

# استخدام نماذج السلسلة الزمنية الهجينه وغير الهجينه للتتبؤ بإعتماد المسافرين لمطار بغداد الدولي

\*\* علي احمد حسن

\* أ.م.د. بشينة عبد الجادر عبد العزيز

## المستخلص

يعد التنبؤ في السلاسل الزمنية من الموضوعات المهمة في الأساليب الأحصائية ولكلفة المجالات الحيوية إذ يساعد الإدارات في التخطيط الاقتصادي والستراتيجي وإتخاذ القرارات المستقبلية ، لذا تناول هذا البحث دراسة لاستخدام نماذج السلاسل الزمنية الهجينه المتولدة من دمج نموذج ARIMA مع نموذج الشبكات العصبية المتعددة الطبقات او بالعكس على فرض أن السلسلة تتضمن المركبتين الخطية وغير الخطية اذ يستعمل نموذج ARIMA لتمثيل المركبة الخطية للسلسلة الزمنية وأنموذج الشبكات العصبية المتعددة الطبقات لتمثيل المركبة غير الخطية للسلسلة اذ أن الأنماذج الهجين الأول (ARIMA-ANN) والثاني (ANN-ARIMA) وقد تم استخدام هذين النماذجين مع النماذج المفردة للتتبؤ بأعداد المسافرين في مطار بغداد الدولي لغرض المقارنة بين هذه النماذج من خلال جملة من المقاييس الأحصائية وقد اظهرت النتائج المستخرجة تفوق الأنماذج الهجين (ANN-ARIMA) على النماذج الأخرى لأمتلاكه أقل القيم لهذه المقاييس وقد تم استخدامه لحساب التنبؤات المستقبلية لأعداد المسافرين للفترة الزمنية من أولول 2015 ولغاية كانون الأول 2016 وبشكل شهري ، وقد تم تحليل البيانات وأستخراج النتائج بالأعتماد على البرامج الأحصائية الجاهزة (Minitab 16 , SPSS 19) .

## Abstract

*Prediction in time series is one of the most important topics in statistical procedures and all vital areas it can help managements in the economic and strategic planning and decision-making . This research use time series hybrid models generated from the integration of Box- Jenkins (ARIMA) model and multi-layered neural networks as The first hybrid model (ARIMA-ANN) and second (ANN-ARIMA) model and assuming series includes two components linear and non-linear with the single models such as Box- Jenkins model in which time series is a linear combination , and multi-layered neural networks in which time series has a nonlinear combination to predict the number of passengers in International Baghdad Airport , when comparing these models through a number of statistical criteria ,they show that the hybrid model (ANN-ARIMA) is the superior model because it has lower values of these criteria , and it has been used to calculate the prediction of passenger numbers for the time period from September 2015 until December 2016 , where the data were analyzed and the results were obtained based on the statistical programs package (Minitab 16 , SPSS 19) .*

\* الجامعة المستنصرية / كلية الادارة والاقتصاد .

\*\* باحث .

مقبول للنشر بتاريخ 28/12/2015

مستنـى من رسـالـة ماجـسـتـير

## المقدمة Introduction

نظراً للتطور والنمو السكاني الحاصل في العراق وإردياد حركة السياحة الدينية والترفيهية في الأونة الأخيرة فقد تم التطرق إلى موضوع التنبؤ لأعداد المسافرين لمطار بغداد الدولي لاكتسابه أهمية كبيرة من حيث حركة المسافرين فيه ، حيث أن المنشأة العامة للطيران المدني شأنها شأن كافة الدوائر والمؤسسات الحكومية تحتاج إلى تنبؤات دقيقة لحركة المسافرين والتي تساعدها في عملية ادارة المطار والتخطيط المستقبل للخدمات المقدمة وال الحاجة لأشياء مطارات أخرى وحسب الحاجة التي تبيّنها حركة المسافرين .

توجد اساليب احصائية كثيرة تستخدمن لحساب التنبؤات المستقبلية ظاهرة معينة حيث أهتم الكثير من الباحثين الأحصائيين بدراسة تحليل السلسلة الزمنية إذ تم وضع أنموذج خطى لها وآخر غير خطى لتمثيل السلسلة كأنموذج بوكس- جنكينز وأنموذج الشبكات العصبية على التوالي ، والتنبؤ بقيمها المستقبلية ، وقد شاع استخدام هذه النماذج في مجالات حيوية مختلفة ، إذ ساعدت البرامج الأحصائية الجاهزة مثل (MINITAB,SPSS) وغيرها من استعمال هذه النماذج .

وفي الوقت نفسه ظهرت بحوث ودراسات أخرى تهتم بتنبؤات السلسلة الزمنية تؤيد فكرة دمج الأنماذج الخطى (Linear model) مع الأنماذج غير الخطى (Non-Linear model) لأنماذج جديده هو الأنماذج الهجين واستخدامه لأيجاد تنبؤات دقيقة للسلسلة ، أن فكرة الدمج بين الأنماذج الخطى وغير الخطى متأتية من الافتراض بأن الأنماذج المفرد (single model) لا يمكن أن يوظف البيانات الحقيقية لهذه السلسلة إذ أن الأنماذج المفرد ربما يكون غير قادر لتشخيص كل الخواص والمميزات (characteristic) للسلسلة الزمنية ، فالسلسلة الزمنية ربما تتضمن كلا المركيتين الخطية وغير الخطية خلال مدة من الزمن وفي هذه الحالة لايمكن للأنموذج الخطى وغير الخطى أن يعالج هاتين المركيتين معاً ، لذا تم اقتراح تقنية جديدة الأ وهي النماذج الهجينة (Hybrid models) .

درس عدد من الباحثين مسألة الدمج بين النماذج الخطية (Linear models) المستخدمة لتمثيل السلسلة الزمنية الخطية كنماذج بوكس- جنكينز مع النماذج غير الخطية (Non-Linear models) المستخدمة لتمثيل السلسلة الزمنية غير الخطية كنماذج الشبكات العصبية الأصطناعية (ANN) لأنماذج الهجينة (Hybrid models) ، وذلك للحصول على أفضل وادق التنبؤات المستقبلية للسلسلة الزمنية ، واهم وابرز البحوث والدراسات الحديثة التي تناولت هذه النماذج من قبل الباحث (Zhang<sup>{16}</sup>) وبالباحثين (Šterba Ján and Hilovsda Katarína)<sup>{14}</sup> (N.Merh)<sup>{13}</sup> وآخرين<sup>{13}</sup> وبالباحثين (Zheng and Zhong)<sup>{6}</sup> غيرهم من الباحثين .

## هدف البحث Objective of Research

يهدف البحث إلى دراسة النماذج الهجينة وغير الهجينة للسلسلة الزمنية وتحديد الأنماذج الأفضل واستعماله للتنبؤ بأعداد المسافرين لمطار بغداد الدولي بالأعتماد على جملة من المقاييس الأحصائية (MAD, RMSE , SEP , MAPE , MAE) .

## الجانب النظري

### 1. الأنماذج الهجينة Hybrid Model<sup>{13},{16}</sup>

أن الأنماذج الهجينة الذي سيتم دراسته هو الأنماذج الناتج والمتولد من دمج أنماذج خطى مع آخر غير خطى للسلسلة وبالعكس لغرض تحسين التنبؤات المستقبلية للسلسلة على افتراض أن السلسلة الزمنية  $Z_t$  مؤلفة من مرکيتين الأولى خطية (L) والثانية غير خطية (N) Non-Linear(N) ، وكما موضح بالمعادلة الآتية:-

$$Z_t = L + N \quad t = 1, 2, 3, 4, \dots \quad (1)$$

إذ أن  $Z_t$  : تمثل السلسلة الزمنية .

$L$  : تمثل المركبة الخطية في السلسلة الزمنية ،  $N$  : تمثل المركبة غير الخطية في السلسلة الزمنية .

إذ سيتم دراسة نوعين من النماذج الهجينة المتولدة بهذه الطريقة وهي كالتالي :-

#### 1.1. الأنماذج الهجينة Hybrid Model (ARIMA-ANN) (ARIMA-ANN)

بافتراض السلسلة الزمنية مؤلفة من بنية الارتباط الذاتي الخطى والعنصر غير الخطى ، ولتحليل هذه السلسلة باستخدام الأنماذج الهجينة يكون بمرحلتين :-

المرحلة الأولى :

يتم استخدام احد نماذج (ARIMA) لتمثيل الجزء الخطى للسلسلة الزمنية ومن ثم حساب التنبؤات ، وأن الأخطاء العشوائية المقدرة (البواقي) المستخرجة من أنماذج ARIMA إذ ان هذه البواقي تكون ضرورية جداً لتدقيق تشخيص الأنماذج الخطى .

أن الباحث (Zhang) هو أول من طرح فكرة دمج هذين الأنماذجين وسار عليه الباحثون الآخرون لذا فاعن هذه البوافي بأعتبرها الجزء غير الخطى للسلسلة إذ تمثل بأنموذج الشبكات العصبية المتعددة الطبقات لحساب التنبؤات لها.

إذ أن هذه البوافي تحسب من المعادلة الآتية :

$$a_t = Z_t - \hat{Z}_t, \dots \quad (2)$$

إذ أن  $\hat{Z}$  : تمثل تقديرات السلسلة الزمنية باستخدام أنموذج ARIMA .  $a_t$  : تمثل البوافي .  
أن هذه البوافي (الأخطاء العشوائية) تمثل المركبة غير الخطية (N) للسلسلة التي يتم تمثيلها بأنموذج الشبكات العصبية المتعددة الطبقات ( ANN ) للحصول على القيم المتوقعة لها وكما في المعادلة الآتية:  
 $N = f(a_{t-1}, a_{t-2}, \dots, a_{t-p}) + \varepsilon_t, \dots \quad (3)$

إذ أن  $\varepsilon$  : الخطأ العشوائي ،  $f$  : دالة غير خطية تحدد من خلال الشبكة العصبية .

المرحلة الثانية :

في هذه المرحلة يتم جمع القيم المتتبلا بها للسلسلة بواسطة أنموذج (ARIMA) مع توقعات البوافي التي تم حسابها من قبل أنموذج (ANN) ، والتي بدورها تنتج القيمة المتوقعة النهائية للسلسلة الزمنية كما في المعادلة الآتية:  $\hat{Z}_t = \hat{L} + \hat{N} \quad (4)$

**2.1. الأنماذج الهجين (Hybrid Model) (ANN-ARIMA) (ANN-ARIMA)**  
هذا النوع من النماذج الهجين يتكون من مرحلتين ولكن عكس الأنماذج الهجين السابق إذ يكون في:

المرحلة الأولى :

يتم استخدام أنماذج الشبكات العصبية الصناعية (ANN) لتمثيل الجزء غير الخطى للسلسلة الزمنية ومن ثم التنبؤ بالقيم المستقبلية ثم تستخرج البوافي من أنموذج الشبكة العصبية وتمثيلها بأنموذج (ARIMA) وحساب القيم التنبؤية للأخطاء كما مبين أدناه :

المركبة غير الخطية (N) تمثل بأنموذج الشبكات العصبية الصناعية (ANN) وحسب المعادلة الآتية .  
 $N = f(Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}) + a_t, \dots \quad (5)$

إذ أن  $\hat{N}$  : تمثل تقديرات أنماذج الشبكات العصبية الصناعية (ANN) .  
أن البوافي المستخرجة ( $a_t$ ) تمثل المركبة الخطية (L) للسلسلة الزمنية التي يتم تمثيلها بأنموذج ARIMA وحساب القيم المتتبلا بها .

المرحلة الثانية :

يتم جمع القيم التي تم التنبؤ بها بواسطة (ANN) مع القيم المتتبلا بها للأخطاء التي تم حسابها من قبل أنموذج (ARIMA) ، والتي بدورها تنتج القيمة المتوقعة النهائية للسلسلة الزمنية كما في المعادلة الآتية(4).

**2. تمثيل المركبة الخطية للسلسلة الزمنية بأنموذج ARIMA**  
تعد نماذج بوكس- جنكينز من الأساليب الأحصائية المهمة إذ تستخدم لتمثيل بيانات سلسلة زمنية لظاهرة معينة والتنبؤ بقيمها المستقبلية، وتكون على نوعين وفق استقرارية السلسلة الزمنية

## 2.1. نماذج السلسلات الزمنية المستقرة أنموذج الأندار الذاتي والأوساط المتحركة

{11} Autoregressive– Moving average model

أن هذا الأنماذج يجمع بين أنموذجي الأندار الذاتي(AR) والأوساط المتحركة(MA) إذ يرمز له بالرمز ARMA(p,q)، والصيغة العامة لهذا الأنماذج كالآتي :

$$Z_t = \theta_0 Z_{t-1} + \dots + \theta_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \dots \quad (6)$$

إذ أن  $\theta_0, \dots, \theta_p$ : تمثل معلمات أنماذج الأندار الذاتي،( $p$ ): رتبة الأندار الذاتي  
 $\theta_1, \dots, \theta_q$  : تمثل معلمات أنماذج الأوساط المتحركة،( $q$ ): رتبة المتوسطات المتحركة  
 $a_t$ : يمثل الخطأ العشوائي الذي يطلق عليها بالتشويش الأبيض ( White noise ) و يتوزع بمتوسط صفر و تباين  $\sigma_a^2$  .

وعندما تكون  $(q=0)$  نحصل على أنموذج الأحدار الذاتي  $AR(p)$  وعندما  $(p=0)$  نحصل على أنموذج الأوساط المتحركة  $MA(q)$ .

## 2.2. نماذج السلسلات الزمنية غير المستقرة<sup>{15}</sup>

### أنموذج الأحدار الذاتي والأوساط المتحركة التكمالي

<sup>{11}</sup> Autoregressive integrated Moving average model

عندما تكون السلسلة الزمنية غير مستقرة يمكن تحويلها إلى سلسلة مستقرة بأخذ الفروق من الدرجة  $d$  عندئذ يرمز له بالرمز ARIMA(p,d,q) وتكتب معادلته :

$$\theta(B)(1-B)^d Z_t = \theta(B)a_t, \dots \quad (7)$$

إذ أن : (d) : درجة الفرق المأخوذ للسلسلة الزمنية ، (B) : عامل الأرتداد الخلفي

### 3. مراحل بناء أنموذج السلسلة الزمنية<sup>{11}</sup>

أن مراحل بناء الأنموذج هي كما يلي :-

#### 1.3 المرحلة الأولى: التشخيص<sup>{15}</sup>

تم مرحلة تشخيص أنموذج السلسلة الزمنية المستقرة من خلال :

1. دالة الارتباط الذاتي والأرتباط الذاتي الجزئي

#### 2. دالة الارتباط الذاتي الموسعة للعينة The Extended Sample Autocorrelation Function

و عند فشل الأساليب اعلاه في تشخيص الأنموذج نلجا الى الاعتماد على المقاييس الآتية:

معيار اكيكي (AIC)<sup>{15}</sup> Akaikie Information

وهو معيار يستخدم لتشخيص درجة الأنموذج ARMA(p,q) وحسب الصيغة الآتية .

$$AIC = n \ln(\hat{\sigma}_a^2) + 2m, \dots \quad (8)$$

إذ أن m : عدد المعلمات في الأنموذج، n : عدد المشاهدات ،  $\hat{\sigma}_a^2$  : تباين الباقي

معيار شوارز (SC) Schwarz Criterion<sup>{15}</sup>

ويعرف أيضاً بمعيار Beyeson Information Criterion (BIC) وحسب الصيغة الآتية:-

$$BIC(m) = n \ln(\hat{\sigma}_a^2) + m \ln(n), \dots \quad (9)$$

ولقد اقترح كل من (Brock Well and Davis . 1993) تصحيح حالة التحيز في معيار (AIC) فأصبح :

$$AIC_c(m) = n \ln(\hat{\sigma}_a^2) + \frac{2mn}{(n - m - 1)}, \dots \quad (10)$$

ووفق هذه المعايير فإن الأنموذج الأفضل هو الأنموذج الذي يعطي أقل قيمة من AIC(m) و  $AIC_c(m)$  و  $BIC(m)$ .

### 2.3 المرحلة الثانية : التقدير<sup>{4} {15}</sup> Estimation

بعد أن تم التعرف على الأنموذج المقترن الذي يمثل بيانات السلسلة الزمنية قيد الدراسة وتحديد الرتبة المناسبة له ، يتم تقدير معلمات الأنموذج المختار، وهناك عدة طرائق للتقدير منها طريقة الأمكان الأعظم (Maximum likelihood).

#### 3.3 المرحلة الثالثة : دقة التشخيص<sup>{11}</sup> Diagnostic checking

لفرض تدقيق صحة الأنموذج المقترن لممثل بيانات السلسلة الزمنية تستخرج الباقي والتي ينبغي أن تكون متغيرات عشوائية غير مترابطة عندئذ تكون فرضية عدم .

$$H_0: \rho = 0, \dots \quad (11)$$

ولاختبار هذه الفرضية ينبغي استخراج مايلي :

<sup>{11}</sup> 1.3.3 احصاءة Box-Ljung(Q)

ولقد قام كل من (Ljung , G.M&Box,G.E.P.) بتعديل صيغة اختبار Q الأصلية بالشكل الآتي

$$Q = n(n+2) \sum_{k=1}^m (n-k)^{-1} r_k^2(\hat{a}) \sim \chi^2_{(m)}, \dots, k=1, \dots, m \quad (12)$$

إذ ان : n : يمثل عدد المشاهدات للأنموذج الشخص ، و:  $n = N - d$

N : عدد المشاهدات الأصلية للسلسلة الزمنية ، m : تمثل  $\sqrt{n}$  و d معرفة سابقا.

إذا كانت معاملات الارتباط الذاتي للباقي واقعة ضمن حدود الثقة بأحتمال 95% أي أن:

$$-1.96 \frac{1}{\sqrt{n}} \leq \hat{r}_k(\hat{a}) \leq 1.96 \frac{1}{\sqrt{n}}, \dots \quad (13)$$

### 4.3. المرحلة الرابعة : التنبؤ Forecasting <sup>{4}</sup>

أن أحد الأهداف الأساسية لتحليل السلسلة الزمنية هو التنبؤ ، فمثلاً إذا أردنا التنبؤ بقيمة السلسلة الزمنية في الفترة  $(t+L)$  والتي هي  $\hat{Z}_t^L$  إذ تستخرج هذه القيمة باخذ التوقع الشرطي إلى  $Z_t^L$  عن الزمان  $(L+1)$  .

$$\hat{Z}_t^L = E_t(Z_{t+L} | Z_1, Z_2, Z_3, \dots, Z_n), \dots \quad (14)$$

الذي يجب أن يكون له أقل متوسط مربعات خطاء التنبؤ (M.M.S.E.F.) والذي يساوي

$$M.M.S.E.F = \sigma_a^2 \left\{ 1 + \sum_{j=1}^{L-1} \varphi_j^2 \right\}, \dots \quad (15)$$

إذ أن  $\varphi_j$  :- تمثل معلمات الأنماذج عند كتابته بصيغة الأخطاء العشوائية .

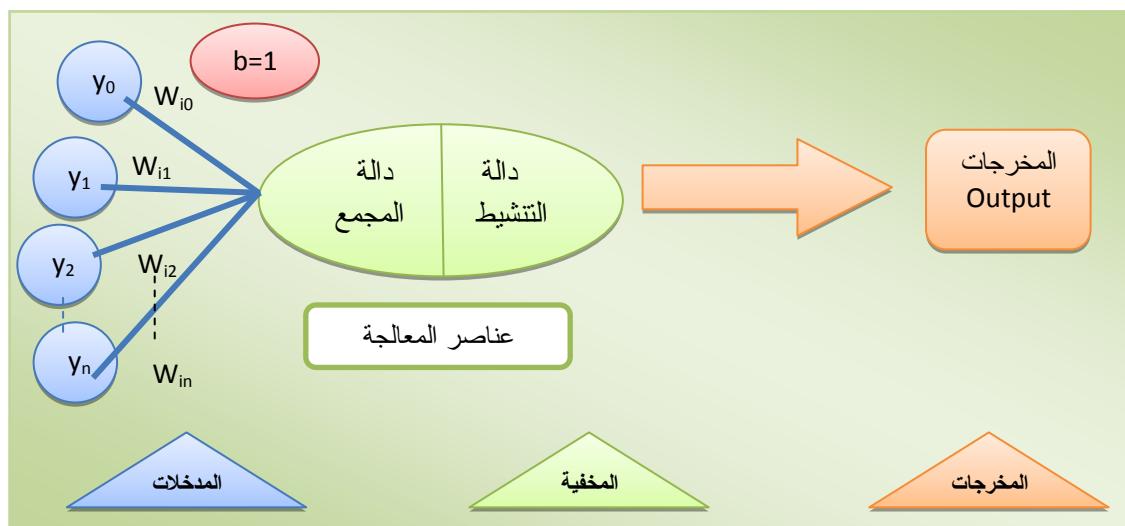
### 4. تمثيل المركبة غير الخطية للسلسلة الزمنية بـأنموذج الشبكات العصبية المتعددة الطبقات

#### 1.4. الشبكة العصبية الأصطناعية <sup>{1},{12}</sup> Artificial Neural Network

تعرف الشبكة العصبية الأصطناعية (ANN) على أنها نظام حسابي مكون من عدد من وحدات (عصيونات) المعالجة (Processing Elements) المترابطة مع بعضها وتتصف بطبيعتها الديناميكية والمترابطة في معالجة البيانات الداخلة إليها ، أن فكرة عمل الشبكات العصبية الأصطناعية هو محاكاة البيانات للوصول إلى أنموذج لهذه البيانات لغرض التحليل أو التنبؤ أو أي معالجة أخرى دون الحاجة إلى أنموذج مقتراح لهذه البيانات ، أن الشبكات العصبية الأصطناعية هي تقنيات حسابية مصممة لمحاكاة الطريقة التي يبدي بها الدماغ البشري مهمة معينة وذلك عن طريق معالجة ضخمة موزعة على التوازي ومكونة من وحدات معالجة بسيطة ، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصيونات أو عقد (Nodes , Neurons) والتي لها خاصية عصبية وكما في الشكل الآتي .

الشكل (1)

يوضح مفهوم بسيط للشبكة العصبية الأصطناعية



ويمكن الملاحظة من خلال الشكل (1) أن الشبكة العصبية الأصطناعية تتكون من عناصر المعالجة التي تحتوي على جزئين هما :

#### الأول - دالة المجموع Sum function

وتحدد طريقة وصيغة ادخال المعلومات إلى الشبكة العصبية والتي تعرف بالمدخلات وغالباً ماتكون عبارة عن تركيبة خطية (Linear combination) بدلالة الأوزان وتوصف :-

$$n = b + \sum_{j=1}^R w_j y_j, \dots \quad (16)$$

إذ أن  $n$  :- نتائج مدخلات التركيبة الخطية ،  $b$  :- الحد المطلق (bias)  $w_j$  :- الأوزان المرتبطة بالمدخلات وهي تقابل المعلمات في أنموذج الأحداث  $y_j$  تمثل متغيرات الأدخلات

### الثاني - دالة التنشيط Activation Functions<sup>{10}</sup>

تعرف بدالة التحويل (Transfer Function) لأنها تقوم بتحويل المدخلات عبر تفاعلها مع الأوزان من صيغة إلى أخرى وتكون منها الخطية وغير الخطية ومنها الدوال الشائعة الاستخدام هي :-

#### الدالة اللوجستية Log-Sigmoid Function

تعد هذه الدالة الأكثر استخداماً عند عقد الطبقة المخفية للشبكة التي مدخلاتها ذات قيم حقيقية بين (-∞, ∞) أما مخرجاتها لكل عقد تكون بين (0,1) والصيغة الرياضية لها هي :

$$f(x) = \frac{1}{1 + exp(-x)}, \dots \quad (17)$$

$$f'(x) = f(x)[1 - f(x)], \dots \quad (18)$$

ومشتقتها

#### الدالة الخطية The Linear Function

تستخدم هذه الدالة عند طبقة الأخرج في حالة التنبؤ وصيغتها :-

$$Output = R(Net), \dots \quad (19)$$

$$Net = X_1W_1 + X_2W_2 + \dots + X_nW_n, \dots \quad (20)$$

إذ أن (R) :- دالة تنشيط خطية .

### 2.4. معالجة البيانات Data Normalization<sup>{7}</sup>

هي عملية تهيئة البيانات قبل معالجتها (Pre – Processing) لاستخدامها في عملية تدريب الشبكة العصبية، وتوجد عدة طرق للتهيئة منها :-

#### الصيغة المعيارية Standardized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط في عقد الأخرج هي الدالة الخطية وحسب الصيغة الآتية.

$$X_{new} = \frac{X - \bar{X}}{S}, \dots \quad (21)$$

إذ أن  $\bar{X}$  :- الوسط الحسابي ، S :- الاتحراف المعياري

### 3.4. الشبكات العصبية المتعددة الطبقات Multi-layered neural networks<sup>{1}, {7}</sup>

تتكون هذه الشبكات من طبقة واحدة أو أكثر من الطبقات المخفية (Hidden Layer) التي بدورها تحتوي على عدد من العقد المخفية (Hidden Nodes) ، ويمكن أن يبين أن الشبكة العصبية الأصطناعية تتكون من ثلاثة مستويات وهي :-

#### مستوى المدخلات (Inputs Level) :

يمثل المستوى الأول في الشبكة ويحتوي على عدد من العقد التي تمثل عدد المتغيرات المفسرة (المدخلات) ويتم فيه تلقي المعلومات المطلوب معالجتها .

#### المستوى المخفي (Hidden Level) :

يمثل المستوى الثاني للشبكة العصبية والذي يلي المستوى الأول (مستوى المدخلات) وقد يحتوي على عدد من العقد المخفية (Hidden Nodes) وكل عقد وزن يربطها مع المستوى السابق (مستوى المدخلات) وزن يربطها مع المستوى اللاحق (مستوى المخرجات).

#### مستوى المخرجات (Output Level) :

يمثل المستوى الأخير في الشبكة العصبية الأصطناعية الذي هو عبارة عن مخرجات الشبكة العصبية ويمكن أن يكون للناتج عقدة واحدة أو أكثر .

### 4.4. عمل الشبكة العصبية متعددة الطبقات Work of Multi-layered N.N.<sup>{9}</sup>

أن القيمة المراد التنبؤ بها والتي يطلق عليها بالنتائج (output) يمكن أن تستخرج بشكل عام فاعن أي أنموذج للشبكات العصبية بطبقة مخفية واحدة وبعد عقد مخفية (r) وعدد عقد الأدخل (p) يكتب بالشكل الآتي :

$$\hat{y}_t = \varphi_0 \left\{ w_o + \sum_{j=1}^r w_j * f \left( w_{1j} + \sum_{i=1}^p w_{ij} y_{t-i} \right) \right\}, \dots \quad (22)$$

إذ أن  $w_{1j}$  :- تمثل الأوزان التي تربط الثابت (Baise) وبين العقد المخفية .

$w$ : الوزن الذي يربط الثابت مع الناتج  $output$ .  $w_j$ : الأوزان التي تربط بين العقد المخفية والناتج .

$w_{ij}$ : - الأوزان التي تربط بين عقد المدخلات والعقد المخفية .

$\varphi_0$ : - دالة التنشيط (التفعيل في مستوى المخرجات) وتكون خطية .

$f$ : - دالة التنشيط (التفعيل في مستوى الخفي) وعادة ما تكون لوجيستية .

$y_{t-i}$ : - تمثل متغيرات الأدخال ،  $r$  : - عدد العقد المخفية ،  $p$  : - عدد عقد الأدخال

ويستخدم الرمز (  $NN$  ) للتعبير عن أنموذج الشبكة العصبية إذ أن (  $m, j_1, \dots, j_p$  ) تمثل المدخلات المزاجة زمنياً عند الإزاحة (  $L_1, \dots, L_p$  ) و (  $h$  ) عدد العقد المخفية ، أما عدد الأوزان ( المعلومات )

لأنه أنموذج الشبكة العصبية فستخرج بواسطة المعادلة الآتية: (23) ... ،

$$P = (ni + 2)h + 1$$

إذ أن  $ni$  : - عدد عقد الأدخال ،  $h$  : - عدد العقد المخفية

#### 4. خوارزمية الانتشار العكسي للخطأ ومنهجيتها Error Back Propagation Algorithm and Approach<sup>(12)</sup>

أن منهجية الانتشار العكسي ( EBP ) للخطأ طورت في عام 1970 من قبل عدة علماء إذ أن الخطوات الأساسية فيها هو حساب خطأ مستوى المخرجات لتحديث أوزان طبقة المستوى المخفي-المخرجات ، ثم حساب خطأ مستوى المخفي لتحديث أوزان طبقة مستوى المدخلات- المخفي ، وبعد ذلك نحسب مخرجات الشبكة بالأوزان الجديدة لتستمر العملية في حساب الخطأ وتحديث الأوزان للوصول إلى أقل خطأ في الشبكة العصبية ، أن خوارزمية الانتشار العكسي تستعمل في تدريب الشبكات العصبية كاملة الارتباط ومتعددة الطبقات وغير الخطية ، ويتم تنفيذ هذه الخوارزمية من خلال ثلاثة مراحل وكالآتي :-

- 1- مرحلة الانتشار الأمامي للخطأ -2- مرحلة الانتشار الخافي للخطأ -3- مرحلة توليف أوزان الشبكة .
- تبعد العملية بحساب قيمة الناتج ( output ) بموجب أنموذج الشبكات العصبية ذات الطبقة المخفية الواحدة بالأعتماد على القيم الابتدائية للأوزان وعلى المدخلات من دون إضافة الخطأ ، ثم يتم أيجاد الخطأ بين المخرج المطلوب والمخرج الفعلي وترجع بهذا الخطأ عكسياً من الطبقة الأخيرة إلى الطبقة الخلفية ثم أخيراً إلى طبقة المدخلات ، وفي اثناء الرجوع (الأرتداد) يتم تغيير الأوزان في الاتجاه الذي يرجع الخطأ إلى النقصان وأحياناً إلى الصفر وهذه مرحلة الانتشار الخافي للخطأ ، وستعمل هذه الطريقة التربوية مع الشبكات ذات التغذية الأمامية إذ أن التغذية الأمامية يرجع إلى بنية الشبكة أما انتشار الخطأ العكسي فيرجع إلى طريقة التدريب التي تستعمل مع هذه الشبكة .

#### 4. التنبؤ Forecasting

أن الهدف الأساس من استخدام أنموذج الشبكة العصبية هو حساب القيم المستقبلية للسلسلة الزمنية المدروسة ، في حالة التنبؤ لخطوة واحدة (One-Step-ahead) يكون باستخدام المشاهدات الفعلية لكل المتغيرات المزاجة كمدخلات .

أما في حالة التنبؤ لعدة خطوات ولتكن (k-Step) فيكون باستخراج التنبؤ لخطوة واحدة ثم تدخل هذه القيمة للتنبؤ لخطوة ثانية وهكذا إلى أن نحصل على ( k ) من التنبؤات وهي طريقة تكرارية .

#### 4. مراحل التنبؤ بواسطة الشبكات العصبية الأصطناعية {5}

##### أولاً : تحديد المتغيرات Variables Selection :

أن النجاح في تصميم الشبكة العصبية يعتمد على فهم واضح للمشكلة، وأن السبب في الأعتماد على الشبكة العصبية هو القدرة القوية للكشف عن العلاقات غير الخطية المعقدة بين عدد من المتغيرات .

##### ثانياً : جمع البيانات Data Collection<sup>{8}</sup>

على الباحث أن يأخذ بنظر الاعتبار الوقت والكلفة والدقة في جمع البيانات للمتغيرات المفسرة عندما يكون أنموذج الشبكة العصبية أندار متعدد غير خطى ، ولمتغير واحد (سلسلة زمنية) عندما يكون أنموذج الشبكة العصبية انحدار ذاتي غير خطى وعليه أن يقوم بفحص هذه البيانات إذ أن بعضها قد يكون مفقود أو غير موجود.

##### ثالثاً : تحويل البيانات Data processing<sup>{8}</sup>

نادرًا ما يتم تغذية الشبكة العصبية بالمدخلات التي تم جمع بياناتها بشكل مواد خام وغالباً ما يؤخذ لها اللوغاريتم الطبيعي إذا كانت كبيرة جداً ، أو يأخذ الفرق الأعتيادي الأول إذا كانت تعاني من اتجاه عام .

##### رابعاً: تجزئة البيانات Data partition<sup>{5}</sup>

في الخلية العصبية الأصطناعية تجزأ البيانات إلى ثلاثة مجتمع لاستعمالها في التحليل والتنبؤ وكما يلي :

- 1- مجموعة التدريب أو التعلم Training Set : وهي مجموعة من بيانات السلسلة الزمنية وتستخدم لتقدير الأوزان وتدريب الشبكة على التنبؤ .

2- مجموعة الاختبار **Test Set** : وهي جزء من بيانات السلسلة الزمنية ولعينة لم تستعمل في التدريب تقوم باختبار قابلية الشبكة على التنبؤ بعد عملية التعليم ولا يوجد أساس علمي لتحديد تجزئة البيانات إلى مجموعتين تعلم وإختبار، فقد تؤخذ 90% من بيانات السلسلة للتعلم و 10% للإختبار أو تكون 50% للتعلم و 50% للإختبار وبعض البرامجيات تحدد 70% للتعلم و 30% للإختبار .

3- مجموعة التقويم **Validation Set** : تقوم بمراقبة نهائية لتقويم إداء تدريب الشبكة العصبية بصورة عامة وأن اختيار عدد بيانات هذه المجموعة يجب أن يكون مناسب لتقويم كلاً من التدريب والأختبار وذلك للتوصيل إلى أفضل تنبؤ .

**خامساً** : تحديد معمارية الشبكة العصبية <sup>(9)</sup> **Determine the Architecture of N.N.** لتحديد هيكلية الشبكة العصبية تتبع الخطوات الآتية :-

1- تحديد عدد عقد الأدخال **of Inputs Nodes Determination** <sup>(10)</sup> أن المتغيرات في نموذج السلسلة الزمنية تكون بدلاًلة المتغيرات المزاحمة أي أن

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

إذ أن :- (p) تمثل درجة الأثار الذاتي أي أثار  $Y_t$  على القيم السابقة له .  
أن تحديد هذه المتغيرات تمثل مشكلة كبيرة تواجه مصمم الشبكة العصبية وقد اقترحت عدة طرق منها:-  
الطريقة الأولى :

اقتراح Kihoro واخرون عام 2004 طريقة تحديد الصلات اليا-  
(Automatic Relevance-Determination Method) - لتحديد عدد المتغيرات المزاحمة زمنياً التي لها تأثير على المتغير المعتمد  
وذلك بالأعتماد على حساب المقدار الآتي

$$Inf(L) = \sum_{h=1}^{N_h} W_{ih} W_{ho}, \dots \quad (24)$$

إذ أن  $Inf(L)$  يمثل التأثير الكلي على الناتج (Output) من قبل المتغير

$$Y_{t-L}$$

$W_{ih}$  تمثل الأوزان بين عقد الأدخال والطبقة المخفية ،  $W_{ho}$  تمثل الأوزان بين الطبقة المخفية والناتج .  
وعلى فرض أن

فإذا كانت قيمة  $r(L)$  صغيرة فاعنه يشير إلى  $Y_{t-L}$  سوف لا يدخل في النموذج ويمكن تلخيص هذه القاعدة كما يلي :  
تحديد عدد العقد المخفية ، نختار قيمة  $P$  التي نشك بأن يكون لها تأثير على القيمة المتباينا بها ، ندرب الشبكة باستخدام كل الأزاحتات المختارة ، نحسب المقدار  $Inf$  ، نختار قيمة  $k$  . فإذا كانت

$$P(Y(t-L) \in Y) = \begin{cases} 1 & \text{if } |r(L)| > k \\ 0 & \text{if } |r(L)| \leq k \end{cases} \quad L = 1, 2, \dots, P \quad \dots \quad (26)$$

مع مراعاة الأخذ بنظر الاعتبار مجموع مربعات الأخطاء لمجموعة التدريب

**الطريقة الثانية :**

الأعتماد على معاملات الارتباط الذاتي المعنوية للسلسلة الزمنية المستقرة .

**الطريقة الثالثة :**

الأعتماد على طريقة تجميع البيانات فإذا كانت شهرية فإن عدد عقد الأدخال هي  $P = 12$  وإذا كانت فصلية فإن  $P = 4$  .

2- تحديد عدد الطبقات المخفية **Layers Determination of Hidden**

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

### 3- تحديد عدد العقد في الطبقة المخفية<sup>{9}</sup> Determination of Hidden Nodes

تواجه مصمم الشبكة العصبية مشكلة اخرى الا وهي تحديد عدد العقد في الطبقة المخفية ، أن عدد العقد المخفية للشبكة العصبية يحدد من قبل المستخدم وللبدء بتدريب الشبكة العصبية لا بد من اعطاء تقدير أولي لعدد العقد المخفية .

#### الطريقة الأولى :

أن بعض الباحثين يختارها بعد المتغيرات المزاحة زمنياً أي بعد عقد الأدخال في حين البعض الآخر يعتمد على مقياس AIC,BIC,AIC<sub>C</sub> .

#### الطريقة الثانية :

أيضاً اقترح الباحث Kihoro وآخرون طريقة لتحديد عدد العقد المخفية بموجب الصيغة الآتية

$$N_h \leq \frac{(N_t - 1) * \epsilon}{(N_I + 2)} \dots (27)$$

إذ أن  $N_h$  : عدد العقد المخفية ،  $N_t$  : حجم العينة لمجموعة التدريب ،  $N_I$  : عدد عقد المدخلات  $\epsilon$  : كمية موجبة فيها  $0.125 \leq \epsilon$

أن هذه الصيغة تعتمد على عدد عقد الأدخال كلما قلت عددها زاد عدد العقد المخفية إذ أن العلاقة بينهما عكسية ، كما يمكن تدريب الشبكة على عدد من العقد قد تكون ( $h,...,3,2,1$ ) ويختار العدد الذي يكون فيه مجموع مربعات الأخطاء أقل ما يمكن .

### سادساً : تحديد عقد الأخراج Determination of output nodes

اتفق الباحثون على أن وجود عقدة اخراج واحدة تكفي لعملية التنبؤ بخطوة واحدة نحو الأمام أما في حالة التنبؤ لعدة خطوات قادمة فاعن عدد العقد يكون مساوياً إلى عدد خطوات التنبؤ.

### سابعاً : اختيار دوال التنشيط Selection of Activation functions

وهي المعادلات الرياضية التي تحدد الناتج لمعالجة الشبكات العصبية ، وتسمى أيضاً دوال التحويل وغالبية الشبكات العصبية الحالية تستخدم الدالة логистическая في الطبقة المخفية والدالة الخطية عند طبقة المخرجات عندما يكون أكثر من عقدة للناتج .

### ثامناً : تدريب الشبكة العصبية Neural Network Training<sup>{8}</sup>

أن عملية تدريب الشبكات العصبية على التنبؤ تتم من خلال تعديل أوزان الشبكة للحصول على أقل خطأ بالأعتماد على خوارزمية الانتشار الخفي (BP) ، ومن أهم خطوات تدريب الشبكة هي :

#### 1- تحديد قيم الأوزان الأولية Select the weight initialization

وتحدد نقطة البداية لعملية التدريب وغالباً ما يتم اختيار قيم عشوائية صغيرة للأوزان والحد المطلق تقع ما بين (-1,1).

#### 2- عدد تكرارات التدريب Number of training iteration<sup>{8}</sup>

الباحث يجب أن يوقف التدريب فقط حتى يكون هناك أي تحسن في وظيفة الخطأ استناداً إلى عدد معقول من الأوزان التي تم اختيارها عشوائياً وتسمى النقطة التي لا تحسن الشبكة بالتقارب .

#### 3- معدل التعلم (η) وعامل الزخم (α)<sup>{1},{8}</sup> Learning Rate and Momentum

أن حجم الشبكة يؤثر على عملية التعلم حيث ان الشبكة الكبيرة تحتاج الى وقت اكبر للتعلم والوصول الى أقل خطأ ، ويتأثر بمعدل التعلم ( $\eta$ ) ومعامل الزخم ( $\alpha$ ) فكلما كانت عملية التعلم بطيئة نعطي قيمة اكبر الى ( $\eta$ ) وعندما تكون عملية التخفيف في الخطأ سريعة فنختار قيمة اصغر الى ( $\eta$ ) لضمان الوصول الى اصغر قيمة للخطأ ولكنها ستحتاج الى وقت طويل لتدريب الشبكة.

اما بالنسبة الى ( $\alpha$ ) فالقيمة الكبيرة لها سلبيات الى زيادة سرعة التعلم ونوصي بها عندما تكون عملية الوصول الى أقل خطأ بطيئة .

### تاسعاً : التنفيذ<sup>{5}</sup> Implementation :

وهي من أهم المراحل حيث تختبر الشبكة من حيث قدرة التكيف مع حالة التغير في دورة وأمكانية إعادة التدريب والوصول الى أقل مربع خطأ عند تغيير البيانات .

## 5. مقاييس الكفاءة على دقة النماذج {15}

نقياس كفاءة اداء النماذج واختيار الأفضل من خلال استخدام جملة من المقاييس الاحصائية التي تعتبر من المؤشرات التي توضح مدى ملائمة الأنماذج والتي هي :-

### 1- متوسط الانحراف المطلق (MAD)<sup>{13}</sup>

$$MAD = \sum_{t=1}^n \left| \frac{Y_t - \bar{Y}_t}{n} \right|, \dots \quad (28)$$

صيغته كما هو ات :  $n$  : يمثل عدد المشاهدات ،  $Y_t$  : يمثل المشاهدات الحقيقة ،  $\bar{Y}_t$  : يمثل المشاهدات المتوقعة .

### 2- متوسط مطلق الخطأ النسبي (MAPE)<sup>{13}</sup>

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \bar{Y}_t}{Y_t} \right| 100, \dots \quad (29)$$

وصيغة هي

### 3- الجذر التربيعي لمتوسط مربعات الخطأ (RMSE)<sup>{13}</sup>

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum(Y_t - \bar{Y}_t)^2}{n}}, \dots \quad (30)$$

وصيغته هي

### 4- الخطأ المعياري للتنبؤ (SEP)<sup>{13}</sup>

$$SEP = \frac{100}{\bar{Y}} RMSE, \dots \quad (31)$$

وصيغته هي

حيث ان :-  $\bar{Y}$  : يمثل الوسط الحسابي للمشاهدات .

## الجانب النطبيقي

في هذا الجانب سيتم التطبيق لبيانات واقعية تمثل الاعداد الشهرية للمسافرين لمطار بغداد الدولي من الفترة (كانون الثاني 2006 ولغاية اب 2015) وبغية تحقيق هدف البحث فقد قسم التحليل الاحصائي لبيانات السلسلة أعداد المسافرين من الفترة (كانون الثاني 2006 ولغاية كانون الاول 2014) الى ثلاثة اجزاء رئيسية :-

1- بناء أنماذج بوكس- جنكينز لسلسلة أعداد المسافرين، إذ يتم تشخيص الأنماذج الملائم وتقدير معلماته .

2- بناء نماذج الشبكات العصبية الأصطناعية بالأعتماد على الفرض بأن السلسلة الزمنية تحوي فقط المركبة غير الخطية للسلسلة الزمنية للمسافرين وباستعمال خوارزمية الانتشار الخلفي بعد تحديد معمارية مختلفة للشبكة .

3- بناء النماذج الهجينية التي تنص على الفرض بأن السلسلة الزمنية تحوي المركبتين الخطية وغير الخطية .

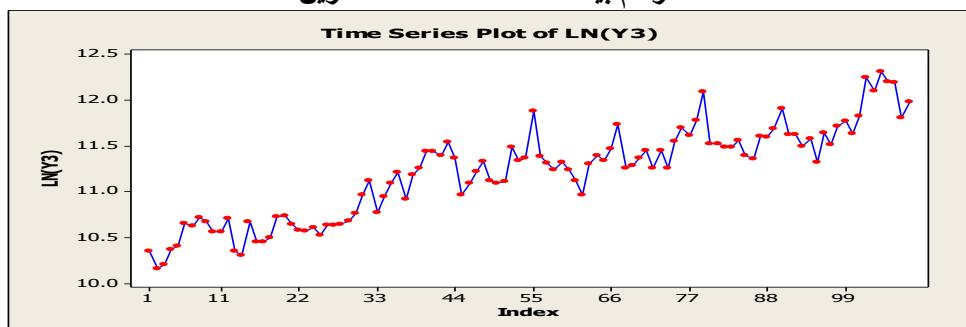
4- ويختتم بأجراء مقارنة بين هذه النماذج (بوكس- جنكينز ، الشبكات العصبية ، الهجينية ) من الفترة كانون الثاني ولغاية اب من العام 2015 بالأعتماد على جملة من المقاييس الاحصائية لأختيار الأنماذج الأكفاء الذي يستخدم لحساب التنبؤات المستقبلية لأعداد المسافرين للفترة الزمنية من (ايلول 2015 ولغاية كانون الأول 2016) .

أنماذج بوكس- جنكينز لتحليل السلسلة الزمنية لأعداد المسافرين لمطار بغداد الدولي لغرض تحليل السلسلة الزمنية يتطلب بناء أفضل أنماذج للتنبؤ وتحديد معلماته وتقديرها والتأكد من ملائمة الأنماذج للبيانات موضوعة البحث وبالاعتماد على البرنامج الجاهز (Minitab 16)، إذ يعتمد تحليل السلسلة الزمنية على عدة خطوات وكما يلي :-

### 1. استقرارية السلسلة

ولغرض أنجاز الاستقرارية في التباين فقد أخذ اللوغاريتم الطبيعي لسلسلة البيانات بأعداد المسافرين للفترة الزمنية من كانون الثاني / 2006 ولغاية كانون الاول / 2014 وتم رسمها كما مبين أدناه .

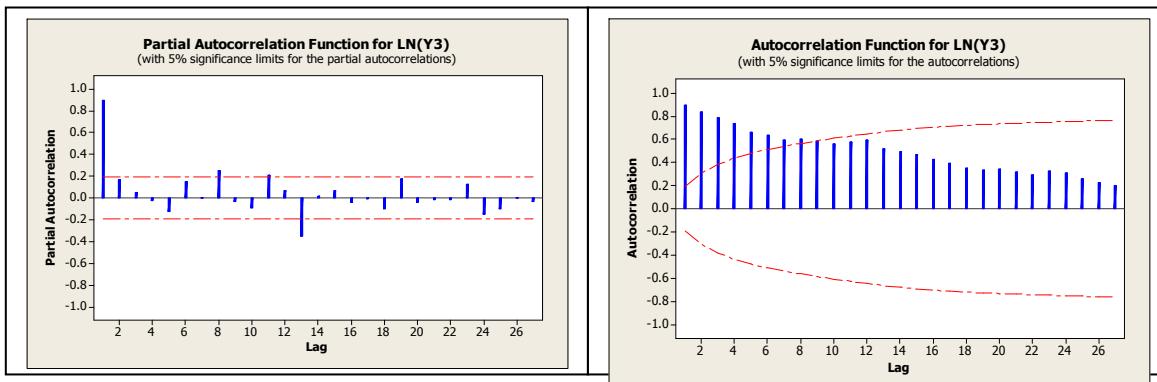
الشكل (2)  
رسم بيانات سلسلة أعداد المسافرين



من خلال رسم السلسلة الزمنية نلاحظ أنها تحوي اتجاه عام مما يدل على أن السلسلة غير مستقرة بال المتوسط ولمزيد من الدقة تم استخراج معاملات الارتباط الذاتي (ACF) والأرتباط الذاتي الجزئي (PACF) على التوالي وقد تم رسمهما كما في الأشكال الآتية.

الشكل (4)  
يمثل (ACF) لسلسلة أعداد المسافرين

الشكل (3)  
يمثل (PACF) لسلسلة أعداد المسافرين

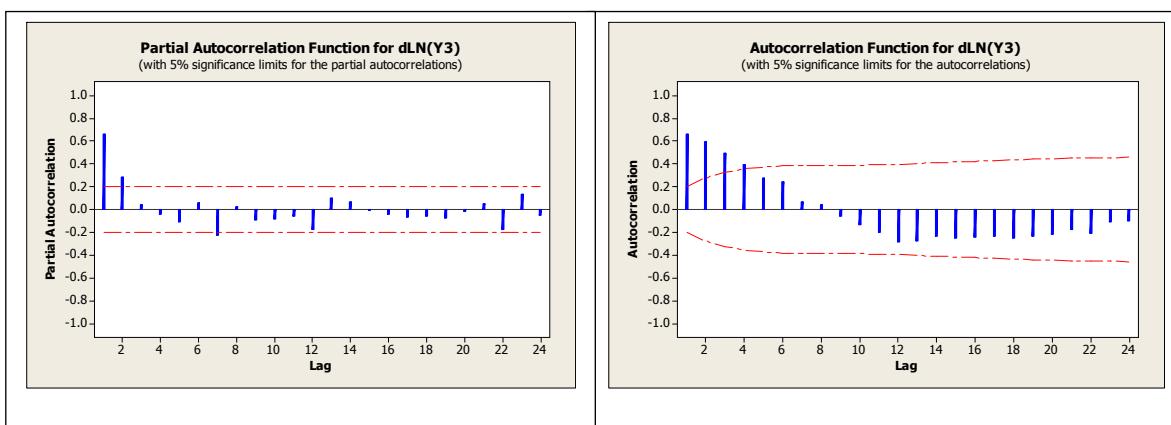


ومن خلال ملاحظة قيم معاملات الارتباط الذاتي (ACF) نجد أنها معنوية لعدد كبير من الأزاحات وتتنازل ببطء مما يشير إلى أن السلسلة الزمنية غير مستقرة وهذا ما يؤيد الشكل (3)، أما الشكل (4) يشير إلى أن الأزاحة الأكثر معنوية هي الأزاحة الأولى وهناك أزاحات أخرى غير معنوية ، لذلك كان لا بد منأخذ الفروقات اللازمة للسلسلة الأصلية لتحقيق الاستقرارية في المتوسط عندئذ تصبح السلسلة الزمنية لبيانات المسافرين مستقرة .

لذا تمأخذ الفرق الأول كما وتم حساب معاملات الارتباط الذاتي والجزئي للسلسلة المستقرة وقد تم رسم كل من دائرة الارتباط الذاتي والذاتي الجزئي (PACF, ACF) كما يظهر في الشكلين أدناه حيث تبين أن السلسلة أصبحت مستقرة .

الشكل (6)  
يمثل (PACF) لسلسلة أعداد المسافرين

الشكل (5)  
يمثل (ACF) لسلسلة أعداد المسافرين



وكذلك تم استخراج دالة الارتباط الذاتي الموسعة للعينة (ESACF) لغرض تشخيص الأنماذج كما مبين في الجدول (1).

**جدول (1)**  
يبين دالة الارتباط الذاتي الموسعة للعينة (ESACF) لسلسلة اعداد المسافرين

		$-0.2 \leq \hat{r}_k(\hat{a}) \leq 0.2$							MA						
AR	0	MA						AR	0	MA					
		1	2	3	4	5	...			1	2	3	4	5	...
0	0.6602	0.5967	0.4932	0.394	0.2722	0.2446	...	0	x	x	x	x	x	x	...
1	-0.331	0.1127	0.0168	0.0631	-0.11	0.2451	...	1	x	x	0	0	0	x	...
2	-0.056	-0.089	0.0324	-0.01	-0.047	0.1689	...	2	0	0	0	0	0	0	...
3	-0.024	-0.025	-0.024	0.0096	-0.053	0.1657	...	3	0	0	0	0	0	0	...
4	-0.022	-0.021	-0.011	0.0015	-0.052	0.1654	...	4	0	0	0	0	0	0	...
5	-0.019	-0.041	-0.034	-0.045	-0.019	0.1648	...	5	0	0	0	0	0	0	...
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

حيث ان  $(\hat{a}_k)$  : تشير الى معاملات الارتباط الذاتي للباقي

من الملاحظ في الجدول (1) أن رأس المثلث عند النقطة (2,0)

## 2. تشخيص وتقدير الأنماذج و اختيار الأنماذج الأفضل

من خلال ملاحظة دالة الارتباط الذاتي في الشكل(5) يبدو أن السلسلة الزمنية لبيانات المسافرين تتناقص بشكل اسي متاوب وأن دالة الارتباط الذاتي الجزئي كما في الشكل(6) معنوية عند الأزاحة الثانية وبالاعتماد على النتائج المستخرجة من دالة الارتباط الذاتي الموسعة للعينة كما مبين في الجدول (1) بالأمكان أن نفترض أنماذج الأصدارات الذاتي من الدرجة الثانية لبيانات المسافرين، ويكون الا نموذج هو (2) الذي معادلته بالشكل الآتي :-

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + a_t$$

ولقد تم تقدير معلمات الأنماذج وكانت النتائج كما مبين في الجدول أدناه .

**جدول (2)**

يبين تقدير معلمات الأنماذج ومتوسط مربعات الخطأ لسلسلة أعداد المسافرين

Final Estimates of Parameters					متوسط مربعات الأخطاء		
Type	Coef	SE Coef	T	P	MS = 0.02946		
AR 1	0.4706	0.0991	4.75	0.000			
AR 2	0.2991	0.0999	2.99	0.004			
Constant	0.04225	0.01753	2.41	0.018			

## 3. اختبار دقة الأنماذج

بعد تشخيص الأنماذج وتحديد درجته وتقدير معلماته لابد من التأكد من صحة ملاءمة الأنماذج وكفاءته إذ تم حساب معاملات الارتباط الذاتي للباقي كما تم حساب :

### 1- اختبار (Ljung-Box) :-

من خلال تطبيق احصاءة (Ljung-Box) المعدلة لفحص ملاءمة الأنماذج وظهر بأن قيمة ( $Q=18.9$ ) عند الأزاحة ( $K=24$ ) لسلسلة المسافرين ومن خلاقيمة ( $P-Value$ ) وهذا يدل على أن الأخطاء ( $a_t$ ) ماهي إلا متغيرات عشوائية غير مترابطة وهذا يدل على أن الأنماذج جيد وملائم وكفؤة لتمثيل السلسلة الزمنية وبالتالي قبول الفرضية الآتية :

$$H_0: \rho_i(a_t) = 0 \quad , \quad i = 1, 2, \dots, k$$

جدول (3) ببيان قيم احصاء (Ljung-Box) المعدلة لسلسلة اعداد المسافرين

Modified Box-Pierce (Ljung-Box) Chi-Square statistic				
Lag	12	24	36	48
Chi-Square	10.7	18.9	35.0	42.5
DF	9	21	33	45
P-Value	0.296	0.590	0.375	0.580

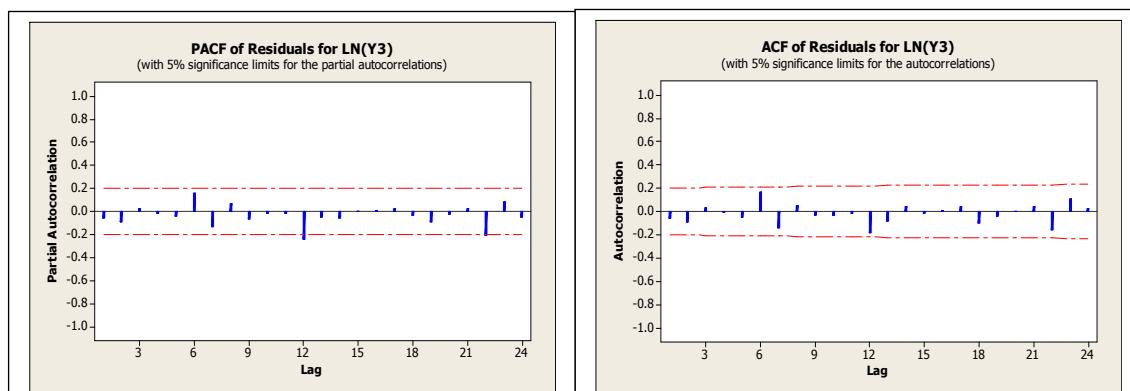
## 2-اختبار البوافي :-

من خلال رسم معاملات الارتباط الذاتي والجزئي للبوافي المستخرجة كما في الشكلين (7) و (8) ، نلاحظ أن قيم معاملات الارتباط الذاتي للبوافي جميعها تقع ضمن حدود الثقة مما يعني أن سلسلة البوافي هي عبارة عن متغيرات عشوائية غير مترابطة وأن الأنماذج المستعملة ملائمة وجيدة في تمثيل بيانات المسافرين.

الشكل (8)

يمثل (PACF) للبوافي لسلسلة المسافرين

يمثل (ACF) للبوافي لسلسلة المسافرين



## 4. التنبؤ :

بعد اجتياز الأنماذج لاختبارات التشخيص يصبح بالأمكان استعمال الأنماذج للتنبؤ والجدول أدناه يمثل القيم التقديرية للأشهر الثمانية الأولى من عام 2015(بيانات المسافرين).

جدول (4)

بيان القيم التقديرية والحدين الأدنى والأعلى مع القيم الحقيقة لسلسلة المسافرين

الشهر/ 2015	الحد الأعلى	الحد الأدنى	القيم التقديرية	الحد الأعلى
كانون الثاني	12.20	11.86	11.87	12.20
شباط	12.39	12.02	12.18	12.39
آذار	12.48	12.06	12.18	12.48
نيسان	12.33	11.90	12.13	12.33
أيار	12.53	12.08	12.15	12.53
حزيران	12.95	12.49	12.15	12.95
تموز	12.80	12.34	12.18	12.80
آب	13.01	12.54	12.23	13.01

نماذج الشبكات العصبية لتحليل السلسلة الزمنية لأعداد المسافرين لمطار بغداد الدولي استُعملت منهجهية الشبكات العصبية الأصطناعية في تحليل السلسلة الزمنية و بناءً أنماذج للتنبؤ في حركة المسافرين لمطار بغداد الدولي حيث تمأخذ اللوغاريتم الطبيعي لكل من سلسلة أعداد المسافرين ، وتم استخدام الشبكات العصبية المتعددة الطبقات(Multilayer Perceptron) ذات التغذية الأمامية (Feed Forward) وبطبقة مخفية واحدة (One hidden layer) لغرض التنبؤ بالقيم المستقبلية للسلسلة الزمنية من خلال إستعمال دوال التنشيط -غير الخطية لبيانات السابقة إذ استعمل البرنامج الجاهز (SPSS 19) في نمذجة الشبكات العصبية الأصطناعية، ولتحديد معمارية الشبكة تم اختيار متغيرات الأدخال (مدخلات الشبكة) لبيانات السلسلة من  $y_{t-1}$  إلى  $y_{t-12}$  ، وقد تم استخدام دالة تنشيط غير خطية هي الدالة الوجستية للعقد المخفية والمسؤولة عن العمليات الرياضية وحساب الأوزان وتعديلها ، أما القيمة التقديرية ( $\hat{y}_t$ ) فتمثل مخرجات الشبكة العصبية.

وللقيام بعملية التدريب تم تجزئة بيانات السلسلة الزمنية لأعداد المسافرين والمكونة من (108) مشاهدة لكل سلسلة إلى (70%) بيانات التدريب و(30%) للختبار ويمكن تغيير هذه النسب بما يلائم بيانات الأدخال وتحديد معدل للتعلم ( $\eta=0.4$ ) ومعامل الزخم ( $\alpha=0.9$ ) ويقيم أولية عشوائية للأوزان إذ يُعد مجموع هذه الأوزان المضروبة مع قيم متغيرات الأدخل كمدخلات لتركيبة خطية وتؤخذ هذه المدخلات إلى دالة التنشيط الوجستية في عقدتي الطبقة المخفية إلا أن ذلك يتطلب تهيئة البيانات بصورة أولية من خلال تحويلها إلى إحدى الصيغ إذ تم استعمال الصيغة المعيارية لتحقيق مدى هذه الدالة الذي يكون ما بين (0,1) لإجراء العمليات الحسابية للتقدير فضلاً عن وجود الحد الثابت (bias) أو التحيز لكل من العقد المخفية ، وبنفس الأسلوب تم تطبيق العلاقة الخطية **Linear activation function** التي تجمع ما بين الطبقة المخفية وطبقة الأخرج .

وكما ذكر في الجانب النظري من ان الباحث يواجه مشكلتين رئيسيتين هما تحديد عدد عقد الأدخل وتحديد عدد العقد المخفية لذلك سنستخدم الطرائق الأحصائية لتحديد عدد عقد الأدخل والعقد المخفية

### 1. تحديد عقد الأدخل Determination of Inputs Nods

لتتحديد عدد المتغيرات المزاحة زمنياً تم الاعتماد على الطرائق الآتية :

**الطريقة الأولى :**

الطريقة المقترحة من الباحث (Kihoro) وآخرين إذ يتم بأخذ كل متغير مزاح زمنياً مع ( $Y_t$ ) وبيان مقدار تأثيره على ( $Y_t$ ) من خلال حساب  $|Inf|$  واستخراج مجموع مربعات خطأ التدريب وعليه سيكون الأنماذج هو  $NN(Y_{t-k}; 1)$   $k = 1, 2, \dots, 12$  وكما في الجدول (5) لسلسلة أعداد المسافرين كما وتم بيان المتغيرات الطبيعية المهمة وتسلسلها كما في الشكل (9) لسلسلة أعداد المسافرين . ومن خلال ملاحظة قيم  $|Inf|$  ومجموع مربعات خطأ التدريب في الجدول (5) يمكن ان تحدد الأزاحتات المعنوية وهي (12,2,1) اي ان الأنماذج هو: ( $Y_t = f(Y_{t-1}, Y_{t-2}, Y_{t-12})$

$$Y_t = f(Y_{t-1}, Y_{t-2}, Y_{t-12})$$

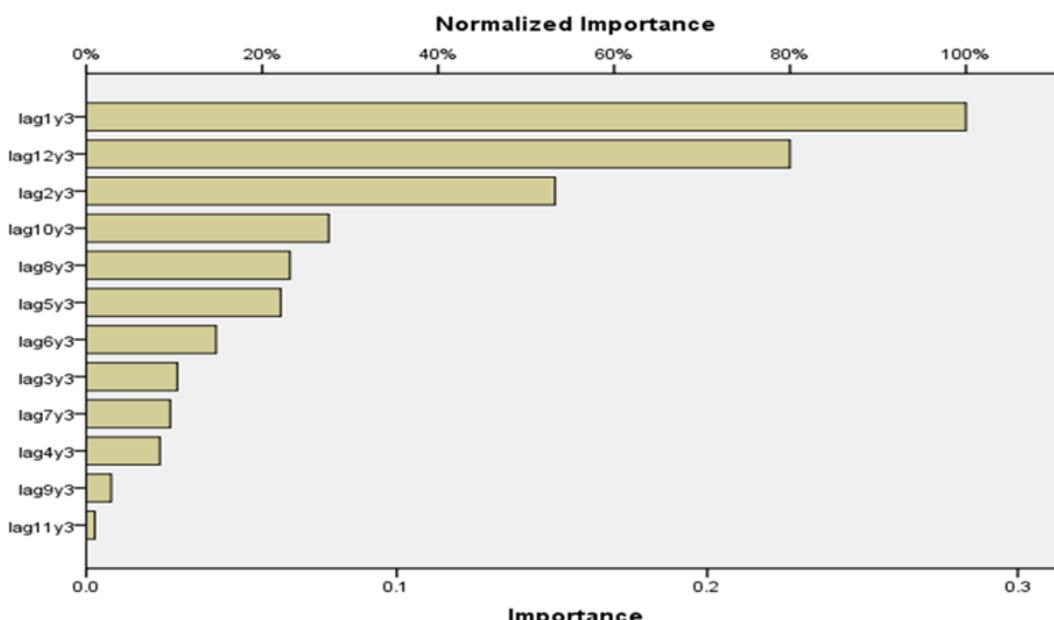
جدول (5)

يبين مقدار  $|Inf|$  ومجموع مربعات خطأ التدريب للإزاحتات (1,2,...,12) لسلسلة المسافرين

Lag	S.S.Et	/inf/
1	7.581	4.752858331
2	13.33893707	5.223757991
3	12.79618161	4.423793287
4	13.31030648	5.636969828
5	18.14969953	4.271605717
6	20.69896892	4.249249794
7	16.97327228	4.108368612
8	16.45886604	4.694648958
9	14.14649564	4.954552927
10	16.67660483	3.903486631
11	19.46417847	2.474694562
12	10.58237406	4.940567112

الشكل (9)

يبين المتغيرات الطبيعية المهمة وتسلسلها حسب الامانة لسلسلة المسافرين



كما في الشكل (9) يؤكد اختيار هذه المدخلات للشبكة العصبية الخاصة بالسلسلة الزمنية لأعداد المسافرين .

#### الطريقة الثانية :

الأعتماد على معاملات الارتباط الذاتي المعنوية لسلسلة أعداد المسافرين المستقرة بعد ان اخذ لها الفرق وجد ان معاملات الارتباط الذاتي لسلسلة أعداد المسافرين معنوية فقط عند الأزاحة الأولى والثانية والثالثة كما في الشكل (5) .

وعلية فاعن عدد مدخلات أنموذج الشبكة العصبية لسلسلة أعداد المسافرين سيكون :-

$$Y_t = f(Y_{t-1}, Y_{t-2}, Y_{t-3})$$

#### الطريقة الثالثة :

ان بيانات السلسلة الزمنية المدروسة تمثل بيانات لسلسلة أعداد المسافرين شهرياً فاعن المتغيرات المزاحاة هي (  $Y_{t-k}$  ,  $k=1,2,\dots,12$  ) اي ان أنموذج الشبكة العصبية يحوي على (12) عقدة ادخال والذي هو :-

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-11}, Y_{t-12})$$

## 2. تحديد عدد العقد المخفية Determination of Hidden Nodes

#### الطريقة الأولى :

ان عدد العقد المخفية تعتمد على عدد عقد الادخال ولهذا فاعن أنموذج الشبكة العصبية لسلسلة أعداد المسافرين سيكون حسب عدد عقد الادخال كما في الجدول (6) .

جدول (6)

يمثل عدد العقد المخفية حسب عدد عقد الادخال وأنموذج الشبكة العصبية لسلسلة المسافرين

الأنموذج	عدد عقد الادخال	عدد العقد المخفية
NN (1,2,12;3)	3	3
NN (1,2,3;3)	3	3
NN(1,2,...,12;12)	12	12

### الطريقة الثانية :

استخدام الصيغة المقترنة من قبل الباحث (Kihoro) وآخرين <sup>(24)</sup> لكل طريقة من طرائق تحديد عدد عقد الأدخال فكانت النتائج كما في الجدول أدناه .

جدول (7)

يمثل عدد العقد المخفية بموجب صيغة الباحث (Kihoro) والأنموذج الخاص لسلسلة المسافرين

الأنموذج	عدد عقد الأدخال	عدد العقد المخفية
NN (1,2,12;2)	3	2
NN (1,2,3;2)	3	2
NN(1,2,...,12;1)	12	1

نظراً لعدم تساوي الطريقتين في اختيار عدد العقد المخفية لسلسلة أعداد المسافرين لذا سيتم اخذ عدد العقد (2 ، 3 ) بالنسبة للأنموذج الأول و الثاني و ( 1 ,..., 12 ) بالنسبة للأنموذج الثالث .  
وحساب المقاييس الاحصائية (AIC, AICC , BIC) لاختيار افضل النماذج كما مبين في الجدول(8).

جدول (8)

بي بين المقاييس الاحصائية (AIC, AICC, BIC) للأنموذج الاول والثاني والثالث لسلسلة أعداد المسافرين

model	$N_p$	SSE	$\hat{\sigma}^2$	AIC	AICC	BIC
NN(1,2,12;2)	11	7.471	0.106	-134.63	-130.08	-98.896
NN(1,2,12;3)	16	7.883	0.112	-120.86	-110.6	-68.889
NN(1,2,3;2)	11	6.747	0.115	-124.53	-119.81	-89.111
NN(1,2,3;3)	16	8.981	0.123	-120.96	-111.24	-68.308
NN(1,2,...,12;1)	15	6.338	0.103	-108.12	-97.456	-61.46
NN(1,2,...,12;2)	29	7.073	0.105	-92.64	-45.613	0.29582
NN(1,2,...,12;3)	43	6.604	0.097	-72.56	85.1071	65.8792
NN(1,2,...,12;4)	57	14.146	0.191	-8.4383	404.812	179.893
NN(1,2,...,12;5)	71	6.273	0.098	-6.6394	-1284.6	217.641
NN(1,2,...,12;6)	85	8.214	0.112	10.5305	-1114.1	290.22
NN(1,2,...,12;7)	99	6.114	0.088	30.7789	-607.93	350.955
NN(1,2,...,12;8)	113	5.717	0.078	40.0699	-588.32	411.892
NN(1,2,...,12;9)	127	5.411	0.091	113.052	-358.14	503.9
NN(1,2,...,12;10)	141	6.271	0.111	159.4	-306.23	585.975
NN(1,2,...,12;11)	155	7.841	0.117	166.255	-377.12	662.983
NN(1,2,...,12;12)	169	9.544	0.146	213.302	-333.94	749.773

و عند ملاحظة الجدول (8) نجد ان اقل قيمة لهذه المقاييس كانت للنماذج الآتية :-

1. الأنماذج الأول (NN(1,2,12;2)) الذي يضم ثلاثة متغيرات مزاحه وهي ( $y_{t-12}, y_{t-2}, y_{t-1}$ ) وعقدتين مخفيتين .
2. الأنماذج الثاني (NN(1,2,3;2)) الذي يضم ثلاثة متغيرات مزاحه وهي ( $y_{t-3}, y_{t-2}, y_{t-1}$ ) وعقدتين مخفيتين .
3. الأنماذج الثالث (NN(1,...,12;1)) الذي يضم اثنى عشرة متغير مزاح وهي ( $y_{t-12}, \dots, y_{t-1}$ ) وعقدة مخفية واحدة.

### 3. التنبؤ :

بعد الحصول على افضل النماذج لسلسلة أعداد المسافرين نقوم باستخدامها لحساب التقديرات ومقارنتها مع القيم الحقيقة لثمانية الاشهر الأولى من عام 2015 ، وكما مبين في الجدول (9).

**جدول (9)**  
بيان التقديرات الشهرية لأعداد المسافرين مع القيم الحقيقية

الشهر / 2015	NN(1,2,12;2)	NN(1,2,3;2)	NN(1,...,12;1)	القيم الحقيقة
كانون الثاني	11.88	11.86	11.87	
شباط	12.02	12.06	12.18	
آذار	12.09	12.01	12.18	
نيسان	12.04	11.99	12.13	
أيار	12.14	11.99	12.15	
حزيران	12.15	12.13	12.15	
تموز	12.17	12.01	12.18	
آب	12.23	12.20	12.23	

وتم حساب المقاييس الأحصائية (**MAD,MAE,RMSE,SEP,MAPE**) للنماذج الثلاثة للحصول على الأنماذج الأفضل الذي يمثل أنماذج الشبكات العصبية المتعددة الطبقات من خلال المقارنة بين هذه المقاييس لسلسلة أعداد المسافرين وكما مبين في الجدول (10) .

**جدول (10)**  
بيان المقاييس الأحصائية للنماذج الثلاثة لسلسلة أعداد المسافرين

(Models) النماذج	MAD	RMSE	SEP	MAPE
NN(1,2,12;2)	0.005	0.073	0.621	0.380
NN(1,2,3;2)	0.019	0.167	1.429	1.273
NN(1,2,...,12;1)	0.008	0.081	0.691	0.493

ومن خلال ملاحظة الجدول اعلاه نجد ان الأنماذج **NN(1,2,12;2)** يمتلك اقل قيمة للمقاييس الأحصائية المستخرجة لذا يعد هذا الأنماذج هو الأفضل من بين نماذج الشبكات العصبية للتتبؤ بأعداد المسافرين . النماذج الهجينة لتحليل السلسلة الزمنية لأعداد المسافرين لمطار بغداد الدولي .

## 1. الأنماذج الهجين من ARIMA و ANN

**المرحلة الأولى :**

بعد استخدام (2) AR لتمثيل الجزء الخطي ( $L$ ) للسلسلة الزمنية وحساب التقديرات المستقبلية لها كما في الجدول (4).

ولغرض بناء الأنماذج الهجين نستعمل الباقي ( $a_t$ ) المستخرجة حيث تمثل المركبة غير الخطية (N) للسلسلة التي يتم تمثيلها بأنماذج الشبكات العصبية المتعددة الطبقات للحصول على القيم المتوقعة لها اي أن الأنماذج سيكونون

$$N = f(a_{t-1}, a_{t-2}, \dots, a_{t-p})$$

ولتحديد المتغيرات المزاحاة ( $a_{t-1}, a_{t-2}, \dots, a_{t-p}$ ) تم استخدام الطريقة المقترحة من الباحث (Kihoro) واخرون من خلال حساب قيم  $|Inf(L)|$  وتحديد العقد المخفية حيث كانت المتغيرات المزاحاة المهمة هي ( $a_{t-8}, a_{t-12}$ ) لسلسلة أعداد المسافرين وكانت عدد عقد الأدخال والعقد المخفية هي (2) **NN(8,12;2)** حيث أصبح الأنماذج كما يلى:

$$N_t = f(a_{t-8}, a_{t-12})$$

وقد تم استخدام هذه النماذج لسلسلة المسافرين لحساب التقديرات لأعداد المسافرين للأشهر الثمانية الأولى من عام 2015 .

**المرحلة الثانية :**

في هذه المرحلة يتم جمع القيم المقدرة بواسطة أنماذج (ARIMA) مع تقديرات الباقي التي تم حسابها من قبل أنماذج (ANN) ، والتي بدورها تنتج القيمة المتوقعة النهائية للسلسلة الزمنية حسب المعادلة (4) وكما مبين في الجدول (11) .

جدول (11)

يبين القيم التقديرية للأنموذج الهجين (ARIMA-ANN) لسلسلة المسافرين

الشهر / 2015	كانون 2	شباط	آذار	نيسان	أيار	حزيران	تموز	أب
ARIMA-ANN	11.87	12.03	12.09	11.94	12.13	12.49	12.34	12.53

## 2. الأنموذج الهجين من ANN و ARIMA Hybrid Model of (ANN-ARIMA)

وفي هذا النوع من النماذج الهجينة أيضاً تتكون من مرحلتين ولكن عكس الأنموذج الهجين السابق وكما

مبين أدناه :-

### المرحلة الأولى :

بعد استخدام أنموذج الشبكات العصبية الأصطناعية (ANN) لتمثيل الجزء غير الخطى (N) للسلسلة الزمنية وحساب التقديرات المستقبلية لها كما مبين في الجدول (9).

ولغرض بناء هذا الأنموذج نستعمل البواقي ( $a_t$ ) المستخرجة من أنموذج الشبكات العصبية المتعددة الطبقات حيث تمثل المركبة الخطية (L) للسلسلة التي يتم تمثيلها بأنموذج (ARIMA) للحصول على القيم التقديرية لها .

بعد استخراج البواقي من أنموذج الشبكات العصبية لسلسلة اعداد المسافرين تم رسم سلسلة البواقي ACF للتعرف على سلوكها وتبيّن أنها مستقرة ، وللمزيد من الدقة تم استخراج قيم معاملات الارتباط الذاتي

والأرتباط الذاتي الجزئي PACF ورسم كل منها على التوالي حيث لم يتم التعرف على الأنموذج .

ولتحديد رتبة الأنموذج بشكل ادق تم توفيق عدد من النماذج واختيار الأنموذج الأفضل وفق معايير المفاضلة وتبيّن أن أفضل أنموذج من نماذج بوكس- جنكينز هو الأنموذج ARIMA(1,0,1) كون قيمة معياري ( معيار معلومات بيز BIC ومعيار ايكى AIC ) لهذا الأنموذج أقل قيمة من بين جميع القيم إضافة إلى قيمة متوسط مربعات الخطأ التي هي أيضاً أقل قليلاً مقارنة مع القيم الأخرى .

وبعد تشخيص الأنموذج وتحديد درجه وتقديره لأبد من التأكيد من صحة ملاءمة الأنموذج وكفاءته وتم ذلك من خلال تطبيق احصاء Ljung-Box (Ljung-Box) لفحص ملائمة الأنموذج وظهر بأنها معنوية عند الأزاحة K=12 ومن خلال قيمة P-Value وهذا يدل على أن الأخطاء غير مرتبطة ببعضها البعض وهذا دليل على أن الأنموذج جيد وملاائم ، فضلاً عن استخراج معاملات الارتباط الذاتي والجزئي للبواقي (الأخطاء) للأنموذج المقدر ورسمها ولوحظ أن قيمة معاملات الارتباط الذاتي للبواقي جميعها تقع ضمن حدود الثقة مما يعني أن سلسلة البواقي عشوائية وأن الأنموذج المستعمل جيد وملاائم .

المرحلة الثانية : في هذه المرحلة يتم جمع القيم المقدرة بواسطة أنموذج (ANN) مع تقديرات البواقي التي تم حسابها من قبل أنموذج (ARIMA) ، والتي بدورها تنتج القيمة المتوقعة النهائية للأنموذج الهجين حسب المعادلة (4) وكما مبين في الجدول (12) .

جدول (12)

يبين القيم التقديرية للأنموذج الهجين (ANN -ARIMA) لسلسلة المسافرين

الشهر / 2015	كانون 2	شباط	آذار	نيسان	أيار	حزيران	تموز	أب
ARIMA-ANN	11.83	12.06	12.11	12.05	12.18	12.17	12.18	12.23

المقارنة بين أساليب التقدير وبناء النماذج لأعداد المسافرين لمطار بغداد الدولي

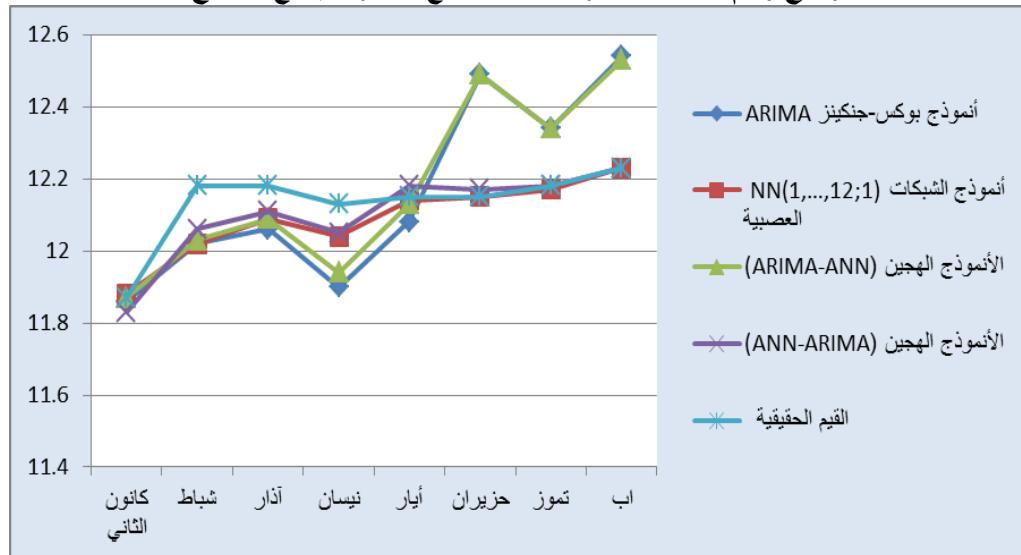
لقد تمت المقارنة بين الأساليب الثلاثة (أنموذج بوكس جنكينز ، وأنموذج الشبكات العصبية ، والأنموذج الهجين) المستعملة في الدراسة لتقدير نماذج التنبؤ بالأعتماد على بعض المقاييس الأحصائية ، (MAD, RMSE , SEP) (MAPE , MAE) والجدول (13) يوضح هذه المقارنة لسلسلة اعداد المسافرين وقد تم اعتماد الأنموذج الهجين (ANN-ARIMA) لحساب التنبؤات المستقبلية لأعداد المسافرين وذلك لإمتلاكه أقل قيمة للمقاييس الأحصائية من بين النماذج .

**جدول (13)**  
يبين القيم التقديرية للنماذج الأربع مع القيم الحقيقة وجملة من المقاييس الأحصائية لسلسلة أعداد المسافرين

الشهر / 2015	بوكس جنكينز ARIMA	الشبكات العصبية NN(1,2,12;2)	الهجين (ARIMA-ANN)	الهجين (ANN-ARIMA)	القيمة الحقيقة
كانون الثاني	11.86	11.88	11.87	11.83	11.87
شباط	12.02	12.02	12.03	12.06	12.18
اذار	12.06	12.09	12.09	12.11	12.18
نيسان	11.90	12.04	11.94	12.05	12.13
ايار	12.08	12.14	12.13	12.18	12.15
حزيران	12.49	12.15	12.49	12.17	12.15
تموز	12.34	12.17	12.34	12.18	12.18
آب	12.54	12.23	12.53	12.23	12.23
المقاييس					
	1.438	0.380	1.283	0.371	0.371
	1.753	0.621	1.654	0.512	0.512
	0.205	0.073	0.193	0.060	0.060
	0.022	0.005	0.020	0.004	0.004

ايضاً بالأعتماد على قيم الجدول (13) تم رسم القيم الحقيقة مع القيم التقديرية للأشهر الثمانية الأولى من عام 2015 لسلسلة اعداد المسافرين وكما مبين في الشكل (10).

**الشكل (10)**  
يوضح رسم اعداد المسافرين الحقيقة مع المقدرة لجميع النماذج



التنبؤ بأعداد المسافرين لمطار بغداد الدولي باستخدام الأنماذج الهجين (ANN-ARIMA) بعد تقديم الأنماذج الهجين (ANN-ARIMA) على باقي النماذج وذلك لأمتلاكه أقل المقاييس الأحصائية لذا تم اعتباره الأنماذج الأكفاء من بين هذه النماذج حيث تم استعماله للتنبؤ المستقبلي للفترة الزمنية لسلسلة اعداد المسافرين، والجدول (14) يمثل القيم المستقبلية لسلسلة أعداد المسافرين للفترة الزمنية من ايلول/2015 ولغاية كانون الأول/2016 قبل وبعد التحويل اللوغاريتمي .

**جدول (14)**  
يبين القيم التنبؤية لسلسلة اعداد المسافرين لمطار بغداد الدولي

السنة	الشهر	اعداد المسافرين	اعداد المسافرين بعد التحويل
2015	ايلول	12.18	194983
	تشرين الأول	12.19	196859
	تشرين الثاني	12.13	184980
	كانون الأول	12.15	188239
	كانون الثاني	12.13	185967
2016	شباط	12.17	193138
	اذار	12.13	185046
	نيسان	12.14	187305

191649	12.16	أيار	
196829	12.19	حزيران	
200643	12.21	تموز	
203877	12.23	آب	
199520	12.20	أيلول	
194726	12.18	تشرين الأول	
196637	12.19	تشرين الثاني	
193213	12.17	كانون الأول	

## الاستنتاجات والتوصيات

### 1. الاستنتاجات Conclusions

- من خلال الدراسة النظرية والتطبيقية للموضوع توصل الباحث إلى جملة من الاستنتاجات وكما يلي:-
- 1 أن السلسلة الزمنية لأعداد المسافرين تؤلف سلسلة زمنية غير مستقرة وذلك من خلال ملاحظة رسم هذه السلسلة والتي الأرتباط الذاتي والجزئي المستخرج لهذه السلسلة.
  - 2 عند حساب معاملات الأرتباط الذاتي والجزئي بعد استقرار السلسلة وجد أن دالة الأرتباط الذاتي تتناقص اسيا نحو الصفر في حين دالة الأرتباطالجزئي انقطعت بعد الأزاحة الثانية ، مما يشير الى أن الأنماذج المقترن لتمثيل السلسلة الزمنية هو الأنماذج الأندار الذاتي من الدرجة الثانية (2) AR(2) وهذا مأكنته تنتائج دالة الأرتباط الذاتي الموسعة للعينة .
  - 3 عند استخدام المقاييس الأحصائية(AIC,  $AIC_C$ , BIC) لأختيار أفضل أنماذج للشبكات العصبية المتعددة الطبقات كانت النماذج  $NN(1,2,12;2)$  ,  $NN(1,2,12;1)$  ,  $NN(1,2,3;2)$  ، تم اختيار أفضل هذه النماذج بالأعتماد على جملة من المقاييس الأحصائية وقد تبين أن الأنماذج  $NN(1,2,12;2)$  هو الأفضل .
  - 4 تفوق الطريقة المقترنة من الباحث (Kihoro) لتجديد عدد عقد الادخار لامتلاكه أقل قيمة من المقاييس الإحصائية المستخدمة (MAD, RMSEM, SEP, MAPE).
  - 5 بعد مقارنة نماذج السلسل الزمانية غير الهجينية والهجينة لأعداد المسافرين وبالاعتماد على جملة من المقاييس الأحصائية المستخدمة تفوق الأنماذج الهجين (ANN-ARIMA) على النماذج الأخرى من خلال امتلاكه أقل قيمة لهذه المقاييس حيث تم استخدامه لحساب التنبؤات المستقبلية لأعداد المسافرين للفترة الزمنية من ايلول / 2015 ولغاية كانون الثاني / 2016 .

### 2. التوصيات Recommendation

- 1 استخدام الأنماذج الهجين (ANN-ARIMA) من قبل المنشأة العامة للطيران المدني العراقي للتنبؤ بأعداد المسافرين وذلك لما يتميز به من دقة في النتائج.
- 2 أجراء دراسة لتحليل السلسلة الزمنية بأعداد المسافرين غير المستقرة بأخذ الفروق الكسرية لها و استخدام الأنماذج الهجين (ARFIMA-ANN) لها ومقارنته مع النماذج غير الهجين (ANN,ARFIMA) .
- 3 تغيير نوع الشبكة من الشبكة العصبية الأمامية (FNN) إلى الشبكة العصبية الاسترجاعية كشبكة (Jordan) أو شبكة (Elmans) في دراسات أخرى بغية زيادة دقة التنبؤات .

## المصادر

1. العباسى، عبد الحميد ،(2013) ،"مقدمة في الشبكات العصبية الاصطناعية وتطبيقاتها في العلوم الاجتماعية باستخدام SPSS"قسم الإحصاء الحيوانى السكاني/معهد الدراسات والبحوث الإحصائية .
2. فاندل ، والتر،(1983)،"السلسل الزمانية من الوجهة التطبيقية ونماذج بوكس- جنكينز" ، ترجمة عبد المرضى عزام ، المملكة العربية السعودية .
3. وزارة النقل/المنشأة العامة للطيران المدني/قسم التخطيط والمتابعة ، بيانات لأعداد المسافرين الشهرية للفترة الزمنية (2014-2006) لمطار بغداد الدولى ، بيانات غير منشورة .
4. Box G, E.P & Jenkins, G. M.,(1976), "Time series analysis forecasting and control sanfrancisco Helden-day" .
5. Dr.Andranik Macrdechian, (2003)," Designing a neural network for forecasting financial and economic time series ".
6. Fengxia Zheng and Shouming Zhong,(2011),"Time series forecasting using a hybrid RBF neural network and AR model based on binomial smoothing".
7. G. Zhang, B. E. Patuwo, Michael Y. Hu. , (2001), " The Use of Neural Networks in Forecasting", Review of Economic Sciences, 6, TEI of Epirus, pp. 161-176.
8. I. Kaastra & M. Boyd , (1996),"Designing a neural network for forecasting financial and economic time series", Neurocomputing, 10,215–236.

9. Julian Faraway , Chris Chatfield , (1998), " Time Series Forecasting with neural networks : acomparative study using the airline data " Appl. Statist. 47, part 2 , pp. 231-250.
  10. Kihoro, J.M, Otieno, R.O. , Wafwa, (2004), "SEASONAL Time Series Forecasting ;Acomparatime Study of ARIMA and ANN models", African Journal of Science and Technology (AJST) science and Engineering series.
  11. Makridakis, S., Wheelwright, SC, and Hyndman, R. (1998), "Forecasting Methods and Applications" , 3rd ed., John Wiley & Sons, New York.
  12. Mirza Cilimkovic , (2011), " Neural Networks and Back Propagation Algorithm", Institute of Technology Blanchardstown , Ireland.
  13. N. Merh, et al.,(2010), "A comparison between Hybrid Approaches of ANN and ARIMA for Indian stock trend forecasting," Business Intelligence Journal, vol. 3, pp. 23-43 .
  14. Sterba Ján and Hilovsda Katarína ,(2010),"The Implementation of Hybrid ARIMA-Neural Network Prediction Model for Aggregate Water Consummation Prediction ", Faculty of Mechanical Engineering – Slovak University of Technology in Bratislava.
  15. William W.S. Wei, (2006) "Time Series Analysis Univariate and Multivariate Methods".
  16. Zhang, G.-P. , (2003),"Time series forecasting using a hybrid ARIMA and neural network model", Neurocomputing, 50,159–175 .
- .....  
.....  
.....