52	7.18	6.72	219	3.54	32.76
53	1.86	13.04	220	1.20	34.30
54	-0.02	14.82	221	-3.42	37.22
55	2.80	12.80	222	-0.17	34.07
56	-0.81	15.91	223	3.07	31.73
57	2.54	14.06	224	5.98	30.12
58	2.91	14.19	225	6.20	32.60
59	2.57	14.03	226	2.80	35.50
60	-5.49	17.39	227	-2.84	39.84
61	-3.42	15.42	228	-6.61	41.51
62	4.90	9.10	229	-1.28	34.48
63	10.37	4.83	230	2.33	31.77
64	4.35	12.35	231	6.27	27.83
65	1.99	14.71	232	6.76	28.64
66	-0.95	17.25	233	1.06	33.94
67	-9.08	20.78	234	0.65	34.25
68	-0.02	14.42	235	-2.26	36.86
69	7.03	8.27	236	2.70	33.60
70	9.36	6.44	237	3.60	32.70
71	-0.76	17.16	238	2.11	34.49
72	5.17	13.73	239	1.58	36.22
73	0.55	16.85	240	2.66	35.14
74	-6.05	21.65	241	-0.66	37.46
75	1.96	16.94	242	-1.58	37.98
76	4.70	11.30	243	1.46	33.94
77	-1.16	16.16	244	-0.24	34.04

78	-2.07	17.87	245	0.44	33.16
79	9.45	6.85	246	3.57	29.73
80	-0.18	15.88	247	3.31	30.09
81	0.94	16.06	248	1.41	32.09
82	5.69	12.11	249	2.47	31.23
83	-1.27	17.27	250	-0.52	32.82
84	0.60	18.80	251	-1.64	33.24
85	2.27	14.33	252	0.75	30.95
86	1.44	15.96	253	3.06	28.34
87	-3.04	20.24	254	1.53	29.47
88	8.81	10.19	255	1.43	29.57
89	3.05	17.95	256	2.67	28.73
90	2.49	17.51	257	2.28	30.02
91	-5.72	20.12	258	4.24	30.26
92	-5.81	22.81	259	2.01	31.19
93	8.92	10.48	260	-0.61	34.61
94	11.71	9.29	261	-2.12	34.72
95	0.34	20.86	262	-0.08	30.78
96	0.76	19.44	263	-0.74	32.64
97	-2.30	23.40	264	7.30	25.90
98	-0.68	22.98	265	4.66	27.14
99	6.88	16.62	266	-3.87	34.27
100	3.61	20.89	267	0.33	30.47
101	1.33	22.37	268	3.15	28.15
102	-3.16	24.86	269	4.85	29.25
103	-2.71	24.31	270	2.06	29.14
104	4.07	18.43	271	-0.93	32.33

105	7.20	17.10	272	-3.04	34.24
106	5.34	20.26	273	4.09	26.61
107	-1.10	23.00	274	-0.13	30.93
108	-6.06	27.16	275	6.04	27.46
109	-1.81	23.01	276	6.08	27.02
110	4.14	14.86	277	-6.30	34.60
111	1.73	18.97	278	-7.12	34.62
112	2.13	15.07	279	3.10	25.50
113	3.21	15.59	280	8.80	20.80
114	-1.73	20.53	281	3.85	26.55
115	7.63	12.07	282	4.69	26.41
116	0.41	20.49	283	0.65	30.55
117	4.01	18.29	284	-3.97	34.17
118	3.50	20.10	285	-0.28	30.98
119	-0.03	24.83	286	2.46	28.04
120	0.91	22.89	287	0.27	27.53
121	1.65	25.45	288	-2.54	29.34
122	5.49	23.41	289	1.70	24.90
123	4.99	24.11	290	6.49	21.81
124	-5.86	31.66	291	3.85	24.75
125	-4.17	28.37	292	2.93	25.57
126	1.64	24.36	293	-0.77	29.37
127	10.17	19.33	294	-1.29	28.89
128	7.80	20.80	295	-3.07	27.97
129	-3.48	28.98	296	-2.63	26.23
130	-5.98	30.98	297	1.95	20.55
131	0.80	24.80	298	1.53	18.47

132	7.23	21.37	299	2.60	19.30
133	9.19	22.21	300	7.30	16.00
134	6.49	25.11	301	5.60	17.80
135	-2.95	34.95	302	-2.78	26.28
136	-4.62	35.62	303	-0.65	23.35
137	0.64	31.46	304	-3.60	23.30
138	0.93	30.27	305	-3.21	23.21
139	4.77	27.33	306	5.91	15.29
140	1.00	29.70	307	8.80	13.90
141	1.43	29.07	308	2.64	20.46
142	-0.13	30.53	309	-1.29	21.89
143	3.87	27.33	310	-2.72	24.22
144	4.24	28.36	311	-1.65	21.45
145	4.63	29.87	312	2.66	16.74
146	2.64	31.66	313	-0.78	18.98
147	-2.94	35.94	314	4.51	13.69
148	-1.29	35.39	315	1.86	16.54
149	2.62	31.28	316	2.24	16.26
150	2.53	31.07	317	2.96	16.24
151	0.17	33.03	318	1.91	18.09
152	2.66	30.04	319	1.53	18.07
153	1.52	31.98	320	-1.95	20.35
154	2.90	31.40	321	-4.55	18.95
155	5.64	30.56	322	-1.50	16.20
156	1.87	34.13	323	1.51	11.09
157	0.31	35.89	324	5.74	7.46
158	-1.92	37.42	325	1.90	11.00

159	1.39	34.71	326	5.84	7.96
160	2.45	34.25	327	0.59	13.51
161	3.91	33.09	328	0.83	13.77
162	0.86	35.04	329	2.65	13.65
163	-2.68	36.28	330	1.48	14.72
164	-0.16	34.66	331	1.93	15.37
165	3.21	30.99	332	0.91	17.19
166	5.67	29.83	333	2.44	15.06
167	3.22	33.48	334	-1.49	18.59



شكل (3-12) القيم التقديرية بموجب طريقة الامكان الاعظم التقريبية والحقيقية لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل بموجب طريقة الامكان الاعظم المضبوطة **EMLE**

3- باستعمال طريقة المربعات الصغرى اللاخطية **NNOLS**

بتطبيق طريقة المربعات الصغرى اللاخطية على بيانات السلسلة الزمنية قيد الدراسة تم الحصول على تقدير معالم الانموذج الموسمي المضاعف $ARIMA(1,1,0)X(1,2,0)_2$ كما في جدول (3-14):

جدول (3-14) نتائج تقدير الانموذج المقترح بموجب طريقة المربعات الصغرى اللاخطية **NNOLS**

Type	Coef.	SE Coef.	T	P-Value
AR 1	-0.34905	0.047668	-7.32246	0.007

SAR 2	-0.60388	0.044918	-13.4441	0.009
Differencing: 1 regular, 2 seasonal of order 2				
MSE = 14.06				

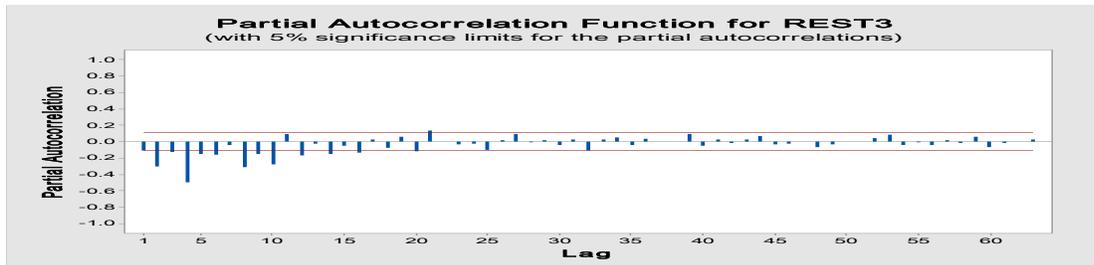
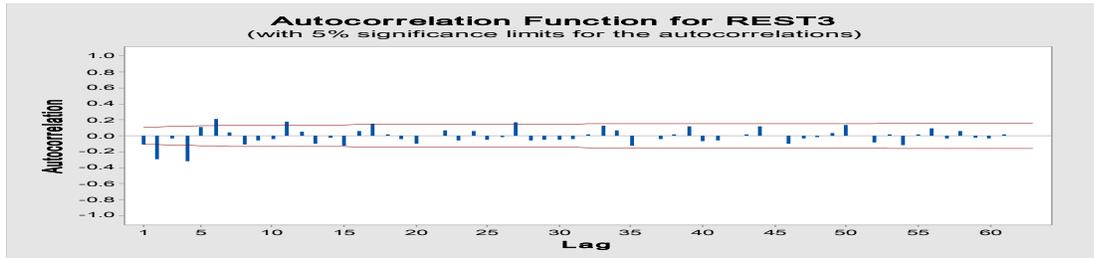
اذ نلاحظ من جدول (3-14) ان الإنموذج معنوي من الناحية الاحصائية لان قيمة P-Value اقل من مستوى المعنوية (0.05)

1-1 فحص ملائمة الانموذج المقدر بموجب طريقة المربعات الصغرى اللاخطية NNOLS :

بعد تشخيص الإنموذج وتحديد درجته وتقديره لابد من التاكد من صحة ملائمة الانموذج وكفاءته وتم ذلك عن طريق ما يأتي:

أ- إختبار معاملات الارتباط الذاتي المقدر بموجب طريقة المربعات الصغرى اللاخطية NNOLS :

تم استخراج معاملات الارتباط الذاتي والارتباط الذاتي الجزئي للبواقي (الاحطاء العشوائية) للإنموذج المقدر كما في جدول (3-15) وتم رسمها كما في شكل (3-13) اذ تبين بان اغلبية قيم معاملات الارتباط الذاتي والارتباط الذاتي الجزئي ضمن حدود الثقة يعني ان سلسلة البواقي عشوائية وان الانموذج المستعمل جيد وملائم.



شكل (3-13) دالة الارتباط الذاتي والارتباط الذاتي الجزئي لبواقي الانموذج الموسمي المضاعف بموجب طريقة المربعات الصغرى اللاخطية

الجدول (3-15) يبين قيم دالتي **ACF** , **PACF** لدرجات الحرارة في مركز قضاء الحلة / محافظة بابل الانموذج المقدر بموجب طريقة المربعات الصغرى اللاخطية **NNOLS**

Lag	ACF	PACF	Lag	ACF	PACF
1	0.111015-	0.0859971	33	0.127769	0.0212140
2	0.292171-	0.0446495-	34	0.071639	0.0859971
3	0.033569-	0.0099011-	35	0.128492-	0.0446495-
4	0.325029-	0.0430466-	36	0.008150-	0.0099011-
5	0.112172	0.0184420	37	0.042939-	0.0430466-
6	0.214503	0.0182581-	38	0.013767	0.0184420
7	0.041774	0.0570489	39	0.120570	0.0182581-
8	0.112374-	0.0704798-	40	0.067585-	0.0570489
9	0.056217-	0.0128145-	41	0.056547-	0.0704798-
10	0.043880-	0.0069749	42	0.007275-	0.0128145-
11	0.177686	0.0212140	43	0.016356	0.0069749
12	0.049640	0.0859971	44	0.115802	0.0212140
13	0.097467-	0.0446495-	45	0.006307-	0.0859971
14	0.028635-	0.0099011-	46	0.100317-	0.0446495-
15	0.127169-	0.0430466-	47	0.031642-	0.0099011-
16	0.061161	0.0184420	48	0.018613-	0.0430466-
17	0.148395	0.0182581-	49	0.032193	0.0184420
18	0.020089	0.0570489	50	0.133297	0.0182581-
19	0.039721-	0.0704798-	51	0.005229	0.0570489

20	0.105156-	0.0128145-	52	0.085402-	0.0704798-
21	0.005609-	0.0069749	53	0.013620	0.0128145-
22	0.071441	0.0212140	54	0.115837-	0.0069749
23	0.057661-	0.0859971	55	0.015618	0.0212140
24	0.058703	0.0446495-	56	0.093576	0.0859971
25	0.050157-	0.0099011-	57	0.030572-	0.0446495-
26	0.015983-	0.0430466-	58	0.059597	0.0099011-
27	0.165627	0.0184420	59	0.022183-	0.0430466-
28	0.061974-	0.0182581-	60	0.037160-	0.0184420
29	0.051223-	0.0570489	61	0.019328	0.0182581-
30	0.048046-	0.0704798-	62	0.002733	0.0570489
31	0.046383-	0.0128145-	63	0.002080-	0.0704798-
32	0.017688	0.0069749			

ب- إختبار Portmanteau للاخطاء العشوائية المقدره بموجب طريقة المربعات الصغرى اللاخطية
:NNOLS

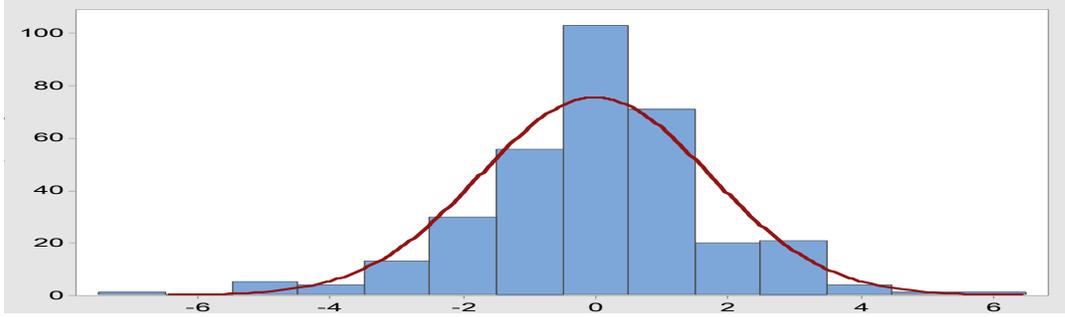
بما ان الاخطاء تعد (White Noise) اي ان $\mathbf{a}_t \sim NID(\mathbf{0}, \sigma_a^2)$ وان معاملات الارتباط للبواقى $r_k(\hat{a})$ تتوزع طبيعياً بوسط حسابي يساوي صفراً وتباين مقداره $(1/N)$ فقد تم تطبيق احصاءة (Ljung-Box) لفحص ملائمة الانموذج وظهر ان:

$$Q.stat = LBQ = 396.531 > \chi^2_{(61, 0.05)} = 88.38$$

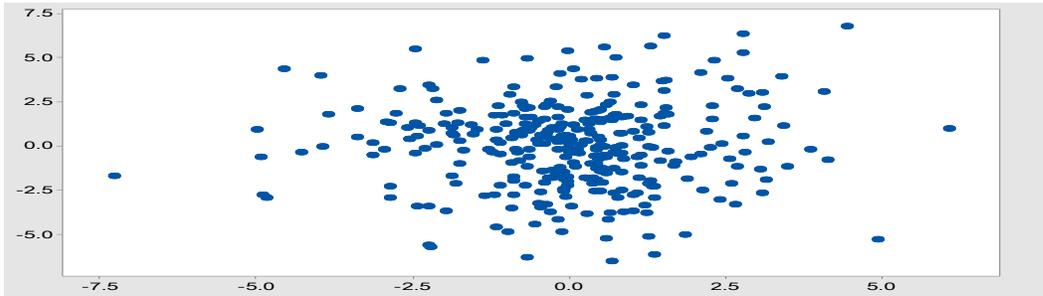
ومن ذلك نستنتج بأن سلسلة البواقى غير معنوية (عشوائية) ومن ثم فان توفيق الانموذج جيدة وملائمة وكفاءة .

ب- اختبار التوزيع الطبيعي للبواقى المقدره بموجب طريقة المربعات الصغرى اللاخطية:

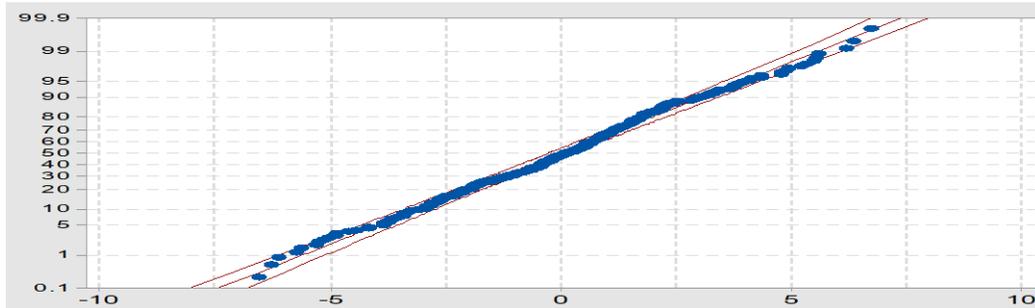
يوضح الشكل (3-14) اختبار التناظر والتسطح الطبيعي لسلسلة البواقي للإنموذج المقدر وهو يدل على ان سلسلة البواقي تحمل خصائص التوزيع الطبيعي يؤكد على دقة وكفاءة وملائمة الإنموذج المقدر .



(a)



(b)



(c)

شكل (14-3) (a) المدرج التكراري لسلسلة البواقي الانموذج المقدر (b) الرسم الانتشاري لسلسلة البواقي الانموذج المقدر (c) المنحى الاحتمالي الطبيعي لسلسلة البواقي الانموذج المقدر بموجبه طريقة المربعات الصغرى اللاخطية NNOLS

ج- القيم التقديرية الانموذج المقدر بموجبه طريقة المربعات الصغرى اللاخطية NNOLS:

نلحظ من الجدول (16-3) والشكل (15-3) ان القيم التقديرية لسلسلة درجات الحرارة اليومية في مركز قضاء الحلة /محافظة بابل متناسقة مع القيم الاصلية للسلسلة وهذا يدل على دقة وكفاءة جيدة للإنموذج المقدر.

جدول (16-3) القيم التقديرية والبواقي لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل الانموذج المقدر بموجبه طريقة المربعات الصغرى اللاخطية NNOLS

NO	Residuals	Fits	NO	Residuals	Fits
1	*	*	168	-3.5736	36.3
2	*	*	169	-3.5662	41.83
3	*	*	170	-3.5729	39.37
4	*	*	171	-3.566	32.93
5	*	*	172	-3.5663	34.91
6	*	*	173	-3.5735	32.52
7	-4.5652	16.07	174	-3.5749	34.08
8	-4.7768	18.31	175	-3.5701	36.34
9	-7.5777	19.64	176	-3.5745	37.31
10	-3.5721	8.72	177	-3.5654	38.38
11	-3.5661	17.4	178	-3.5702	40.29
12	-3.5704	11.75	179	-3.5748	39.45
13	-6.8846	8.96	180	-3.5707	39.45
14	-5.5696	16.08	181	-3.5688	37.73
15	-3.5705	13.71	182	-3.5731	35.7

16	-5.5731	19.36	183	-3.5746	35.79
17	-3.5708	16.25	184	-3.5685	35.55
18	-3.5693	13.52	185	-3.57	35.45
19	-3.5661	14.21	186	-3.5729	37.56
20	-3.5735	7.69	187	-3.5693	36.55
21	-7.5732	6.59	188	-3.5722	35.01
22	-3.5699	8.51	189	-3.5708	38.76
23	-3.5663	11.38	190	-3.5694	36.65
24	-3.5716	12.85	191	-3.5685	36.37
25	-3.5747	15.04	192	-3.5703	37.94
26	-3.5735	15.9	193	-3.5716	36.14
27	-3.5682	17.46	194	-3.5673	37.54
28	-3.5747	21.1	195	-3.5704	37.74
29	-3.5735	17.72	196	-3.5742	36.84
30	-3.5693	19.25	197	-3.5685	34.71
31	-3.5667	12.17	198	-3.5731	36.23
32	-3.5692	9.06	199	-3.5677	36.75
33	-3.5747	15.84	200	-3.571	33.33
34	-3.5689	17.38	201	-3.5721	38.67
35	-3.5742	15.3	202	-3.5714	36.89
36	-3.5696	14.32	203	-3.5733	34.36
37	-3.5684	11.87	204	-3.5709	39.51
38	-3.574	11.85	205	-3.5691	37.42
39	-3.5679	12.89	206	-3.5717	37.72
40	-3.5718	15.4	207	-3.5745	39.63
41	-3.5749	17.86	208	-3.5741	39.36
42	-3.8846	18.41	209	-3.5719	37.2

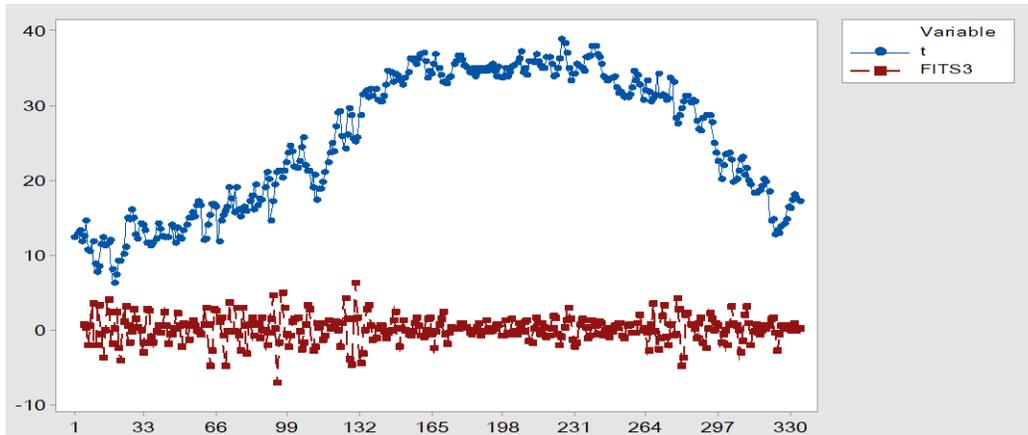
43	-3.5654	13.22	210	-3.5678	33.24
44	-4.5685	14.61	211	-3.5685	37.12
45	-3.5719	13.63	212	-3.5704	35.73
46	-3.5737	12.83	213	-3.5674	40.27
47	-3.5731	16.99	214	-3.5656	39.01
48	-3.5688	18.46	215	-3.57	38.75
49	-3.574	12.6	216	-3.5652	39.69
50	-3.5675	13.55	217	-3.5669	34.44
51	-3.5673	16.91	218	-3.5684	36.65
52	-3.5658	10.29	219	-3.5677	36.33
53	-3.5676	16.61	220	-3.5658	37.87
54	-3.5718	18.39	221	-3.5745	40.79
55	-3.5724	16.37	222	-3.5659	37.64
56	-3.5717	19.48	223	-3.5735	35.3
57	-3.5651	17.63	224	-3.5726	33.69
58	-3.5707	17.76	225	-3.5706	36.17
59	-3.5722	17.6	226	-3.571	39.07
60	-3.5704	20.96	227	-3.573	43.41
61	-3.567	18.99	228	-3.5677	45.08
62	-3.5715	12.67	229	-3.574	38.05
63	-3.5672	8.4	230	-3.5731	35.34
64	-3.5666	15.92	231	-3.5658	31.4
65	-3.5737	18.28	232	-3.572	32.21
66	-3.5685	20.82	233	-3.5663	37.51
67	-3.5664	24.35	234	-3.5693	37.82
68	-3.5673	17.99	235	-3.5737	40.43
69	-3.5723	11.84	236	-3.5739	37.17

70	-3.5724	10.01	237	-3.5718	36.27
71	-3.5719	20.73	238	-3.5653	38.06
72	-3.5732	17.3	239	-3.5671	39.79
73	-3.5711	20.42	240	-3.5663	38.71
74	-3.5701	25.22	241	-3.5741	41.03
75	-3.5683	20.51	242	-3.5711	41.55
76	-3.5694	14.87	243	-3.567	37.51
77	-3.5675	19.73	244	-3.5663	37.61
78	-3.5662	21.44	245	-3.572	36.73
79	-3.5742	10.42	246	-3.57	33.3
80	-3.5744	19.45	247	-3.5655	33.66
81	-3.5695	19.63	248	-3.5694	35.66
82	-3.5729	15.68	249	-3.5669	34.8
83	-3.5689	20.84	250	-3.5682	36.39
84	-3.5727	22.37	251	-3.5707	36.81
85	-3.5729	17.9	252	-3.5743	34.52
86	-3.5725	19.53	253	-3.5715	31.91
87	-3.5704	23.81	254	-3.5738	33.04
88	-3.5688	13.76	255	-3.5723	33.14
89	-3.5721	21.52	256	-3.5687	32.3
90	-3.5712	21.08	257	-3.5663	33.59
91	-3.5654	23.69	258	-3.568	33.83
92	-3.5736	26.38	259	-3.5679	34.76
93	-3.5682	14.05	260	-3.5669	38.18
94	-3.5701	12.86	261	-3.5687	38.29
95	-3.5665	24.43	262	-3.5704	34.35
96	-3.5698	23.01	263	-3.5695	36.21

97	-3.5721	26.97	264	-3.9884	29.89
98	-3.5731	26.55	265	-3.5709	30.71
99	-3.5713	20.19	266	-3.5666	37.84
100	-3.5695	24.46	267	-3.5723	34.04
101	-3.5708	25.94	268	-3.5716	31.72
102	-3.5708	28.43	269	-3.5727	32.82
103	-3.5721	27.88	270	-3.5745	32.71
104	-3.5698	22	271	-3.5672	35.9
105	-3.5664	20.67	272	-3.5673	37.81
106	-3.5716	23.83	273	-3.5681	30.18
107	-3.5673	26.57	274	-3.5664	34.5
108	-3.5668	30.73	275	-3.5713	31.03
109	-3.5683	26.58	276	-4.5676	31.59
110	-3.5659	18.43	277	-3.5736	38.17
111	-3.5702	22.54	278	-3.5721	38.19
112	-3.5651	18.64	279	-3.5659	29.07
113	-3.5674	19.16	280	-3.5722	24.37
114	-3.5657	24.1	281	-3.5694	30.12
115	-3.5715	15.64	282	-3.5724	29.98
116	-3.566	24.06	283	-3.5743	34.12
117	-3.5667	21.86	284	-3.571	37.74
118	-3.5657	23.67	285	-3.5694	34.55
119	-3.5723	28.4	286	-3.5653	31.61
120	-3.5651	26.46	287	-3.5697	31.1
121	-3.5741	29.02	288	-3.5658	32.91
122	-3.5731	26.98	289	-3.5699	28.47
123	-3.5668	27.68	290	-3.5675	25.38

124	-3.5656	35.23	291	-3.5733	28.32
125	-3.5686	31.94	292	-3.5694	29.14
126	-3.5727	27.93	293	-3.5712	32.94
127	-3.5726	22.9	294	-3.5728	32.46
128	-3.5738	24.37	295	-3.5682	31.54
129	-3.5727	32.55	296	-3.5749	29.8
130	-3.5735	34.55	297	-3.5742	24.12
131	-3.5741	28.37	298	-3.5657	22.04
132	-3.5667	24.94	299	-3.5656	22.87
133	-3.5664	25.78	300	-3.5675	19.57
134	-3.5678	28.68	301	-3.571	21.37
135	-3.5736	38.52	302	-3.5693	29.85
136	-3.5743	39.19	303	-3.5717	26.92
137	-3.5652	35.03	304	-3.5698	26.87
138	-3.5672	33.84	305	-3.5716	26.78
139	-6.5665	33.9	306	-3.5676	18.86
140	-3.5696	33.27	307	-3.5694	17.47
141	-3.5746	32.64	308	-3.5665	24.03
142	-3.5686	34.1	309	-3.5726	25.46
143	-3.5722	30.9	310	-3.5716	27.79
144	-3.5687	31.93	311	-3.5699	25.02
145	-3.571	33.44	312	-3.571	20.31
146	-3.5725	35.23	313	-3.5668	22.55
147	-3.5716	39.51	314	-3.5744	17.26
148	-3.5682	38.96	315	-3.5743	20.11
149	-3.5658	34.85	316	-3.5731	19.83
150	-3.5727	34.64	317	-3.566	19.81

151	-3.5741	36.6	318	-3.5659	21.66
152	-3.5709	33.61	319	-3.5745	21.64
153	-3.5662	35.55	320	-3.8935	24.24
154	-3.5715	34.97	321	-3.5743	22.52
155	-3.5713	34.13	322	-3.5658	19.77
156	-3.5716	37.7	323	-3.5668	14.66
157	-3.5668	39.46	324	-3.5657	11.03
158	-3.5729	40.99	325	-3.569	14.57
159	-3.5734	38.28	326	-3.5743	11.53
160	-3.5691	37.82	327	-6.9884	20.5
161	-3.5683	36.66	328	-3.5659	17.34
162	-3.5685	38.61	329	-8.5661	22.22
163	-3.5724	39.85	330	-4.5694	19.29
164	-3.5694	38.23	331	-7.5732	22.94
165	-3.5743	34.56	332	-5.5718	22.76
166	-3.5693	33.4	333	-6.5654	21.63
167	-3.5707	37.05	334	-4.5676	23.16



شكل (15-3) القيم التقديرية والحقيقية لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل المقدر بموجب طريقة المربعات الصغرى اللاخطية NNOLS

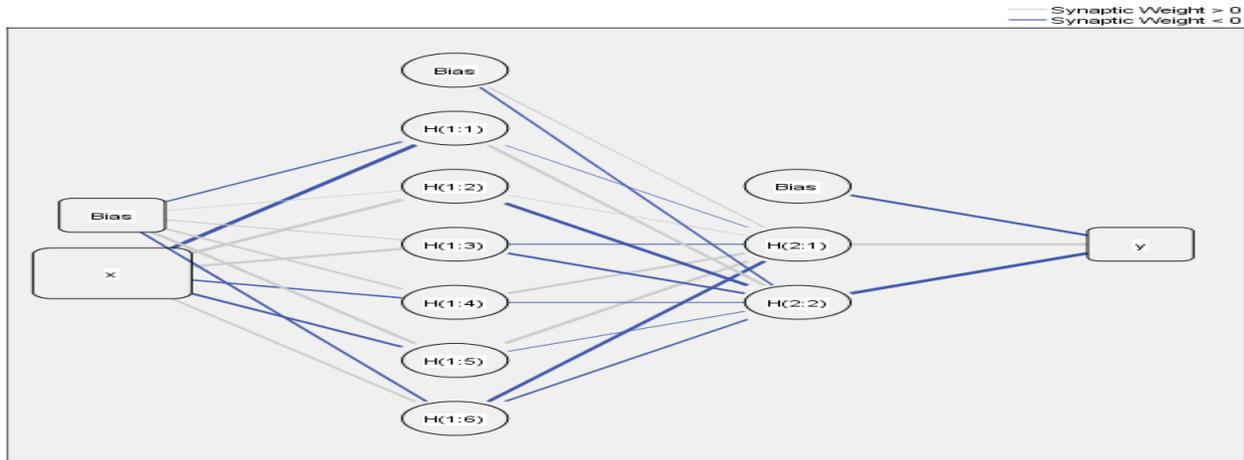
4- التقدير باستعمال الشبكة العصبية الاصطناعية NARX :

لغرض الحصول على القيم التقدير للسلسلة درجات الحرارة في مركز قضاء الحلة محافظة بابل وباستعمال السلسلة الأصلية للبيانات المكونة من (334) مشاهدة والتي تعاني من عدم الاستقرار ، تم تصميم برنامج بلغة ماتلاب (MatLab , 2015a) كما في ملحق (A) والذي تضمن مرحلتين رئيسيتين ، المرحلة الأولى هي الاعداد للبيانات (Preparing Data) وهي عملية تحويل البيانات الى الصيغة المعيارية (Normalized) وكذلك تحديد مدخلات الشبكة العصبية، اما المرحلة الثانية فهي عملية تقسيم البيانات اذ تم تقسيم البيانات بنسبة (8:2) الى مجموعتين هما مجموعة التدريب (Training set) ومن ضمنها مجموعة بيانات التدقيق (Validation set) والمكونة من (260) مشاهدة بنسبة (77.8%) والمجموعة الثانية هي مجموعة بيانات الاختبار (Testing set) المؤلفة من (74) مشاهدة بنسبة (22.2%) ، فبعد ان تم تهيئة البيانات لادخالها الى الشبكة تم تصميم الشبكة والتي تألفت من ثلاثة اطوار رئيسية هي طور التدريب وطور التحقق وطور الاختبار وحسب الآتي:

اولاً: طور التدريب: تم تكوين وتدريب الشبكة العصبية (NARX) باستعمال الدالة (newnarx) واعطاء قيم أقرب ماتكون لبيانات درجات الحرارة بادخال ومعالجة بيانات التدريب واختيار العدد (25000) كعدد لدورات التدريب وبنسبة خطأ (0.0001) وتبين ان افضل معمارية لتقدير المشاهدات هي باختبار خمس عقد لطبقة الادخال واستعمال طبقتين مخفيتين الاولى تضمنت ست عقد والثانية تضمنت عقدتين وعقدة اخراج واحدة .

ثانياً: طور التحقق: تم اختيار الشبكة عن طريق ادخال بيانات التدقيق اذ تقارن هذه البيانات مع البيانات المدربة التي تم الحصول عليها في طور التدريب للحصول على تطابق مع بيانات الهدف وبهذا يتم التحقق من الشبكة قد دربت تدريباً جيداً .

ثالثاً: طور الاختبار: بعد ان تم اكمال عملية التدريب وعمية التحقق يتم الآن ادخال بيانات الاختبار والاوزان المثالية المخزونة للشبكة ومعالجتها وعمل اختبار لكفاءة الشبكة العصبية المدربة وقدرتها على اعطاء قيم تقديرية مقبولة وبهذا تم الحصول على المخرجات المطلوبة من الشبكة العصبية الاصطناعية . والشكل (3-16) يبين معمارية الشبكة العصبية الاصطناعية



شكل (3-16) معمارية الشبكة العصبية الاصطناعية NARX

والجدول (3-17) والشكل (3-16) يبينان القيم التقديرية لسلسلة درجات الحرارة اليومية في مركز قضاء الحلة /محافظة بابل باستعمال الشبكة العصبية الاصطناعية والتي تكون متناسقة مع القيم الاصلية للسلسلة وهذا يدل على دقة وكفاءة جيدة الانموذج المقدر .

جدول (3-17) القيم التقديرية والبواقي لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل للانموذج المقدر بموجب طريقة الشبكات العصبية الاصطناعية NARX

NO	Residuals	Fits	NO	Residuals	Fits
1	0.80	11.50	168	0.05	34.75
2	1.38	11.52	169	-0.82	34.82
3	1.67	11.53	170	-1.79	34.89

4	0.15	11.55	171	-1.85	34.95
5	0.83	11.57	172	-2.21	35.01
6	2.82	11.58	173	-1.57	35.07
7	-1.00	11.60	174	-1.33	35.13
8	-1.22	11.62	175	0.22	35.18
9	0.06	11.64	176	0.67	35.23
10	-2.96	11.66	177	1.32	35.28
11	-4.08	11.68	178	1.18	35.32
12	-3.40	11.70	179	0.64	35.36
13	-0.32	11.72	180	-0.20	35.40
14	0.56	11.74	181	-0.44	35.44
15	-0.56	11.76	182	-1.17	35.47
16	-0.29	11.79	183	-1.11	35.51
17	0.09	11.81	184	-0.64	35.54
18	-3.84	11.84	185	-1.86	35.56
19	-5.66	11.86	186	-1.19	35.59
20	-4.69	11.89	187	-0.71	35.61
21	-2.81	11.91	188	-1.04	35.64
22	-2.84	11.94	189	-0.86	35.66
23	-1.87	11.97	190	-1.07	35.67
24	-1.10	12.00	191	-0.69	35.69
25	2.87	12.03	192	-0.61	35.71
26	2.64	12.06	193	-0.32	35.72
27	3.90	12.10	194	-1.23	35.73
28	2.77	12.13	195	-1.94	35.74
29	0.53	12.17	196	-0.75	35.75
30	-0.20	12.20	197	-2.25	35.75

31	1.86	12.24	198	-1.96	35.76
32	1.72	12.28	199	-0.96	35.76
33	0.78	12.32	200	-1.96	35.76
34	-0.86	12.36	201	-1.36	35.76
35	-0.80	12.40	202	-0.76	35.76
36	-1.25	12.45	203	-0.46	35.76
37	-0.89	12.49	204	-0.06	35.76
38	-0.54	12.54	205	0.35	35.75
39	1.61	12.59	206	1.35	35.75
40	0.66	12.64	207	-1.34	35.74
41	-0.29	12.69	208	-0.83	35.73
42	-0.54	12.74	209	-1.72	35.72
43	-0.50	12.80	210	0.20	35.70
44	-0.55	12.85	211	0.21	35.69
45	1.09	12.91	212	0.02	35.68
46	0.63	12.97	213	1.04	35.66
47	-1.53	13.03	214	0.16	35.64
48	0.40	13.10	215	-0.42	35.62
49	-0.97	13.17	216	-0.80	35.60
50	-1.13	13.23	217	-0.68	35.58
51	-0.10	13.30	218	0.74	35.56
52	0.52	13.38	219	0.77	35.53
53	1.45	13.45	220	0.00	35.50
54	1.27	13.53	221	-1.68	35.48
55	1.99	13.61	222	-1.55	35.45
56	1.41	13.69	223	-0.62	35.42
57	2.82	13.78	224	0.72	35.38

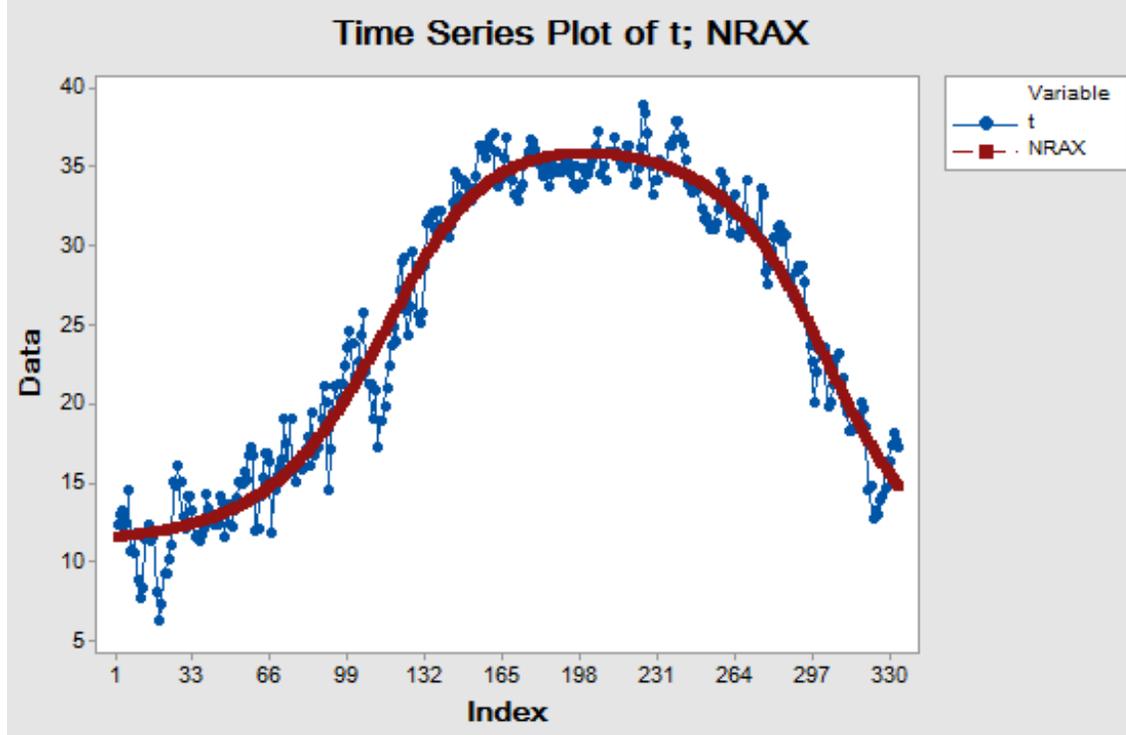
58	3.24	13.86	225	3.45	35.35
59	2.65	13.95	226	2.99	35.31
60	-2.15	14.05	227	1.73	35.27
61	-2.14	14.14	228	-0.33	35.23
62	-0.24	14.24	229	-1.99	35.19
63	0.86	14.34	230	-1.05	35.15
64	2.26	14.44	231	-1.01	35.11
65	2.15	14.55	232	0.34	35.06
66	1.64	14.66	233	-0.01	35.01
67	-3.08	14.78	234	-0.06	34.96
68	-0.49	14.89	235	-0.31	34.91
69	0.29	15.01	236	1.45	34.85
70	0.66	15.14	237	1.51	34.79
71	1.13	15.27	238	1.87	34.73
72	3.50	15.40	239	3.13	34.67
73	1.87	15.53	240	3.19	34.61
74	-0.07	15.67	241	2.26	34.54
75	3.09	15.81	242	1.93	34.47
76	0.04	15.96	243	1.00	34.40
77	-1.11	16.11	244	-0.53	34.33
78	-0.46	16.26	245	-0.65	34.25
79	-0.12	16.42	246	-0.87	34.17
80	-0.88	16.58	247	-0.69	34.09
81	0.26	16.74	248	-0.50	34.00
82	0.89	16.91	249	-0.21	33.91
83	-1.08	17.08	250	-1.52	33.82
84	2.14	17.26	251	-2.13	33.73

85	-0.84	17.44	252	-1.93	33.63
86	-0.23	17.63	253	-2.12	33.52
87	-0.62	17.82	254	-2.42	33.42
88	0.99	18.01	255	-2.31	33.31
89	2.79	18.21	256	-1.80	33.20
90	1.59	18.41	257	-0.78	33.08
91	-4.22	18.62	258	1.54	32.96
92	-1.83	18.83	259	0.37	32.83
93	0.36	19.04	260	1.30	32.70
94	1.74	19.26	261	0.03	32.57
95	1.72	19.48	262	-1.73	32.43
96	0.50	19.70	263	-0.39	32.29
97	1.17	19.93	264	1.06	32.14
98	2.14	20.16	265	-0.19	31.99
99	3.10	20.40	266	-1.43	31.83
100	3.86	20.64	267	-0.87	31.67
101	2.82	20.88	268	-0.20	31.50
102	0.57	21.13	269	2.77	31.33
103	0.22	21.38	270	0.04	31.16
104	0.87	21.63	271	0.43	30.97
105	2.41	21.89	272	0.41	30.79
106	3.46	22.14	273	0.11	30.59
107	-0.50	22.40	274	0.40	30.40
108	-1.57	22.67	275	3.31	30.19
109	-1.73	22.93	276	3.11	29.99
110	-4.20	23.20	277	-1.47	29.77
111	-2.77	23.47	278	-2.05	29.55

112	-6.54	23.74	279	-0.73	29.33
113	-5.21	24.01	280	0.50	29.10
114	-5.48	24.28	281	1.54	28.86
115	-4.85	24.55	282	2.48	28.62
116	-3.93	24.83	283	2.82	28.38
117	-2.80	25.10	284	2.07	28.13
118	-1.78	25.38	285	2.83	27.87
119	-0.85	25.65	286	2.89	27.61
120	-2.13	25.93	287	0.45	27.35
121	0.90	26.20	288	-0.28	27.08
122	2.43	26.47	289	-0.21	26.81
123	2.35	26.75	290	1.77	26.53
124	-1.22	27.02	291	2.35	26.25
125	-3.09	27.29	292	2.54	25.96
126	-1.55	27.55	293	2.92	25.68
127	1.68	27.82	294	2.22	25.38
128	0.52	28.08	295	-0.19	25.09
129	-2.84	28.34	296	-1.19	24.79
130	-3.59	28.59	297	-1.99	24.49
131	-3.25	28.85	298	-4.19	24.19
132	-0.49	29.09	299	-1.99	23.89
133	2.06	29.34	300	-0.29	23.59
134	2.02	29.58	301	0.12	23.28
135	2.18	29.82	302	0.52	22.98
136	0.95	30.05	303	0.03	22.67
137	1.82	30.28	304	-2.67	22.37
138	0.70	30.50	305	-2.06	22.06

139	1.38	30.72	306	-0.56	21.76
140	-0.23	30.93	307	1.25	21.45
141	-0.64	31.14	308	1.95	21.15
142	-0.94	31.34	309	-0.25	20.85
143	-0.33	31.53	310	0.95	20.55
144	0.88	31.72	311	-0.46	20.26
145	2.59	31.91	312	-0.57	19.97
146	2.21	32.09	313	-1.48	19.68
147	0.74	32.26	314	-1.19	19.39
148	1.67	32.43	315	-0.71	19.11
149	1.31	32.59	316	-0.33	18.83
150	0.85	32.75	317	0.64	18.56
151	0.30	32.90	318	1.72	18.28
152	-0.35	33.05	319	1.58	18.02
153	0.31	33.19	320	0.64	17.76
154	0.97	33.33	321	-3.10	17.50
155	2.74	33.46	322	-2.55	17.25
156	2.41	33.59	323	-4.40	17.00
157	2.49	33.71	324	-3.56	16.76
158	1.68	33.82	325	-3.62	16.52
159	2.17	33.93	326	-2.49	16.29
160	2.66	34.04	327	-1.97	16.07
161	2.86	34.14	328	-1.24	15.84
162	1.66	34.24	329	0.67	15.63
163	-0.74	34.34	330	0.78	15.42
164	0.07	34.43	331	2.09	15.21
165	-0.31	34.51	332	3.08	15.02

166	0.91	34.59	333	2.68	14.82
167	2.03	34.67	334	2.47	14.63



شكل (3-17) القيم التقديرية والحقيقية لسلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل المقدر بموجب الشبكة العصبية الاصناعية .NARX.

جدول (3-18) يبين نتائج مقارنة التقدير بين الطرائق المستعملة في تقدير سلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل باستعمال معيار (MSE) :

Data	Y_t	AMLE	AMLE	NLES	NARX
1	12.3	*	*	*	11.50
2	12.9	*	*	*	11.52
3	13.2	*	*	*	11.53
4	11.7	*	*	*	11.55
5	12.4	*	*	*	11.57

6	14.4	*	*	*	11.58
7	10.6	11.50	11.50	16.07	11.60
8	10.4	13.53	13.53	18.31	11.62
9	11.7	12.06	12.06	19.64	11.64
10	8.7	5.15	5.15	8.72	11.66
11	7.6	13.83	13.83	17.4	11.68
12	8.3	8.18	8.18	11.75	11.70
13	11.4	2.08	2.08	8.96	11.72
14	12.3	10.51	10.51	16.08	11.74
15	11.2	11.64	10.14	13.71	11.76
16	11.5	15.29	13.79	19.36	11.79
17	11.9	14.18	12.68	16.25	11.81
18	8	11.45	9.95	13.52	11.84
19	6.2	12.14	10.64	14.21	11.86
20	7.2	5.62	4.12	7.69	11.89
21	9.1	0.52	-0.98	6.59	11.91
22	9.1	6.44	4.94	8.51	11.94
23	10.1	9.31	7.81	11.38	11.97
24	10.9	10.78	9.28	12.85	12.00
25	14.9	12.97	11.47	15.04	12.03
26	14.7	13.83	12.33	15.9	12.06
27	16	15.39	13.89	17.46	12.10
28	14.9	19.03	17.53	21.1	12.13
29	12.7	15.65	14.15	17.72	12.17
30	12	17.18	15.68	19.25	12.20
31	14.1	10.10	8.60	12.17	12.24
32	14	6.99	5.49	9.06	12.28

33	13.1	13.77	12.27	15.84	12.32
34	11.5	15.31	13.81	17.38	12.36
35	11.6	13.23	11.73	15.3	12.40
36	11.2	12.25	10.75	14.32	12.45
37	11.6	9.80	8.30	11.87	12.49
38	12	9.78	8.28	11.85	12.54
39	14.2	10.82	9.32	12.89	12.59
40	13.3	13.33	11.83	15.4	12.64
41	12.4	15.79	14.29	17.86	12.69
42	12.2	16.03	14.53	18.41	12.74
43	12.3	11.15	9.65	13.22	12.80
44	12.3	11.54	10.04	14.61	12.85
45	14	11.56	10.06	13.63	12.91
46	13.6	10.76	9.26	12.83	12.97
47	11.5	14.92	13.42	16.99	13.03
48	13.5	16.39	14.89	18.46	13.10
49	12.2	10.53	9.03	12.6	13.17
50	12.1	11.48	9.98	13.55	13.23
51	13.2	14.84	13.34	16.91	13.30
52	13.9	8.22	6.72	10.29	13.38
53	14.9	14.54	13.04	16.61	13.45
54	14.8	16.32	14.82	18.39	13.53
55	15.6	14.30	12.80	16.37	13.61
56	15.1	17.41	15.91	19.48	13.69
57	16.6	15.56	14.06	17.63	13.78
58	17.1	15.69	14.19	17.76	13.86
59	16.6	15.53	14.03	17.6	13.95

60	11.9	18.89	17.39	20.96	14.05
61	12	16.92	15.42	18.99	14.14
62	14	10.60	9.10	12.67	14.24
63	15.2	6.33	4.83	8.4	14.34
64	16.7	13.85	12.35	15.92	14.44
65	16.7	16.21	14.71	18.28	14.55
66	16.3	18.75	17.25	20.82	14.66
67	11.7	22.28	20.78	24.35	14.78
68	14.4	15.92	14.42	17.99	14.89
69	15.3	9.77	8.27	11.84	15.01
70	15.8	7.94	6.44	10.01	15.14
71	16.4	18.66	17.16	20.73	15.27
72	18.9	15.23	13.73	17.3	15.40
73	17.4	18.35	16.85	20.42	15.53
74	15.6	23.15	21.65	25.22	15.67
75	18.9	18.44	16.94	20.51	15.81
76	16	12.80	11.30	14.87	15.96
77	15	17.66	16.16	19.73	16.11
78	15.8	19.37	17.87	21.44	16.26
79	16.3	8.35	6.85	10.42	16.42
80	15.7	17.38	15.88	19.45	16.58
81	17	17.56	16.06	19.63	16.74
82	17.8	13.61	12.11	15.68	16.91
83	16	18.77	17.27	20.84	17.08
84	19.4	20.30	18.80	22.37	17.26
85	16.6	15.83	14.33	17.9	17.44
86	17.4	17.46	15.96	19.53	17.63

87	17.2	21.74	20.24	23.81	17.82
88	19	11.69	10.19	13.76	18.01
89	21	19.45	17.95	21.52	18.21
90	20	19.01	17.51	21.08	18.41
91	14.4	21.62	20.12	23.69	18.62
92	17	24.31	22.81	26.38	18.83
93	19.4	11.98	10.48	14.05	19.04
94	21	10.79	9.29	12.86	19.26
95	21.2	22.36	20.86	24.43	19.48
96	20.2	20.94	19.44	23.01	19.70
97	21.1	24.90	23.40	26.97	19.93
98	22.3	24.48	22.98	26.55	20.16
99	23.5	18.12	16.62	20.19	20.40
100	24.5	22.39	20.89	24.46	20.64
101	23.7	23.87	22.37	25.94	20.88
102	21.7	26.36	24.86	28.43	21.13
103	21.6	25.81	24.31	27.88	21.38
104	22.5	19.93	18.43	22	21.63
105	24.3	18.60	17.10	20.67	21.89
106	25.6	21.76	20.26	23.83	22.14
107	21.9	24.50	23.00	26.57	22.40
108	21.1	28.66	27.16	30.73	22.67
109	21.2	24.51	23.01	26.58	22.93
110	19	16.36	14.86	18.43	23.20
111	20.7	20.47	18.97	22.54	23.47
112	17.2	16.57	15.07	18.64	23.74
113	18.8	17.09	15.59	19.16	24.01

114	18.8	22.03	20.53	24.1	24.28
115	19.7	13.57	12.07	15.64	24.55
116	20.9	21.99	20.49	24.06	24.83
117	22.3	19.79	18.29	21.86	25.10
118	23.6	21.60	20.10	23.67	25.38
119	24.8	26.33	24.83	28.4	25.65
120	23.8	24.39	22.89	26.46	25.93
121	27.1	26.95	25.45	29.02	26.20
122	28.9	24.91	23.41	26.98	26.47
123	29.1	25.61	24.11	27.68	26.75
124	25.8	33.16	31.66	35.23	27.02
125	24.2	29.87	28.37	31.94	27.29
126	26	25.86	24.36	27.93	27.55
127	29.5	20.83	19.33	22.9	27.82
128	28.6	22.30	20.80	24.37	28.08
129	25.5	30.48	28.98	32.55	28.34
130	25	32.48	30.98	34.55	28.59
131	25.6	26.30	24.80	28.37	28.85
132	28.6	22.87	21.37	24.94	29.09
133	31.4	23.71	22.21	25.78	29.34
134	31.6	26.61	25.11	28.68	29.58
135	32	36.45	34.95	38.52	29.82
136	31	37.12	35.62	39.19	30.05
137	32.1	32.96	31.46	35.03	30.28
138	31.2	31.77	30.27	33.84	30.50
139	32.1	28.83	27.33	33.9	30.72
140	30.7	31.20	29.70	33.27	30.93

141	30.5	30.57	29.07	32.64	31.14
142	30.4	32.03	30.53	34.1	31.34
143	31.2	28.83	27.33	30.9	31.53
144	32.6	29.86	28.36	31.93	31.72
145	34.5	31.37	29.87	33.44	31.91
146	34.3	33.16	31.66	35.23	32.09
147	33	37.44	35.94	39.51	32.26
148	34.1	36.89	35.39	38.96	32.43
149	33.9	32.78	31.28	34.85	32.59
150	33.6	32.57	31.07	34.64	32.75
151	33.2	34.53	33.03	36.6	32.90
152	32.7	31.54	30.04	33.61	33.05
153	33.5	33.48	31.98	35.55	33.19
154	34.3	32.90	31.40	34.97	33.33
155	36.2	32.06	30.56	34.13	33.46
156	36	35.63	34.13	37.7	33.59
157	36.2	37.39	35.89	39.46	33.71
158	35.5	38.92	37.42	40.99	33.82
159	36.1	36.21	34.71	38.28	33.93
160	36.7	35.75	34.25	37.82	34.04
161	37	34.59	33.09	36.66	34.14
162	35.9	36.54	35.04	38.61	34.24
163	33.6	37.78	36.28	39.85	34.34
164	34.5	36.16	34.66	38.23	34.43
165	34.2	32.49	30.99	34.56	34.51
166	35.5	31.33	29.83	33.4	34.59
167	36.7	34.98	33.48	37.05	34.67

168	34.8	34.23	32.73	36.3	34.75
169	34	39.76	38.26	41.83	34.82
170	33.1	37.30	35.80	39.37	34.89
171	33.1	30.86	29.36	32.93	34.95
172	32.8	32.84	31.34	34.91	35.01
173	33.5	30.45	28.95	32.52	35.07
174	33.8	32.01	30.51	34.08	35.13
175	35.4	34.27	32.77	36.34	35.18
176	35.9	35.24	33.74	37.31	35.23
177	36.6	36.31	34.81	38.38	35.28
178	36.5	38.22	36.72	40.29	35.32
179	36	37.38	35.88	39.45	35.36
180	35.2	37.38	35.88	39.45	35.40
181	35	35.66	34.16	37.73	35.44
182	34.3	33.63	32.13	35.7	35.47
183	34.4	33.72	32.22	35.79	35.51
184	34.9	33.48	31.98	35.55	35.54
185	33.7	33.38	31.88	35.45	35.56
186	34.4	35.49	33.99	37.56	35.59
187	34.9	34.48	32.98	36.55	35.61
188	34.6	32.94	31.44	35.01	35.64
189	34.8	36.69	35.19	38.76	35.66
190	34.6	34.58	33.08	36.65	35.67
191	35	34.30	32.80	36.37	35.69
192	35.1	35.87	34.37	37.94	35.71
193	35.4	34.07	32.57	36.14	35.72
194	34.5	35.47	33.97	37.54	35.73

195	33.8	35.67	34.17	37.74	35.74
196	35	34.77	33.27	36.84	35.75
197	33.5	32.64	31.14	34.71	35.75
198	33.8	34.16	32.66	36.23	35.76
199	34.8	34.68	33.18	36.75	35.76
200	33.8	31.26	29.76	33.33	35.76
201	34.4	36.60	35.10	38.67	35.76
202	35	34.82	33.32	36.89	35.76
203	35.3	32.29	30.79	34.36	35.76
204	35.7	37.44	35.94	39.51	35.76
205	36.1	35.35	33.85	37.42	35.75
206	37.1	35.65	34.15	37.72	35.75
207	34.4	37.56	36.06	39.63	35.74
208	34.9	37.29	35.79	39.36	35.73
209	34	35.13	33.63	37.2	35.72
210	35.9	31.17	29.67	33.24	35.70
211	35.9	35.05	33.55	37.12	35.69
212	35.7	33.66	32.16	35.73	35.68
213	36.7	38.20	36.70	40.27	35.66
214	35.8	36.94	35.44	39.01	35.64
215	35.2	36.68	35.18	38.75	35.62
216	34.8	37.62	36.12	39.69	35.60
217	34.9	32.37	30.87	34.44	35.58
218	36.3	34.58	33.08	36.65	35.56
219	36.3	34.26	32.76	36.33	35.53
220	35.5	35.80	34.30	37.87	35.50
221	33.8	38.72	37.22	40.79	35.48

222	33.9	35.57	34.07	37.64	35.45
223	34.8	33.23	31.73	35.3	35.42
224	36.1	31.62	30.12	33.69	35.38
225	38.8	34.10	32.60	36.17	35.35
226	38.3	37.00	35.50	39.07	35.31
227	37	41.34	39.84	43.41	35.27
228	34.9	43.01	41.51	45.08	35.23
229	33.2	35.98	34.48	38.05	35.19
230	34.1	33.27	31.77	35.34	35.15
231	34.1	29.33	27.83	31.4	35.11
232	35.4	30.14	28.64	32.21	35.06
233	35	35.44	33.94	37.51	35.01
234	34.9	35.75	34.25	37.82	34.96
235	34.6	38.36	36.86	40.43	34.91
236	36.3	35.10	33.60	37.17	34.85
237	36.3	34.20	32.70	36.27	34.79
238	36.6	35.99	34.49	38.06	34.73
239	37.8	37.72	36.22	39.79	34.67
240	37.8	36.64	35.14	38.71	34.61
241	36.8	38.96	37.46	41.03	34.54
242	36.4	39.48	37.98	41.55	34.47
243	35.4	35.44	33.94	37.51	34.40
244	33.8	35.54	34.04	37.61	34.33
245	33.6	34.66	33.16	36.73	34.25
246	33.3	31.23	29.73	33.3	34.17
247	33.4	31.59	30.09	33.66	34.09
248	33.5	33.59	32.09	35.66	34.00

249	33.7	32.73	31.23	34.8	33.91
250	32.3	34.32	32.82	36.39	33.82
251	31.6	34.74	33.24	36.81	33.73
252	31.7	32.45	30.95	34.52	33.63
253	31.4	29.84	28.34	31.91	33.52
254	31	30.97	29.47	33.04	33.42
255	31	31.07	29.57	33.14	33.31
256	31.4	30.23	28.73	32.3	33.20
257	32.3	31.52	30.02	33.59	33.08
258	34.5	31.76	30.26	33.83	32.96
259	33.2	32.69	31.19	34.76	32.83
260	34	36.11	34.61	38.18	32.70
261	32.6	36.22	34.72	38.29	32.57
262	30.7	32.28	30.78	34.35	32.43
263	31.9	34.14	32.64	36.21	32.29
264	33.2	27.40	25.90	29.89	32.14
265	31.8	28.64	27.14	30.71	31.99
266	30.4	35.77	34.27	37.84	31.83
267	30.8	31.97	30.47	34.04	31.67
268	31.3	29.65	28.15	31.72	31.50
269	34.1	30.75	29.25	32.82	31.33
270	31.2	30.64	29.14	32.71	31.16
271	31.4	33.83	32.33	35.9	30.97
272	31.2	35.74	34.24	37.81	30.79
273	30.7	28.11	26.61	30.18	30.59
274	30.8	32.43	30.93	34.5	30.40
275	33.5	28.96	27.46	31.03	30.19

276	33.1	28.52	27.02	31.59	29.99
277	28.3	36.10	34.60	38.17	29.77
278	27.5	36.12	34.62	38.19	29.55
279	28.6	27.00	25.50	29.07	29.33
280	29.6	22.30	20.80	24.37	29.10
281	30.4	28.05	26.55	30.12	28.86
282	31.1	27.91	26.41	29.98	28.62
283	31.2	32.05	30.55	34.12	28.38
284	30.2	35.67	34.17	37.74	28.13
285	30.7	32.48	30.98	34.55	27.87
286	30.5	29.54	28.04	31.61	27.61
287	27.8	29.03	27.53	31.1	27.35
288	26.8	30.84	29.34	32.91	27.08
289	26.6	26.40	24.90	28.47	26.81
290	28.3	23.31	21.81	25.38	26.53
291	28.6	26.25	24.75	28.32	26.25
292	28.5	27.07	25.57	29.14	25.96
293	28.6	30.87	29.37	32.94	25.68
294	27.6	30.39	28.89	32.46	25.38
295	24.9	29.47	27.97	31.54	25.09
296	23.6	27.73	26.23	29.8	24.79
297	22.5	22.05	20.55	24.12	24.49
298	20	19.97	18.47	22.04	24.19
299	21.9	20.80	19.30	22.87	23.89
300	23.3	17.50	16.00	19.57	23.59
301	23.4	19.30	17.80	21.37	23.28
302	23.5	27.78	26.28	29.85	22.98

303	22.7	24.85	23.35	26.92	22.67
304	19.7	24.80	23.30	26.87	22.37
305	20	24.71	23.21	26.78	22.06
306	21.2	16.79	15.29	18.86	21.76
307	22.7	15.40	13.90	17.47	21.45
308	23.1	21.96	20.46	24.03	21.15
309	20.6	23.39	21.89	25.46	20.85
310	21.5	25.72	24.22	27.79	20.55
311	19.8	22.95	21.45	25.02	20.26
312	19.4	18.24	16.74	20.31	19.97
313	18.2	20.48	18.98	22.55	19.68
314	18.2	15.19	13.69	17.26	19.39
315	18.4	18.04	16.54	20.11	19.11
316	18.5	17.76	16.26	19.83	18.83
317	19.2	17.74	16.24	19.81	18.56
318	20	19.59	18.09	21.66	18.28
319	19.6	19.57	18.07	21.64	18.02
320	18.4	21.85	20.35	24.24	17.76
321	14.4	20.45	18.95	22.52	17.50
322	14.7	17.70	16.20	19.77	17.25
323	12.6	12.59	11.09	14.66	17.00
324	13.2	8.96	7.46	11.03	16.76
325	12.9	12.50	11.00	14.57	16.52
326	13.8	9.46	7.96	11.53	16.29
327	14.1	15.01	13.51	20.5	16.07
328	14.6	15.27	13.77	17.34	15.84
329	16.3	15.15	13.65	22.22	15.63

330	16.2	16.22	14.72	19.29	15.42
331	17.3	16.87	15.37	22.94	15.21
332	18.1	18.69	17.19	22.76	15.02
333	17.5	16.56	15.06	21.63	14.82
334	17.1	20.09	18.59	23.16	14.63
MSE		11.65	13.68	14.06	3.55

وكما هو واضح من جدول (3-18) بان طريقة الشبكات العصبية الاصناعية قد تفوقت على باقي طرائق تقدير سلسلة درجات الحرارة في مركز قضاء الحلة /محافظة بابل كونها حققت اقل قيمة لمتوسط مربعات الخطأ بلغت (3.55) .

الفصل الرابع

الاستنتاجات

والتوصيات

4-1 الاستنتاجات Conclusions

عن طريق نتائج الجانب التطبيقي لبيانات درجات الحرارة في قضاء الحلة تم التوصل الى الاستنتاجات الآتية :

1- ان الانموذج الموسمي المضاعف $ARIMA(p, q, d)(P, Q, D)_2$ حدد كأفضل إنموذج ممثل للسلسلة الزمنية الموسمية محل الدراسة.

2- تم تشخيص الإنموذج الموسمي المضاعف من الرتبة $ARIMA(1,1,0)(1,2,0)_2$ كأفضل إنموذج موسمي لسلسلة درجات الحرارة في قضاء الحلة .

3- تفوق طريقة الامكان الاعظم التقريبية على طريقة الامكان الاعظم المضبوطة وطريقة المربعات

الصغرى اللاخطية في تقدير معاملات الانموذج الموسمي المضاعف $ARIMA(1,1,0)(1,2,0)_2$

4- تفوق اسلوب الشبكات العصبية الاصطناعية على باقي طرائق التقدير اذ حقق هذا الاسلوب اقل متوسط مربعات خطأ .

5- تتناسق قيم بيانات السلسلة الزمنية الممثلة لدرجات الحرارة في محافظة بابل المقدرة بطريقة الشبكات العصبية الاصطناعية اكثر من بقية الطرائق.

4-2 التوصيات Recommendations

عن طريق ما تم التوصل اليه من نتائج ، أوصى الباحثان بالآتي :

1-توسيع نطاق عمل هذه الرسالة بدراسة سلاسل زمنية ذات اكثر من متغير واحد

2-استعمال المنطق الضبابي في تقدير نماذج الانحدار الذاتي والايوساط المحتركة الموسمي للوصول الى دقة اكثر في تقدير قيمة الظواهر .

3-استعمال طرائق اخرى في تقدير نماذج الانحدار الذاتي الاوساط المتحركة المضاعفة مثل طريقة العزوم وطريقة الامكان الأعظم ذات المرحلتين

4-مقارنة النماذج الموسمية المضاعفة مع نماذج أخرى مثل ARCH و CHARG.

5-استعمال الشبكات الاصطناعية المحسنة في تقدير السلاسل الزمنية .

6-استخدام أسلوب التنبؤ في درجات الحرارة في محافظة كربلاء المقدسة .

المصادر

* القرآن الكريم

المصادر العربية:

- البدراني ، ظافر رمضان مطر، صليو ، رهاد عماد صليو، (2014) ، " تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستعمال الشبكات العصبية " المجلة العراقية للعلوم الاحصائية ، (26) ، (1-19)
- التميمي ، د. رعد فاضل (2013) " الانحدار والسلاسل الزمنية أساليب إحصائية تطبيقية متقدمة باستعمال نظام **Minitab** " ، كتاب ، بغداد.
- الجبوري ، وليد دهان صليبي (2010) " التنبؤ بمستوى التضخم في أسعار المستهلك الشهرية في العراق باستعمال السلاسل الزمنية ثنائية المتغيرات" رسالة ماجستير في العلوم الإحصائية، كلية الإدارة والاقتصاد/ الجامعة المستنصرية .
- الجراح، ريم علي. (2003). "تحليل المكونات الاساسية باستعمال الشبكات العصبية الاصطناعية مع التطبيق على مرضى سرطان الثدي"، اطروحة دكتوراه، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.
- الجمال . زكريا يحيى ، العمري ، هيلاء أنس ، صالح ، فرح عبد الغني ، " استخدام بعض معايير المعلومات في تحديد افضل نموذج موسمي مضاعف" ، 2011، المجلة العراقية للعلوم الاحصائية ص ص 249-266 .
- ا
- لحافظ ، هبة سليمان داود . (2007) ، "مقارنة متكهنات بوأس - جنكنز مع بعض الأساليب الذائتية مع التطبيق " ، رسالة ماجستير، غير منشورة ، آلية علوم الحاسبات والرياضيات ، الموصل ،العراق
- الخضيرى، محمد قدوري عبد ، (1996) "دراسة مقارنة لطرائق التقدير والتنبؤ لبعض نماذج بوكس وجنكنز الموسمية " ، رسالة ماجستير احصاء، كلية الادارة والاقتصاد ، جامعة بغداد .
- الخياط ، باسل يونس ، زكي ، عزة حازم ، (2005) استخدام الشبكات العصبية في التكهن بالسلسلة الزمنية لاستهلاك الطاقة الكهربائية في مدينة الموصل " المجلة العراقية للعلوم الاحصائية (8) ، صص (76-63).
- الشخيلي، ايغان علاء ناظم. (2003). "تصميم نظام رياضي ديناميكي لاخطي باستعمال الشبكات العصبية (NARMAX) لاغراض تحليلية وتنبؤية لنشاط المبيعات في شركة كهرباء بغداد"، رسالة ماجستير، كلية الادارة والاقتصاد، جامعة بغداد، العراق.

- الصراف ، نزار مصطفى وشومان ، عبد اللطيف حسن (2013) "السلاسل الزمنية والأرقام القياسية"، دار الدكتور للعلوم الإدارية والاقتصادية ، بغداد.
- الطائي ، فاضل عباس (2010) "التنبؤ والتمهيد للسلاسل الزمنية باستعمال التحويلات مع التطبيق" بحث منشور في مجلة العراقية للعلوم الاحصائية ، العدد 17
- ا
- لطائي، فاضل عباس، الكوراني ، جيهاني فخري صالح ، " التنبؤ بنماذج ARIMA باستعمال طرائق التمهيد الاسي مع التطبيق " ، المجلة العراقية للعلوم الاحصائية ، 2008 ، (14) ص 205-171
- العمري، ضحى عوني. (2004). "استخدام شبكة التدرج المترافق في تشخيص التهاب المفصل العظمي"، رسالة ماجستير، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.
- ا
- لكسو ، ابتهاج عبدالحميد محمد علي (2005) ، " استخدام الشبكات العصبية في تقدير رتب سلاسل ماركوف مع التطبيق على سلسلة جبل بطمة في محافظة نينوى" ، اطروحة دكتوراه - كلية علوم الحاسبات والرياضيات في جامعة الموصل .
- المحمدي، ناظم عبد الله عبد ، طعمة ، سعدية عبد الكريم ، " استخدام السلاسل الزمنية الموسمية للتنبؤ باستهلاك الطاقة الكهربائية في مدينة الفلوجة" مجلة جامعة الانبار للعلوم الاقتصادية والادارية ، 2011 المجلد 4 العدد 7.
- بني خالد، مرعي حسن حمد. (2003). "دور التحليل الائتماني في الحد من تعثر القروض المصرفية دراسة ميدانية للبنوك التجارية في الاردن"، اطروحة دكتوراه، جامعة بغداد، العراق.
- خ
- لود جمال عوض الله، (2016) ، " استخدام نماذج SARIMA و Holt-Winters في التنبؤ بالسلاسل الزمنية الموسمية Using SARIMA and Holt-Winters models to forecast seasonal time series" ،رسالة ماجستير في الاحصاء ، جامعة الأزهر غزة- عمادة الدراسات العليا كلية الاقتصاد والعلوم الإدارية قسم الإحصاء التطبيقي.
- خليل، بيداء ابراهيم. (2001). "مقارنة التطبيق لبعض الشبكات العصبية الاصطناعية"، بحث ماجستير ، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.
- خلود جمال مصلح عوض الله. (2016). استخدام نماذج SARIMA و Holt-Winters في التنبؤ بالسلاسل الزمنية الموسمية. (Doctoral dissertation).

- ز
- رمان , كريم(2015) "دراسة تحليلية وتنبؤية لمعدلات الخسارة في شركات التأمينات دراسة حالة الشركة الجزائرية للتأمين الشامل CAAT بقسنطينة منذ 1995" رسالة دكتوراه, جامعة محمد خيضر بسكرة , الجزائر .
- ش
- رماط ، طاهر ، بوعيشاوي يوسف، " دراسة تنبؤية لاستهلاك الكهرباء باستعمال إنموذج الانحدار الذاتي الاوساط المتحركة الموسمي دراسة حالة مدينة المدية للفترة من 2017-2019"، مجلة بحوث الادارة والاقتصاد ، الجزائر .
 - صليو ، رهاد عماد ، مطر، ظافغر رمضان ، (2019) "مقارنة اداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية بوكس-جنكنز) مع التطبيق " المجلة العراقية للعلوم الاحصائية (828) ، ص ص (76-51).
- ط
- عمه ، سعدية عبد الكريم، (2012). "استعمال السلاسل الزمنية في للتنبؤ بإعداد المصابين بالأورام الخبيثة في محافظة الانبار"مجلة جامعة الانبار للعلوم الاقتصادية والإدارية ،مجلد 4 . العدد 8 .
 - عاشور ، مروان عبد الحميد ، (2020) ، " استخدام الشبكات العصبية الاصطناعية المحسنة ونماذج بوكس-جنكينز في تحليل السلاسل الزمنية " ، اطروحة دكتوراه ، المملكة العربية السعودية
- ف
- اندل، والتر" (1992) السلاسل الزمنية من الوجة التطبيقية ونماذج بوكس-جينكنز"، تعريب عبد المرضي حامد عزام، دار المريخ للنشر، الرياض، المملكة العربية السعودية.
- ل
- قوقي فاتح ، "جودة نماذج السلاسل الزمنية الموسمية المختلطة في التنبؤ بالمبيعات دراسة حالة مؤسسة مطاحن جديع بتقريت" ، رسالة ماجستير ، وزارة التعليم العالي والبحث العلمي الجزائر .
 - محمد ، عبد الرحمن جاسم (2014) "مقارنة بعض طرائق تحديد رتبة و تقدير معلمات إنموذج (ARX) مع تطبيق عملي على سعر صرف الدينار العراقي" ، رسالة ماجستير في الاحصاء ، كلية الإدارة والاقتصاد/جامعة بغداد.
- م
- حمد عبدالرحمن جاد الله أب ولبدة،(2017) " استخدام نماذج ARIMAX في التنبؤ بالسلاسل

الزمنية" ، جامعة الأزهر-غزة عمادة الدراسات العليا كلية الاقتصاد والعلوم الإدارية برنامج
ماجستير الإحصاء.

المصادر الأجنبية:

- shour, M. A. H., Al-Dahhan, I. A. H., & Hassan, A. K. (2020, April). Forecasting by using the optimal time series method. In International Conference on Human Interaction and Emerging Technologies (pp. 148-154). Springer, Cham. A
- erson O.D., (1976), "Time series analysis and forecasting" , Butter worths , London and Boston. d
- ox , Georg E.P and Jenkins , Gwilym M. and Reinsel ,Gregory C. (2013) Time Series Analysis for casting and Control. B
- ox ,G.E.P. & Jenkins ,G.M.(2008).Time Series Analysis:Forecasting and Control . Holden – Day . Sanfransco . USA . B
- ox G. , E. , P. , and Jenkins G. , M. , T. (1976) , " Time Series Analysis B
- heng, Xiaoyu, (2014), " Applications of Artificial Neural Networks (ANNs) in exploring materials property-property correlations" , a theses of the Degree of Doctor of Philosophy at University of London . C
- Chong, Edwin K. P, Zak, Stanislaw H. (2001). "An Introduction to Optimization"2nd Ed., John Wiley and Sons, Inc., New York.
- omwpertwait Paul.S.P. & Metcalf Andrew.V., (2009). " Introduction to Time Series with Rn " ,Spring, New York. Forecasting and Control " , San Francisco , Holden-Day , U.S.A. C
- ajdu, Gergo, Minoso, Yaclaudes, Rafael, Lopez, Acosta, Miguel, Elleithy, Abdelrahman, (2019) , "Use of Artificial Neural Networks to Identify Fake H
- arba , M.I.A. , (1981) , " Signal Processing & Digital Computer Techniques Applied To Surface Electromyography Ph.D. Dissertation University Of Bristol . H
- ossein Hassani, Mohammad Reza Yeganegi,(2019), "Selecting optimal lag order in Ljung–Box test" , Physica A 541 (2020) 123700 H
- dowu, Peter Adebayo, Osakwe, Chris, Anthonia, Aderonke Kayode, Adagunodo, Rotimi , Emmanuel , (2012) , "Prediction of Stock Market in Nigeria Using Artificial Neural Network" , I.J. Intelligent Systems and I

Applications, 2012, 11, 68-74 Published Online October 2012 in MECS (<http://www.mecs-press.org/>) DOI: 10.5815/ijisa.

- M
Gupta1Madan, Bukovsky, Ivo, Homma, Noriyasu, G. Solo ,Ashu M., and Zeng-Guang Hou5 (2006), " Fundamentals of Higher Order Neural Networksfor Modeling and Simulation",
- M
akridakis , S. , Wheel Wright S. , C. , and McGee (1983) , " Forecasting
- M
engqing Qin, (2019),"Seasonal Time Series Models with Application o Weather and Lake Level Data", Missouri State University, Mengqing1214@live.missouristate.edu , Method and Application " , 2nd ed , John Wily and Sons. Inc. U.S.A. .Methods. Addison-Wesley publishing company. USA.
- M
oreno, S., Bialystok, E., Barac, R., Schellenberg, E. G., Cepeda, N. J., & Chau, T. (2011). Short-term music training enhances verbal intelligence and executive function. *Psychological science*, 22(11), 1425-1433. oreno, J. J.M., Pol, A. P., Gracia, P. M. (2011). " Artificial Neural Networks Applied to Forecasting time series " , Universidad de las Islas Baleares & Universidad Politecnica de Cataluna, Vol.23-No. 2, PP. 322-329, ISSN 0214 – 9915 .
- M
oreno, J. J.M., Pol, A. P., Gracia, P. M. (2011). " Artificial Neural Networks Applied to Forecasting time series " , Universidad de las Islas Baleares & Universidad Politecnica de Cataluna, Vol.23-No. 2, PP. 322-329, ISSN 0214 – 9915 .
- N
egnevitsky, M. (2011). "Artificial Intelligence", 3rd ed., University of Tasmania, ISBN 978-1-4082-2574-5 .
- P
alma ,W. (2007).Long – Memory Time Series:Theory & Methods. John – Wiley & Sons , Inc. , Puplication . USA .
- Principe, Jese C., Euliano, Neil R. and Lefebvre, W. Curt. (2000): “Neural and Adaptive Systems: Fundamentals through Simulation “, John Wiley and Sons INC, New York.
- P
rofiles" , Department of Computer Science William Paterson UniversityWayne, NJ, USA.
- R
ajae AZRAK and Guy MÉLARD, 2013, "EXACT MAXIMUM LIKELIHOOD ESTIMATION FOR EXTENDED ARIMA MODELS", Boulevard du Triomphe, B-1050 BELGIUM, DOI: 10.1007/978-1-4899-4515-0_9

- eisen , V. , Abraham , B. and Lopes , S.(2001).” Estimation Paramerters in ARFIMA Processes : A Simulation Study “ . *Communications in Statistics – Simulation and computation* . Vol.30 , Issue 4 . R
- eisen , V. , Abraham , B. and Lopes , S.(2001).” Estimation Paramerters in ARFIMA Processes : A Simulation Study “ . *Communications in Statistics – Simulation and computation* . Vol.30 , Issue 4 R
- Shen, H. Y. and Chang, L. C. (2013), " Online multistep-ahead inundation depth forecasts by recurrent NARX networks ", Published: 5 March 2013 , PP. 935–945.
- humway Robert H. & Stoffer David .S., Springer ,(2006) . "Time Series Analysis and its Applications with R Examples", 2nd edition , Science & Business Media , LLC,US. S
- say , R.S. (2005) . Analysis of Fractional Time Series . Second Edition , John – Wiley and Sons , Inc. , USA . T
- ucker McElroy and Brian Monsell, (2014), " The multiple testing problem for Box-Pierce statistics" , Electronic Journal of Statistics Vol. 8 (2014) 497–522 ISSN: 1935-7524. T
- ikas Chaurasia & Saurabh Pal, (2020), "Application of machine learning time series analysis for prediction COVID-19 pandemic", Research on Biomedical Engineering <https://doi.org/10.1007/s42600-020-00105-4> V
- AFAA A. M. EID, (2017), " ADDRESSING SEASONAL VARIATIONS TO PREDICT CONSUMER PRICES OF RED MEAT', Egypt. J. Agric. Res., 96 (2), 2018 W
- ang, Shengwei, Feng, Juan, Liu ,Gang , (2013). "Application of seasonal time series model in the precipitation forecast", Mathematical and Computer Modeling 58 (2013) 677–683 W
- ei , William , W.S ,1989,"Time Serias Analysis Univarite and Multivariate Methods ",Addison , Wesley publishing Company. W
- ei, W. W. S., (1990), Time Series Analysis: Univariate and Multivariate W

الملاحق

ملحق (A) البيانات التطبيقية لسلسلة درجات الحرارة في محافظة بابل-مركز قضاء الحلة

12.3	23.7	34.4	23.4
12.9	21.7	35	23.5
13.2	21.6	35.3	22.7
11.7	22.5	35.7	19.7
12.4	24.3	36.1	20
14.4	25.6	37.1	21.2
10.6	21.9	34.4	22.7
10.4	21.1	34.9	23.1
11.7	21.2	34	20.6
8.7	19	35.9	21.5
7.6	20.7	35.9	19.8
8.3	17.2	35.7	19.4
11.4	18.8	36.7	18.2
12.3	18.8	35.8	18.2
11.2	19.7	35.2	18.4
11.5	20.9	34.8	18.5
11.9	22.3	34.9	19.2
8	23.6	36.3	20
6.2	24.8	36.3	19.6
7.2	23.8	35.5	18.4
9.1	27.1	33.8	14.4
9.1	28.9	33.9	14.7
10.1	29.1	34.8	12.6
10.9	25.8	36.1	13.2
14.9	24.2	38.8	12.9
14.7	26	38.3	13.8
16	29.5	37	14.1
14.9	28.6	34.9	14.6
12.7	25.5	33.2	16.3
12	25	34.1	16.2
14.1	25.6	34.1	17.3
14	28.6	35.4	18.1
13.1	31.4	35	17.5
11.5	31.6	34.9	17.1
11.6	32	34.6	
11.2	31	36.3	
11.6	32.1	36.3	
12	31.2	36.6	
14.2	32.1	37.8	
13.3	30.7	37.8	

12.4	30.5	36.8	
12.2	30.4	36.4	
12.3	31.2	35.4	
12.3	32.6	33.8	
14	34.5	33.6	
13.6	34.3	33.3	
11.5	33	33.4	
13.5	34.1	33.5	
12.2	33.9	33.7	
12.1	33.6	32.3	
13.2	33.2	31.6	
13.9	32.7	31.7	
14.9	33.5	31.4	
14.8	34.3	31	
15.6	36.2	31	
15.1	36	31.4	
16.6	36.2	32.3	
17.1	35.5	34.5	
16.6	36.1	33.2	
11.9	36.7	34	
12	37	32.6	
14	35.9	30.7	
15.2	33.6	31.9	
16.7	34.5	33.2	
16.7	34.2	31.8	
16.3	35.5	30.4	
11.7	36.7	30.8	
14.4	34.8	31.3	
15.3	34	34.1	
15.8	33.1	31.2	
16.4	33.1	31.4	
18.9	32.8	31.2	
17.4	33.5	30.7	
15.6	33.8	30.8	
18.9	35.4	33.5	
16	35.9	33.1	
15	36.6	28.3	
15.8	36.5	27.5	
16.3	36	28.6	
15.7	35.2	29.6	
17	35	30.4	
17.8	34.3	31.1	
16	34.4	31.2	

19.4	34.9	30.2	
16.6	33.7	30.7	
17.4	34.4	30.5	
17.2	34.9	27.8	
19	34.6	26.8	
21	34.8	26.6	
20	34.6	28.3	
14.4	35	28.6	
17	35.1	28.5	
19.4	35.4	28.6	
21	34.5	27.6	
21.2	33.8	24.9	
20.2	35	23.6	
21.1	33.5	22.5	
22.3	33.8	20	
23.5	34.8	21.9	
24.5	33.8	23.3	


```
estttest=sim(netopt{nn},ptest);
pval=p(:,tropt(nn).valInd);
tval=t(:,tropt(nn).valInd);
estval=sim(netopt{nn},pval);
estwhole=sim(netopt{nn},p);
% ttrain=exp(ttrain); ttest=exp(ttest);
tval=exp(tval); t=exp(t);
% estttrain=exp(estttrain);
estttest=exp(estttest);
estval=exp(estval);
estwhole=exp(estwhole);
figure; plot(ttrain,estttrain,'.b'); %train data: ttrain: real and
estttrain: estimated
figure; plot(tval,estval,'.g'); %validation
figure; plot(ttest,estttest,'.r'); %test
figure; plot(t,estwhole,'.k') %whole figure;
plotregression(ttrain,estttrain,'Train',tval,estval,'Validation',ttest,es
ttest,'Test',t,estwhole,'Whole Data');
%% *****%%
```

In this thesis, the series of daily temperatures recorded in the center of Hilla District / Babylon Governorate for the year (2020), which included (334) observations, which were obtained from the Iraqi Meteorological Authority, was analyzed using autoregressive models of seasonal moving averages SARIMA and autoregressive models of multiple moving averages. Seasonality based on ready-made programs (Minitab 17, Matlab 2015, E-views 10) with the aim of diagnosing the best seasonal model for the time series from a set of models that have been reconciled, and then choosing the best model from these models using the comparison criteria between models (AIC, BIC, SMAIC).) And then estimating the diagnosed model using three methods of estimation, which are the approximate maximum possibility method, the exact maximum possibility method, and the nonlinear least squares method, and then comparing these methods using the statistical criterion, the mean squares of error, to reach the best one. And then compare the method of artificial neural networks with the rest of the methods. It was concluded that the doubled seasonal model $ARIMA(p,q,d) \times (P,Q,D)_2$ as a representative model for the seasonal time series under study, as well as the multiple seasonal model of the rank $ARIMA(1,1,0) \times (1,2,0)_2$ as the best seasonal model for the temperature series. The approximate maximum possibility method outperformed the exact maximum possibility method and the nonlinear least squares method in estimating the parameters of the multiplicative seasonal model $ARIMA(1,1,0) \times (1,2,0)_2$. It has been shown that the artificial neural networks method is better than the rest of the estimation methods based on the MSE standard.

Republic of Iraq
Ministry of Higher Education
And Scientific Research
University of Karbala
Faculty of Management and
Economics
Department of Statistics



Diagnosis and estimation of seasonal time-series models with practical application

**A thesis submitted to the council of the college of
Administration & Economics\ University of Karbala as
partial fulfillment of the requirements for the degree of
Master of Statistics Sciences**

By

Karrar Hamza Hussein Ali Al-Morshedy

Supervised by

Ass. Prof. Dr . Enas Abdel Hafez Mohammed

A.H. 1443

A.D. 2021

Holy Karbala