

استخدام الطرق الهجينة في التنبؤ لسعر الصرف للدولار الامريكي مقابل الدينار العراقي

المدرس نوال الجراح-كلية الادارة والاقتصاد/ الجامعة المستنصرية
الدكتور ندى الحكاك - كلية بغداد للعلوم الاقتصادية الجامعة

الملخص

في هذه الدراسة تم تطبيق اقتراح نماذج هجينة مكونة من نموذجي التمهيد الاسي والشبكات العصبية و اخر مكون من نموذجي الشبكات العصبية ونموذج ARIMA ونموذج اخر مركب من نماذج التمهيد الاسي والشبكات العصبية و ARIMA باستخدام الانحدار المتعدد لحساب اوزان الدمج. تم تطبيق هذه النماذج على بيانات سعر الصرف اليومي للدولار الامريكي مقابل الدينار العراقي في السوق العراقية وللفترة من كانون الاول 2011 الى السادس عشر من نيسان لسنة 2012 عدا ايام الجمع والعطل الرسمية ولقد تم اختيار النموذج ANNARIMA كأفضل نموذج حسب معيار المقارنة MSE .

Abstract

This study proposed and applied a new hybrid models. The first hybrid model built from exponential smoothing model and neural network model. The second hybrid model built from neural network model and ARIMA model. The third model built from the exponential smoothing model, neural network model, and ARIMA model using multiple-regression to calculate the weights for the compound model.

These models have been applied on the price of American dollar next Iraqi dinar data in Iraqi market. Then the ANNARIMA model has been choosed to be the optimal model depends on MSE measure.

المقدمة

يعرف معدل سعر الصرف على انه سعر الصرف للعملة الاجنبية ويدل على قيمة العملة الاجنبية مقابل قيمة عملة البلد المحسوبة فيه. والتقدير الملائم لمعدل سعر الصرف يعتبر من العوامل المهمة في معدل النمو الاقتصادي للبلدان لذلك ازداد البحث في هذا المجال لانه كما ذكرنا بان معدل سعر الصرف للعملة الوطنية مقابل العملة الاجنبية يؤثر على الاداء الاقتصادي للبلد المعني بالدراسة وكثير من الباحثين في مجال التنبؤ لمعدل سعر الصرف اشارو الى صعوبة التوقع لمعدل سعر الصرف الواقعي كما في (Appiah and Adetunde, 2011, 76). خلال الفترات الماضية استخدمت نماذج كثيرة للتنبؤ بسعر الصرف للعملة الوطنية ومن اكثر هذه النماذج شيوعا كان نموذج التمهيد الاسي ونماذج ARIMA ، بالنسبة لنموذج التمهيد الاسي اشارت الدراسات على اعتباره واحد من الطرق المهمة في التنبؤ كما جاء في (Lai and Wang and Huang, 2006, 493) حيث تم استخدام النموذج الاسي للتنبؤ بالطلب على الخزين ، كما جاء في (الجراح ، 1195 ، 207) وكذلك في (الكيلاني ، الجراح ، و جاسم ، 1992 ، 105) . وكما نعلم بان نموذج التنبؤ بالتمهيد الاسي تم استخدامه في مجالات الادارة والتمويل بصورة كبيرة .و يعتبر من ضمن صنف النماذج الخطية ويساعد على التنبؤ للصفات الخطية للسلاسل الزمنية المالية. ولكن هذا النوع من السلاسل تضمن صفة الخطية والغير خطية والصفات الغير منتظمة . ويعتمد النموذج الاسي على المشاهدات للفترات السابقة وهو غير قادر على التنبؤ للصفات الغير خطية المتواجدة خلال السلسلة الزمنية وغالبا ما تكون النماذج الخطية غير كفوءة في التنبؤ للسلاسل الزمنية المعقدة.

وعليه فمن الضروري اعادة النظر خلال النماذج الغير خطية لسد النقص الموجود في نموذج التمهيد الاسي. اما بالنسبة الى نماذج ARIMA فلقد استخدمت بنجاح في التنبؤ وتحليل السلاسل الزمنية الخطية وهي طريقة توصل اليها العالمان Box and Jenkins كما جاء في (1468, 2009, Aladag, Egrioglu, and Kadilar) ولكنها اقل كفاءة في مجال السلاسل الزمنية الغير خطية المعقدة .

حديثا فان نماذج الشبكات العصبية الذكية ANN اشتهرت بقابليتها على التعرف على الصفات الغير خطية المتواجدة في بيانات السلاسل الزمنية المالية وعليه فان نماذج ANN تم استخدامها بشكل واسع في مجال التنبؤ بالسلاسل الزمنية كما جاء في (1468, 2009, Aladag, Egrioglu, and Kadilar) ولقد تم تطبيق نموذج الشبكات العصبية المتعددة الطبقات للتنبؤ بأسعار صرف العملة وفي مجال سوق الاوراق المالية كما جاء في (2,2007,FATIMA) وتم التوصل الى نتائج جيدة ومع ذلك فان مساوئ تطبيق هذا النموذج في حالة السلاسل الزمنية المعقدة وهو ان هذه السلاسل تتوفر فيها صفة النموذج الخطي وصفة النموذج الغير خطي بنفس الوقت . وعليه فانه من غير المناسب استخدام النماذج الغير خطية للتنبؤ بالسلاسل الزمنية المعقدة لان هذه النماذج قد لا تأخذ بنظر الاعتبار الصفات الخطية المتوفرة في السلسلة الزمنية . وفي بعض الحالات وجد بانه من المناسب استخدام نموذج هجين يعالج الصفات الخطية والغير الخطية ولان نماذج الشبكات العصبية ونماذج التمهيد الاسي ونماذج ARIMA هي نماذج متكاملة وخلال هذه الدراسة تم التوصل الى نموذج مركب من نموذجي التمهيد الاسي والشبكات العصبية ونموذج اخر من نموذجي ARIMA والشبكات العصبية ونموذج اخر يجمع ما بين النماذج الثلاثة باستخدام اساليب مختلفة في الدمج .

نموذج التمهيد الأسّي البسيط والخطي (EXP) Exponential Smoothing Method

نموذج التمهيد الأسّي البسيط هي تقنية تستخدم المتوسط المتحرك الموزون للبيانات السابقة كقاعدة في التنبؤ ، هذه الطريقة تعطي وزن اقل للبيانات الاكثر قدما كما جاء في (1,2003,Ryu and Sanches) ومعادلة نموذج التمهيد الاسي البسيط هي كما يلي :

$$F_{t+1} = \alpha y_t + (1-\alpha)F_{t-1} \dots \dots \dots (1)$$

حيث

F_{t+1} : التنبؤ للفترة القادمة .

α : ثابت التمهيد الاسي وقيمه ما بين الصفر و الواحد .

y_t : المشاهدة الجديدة بالنسبة للسلسلة الزمنية y .

F_t : القيمة الممهدة السابقة او التنبؤ للفترة t السابقة .

لان النموذج يعتمد على قيمة (α) المثلى .

وهناك تقنية تستخدم عادة لتشمل الاتجاه الخطي وتدعى بطريقة Holts.

وتستخدم ثلاثة انواع من المعادلات وهي :

$$L_t = \alpha y_t + (1-\alpha)(L_{t-1} + T_{t-1} \dots \dots \dots (2)$$

$$T_t = \beta(L_t - T_{t-1}) + (1-\beta)T_{t-1} \dots \dots \dots (3)$$

$$F_{t+p} = L_t + PT_t \dots \dots \dots (4)$$

حيث

L_t : القيمة الممهدة حديثاً .

α : ثابت التمهيد للبيانات .

y_t : المشاهدة الجديدة الحقيقية خلال الفترة t .

β : ثابت التمهيد للاتجاه الخطي المتعدد .

P : الفترة المطلوب التنبؤ لها .

F_{t+p} : التنبؤ للفترة P في المستقبل .

القيمة الابتدائية للبيانات الممهدة والاتجاه العام يجب تثبيتها لكي يبدأ النظام بالتنبؤ .

نماذج بوكس جنكنز

منهجية بوكس جنكنز تشير الى مجموعة اجراءات تخص التعريف identifying ، والملائمة fitting

والتدقيق checking لنماذج ARIMA من خلال السلاسل الزمنية للبيانات والتنبؤ يتبع مباشرة من خلال صيغة

النموذج الملائم كما في (2,2006,NOCHAI).

1- نماذج الانحدار الذاتي من الدرجة P . Autoregressive Model AR(P)

ويكون حسب الصيغة التالية كما جاء في (راهي، الجراح، الحكاك، 2011، 428) :

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \dots \dots \dots (5)$$

حيث :

Y_t : تشير الى الاستجابة الى المتغير الى المتغير المستقل عند الفترة t .

Y_{t-1} , Y_{t-2} , Y_{t-p} : تشير الى المتغير او الاستجابة عند الفترات $t-1$, $t-2$, ... , $t-p$ على التوالي .

ϕ_0 , ϕ_1 , ϕ_2 , ... , ϕ_p : تشير الى المعاملات المقدرة .

ε_t : تشير الى الخطأ عند الفترة t .

2- نماذج المتوسطات المتحركة من الدرجة q . Moving Average Model MA (q)

وتكون حسب الصيغة التالية ، (راهي، الجراح، الحكاك، 2011، 428) :

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \dots \dots \dots (6)$$

حيث :

Y_t : هو الاستجابة او المتغير المعتمد عند الفترة t .

μ : المعدل او الثابت خلال تطبيق النموذج.

$\theta_1, \theta_2, \dots, \theta_q$: المعاملات المفروض تقديرها للنموذج.

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$: الاخطاء للفترات السابقة المرتبطة مع المتغير Y_t .

ε_t : هو حد الخطأ عند الزمن t .

3- النماذج المختلطة من الدرجة $ARMA(p,q)$

والصيغة العامة للنموذج ، (راهي، الجراح، الحكاك، 2011، 428) ، هي:

$$\phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \dots (7)$$

ويمكن استخدام شكل دوال الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي Autocorrelation

(PACF), Partial Autocorrelation Function (ACF) لتحديد النموذج حيث يتبع كل منهما

الخواص التالية حسب الجدول التالي:

النموذج	ACF	PACF
AR (p)	يتناقص تدريجيا	هناك قطع مباشر بعد الفترة q .
MA (q)	هناك قطع مباشرة بعد الفترة p .	يتناقص تدريجيا
ARMA (p,q)	يتناقص تدريجيا	يتناقص تدريجيا

الجدول (1) اسلوب تحديد النموذج بأستخدام دوال ACF و PACF

الجدول (1) يبين اسم النموذج وعلاقته بالدوال ACF و PACF .

خطوات بناء نموذج بوكس جنكنز

1-تعريف النموذج Model Identification

1-1 تحديد فيما اذا كانت السلسلة الزمنية مستقرة stationary ام لا. وذلك بأستخدام شكل الدالة ACF . فاذا كان

هناك قطع سريع او هبوط سريع عندها نقول ان سلسلة البيانات مستقرة. اما اذا كانت قيم دالة ACF تتناقص

ببطئ عليه فان السلسلة غير مستقرة.

واذا كانت السلسلة غير مستقرة فيجب تحويلها الى سلسلة مستقرة بأخذ الفروق لها وتستمر بأخذ الفروق الى ان

يكون شكل رسم السلسلة يشير الى تقلب ثابت حول مستوى معين. وان كون شكل دالة ACF اما يتصف

بقطع سريع او هبوط سريع.

في تحليل السلاسل الزمنية هنالك بعض المصطلحات المهمة والتي تستخدم لوصف النموذج مثلاً عامل القيم السابقة (B) والذي يعرف كما يلي

$$BY_t = Y_{t-1} \dots \dots \dots (8)$$

نموذج السلاسل الغير موسمية يسمى بنموذج $ARIMA(p,d,q)$ حيث p تشير الى رتبة الانحدار الذاتي. d تشير الى عامل الفروق. و q تشير الى رتبة المتوسطات المتحركة. فاذا كانت السلسلة الاصلية مستقرة أي $d=0$ فان النموذج $ARIMA$ يقلص الى $ARMA$. ونستخدم العلامة Δ للإشارة الى عملية الفروق حيث :

$$\Delta Y_t = Y_t - Y_{t-1} = Y_t - BY_t = (1 - B)Y_t \dots \dots \dots (9)$$

السلسلة الزمنية المستقرة W_t يتم الحصول عليها بعد اخذ الفرق d لها ونشير الى هذه العملية ب (Δ^d) الى Y_t .

$$W_t = \Delta^d Y_t = (1 - B)^d Y_t \dots \dots \dots (10)$$

اذا يمكن كتابة النموذج $ARIMA(p,d,q)$ بصورة عامة كما يلي:

$$\phi_p(B)(1 - B)^d Y_t = \mu + \theta_q(B)\varepsilon_t \dots \dots \dots (11)$$

2-1 عندما يتم الوصول الى البيانات المستقرة عندها يعرف النموذج حسب الجدول (1).

2- تقدير النموذج Model Estimation: يتم تقدير معاملات النموذج الذي تم اختياره.

3- تدقيق النموذج Model Checking

في هذه المرحلة يجب تدقيق النموذج ومدى ملائمته وذلك بالاهتمام بخواص البواقي $residuals$ فيما اذا كانت قيم الأخطاء الناتجة عن تطبيق نماذج $ARIMA$ تتبع التوزيع الطبيعي وان تكون قيمها عشوائية ويتم ذلك بالأعتماد على اختبار $Ljung-Box Q statistic$ وتحسب قيمة المعلمة Q كما يلي :

$$Q_m = n(n+2) \sum_{k=1}^m \frac{r_k^2(e)}{n-k} \sim \chi_{m-r}^2 \dots \dots \dots (12)$$

حيث :

$r_k(e)$: هو معامل الارتباط الذاتي للخطأ عند الازاحة k

n : عدد الأخطاء

M : عدد فترات الازاحة المشمولة بالاختبار

فاذا كانت قيمة (p -value) المرافقة الى قيمة المعلمة Q صغيرة أي (p -value $< \infty$) فسيكون النموذج غر ملائم . وعلى المحلل ان يختار نموذج اخر او يقوم بتعديل النموذج الذي تم اختياره. ويستمر بالتحليل الى ان يصل الى النموذج الملائم. وكذلك يمكن تدقيق خواص الاخطاء حسب عند ملاحظة شكل الدوال $ACF, PACF$ للاخطاء والتي من المفروض ان تكون صغيرة وواقعة ضمن $\pm 2/\sqrt{n}$.


4- التنبؤ forecasting :

ويكون التنبؤ للفترة او الفترات القادمة باستخدام المعلمات المقدرة للنموذج الذي تم اختياره.

طريقة الشبكات العصبية الذكية (ANN) Artificial Neural Networks

الشبكات العصبية ANN عبارة عن تقنية رياضية صممت لتنفيذ مهام وواجبات مختلفة . كانت هناك دراسات كثيرة في مجال الشبكات العصبية خلال العقود المنصرمة ولكنها ظهرت وبوضوح ابتداء من سنة 1980 . وفي الوقت الحاضر فان تطبيقات الشبكات العصبية ظهرت بوضوح في عدة مجالات وعلى سبيل المثال في مجال النمذجة والتصنيف والتنبؤ كما جاء في (2,2005,Azadeh,Maghsoudi,and Khani) . تتصف الشبكات العصبية ANN ببعض الصفات التي تساعدها في الوصول الى حلول مميزة من خلال تطبيقاتها في مجالات غايتها التعرف على النماذج الخطية والغير خطية . ومن هذه الصفات هي قابلية التعلم Learning ability وصفة العمومية generalization والمعالجة المتوازية parallel processing واجتياز الخطأ error endurance كما جاء في (76,2011,Appiah and Adetunde) هذه الصفات تساعد الشبكات العصبية في حل المشاكل المعقدة بدقة عالية ومرونة كافية .

الشبكات العصبية تتكون من عدد من العصبونات neurons المترابطة ببعضها . وتختلف هيكليّة الشبكات العصبية من حيث طريقة هذه الارتباطات ولكننا سنهتم بنوع واحد فقط ويسمى هذا النوع multi layer perceptron (MLP) أي الشبكات المتعددة المستويات والشكل (1) يوضح شبكة نموذجية متعددة المستويات ، حيث عقد الادخال تستخدم لادخال بيانات السلسلة الزمنية بينما عقد الاخراج تستخدم لحساب التنبؤات والعقد المخفية والتي ترتبط بدالة تحويل ملائمة تستخدم لمعالجة البيانات المستلمة من عقد الادخال كما في (3941,2009,Bon and Leng) و (الجراح ، 19، 2011).



الشكل (1) شبكة عصبية نموذجية ذات ثلاث مستويات

ويمكن كتابة النموذج الخاص بهذه الشبكة كما يلي :

$$y_t = \alpha + \sum_{j=1}^n \alpha_j f\left(\sum_{i=1}^m \beta_{ij} y_{t-i} + \beta_j\right) + \varepsilon_t \dots \dots \dots (13)$$

حيث :

m : تمثل عدد عقد الادخال.

n : تمثل عدد العقد المخفية .

f : تمثل دالة التحويل الاسية sigmoid transfer function وعلى سبيل المثال الدالة اللوغارتمية .

$$\text{Logistic : } f(x) = \frac{1}{1 + \exp(-x)} \dots \dots \dots (14)$$

وان $\{\alpha_j, j = 0, 1, \dots, n\}$ تمثل متجه الاوزان ابتداء من العقد المخفية وانتهاء بعقد الاخراج وان $\{\beta_{ij}, i = 1, 2, \dots, m, j = 1, 2, \dots, n\}$ تمثل الاوزان ابتداء من عقد الادخال وانتهاء بالعقد المخفية .
وان كل من α, β_j اوزان خاصة بحد التحيز ولها قيمة مساوية الى الواحد .
ملاحظة : المعادلة (14) تشير الى استخدام دالة تحويل خطية بالنسبة الى عقد الاخراج لاغراض التنبؤ .
بالنسبة الى نماذج MLP فان خوارزمية التعلم المستخدمة بالاغلب تكون خوارزمية الانتشار الخلفي أي back propagation algorithm وهذه الخوارزمية هي من نوع خوارزميات التعلم بالاشراف supervised توصل اليها العالم werbos في 1974 وتم تحديثها عن طريق العالم (1986) Rumelhart of McClelland . في المرحلة الاولى لعملية التعلم يتم اعطاء قيم ابتدائية عشوائية لجميع الاوزان وتستخدم الخوارزمية مجموعة من البيانات خاصة بمرحلة التعلم ويطلق عليها learning set وتتكون من مجموعة بيانات الادخال ومجموعة بيانات المخرجات المفروضة وكل زوج من بيانات المدخلات والمخرجات يتم الحصول عليها من البيانات التاريخية الخاصة بالسلسلة الزمنية وتستخدم هذه البيانات لتحديث الاوزان عن طريق حساب اصغر قيمة لمجموع مربعات الخطا (SSE) (minimize the sum squared error) المحتسبة عن طريق حساب الفرق مابين قيم مخرجات الشبكة الفعلية والقيم المخطط لها . وبعد حساب قيمة SSE فان خوارزمية الانتشار العكسي ستقوم باجراء التعديلات اللازمة على الاوزان . نماذج الشبكات العصبية استخدمت في مختلف البحوث والتطبيقات وعلى سبيل المثال التنبؤ قصير المدى والنماذج الاكثر استخدام هي نماذج شبكات MLP لان هذه النوعية من الشبكات عندها قابلية لتعلم العلاقات المعقدة مابين مدخلات ومخرجات النموذج والتي يكون من الصعب نمذجتها عن طريق الخوارزميات التقليدية .

هنالك ثلاث خطوات يستخدمها نظام الشبكات العصبية لحل مشكلة معينة وهي :

- التدريب *training*
- الاجمال والعمومية *generalization*
- التطبيق والتنفيذ *implementation*

التدريب هي الاجراءات التي تعتمد على الشبكة للتعلم والتعرف على النموذج الحالي عن طريق مجموعة بيانات الادخال .ويتم تغذية الشبكة ببيانات التدريب والتي تشمل مجموعة بيانات المدخلات ومجموعة بيانات المخرجات المتوقع لها .ولهذا فتوجد لكل شبكة قواعد خاصة لتدريب تلك الشبكة .اما العمومية او اختبار قابلية الشبكة للتوصل الى الحل الامثل عندما تكون المدخلات جديدة ولم تتدرب الشبكة عليها سابقا ويتم في هذه المرحلة تحديد مدى اقتراب وتشابه المخرجات الحقيقية للشبكة بالمخرجات المخطط لها أي مطلوبة ان تكون . خلال فترة التعلم فان الاوزان الخاصة بالربط الداخلى للشبكة يتم تحديثها من اجل تحسين قابلية الشبكة لانتاج مخرجات اكثر اقترابا وتشابها للمخرجات المخطط لها كما جاء في(راهي،الجراح،والحكاك،433،2011).

النظام الهجين و الطريقة المقترحة hybrid method & proposal

طريقتي التمهيد الاسي و طريقة بوكس جنكنز تعالجان الصفات الخطية للسلسلة الزمنية بينما الشبكات العصبية تعالج الصفات الغير خطية للسلسلة الزمنية وللتوصل الى طريقة كفوءة في التنبؤ تم استخدام الطرقة الهجينة عن طريق دمج الشبكات العصبية مع التمهيد الاسي او الشبكات العصبية مع نموذج بوكس جنكنز او نماذج *ARMA* وكما يلي :

$$Y_t = F_1 + F_2 \dots\dots\dots(15)$$

حيث :


F_1 :تمثل الجزء الخطي من السلسلة الزمنية .

F_2 : تمثل الجزء الغير الخطي من السلسلة الزمنية .

الطرق المقترحة للدمج

الجزء الخطي يمكن تقديره باستخدام نموذج التمهيد الاسي الخطي بطريقة *Holt* او بطريقة بوكس جنكنز *ARMA* اما الجزء الغير خطي فيمكن تقديره باستخدام الشبكات العصبية . والاساليب المقترحة للدمج كانت كما يلي :

١ تكون عملية الدمج على مرحلتين ، خلال المرحلة الاولى يستخدم نموذج التمهيد الاسي الخطي بطريقة *Holt* لتقدير معدل سعر الصرف اليومي للدولار مقابل الدينار العراقي او باستخدام نماذج *ARMA* ، وفي المرحلة الثانية يتم تغذية نموذج الشبكات العصبية بمخرجات طريقة التمهيد الاسي او نماذج *ARMA* للمرحلة الاولى لتكون المخرجات هي القيم المتنبأ بها لمعدل سعر الصرف اليومي للدولار الأمريكي مقابل الدينار العراقي .كما هو موضح في المخطط التالي :



الشكل (2) مخطط الفكرة المقترحة الاولى و الثانية

٢ - الاسلوب الثاني للدمج وكما جاء في (Chaimoungkol and Tansathit, 2010, 4) باستخدام اسلوب تحليل الانحدار الخطي لتحديد اوزان الدمج للطرق السابقة وكما يلي:

$$A = a + W_1 F_{EXP} + W_2 F_{ARIMA} + W_3 F_{ANN} \dots \dots \dots (16)$$

حيث :

F_{EXP} : التنبؤ بطريقة التمهيد الاسي الخطي.

F_{ARIMA} : التنبؤ بطريقة بوكس جنكنز

F_{ANN} : التنبؤ بطريقة الشبكات العصبية.

W_1 : الوزن الاول أي معامل الانحدار الخطي الاول.

W_2 :الوزن الثاني أي معامل الانحدار الخطي الثاني.

W_3 : الوزن الثالث أي معامل الانحدار الخطي الثالث

A :البيانات الحقيقية أي المتغير المعتمد.

وعلى اعتبار ان $a=0$ سيكون نموذج الانحدار على فرض ان المتغير المعتمد سيكون البيانات الاصلية
 لسعر الصرف ونتائج التنبؤ بطريقة التمهيد الاسي هي المتغير المستقل الاول ونتائج التنبؤ بنموذج $ARMA$
 هو المتغير المستقل الثاني ونتائج التنبؤ بنموذج الشبكات هو المتغير المستقل الثالث .

دقة النموذج

كما جاء في (3941,2009,Bon and Leng) تم الاعتماد على مقياس الجذر التربيعي لمعدل مربعات الخطا
 كمقياس للمقارنة وكما يلي :

$$RMSE = \sqrt{\frac{\sum (A_t - F_t)^2}{n}} \dots \dots \dots (17)$$

حيث :

A_t :البيانات الاصلية.

F_t :النموذج المركب الهجين.

التطبيق العملي :

البيانات التي استخدمت في هذا البحث كانت لمعدل سعر الصرف اليومي للدولار مقابل الدينار العراقي في السوق
 العراقية وللفترة من الاول من كانون الاول لسنة 2011 والى السادس عشر من نيسان لسنة 2012 تم الحصول
 عليها من النشرة اليومية الخاصة بالبنك المركزي العراقي.

تم تطبيق البرامج الجاهزة statigraph و statistica في حساب نتائج البحث وكما يلي :

١ - الشكل (3) يبين بيانات سعر الصرف اليومي للدولار الأمريكي مقابل الدينار العراقي والذي يشير الى تنذبذ
 سعر الصرف حول معدل ثابت مع تغير مفاجئ الى اسعار ما بين 1210 الى 1250 ثم الى 1290
 دينار مقابل الدولار الواحد. خلال الفترة الاخيرة.

٢ - تم استخدام برنامج statigraph في تطبيق نموذج التمهيد الاسي الخطي على هذه البيانات وكان النموذج
 المفضل كما هو في الشكل (4) عندما كانت قيمة الفا مساوية الى 0.621 وقيمة كاما مساوية الى رقم صغير
 جدا مقارب الى الصفر. والخط المنقط يشير الى قيمة التنبؤ مقارنة بالقيمة الاصلية (الخط الغامق). والجدول
 (2) يوضح قيمة MSE وكذلك مقاييس المقارنة الاخرى. ولكن تم الاعتماد على مقياس MSE في هذه
 الدراسة.

٣ - تم استخدام البرنامج الجاهز statigraph في تحديد النموذج الملائم من نماذج ARIMA على هذه البيانات
 وكان النموذج الافضل هو النموذج $ARIMA(2,1,0)$ والجدول (3) يوضح مقياس MSE بالاضافة الى
 المقاييس الاخرى والجدول (4) يوضح القيم المقدرة لمعاملات النموذج والاشكال (6) و(7) توضح شكل معامل
 الارتباط الذاتي والارتباط الذاتي الجزئي لخطأ النموذج والتي تشير الى جودة النموذج وان الاخطاء عشوائية ولا
 تشير الى نموذج معين.


٤ - تم استخدام البرنامج الجاهز statistica لمعرفة نموذج الشبكات العصبية الملائم وتم اختيار النموذج [MLP 1-5-1] اي عقدة ادخال واحدة وخمسة عقد مخفية وعقدة اخراج واحدة. والجدول (6) يوضح قيمة الاوزان المقدره للعقد المخفية خلال عملية تقدير النموذج النهائي. والجدول (7) يوضح كفاءة النموذج الذي تم اختياره خلال فترة التدريب والذي كانت قيمته 0.9088 وخلال فترة الاختبار والذي كانت قيمته 0.9902 وكانت قيمة الخطأ خلال فترة التدريب 0.006 اما خلال فترة الاختبار فكانت قيمة الخطأ مساوية الى 0.0017 والذي يشير الى جودة النموذج. وكانت الدالة المستخدمة في عقدة الادخال هي الدالة الاسية واستخدمت الدالة اللوجستية في مخرجات النموذج.

٥ - الشكل (8) والجدول (9) يبين مقاييس ونتائج مشابهة الى الفقرة (5) ولكن بعد تطبيقها على مخرجات النموذج الاسي الذي تم اختياره في الفقرة (2).

٦ - الشكل (10) والجدول (10) و الجدول (11) يبين مقاييس ونتائج مشابهة الى الفقرة (5) ولكن بعد تطبيقها على مخرجات نموذج ARIMA الذي تم اختياره سابقا في الفقرة (3) .


٧ - الشكل (10) والجدول (12) يبين نتائج النموذج المركب من نماذج التمهيد الاسي ونموذج ARIMA ونموذج الشبكات العصبية بأستخدام الانحدار المتعدد لتقدير اوزان الدمج. وكانت الاوزان مساوية الى 0.39 ، 0.63 ، 0.75 ، وكان النموذج المفضل كمايلي: $forcast = 0.39 * Exp + 0.63 * ARIMA + 0.75 * NNN$

حيث الارقام تشير الى الاوزان والمصطلحات تشير الى نماذج التمهيد الاسي ونموذج ARIMA ونموذج الشبكات العصبية. اما بقية الاعمدة في الجدول (12) فتشير الى قيم الخطأ القياسي وقيم حدود الثقة لمعاملات النموذج المركب. حسب مقياس الارتباط R ، R^2 ومقياس MSE للنموذج. والجدول (14) يشير الى جدول المقارنة ما بين جميع هذه النماذج حسب قيمة MSE .



الشكل (3) بيانات سعر الصرف اليومي للدولار مقابل الدينار العراقي

الشكل (3) يوضح تنذبذبات البيانات حول معدل ثابت مع وجود تغيير واضح بعد الفترة 41 والفترة 77.




الشكل (4) التنبؤ بطريقة التمهيد الاسي

الشكل (4) يوضح التنبؤ بطريقة التمهيد الأسّي ، حيث يلاحظ بأن التنبؤ يحاول موازنة البيانات الحقيقية ولاستجابة للتغيرات المفاجئة.

Exp. smoothing: S0=1215. T0=.6235 (A1:CH86)) Lin.trend,no season; Alpha= .621 Gamma=0.00 VAR1	
Summary of error	Error
Mean error	0.01182521554
Mean absolute error	4.56180720242
Sums of squares	5680.75639848856
Mean square	66.05530695917

الجدول (2) قيمة MSE لطريقة التمهيد الاسي

الجدول (2) يتضمن قيمة MSE لطريقة التمهيد الأسّي ، حيث يلاحظ وجود قيم لمقاييس أخرى وهي متوسط الأخطاء والمتوسط المطلق للأخطاء ومجموع مربعات الخطأ وأخيرا معدل مربعات الخطأ MSE والذي اعتمد البحث عليه في المقارنة.



الشكل (5) التنبؤ بطريقة بوكس جنكز

الشكل (5) يوضح التنبؤ بطريقة بوكس جنكيز ويلاحظ بأن التنبؤ المتمثل بشكل الخط الاسود المستمر ايضا مقارب الى القيم الحقيقية الممثلة بالمربعات.

```
Nonseasonal differencing of order: 1

Forecast model selected: ARIMA(2,1,0) with constant
Number of forecasts generated: 12
Number of periods withheld for validation: 0
```

Statistic	Estimation Period	Validation Period
MSR	66.3368	
MAE	4.55092	
MAPE	0.36939	
ME	0.000255778	
MPE	-0.00368095	


الجدول (3) قيمة MSE لنموذج ARIMA(2,1,0)

من الجدول (3) نلاحظ قيمة معدل مربعات الخطأ MSE لهذا النموذج وهي 66.3368 مع مقاييس أخرى وهي معدل الخطأ المطلق MAE ومعدل الخطأ المطلق النسبي MAPE ومعدل الخطأ ME ومعدل الخطأ النسبي MPE.

ARIMA Model Summary				
Parameter	Estimate	Std. Error	t	P-value
AR(1)	-0.247658	0.105919	-2.33819	0.021814
AR(2)	-0.282948	0.105921	-2.67131	0.009111
Mean	0.628863	0.580923	1.08252	0.282193
Constant	0.962541			


الجدول (4) معاملات نموذج ARIMA(2,1,0) المقدرة

من الجدول (4) نلاحظ قيمة AR(1) اي θ_1 ، وقيمة AR(2) اي θ_2 وقيمة متوسط القيم والثابت.




الشكل (6) دالة ACF للاخطاء

الشكل (6) يوضح انحصار قيم دالة ACF ما بين حدود الثقة مما يدل على ملائمة النموذج. وعشوائية الاخطاء.



الشكل (7) دالة $PACF$ للاخطاء

الشكل (7) يوضح انحصار هذه القيم ما بين حدود الثقة مما يدل على ملائمة النموذج وعشوائية هذه الاخطاء.



الشكل (8) التنبؤ بطريقة الشبكات العصبية

الشكل (8) يوضح قيم التنبؤ، والمتمثلة باللون الرمادي، بأنها مقاربة جدا للقيم الحقيقية والمتمثلة باللون الغامق.

Weight ID	Network weights (A1:CH86)	
	Connections 7.MLP 1-5-1	Weight values 7.MLP 1-5-1
1	input bias --> hidden neuron 1	0.00436
2	input bias --> hidden neuron 2	0.24349
3	input bias --> hidden neuron 3	3.40886
4	input bias --> hidden neuron 4	-1.34497
5	input bias --> hidden neuron 5	1.12211
6	hidden neuron 1 --> Var1	2.38463
7	hidden neuron 2 --> Var1	0.08245
8	hidden neuron 3 --> Var1	-0.26292
9	hidden neuron 4 --> Var1	-2.10533
10	hidden neuron 5 --> Var1	0.56647
11	hidden bias --> Var1	1.30760
12		


الجدول (6) الاوزان المقدرة للنموذج $MLP 1-5-1$

الجدول (6) يتضمن قيم الازان النهائية لنموذج الشبكات العصبية لعقد الادخال والايخراج.

Summary of active networks (A1:CH86))								
Net. name	Trainin g perf.	Test perf.	Trainin g error	Test error	Training algorithm	Error function	Hidden activation	Output activation
MLP 1-5-1	0.908866	0.990229	0.006174	0.001723	BFGS 110	SOS	Exponential	Logistic

الجدول (7) كفاءة النموذج MLP 1-5-1

الجدول (7) يبين بأن كفاءة النموذج خلال فترة التدريب كانت 0.908866 بينما خلال فترة الاختبار كانت 0.990229 مما يدل على جودة النموذج وإمكانية استخدامه للتنبؤ. إضافة الى وجود قيمة الخطأ أثناء فترة التدريب 0.006174 وأثناء فترة الاختبار 0.001723 وكذلك يوضح الدوال المستخدمة للادخال وهي exp ، وللاخراج حيث كانت الدالة Logistic.



الشكل (9) التنبؤ بطريقة الشبكات العصبية لنموذج التمهيد الاسي

الشكل (9) يوضح جودة التنبؤ بصورة اكبر مما سبق والخط الرمادي يمثل التنبؤ اما الغامق فيمثل نمو القيمة الحقيقية.

Weight ID	Network weights (exp (A1:CH86))	
	Connections 3.MLP 1-4-1	Weight values 3.MLP 1-4-1
1	input bias --> hidden neuron 1	-0.022035
2	input bias --> hidden neuron 2	0.033244
3	input bias --> hidden neuron 3	0.158435
4	input bias --> hidden neuron 4	-0.104704
5	hidden neuron 1 --> Var1	1.895527
6	hidden neuron 2 --> Var1	0.084649
7	hidden neuron 3 --> Var1	1.058420
8	hidden neuron 4 --> Var1	1.784542
9	hidden bias --> Var1	0.046416


الجدول (8) الاوزان المقدرة للنموذج MLP 1-4-1

الجدول (8) يوضح قيمة الاوزان لعقد الادخال والاخراج المستخلصة كأفضل قيمة للنموذج MLP 1-4-1.

Summary of active networks (exp (A1:CH86))								
Net. name	Trainin g perf.	Test perf.	Trainin g error	Test error	Training algorithm	Error function	Hidden activation	Output activation
MLP 1-4-1	0.9553 03	0.975 469	0.00273 8	0.000 919	BFGS 6	SOS	Tanh	Identity

الجدول (9) كفاءة النموذج MLP 1-4-1

الجدول (9) يوضح كفاءة النموذج اثناء التدريب حيث كانت 0.955303 اما اثناء الاختبار فكانت 0.975469 وقيمة الخطأ اثناء التدريب 0.00273 اما اثناء الاختبار فهي 0.000919 وهي صغيرة جدا. ودالة الادخال كانت Tanh اما الاخراج فكانت Identity.



الشكل (10) التنبؤ بطريقة الشبكات العصبية لنموذج $ARIMA(2,1,0)$

الشكل (10) يوضح تقارب التنبؤ للقيم الحقيقية بشكل واضح والذي يمثل بالخط الرمادي.

Weight ID	Network weights (ARMA(2,1,0) (B2:CH86))	
	Connections 5.MLP 1-8-1	Weight values 5.MLP 1-8-1
1	input bias --> hidden neuron 1	0.24001
2	input bias --> hidden neuron 2	0.40325
3	input bias --> hidden neuron 3	-0.45215
4	input bias --> hidden neuron 4	0.19432
5	input bias --> hidden neuron 5	0.04151
6	input bias --> hidden neuron 6	0.10251
7	input bias --> hidden neuron 7	0.52607
8	input bias --> hidden neuron 8	-0.16047
9	hidden neuron 1 --> Var2	-1.28971
10	hidden neuron 2 --> Var2	2.27497
11	hidden neuron 3 --> Var2	1.52300
12	hidden neuron 4 --> Var2	-1.96663
13	hidden neuron 5 --> Var2	-0.95034
14	hidden neuron 6 --> Var2	-0.76259
15	hidden neuron 7 --> Var2	-1.45499
16	hidden neuron 8 --> Var2	0.35607
17	hidden bias --> Var2	-1.23774
18		

الجدول (10) الاوزان المقدرة للنموذج $MLP 1-8-1$


الجدول (10) يوضح قيم الاوزان النهائية لعقد الادخال والاخراج ، وهي القيم الافضل للنموذج $MLP 1-8-1$.

Summary of active networks (ARMA(2,1,0) (B2:CH86))

Index	Net. name	Training perf.	Test perf.	Training error	Test error	Training algorithm	Error function	Hidden activation	Output activation
5	MLP 1-8-1	0.933645	0.982201	0.003596	0.001124	BFGS 18	SOS	Tanh	Exponential

الجدول (11) كفاءة النموذج MLP 1-8-1

الجدول (11) يوضح كفاءة النموذج في فترة التدريب الى 0.93364 وفترة الاختبار كانت 0.982201 اي جودتهما في مرحلتي التخطيط والاختبار. والخطأ في مرحلة التدريب 0.003596 والاختبار 0.001124 .



الشكل (10) التنبؤ بالطريقة المركبة

الشكل (10) يبين المعادلة المستخدمة في النموذج المركب والموجودة في اعلى الشكل حسب نموذج الانحدار .

Parameter Estimates (OBSEXPNNNARMA (B2:CH86)) Sigma-restricted parameterization

	Var1 - Param.	Var1 - Std.Err	Var1 - t	Var1 - P	-95.00% - Cnf.Lmt	+95.00% - Cnf.Lmt	Var1 - Beta (?)	Var1 - St.Err. ?	-95.00% - Cnf.Lmt	+95.00% - Cnf.Lmt
"Var2"	- 0.39560 4	0.45700 7	- 0.86564 1	0.38921 3	- 1.30474	0.51352 9	- 0.39559 2	0.45699 3	- 1.30470	0.51351 3
"Var3"	0.63854 7	0.44512 1	1.43454 8	0.15521 9	- 0.24694	1.52403 4	0.63853 6	0.44511 3	- 0.24694	1.52400 8
"Var4"	0.75696 4	0.19800 4	3.82297 8	0.00025 6	0.36307	1.15085 7	0.75703 8	0.19802 3	0.36311	1.15096 9

الجدول (12) تقدير اوزان النموذج المركب بطريقة الانحدار المتعدد

الجدول (12) يوضح قيم معاملات النموذج المركب حسب نموذج الانحدار وحسب معادلة الانحدار وهي 0.39 ، 0.63 ، 0.75 وقيم الخطأ المطلق وحدود الثقة لكل معامل.

Test of Whole Model, Adjusted for the Mean (Y=Mean) (OBSEXPARMANN
(B2:CH86))

	Multi ple - R	Multi ple - R ²	Adju sted - R ²	SS - Mod el	df - Mod el	MS - Mod el	SS - Resid ual	df - Resid ual	MS - Resid ual	F	p
Var1	0.9300 58	0.8650 08	0.8617 15	29570. 28	3	9856.7 61	4614.7 06	82	56.276 90	175.14 75	0.00

الجدول (13) كفاءة النموذج المركب

الجدول (13) يوضح قيم معامل الارتباط R وكانت 0.93 ومعامل الارتباط R^2 وكان 0.865 والذي كان يقيس كفاءة النموذج المركب. بالإضافة الى المعاملات الاخرى.

الانموذج	exp	ARIMA	nnnobs- 1-5-1	nnnexp- 1-4-1	NNNARMA1- 8-1	REGEXPARMANN
MSE	66.055	63.9927	56.347	28.585	3.166093	53.97695

الجدول (14) جدول المقارنة لجميع النماذج حسب قيمة MSE

الجدول (14) يوضح قيم معدل مربعات الخطأ MSE لجميع النماذج المستخدمة ويلاحظ بأن اصغر معامل كان للنموذج الخامس وكانت قيمته 3.166 .

النتائج والتوصيات

١. اثبتت الدراسة بأن نموذج التمهيد الأسّي الخطي ، وعندما كانت قيمة الفا مساوية الى 0.621 وقيمة كما مقارنة الى الصفر ، هو الافضل بالنسبة الى نماذج التمهيد الأسّي.
٢. اثبتت الدراسة بأن نموذج ARIMA(2,1,0) كان النموذج الافضل بالنسبة الى نماذج بوكس جنكز ولهذه الفئة من البيانات.
٣. اثبتت الدراسة بأن النموذج [MLP 1-5-1] هو الافضل بالنسبة الى نماذج الشبكات العصبية ولهذه الفئة من البيانات.
٤. الجدول (12) اظهر نتائج المقارنة للطرق الاصلية والطرق الهجينة، من ملاحظة الجدول فان النموذج NNNARMA1-8-1 هو الافضل وكذلك نموذج REGEXPARMANN حسب مقياس المقارنة MSE .
٥. اثبتت الدراسة افضلية استخدام النماذج الهجينة المقترحة على استخدام طرق التمهيد الاسي الخطي ونماذج بوكس جنكز وطريقة النماذج العصبية كل على حدة حسب المقياس MSE والاشكال البيانية السابقة .
٦. نوصي باجراء تجارب جديدة لتقدير اوزان الدمج وكذلك الدمج مابين الطرق الاخرى في التنبؤ من اجل التوصل الى افضل الطرق الهجينة في التنبؤ.

المصادر:

- [1] الكيلاني محمد، الجراح نوال، و جاسم إنتصار نموذج تكيفي مركب للتنبؤ بطريقة التمهيد الاسي المؤتمر العلمي الثامن لكلية الادارة والاقتصاد ، الجامعة المستنصرية ، العراق ، 1992.
- [2] الجراح نوال وضع الخطة السنوية لتعزيز الخزين بواسطة البرمجة الخطية مجلة كلية الادارة والاقتصاد ، العدد السابع عشر ، الجامعة المستنصرية ، العراق ، 1995.
- [3] الجراح نوال كفاءة طريقتي الشبكات العصبية وطريقة بوكس جنكنز في التنبؤ مع حالات تطبيقية في العراق مجلة الادارة والاقتصاد ، العدد التاسع والثمانون ،الجامعة المستنصرية ، العراق ، 2011.
- [4] راهي عبد الرحيم ، الجراح نوال ، الحكاك ندى التنبؤ للحمل الاقصى للطاقة الكهربائية للشبكة الوطنية (دراسة مقارنة) المؤتمر العلمي الحادي عشر، كلية الادارة والاقتصاد ، الجامعة المستنصرية ، العراق ، 2011.
- [5] Aladag Cagdas H., Egrioglu Erol, and Kadilar Cem **Forecasting nonlinear time series with a hybrid methodology**, Hacettepe University, Turkey, Applied Mathematic Letters, Elsevier, 2009.
- [6] Appiah S.T. and Adetunde I.A. **Forecasting Exchange Rate between the Ghana Cedi and the US Dollar Using Time Series Analysis**, University of Mins and Technology, China, Current Research Journal of Economic Theory, Maxwell Scientific Organization, 2011.
- [7] Azadeh A., Maghsoudi A., and Khani S. Sohrab **Using an Integrated Artificial Neural Networks Model for Predicting Global Radiation: The Case Study of Iran**, Research Institute of Energy Management and Planning, University of Tehran, 2005.
- [8] Chaimongkol Watchareeporn and Tansathit Chutatip **Forecasting Model for Automobile Sales in Thailand**, National Institute of Developing Administration, 2010.
- [9] Lai Kin Keung, Yu Lean, Wang Shouyang, and Hang Wei **Hybridizing Exponential Smoothing and Neural Network for Financial Time Series Predication**, City University of Hong Kong, Springer, 2006.
- [10] Nochai Rangsan and Nochai Titida **Arima Model for Forechasting Oil,Plam Price**, Mongkut's Institute of Thcnology Ladkrabang, Bangkok, proceding the 2nd IMT-GT Regional Conference on Mathematics, Statistics and Applicaton, USM, Malaysia, 2006.
- [11] Ryu Kisang and Sanches Alfonso **The Evaluaion of Forcasting Methods at an Institutional Foodservice Dining Facility**, Journal of Hospitality Financial Management, Volume 11, Issue 1, 2003.
- [12] Samreen Fatima **Hybrid System of Simple Exponential Smoothing and Neural Network**, FAST national university, Karachi, Market Forces January, 2007