

التنبؤ بمعدل الاحتفاظ الأمثل لأقساط التأمين المكتسبة
باستخدام نموذج إحصائي مدمج
"دراسة تطبيقية على فروع التأمينات العامة بسوق التأمين المصري"

دكتور/

وائل محمود علي محمد

كلية التجارة - جامعة أسيوط

قسم الإحصاء والرياضة والتأمين

ahsagr@aun.edu.eg

دكتور/

أحمد عبدالوهاب أحمد علي

كلية التجارة - جامعة أسيوط

قسم الإحصاء والرياضة والتأمين

wmohamed@tu.edu.sa

ملخص البحث :

تهدف الدراسة إلى بناء نموذج إحصائي مدمج يمكن من خلاله التنبؤ بمعدل الاحتفاظ الأمثل بالأقساط المكتسبة بفروع التأمينات العامة لدى شركات التأمين المباشر في سوق التأمين المصري، وذلك بالاعتماد على كلٍ من نموذج الشبكات العصبية (ANN) ونموذج السلاسل الزمنية (ARIMA) وفقا لمنهجية Box-Jenkins، وذلك لما توفره النماذج المدمجة من دقة وكفاءة عالية في التنبؤ مقارنة بالنماذج الإحصائية الفردية، وتم ذلك باستخدام أسلوبين مختلفين في الدمج أحدهما باستخدام القيم المقدرة للبواقي (الأخطاء العشوائية)، والآخر باستخدام القيم المقدرة لمعدلات الاحتفاظ، وأجريت الدراسة على جميع شركات التأمين المباشر بسوق التأمين المصري، والتي تعمل في مجال التأمينات العامة بفروعها المختلفة، خلال السلسلة الزمنية (١٩٨٩م-٢٠١٨م)، وتم التنبؤ بمعدلات الاحتفاظ باستخدام النماذج الفردية ثم التنبؤ باستخدام النماذج المدمجة، ووفقا للمقاييس الإحصائية لدقة التنبؤ تبين أن هناك انخفاض في قيمتي كل من متوسط مربع الأخطاء المطلقة MSE ومتوسط الانحرافات المطلقة MAPE للنموذج المدمج باستخدام القيم المقدرة للبواقي مقارنة باستخدام أسلوب القيم المقدرة لمعدلات الاحتفاظ وأسلوب النماذج الفردية، حيث نتج عن استخدام النموذج المدمج دقة عالية في القدرة التنبؤية بمعدلات الاحتفاظ بالأقساط المكتسبة.

الكلمات المفتاحية: التأمينات العامة، معدلات الاحتفاظ بالأقساط المكتسبة، نماذج ARIMA، نماذج الشبكات العصبية الاصطناعية ANN، النماذج الإحصائية المدمجة.

**Forecasting The Optimal Retention Rate of Earned Premiums
Using a Built-in Statistical Model
"An Applied Study On The Branches of General Insurance In The
Egyptian Insurance Market"**

Abstract

The study aims to build a built-in statistical model through which it is possible to predict the retention of premiums acquired in general insurance branches with direct insurance companies in the Egyptian insurance market, by relying on the Neural Networks Model (ANN) and Time Series Model (ARIMA) according to the Box-Jenkins methodology This is because the models provided provide high accuracy and efficiency in forecasting compared to individual statistical models, and this was done using a different method of consolidation, one using the estimated values of the errors , and the other using the estimated values of retention rates.

the study was conducted on all direct insurance companies in the Egyptian insurance market that work in the field of general insurance with its various branches throughout the time series (1989-2018).

Retention rates were predicted using individual models and then predicted using models. According to statistical measures of prediction accuracy, it was found that there was a decrease in the values of both the mean square error errors MSE and the mean absolute deviations of the MAPE model using the estimated values of the remaining compared to using the estimated values method for the retention rates. And the individual model method, whereby the use of the combined model resulted in a high accuracy in predictive power of the premiums retention rates.

Keywords: General Insurance, Retention Rate of Earned Premiums, ARIMA Models, ANN Model,

المبحث الأول

الإطار العام للدراسة

أولاً: مقدمة البحث:

تهتم العديد من شركات التأمين بتطبيق الأسس والأساليب العلمية في إدارة العمليات الفنية وبرامج التأمين المختلفة، ومن ثم وضع السياسات الاكتتابية والاستثمارية لجميع أنشطتها التأمينية بكافة فروع التأمين التي تزاولها، وتسعى تلك الشركات جاهدة لدراسة واستخدام الأساليب الإحصائية الحديثة اللازمة لتحقيق الاستمرارية والتطوير للمنظومة التأمينية، ومن هذا المنطلق تسعى شركات التأمين المباشر إلى الاهتمام بجميع العناصر الرئيسية في عمليات الاكتتاب، ومن أهمها معدلات الاحتفاظ بالأقساط المكتسبة بفروع التأمينات العامة.

ويعرف معدل الاحتفاظ بأنه قيمة الأقساط التي تحتفظ بها شركات التأمين ضمن طاقتها الاستيعابية من إجمالي الأقساط المكتسبة بكل فرع من فروع التأمين، وتقوم شركات التأمين المباشر بإعادة تأمين ما يزيد عن معدل الاحتفاظ لدى شركات إعادة التأمين المحلية أو الأجنبية أو في كلاهما. (الحميدي، حسين، ٢٠١٥)

ويحظى تحديد معدل الاحتفاظ الأمثل باهتمام كبير من قبل شركات التأمين لما له من أهمية وتأثير بالغين على حجم الأعمال التي تستطيع الشركة تغطيتها، فزيادة معدلات الاحتفاظ يتبعه زيادة الطاقة الاستيعابية للسوق ككل دون إهمال الأسس الفنية السليمة لعملية الاكتتاب، إلا أن هذه الزيادة تحتاج لمطالبات ومعايير علمية سليمة تتيح النجاح لتلك الشركات في تبني هذه الفلسفة كمنهاج عمل يتيح لها الارتقاء بمبيعاتها من الوثائق وتوسيع تغطيتها ومواجهة المنافسة، والتكيف مع التغيرات الخارجية وحالة عدم الاستقرار السائدة في الأسواق العالمية. (ابراهيم، ٢٠١٣)

كما أن تحديد معدل الاحتفاظ الأمثل من الأقساط المكتسبة يعطي مؤشراً هاماً على حجم ونوعية الأخطار المكتتب فيها مما يؤدي إلى توفير إمكانية الاكتتاب الفوري للأخطار، وتوسيع قاعدة التغطيات التأمينية لتلبية كافة الخدمات التأمينية للعملاء. (ابراهيم، ٢٠١٣)

وتعتبر عملية التنبؤ من أهم الأدوات الفنية التي تبني عليها العديد من القرارات الهامة في مجال التأمينات العامة، حيث تعتبر عنصراً أساسياً في عملية التخطيط المستقبلي لعمليات الاكتتاب في

مختلف الأخطار نظراً لاعتماد شركة التأمين بشكل كبير على هذه العملية الفنية في تحديد قيم الأقساط الواجب تحصيلها مستقبلاً، وتقدير قيم الالتزامات المستقبلية (التعويضات) عند تحقق الأخطار المؤمن منها، إلى جانب أهميتها في تحديد الأهداف ورسم السياسات المتعلقة ببرامج إعادة التأمين (مشعال، ٢٠١٥).

وتعددت النماذج والأساليب الإحصائية التي استخدمت في عملية التنبؤ في مختلف الأنشطة الاقتصادية بشكل عام ومجال التأمين بشكل خاص، ومن النماذج الإحصائية التي تم استخدامها في التنبؤ في مجال التأمينات العامة ما يلي:

(١) - نماذج السلاسل الزمنية ARIMA

وهي أحد أساليب التحليل الإحصائي للبيانات غير المستقلة زمنياً، وهذه النماذج تقدم حلاً جيداً أكثر عملية ومنطقية من الأساليب الإحصائية الأخرى في عملية التنبؤ بالظواهر المستقبلية. (أبولانصر، ٢٠١٣).

(٢) - نماذج الشبكات العصبية الاصطناعية ANN

وتعتمد هذه النماذج على تحليل البيانات المشوشة مع إمكانية التحليل والتعلم من البيانات التاريخية وتناهي الخطأ القياسي في عملية التنبؤ، وظهرت هذه النماذج كبديل للنماذج الإحصائية التقليدية المستخدمة في عملية التنبؤ، بل تفوقت عليها في دقة النتائج المتحصل عليها، وتظهر مقدرة الشبكات العصبية الاصطناعية في قدرتها الكبيرة على التعامل مع سلوك عدم الخطية في البيانات (إبراهيم، ٢٠١٣)، وتم تطبيق الشبكات العصبية بفعالية في مجال التأمين وخاصة في التنبؤ والتصنيف.

ومعظم البحوث التأمينية التي اهتمت بتقدير معدلات الاحتفاظ بالأقساط المكتسبة تستخدم النماذج الفردية التقليدية في عملية التنبؤ، وهي نماذج يعترها الكثير من العيوب كعدم الدقة في التقدير، وافترض استقلالية الخطأ العشوائي. (إبراهيم، ٢٠١٣).

وبالتالي فإن دراسة وتطوير أساليب إحصائية حديثة للتنبؤ أصبح هدفاً رئيسياً تسعى إليه العديد من شركات التأمين المباشر، ومع الحاجة المستمرة لاستخدام نماذج إحصائية أكثر دقة في عملية التنبؤ في شركات التأمين، يسعى الباحثان إلى بناء نموذج إحصائي مدمج يجمع بين أكثر من نموذج فردي لاستخدامه في عملية التنبؤ بمعدلات الاحتفاظ، حيث أن تقنيات الدمج المختلفة

تعويض النقص الموجود في كل نموذج على حدة، بمعنى أنها تقلل الخطر الناشئ من استخدام نموذج فردي غير مناسب، وبالتالي الحصول على دقة تنبؤية أكثر نسبياً.

وفي هذه الدراسة يتم التنبؤ بمعدلات الاحتفاظ المثلى للأقساط المكتسبة في فروع التأمينات العامة بسوق التأمين المصري من خلال استخدام نموذج مدمج بين نموذج ARIMA ونموذج الشبكات العصبية الاصطناعية ANN وذلك للاستفادة من مزايا النموذج المدمج في عملية التنبؤ ومعالجة الصفات غير الخطية في بيانات السلسلة الزمنية.

ثانياً: الدراسات السابقة:

تسعى جميع الدراسات التطبيقية في مجال التأمينات العامة إلى اختيار الأساليب الإحصائية المناسبة للحصول على مقدرات دقيقة لمعالم العلاقات بين المتغيرات بحيث تتميز هذه المقدرات بالدقة والكفاءة والاتساق بما يضمن دقة التحليل والاختبار، ومن ثم الحصول على التنبؤ العلمي السليم. (محمد، ٢٠١٤).

وتنوعت الدراسات السابقة التي استخدمت النماذج الإحصائية الفردية والمدمجة للقيام بعملية التنبؤ في مجال التأمينات العامة، فقد استخدمت دراسة (الغنام، ٢٠٠٣) منهجية Box-Jenkins في تحليل السلسلة الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية، وتوصلت الدراسة إلى أن أفضل نموذج يمكن تطبيقه على بيانات المؤشر العام للأسعار الأسهم هو نموذج الانحدار الذاتي من الدرجة الأولى.

كما قامت دراسة (طاقية، ٢٠٠٥) بإجراء مقارنة بين نموذجين مختلفين للتنبؤ بالقيم المستقبلية لأسعار الأسهم في البورصة المصرية: الأول هو نموذج السلاسل الزمنية (ARIMA) وفقاً لمنهجية (Box-Jenkins) والثاني: نموذج الانحدار الديناميكي وهو ما يطلق عليه دالة التحويل (TF) Transfer Function، وتوصلت الدراسة إلى أن نموذج دالة التحويل يعتبر أكثر دقة في عملية التنبؤ من نموذج السلاسل الزمنية ARIMA.

واقترحت دراسة (Lai, Yu, Wang, & Huang, 2006) منهجية النماذج المدمجة بين كل من التحليل الآسي والشبكات العصبية للتنبؤ بالسلسلة الزمنية المالية، واستكشاف القدرة على التنبؤ بمنهجية النماذج المختلطة المقترحة للتنبؤ، ونتج عن الدراسة أن المنهجية المختلطة للنماذج تعمل بشكل أفضل من النماذج الفردية.

وحاول كلاً من (Mantri & Gahan, 2010) دراسة تقلبات أسعار الأسهم لمؤشري (S&P500) و (Hang Seng) في أسواق الأسهم الهندية باستخدام عدة نماذج مثل نموذج GARCH و EGARCH و GJRGARCH و IGARCH ونموذج الشبكات العصبية الاصطناعية ANN، وتوصلت الدراسة إلى دقة التنبؤ باستخدام نموذج الشبكات العصبية الاصطناعية عن باقي النماذج المستخدمة.

وفي دراسة (Merh & Prakash & Pardasani, 2010) تم تطوير نموذج مدمج باستخدام تقنيات الشبكات العصبية الاصطناعية للتنبؤ بسعر إغلاق اليوم التالي والتنبؤ باتجاه الأسهم في الأسواق المالية الهندية، وأظهرت النتائج أن التنبؤ بالنموذج المختلط ARIMA-ANN قادر على التنبؤ بسعر الإغلاق في الأسواق المالية بدقة أفضل من النماذج الفردية.

وفي دراسة (الجراح، ٢٠١١) تم مقارنة كفاءة طريقة بوكس جينكينز مع طريقة الشبكات العصبية للتنبؤ بالسلاسل الزمنية، وتم التوصل إلى أن طريقة الشبكات العصبية أكثر كفاءة ودقة وتعطي نتائج أدق للتنبؤ، وبالإمكان الاعتماد عليها كطريقة بديلة في التنبؤ.

كما هدفت دراسة (القاسمي، ٢٠١٣) إلى استخدام نماذج (ARIMA) ونموذج الشبكات العصبية (ANN) ومقارنة النموذجين لغرض التنبؤ بالاتجاه الشهري لأسعار النفط الخام في اليمن، وتبين من الدراسة أن نموذج الشبكات العصبية هو الأكثر دقة في عملية التنبؤ.

وجاءت دراسة (مشعال، ٢٠١٥) كمحاولة للتنبؤ بأقساط التأمين التعاوني في السوق السعودي، وتم استخدام نموذج دالة التزاوج ليشمل نموذج الانحدار المتعدد ونموذج الشبكات العصبية ونموذج السلاسل الزمنية، وتبين أن النموذج المدمج هو الأكثر ملائمة للبيانات وأكثر دقة مقارنةً بالنماذج الفردية.

واقترحت دراسة (أحمد، ٢٠١٧) نموذج إحصائي للتنبؤ بالأزمات المالية وإدارتها في البنوك التجارية من خلال استخدام نموذج الشبكات العصبية (ANN)، وأظهرت نتائج الدراسة أن الشبكات العصبية الاصطناعية أداة قوية يمكن الاستفادة منها في عمليات التنبؤ بالأزمات المالية التي تواجه البنوك التجارية.

كما هدفت دراسة (Al-Shayea, 2017) إلى التنبؤ بسعر الإغلاق المستقبلي لمؤشر داوجونز للأوراق المالية باستخدام الشبكات العصبية الاصطناعية ونموذج الانحدار الذاتي غير الخطي، وأظهرت النتائج أن النموذج المدمج من النماذج عالية الدقة في التنبؤ.

إضافة البحث للدراسات السابقة:

من الملاحظ أن معظم الدراسات التأمينية التي اهتمت بتقدير معدلات الاحتفاظ في شركات التأمين اعتمدت على النماذج الفردية التقليدية في عملية التنبؤ، مما انعكس أثرها على العديد من القرارات التأمينية للشركات مثل القرارات المتعلقة بالسياسات الاكتتابية أو البرامج الاستثمارية أو برامج إعادة التأمين أو تكوين الاحتياطات الفنية وغيرها، ورغبةً في تحسين قدرة الشركات على اتخاذ القرارات السليمة جاءت إضافة هذا البحث في اقتراح نموذج إحصائي مدمج ثنائي بين نموذج الشبكات العصبية الاصطناعية ونموذج السلاسل الزمنية ARIMA، وذلك للاستفادة من الدقة العالية في عملية التنبؤ باستخدام النماذج المدمجة.

ثالثاً: مشكلة البحث:

تعتبر عملية التنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة في شركات التأمين المباشر من أهم العمليات الفنية التي تعتمد عليها الكثير من المؤشرات الهامة في السياسات التأمينية المختلفة، لما لها من دور فعال في رسم السياسات والخطط التمويلية والتسويقية للشركة، ويترتب على عدم دقة تلك التقديرات خلل كبير في اتخاذ القرارات والسياسات الاكتتابية المرتبط تحديدها بتقدير معدلات الاحتفاظ.

وبدراسة وتحليل معدلات الاحتفاظ بالأقساط المكتسبة في فروع التأمينات العامة في سوق التأمين المصري خلال الفترة الزمنية (١٩٨٩ - ٢٠١٨م) كما في الجدول التالي:

جدول رقم (١)

معدلات الاحتفاظ بالأقساط المكتسبة لفروع التأمينات العامة بسوق التأمين المباشر المصري خلال الفترة (1989-2018) (%)

Year	Retention Limit	Year	Retention Limit
1989	37.7	2004	45.8
1990	40.2	2005	45.1
1991	40.1	2006	46.5
1992	40.4	2007	45.3
1993	38.8	2008	48.3
1994	40.0	2009	49.7
1995	40.4	2010	52.4
1996	40.6	2011	49.9
1997	41.7	2012	47.8
1998	43.0	2013	46.1
1999	43.3	2014	47.9
2000	45.2	2015	51.4
2001	46.2	2016	53.3
2002	47.6	2017	54.6
2003	47.9	2018	53.8

المصدر: من إعداد الباحثان، الكتاب الإحصائي السنوي، هيئة الرقابة المالية، أعداد مختلفة (٢٠١٨-١٩٨٩م)

ويتضح من الجدول السابق ما يلي:

(١) - أن هناك تذبذب في متوسط معدلات الاحتفاظ خلال سنوات الدراسة، وأن هناك اتجاه عام من جانب شركات التأمين المباشر نحو زيادة معدلات الاحتفاظ ولكنها زيادات طفيفة، حيث بلغ معدل الاحتفاظ بالأقساط المكتسبة لسوق التأمين المباشر ككل في نهاية عام 2018 م حوالي 53.8% من إجمالي الأقساط المباشرة مقارنة بمعدل الاحتفاظ في نهاية عام 1989 حيث بلغ حوالي 37.7% أي بمعدل نمو حوالي 70% .

(٢) - أن هناك ارتفاع في جزء الأقساط غير المستغلة لدى شركات التأمين المباشر (اسنادات إعادة التأمين للغير) حيث بلغ متوسط نسبته لفروع التأمينات العامة في عام 2018 م حوالي 46.2%

(100% - 53.8%) من إجمالي الأقساط المباشرة، وتقوم تلك الشركات بإسناد هذا الجزء من الأقساط لشركات إعادة التأمين سواء كانت شركات محلية أو أجنبية مما يترتب عليه فقدان شركة التأمين المباشر لنسبة عالية من الأرباح المحققة من وراء تلك الأقساط، والتي تؤول إلى شركات إعادة التأمين وخاصة الشركات الأجنبية.

وتعتمد شركات التأمين في التنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة على النماذج الإحصائية الفردية التقليدية التي يعترها الكثير من العيوب كعدم الدقة في التقدير والمشاكل الفنية عند التطبيق وعدم قدرتها على معالجة بعض المشكلات غير الخطية للبيانات.

ومما سبق يمكن تلخيص المشكلة فيما يلي:

(١) - انخفاض معدلات الاحتفاظ بالأقساط المكتسبة في فروع التأمينات العامة في شركات التأمين مما نتج عنه فقدان العديد من العوائد المتوقعة لتلك الأقساط.

(٢) - اهتمام شركات التأمين بتحديد معدلات الاحتفاظ بالأقساط المكتسبة بطرق وأساليب إحصائية تقليدية مما أدى إلى عدم الدقة في تحديد تلك المعدلات، وبالتالي انعكس تأثير ذلك على كثير من العمليات الفنية والسياسات التأمينية والاستثمارية لشركات التأمين.

(٣) - اهتمام معظم الدراسات التأمينية في مجال التنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة بتطبيق النماذج الإحصائية الفردية، والتي يعترها العديد من العيوب مثل: عدم الدقة في التقدير، وانخفاض القدرة التفسيرية للنموذج، ومن ثم انعكس تأثيرها على اتخاذ العديد من القرارات الهامة بشركات التأمين.

(٤) - ندرة البحوث والدراسات التأمينية التي تناولت النماذج الإحصائية المدمجة في مجال التأمين بالرغم من مزاياها المتعددة مقارنة بالنماذج الفردية.

رابعاً: هدف البحث:

يتمثل الهدف الرئيسي للبحث في بناء نموذج إحصائي يمكن من خلاله التنبؤ بمعدل الاحتفاظ الأمثل من الأقساط المكتسبة بفروع التأمينات العامة لدى شركات التأمين المباشر في سوق التأمين المصري، وذلك بالاعتماد على نموذج إحصائي مدمج بين كل من نموذجي تحليل الشبكات العصبية وتحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins)، وذلك لما توفره النماذج الإحصائية المدمجة من دقة وكفاءة عالية في التنبؤ خلال الفترات الزمنية قصيرة

الأجل مقارنة بالنماذج الإحصائية الفردية، ويمكن تحقيق الهدف الرئيسي من خلال تحقيق مجموعة من الأهداف الفرعية التالية:

(١)- دراسة طبيعة نموذج تحليل الشبكات العصبية الاصطناعية وأهميته في عملية التنبؤ في مجالات التأمينات العامة.

(٢)- دراسة طبيعة نموذج تحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins) وأهميته في عملية التنبؤ في مجالات التأمينات العامة.

(٣)- دراسة أثر استخدام دمج نموذجي الشبكات العصبية الاصطناعية وتحليل السلاسل الزمنية (ARIMA) في تحسين ودقة عملية التنبؤ بمعدل الاحتفاظ بالأقساط المكتسبة في التأمينات العامة في سوق التأمين المصري.

خامساً: أهمية البحث:

ترجع أهمية هذا البحث لسوق التأمين المصري للأسباب الآتية:

(١)- يعتبر التنبؤ بمعدل الاحتفاظ الأمثل بالاعتماد على الأساليب العلمية الدقيقة مهماً بالنسبة لعمليات الاكتتاب في مجال التأمينات العامة.

(٢)- هناك حاجة لمثل هذه الدراسات والتي تعتمد على نماذج كمية مدمجة تتميز بدقتها العالية في التنبؤ بما يساعد على سرعة وتحسين عملية اتخاذ القرارات ورسم السياسات المتعلقة بإعادة التأمين والسياسات الاستثمارية في شركات التأمين.

(٣)- يؤدي تحديد معدل الاحتفاظ بشكل أكثر دقة إلى تحقيق الاستفادة بقدر كبير من الأقساط المكتسبة، وبالتالي توجيه طاقة شركات التأمين نحو قبول عمليات التأمين على المشروعات القومية الضخمة، مما يؤثر إيجابياً على الاقتصاد القومي بشكل عام.

(٤)- تحديث الطرق والأساليب الإحصائية التقليدية في شركات التأمين أصبح ضرورياً لمواكبة التطورات العالمية في العديد من المجالات وخاصة مجال التأمينات العامة.

سادساً: فروض البحث:

يمكن تحقيق أهداف البحث من خلال اختبار الفرضيات البحثية التالية:

(١) - لا يؤدي استخدام نموذج تحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins) إلى التنبؤ الدقيق بمعدل الاحتفاظ الأمثل بالأقساط المكتسبة في فروع التأمينات العامة بسوق التأمين المصري.

(٢) - لا يؤدي استخدام نموذج الشبكات العصبية (ANN) إلى التنبؤ الدقيق بمعدل الاحتفاظ الأمثل بالأقساط المكتسبة في فروع التأمينات العامة بسوق التأمين المصري.

(٣) - لا يؤدي الدمج بين نموذجي تحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins) والشبكات العصبية الاصطناعية (ANN) إلى التنبؤ الدقيق بمعدل الاحتفاظ الأمثل بالأقساط المكتسبة في فروع التأمينات العامة بسوق التأمين المصري.

سابعاً: حدود البحث:

(١) - الحدود الزمنية للدراسة: تغطي الدراسة مدة ٣٠ سنة خلال الفترة الزمنية (١٩٨٩ - ٢٠١٨) وتعتبر فترة زمنية كافية نسبياً لتطبيق النموذج الإحصائي المقترح وخاصة نموذج الشبكات العصبية الذي يتطلب سلسلة زمنية طويلة.

(٢) - الشركات محل الدراسة: يتم تطبيق الدراسة على جميع شركات التأمين المباشر العاملة في سوق التأمين المصري.

(٣) - فروع التأمين محل الدراسة: يتم تطبيق الدراسة على فروع التأمينات العامة.

ثامناً: منهج البحث: تجمع الدراسة بين أسلوبين متلازمين لتحقيق الهدف من البحث وهما:

(١) - أسلوب الدراسة المكتبية: يتناول الدراسات والبحوث المنشورة فضلاً عن المراجع الأخرى المرتبطة بموضوع البحث.

(٢) - أسلوب الدراسة الميدانية: وهو جمع وتحليل البيانات الإحصائية لمعدلات الاحتفاظ لفروع التأمينات العامة لشركات التأمين المباشر وذلك خلال الفترة الزمنية محل الدراسة.

تاسعاً: محتويات البحث: يحتوى البحث على ثلاثة مباحث كما يلي :

المبحث الأول: الإطار العام للدراسة.

المبحث الثاني: طبيعة النموذج الإحصائي المقترح.

المبحث الثالث: التطبيق العملي للنموذج الإحصائي المقترح.

النتائج والتوصيات والمراجع

المبحث الثاني

طبيعة النموذج الإحصائي المقترح

تتعدد النماذج الإحصائية المستخدمة في عملية التنبؤ بقيم ظاهرة معينة في المستقبل ومنها النماذج الكمية التي يتطلب استخدامها توافر عدد من الشروط أهمها ضرورة توافر بيانات تاريخية عن الظاهرة محل الدراسة، وأن تكون هذه البيانات مقاسة بوحدات كمية، وكذلك توافر فرضية الاستمرارية لسلوك الظاهرة بمعنى أن يكون سلوك الظاهرة في المستقبل امتداداً لسلوكها في الماضي. (سليمان، ٢٠١٠) (Swanson & White, 1995)

ويعتبر نموذج تحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins) النموذج التقليدي حيث أظهر تحليل السلاسل الزمنية التقليدية كفاءة في التنبؤ المستقبلي بالظاهرة، وكذلك أسلوب الشبكات العصبية الاصطناعية (ANN)، والذي يعد من أساليب التنبؤ الحديثة في المجالات الاقتصادية، وظهرت حديثاً بحوث ودراسات تهتم بتنبؤات السلسلة الزمنية وتؤيد فكرة دمج النماذج الإحصائية الخطية (Linear Model) مع النماذج غير الخطية (Non-Linear Model) للحصول على نموذج مركب جديد، وتقوم فكرة الدمج بين نموذج تحليل السلاسل الزمنية (ARIMA) الخطية ونموذج الشبكات العصبية الاصطناعية (ANN) غير الخطية على حقيقة أن النموذج الإحصائي المفرد قد يفقد بعض الدقة في التنبؤ ولا يمكنه توظيف البيانات الحقيقية للسلسلة في معظم الحالات، وربما قد يكون غير كافٍ لتشخيص كل الخواص والمميزات للسلسلة الزمنية، وبالتالي إذا ما تم استخدام خصائص نموذجين إحصائيين أو أكثر فإنه سيكون هناك نموذجاً مركباً ملائماً جداً لدراسة سلوك الظاهرة بشكل أكثر فاعلية ودقة، كما يؤدي استخدام النماذج المدمجة إلى تحقيق العديد من الفوائد منها ما يلي: (مشعال، ٢٠١٥)

- (١) - تقليل نسبة الخطأ في النموذج الإحصائي المقترح.
- (٢) - زيادة الدرجة التفسيرية للنموذج وخصوصاً إذا كان معدل التحديد في النموذج التقليدي ليس لديه القدرة العالية على تفسير النتائج والتعبير عنها.
- (٣) - مراعاة التباين في درجة الخطر الناتجة عن الاختلافات في سنوات تجميع البيانات والاختلافات بين المناطق الجغرافية.

(٤)- الحصول على تقديرات أكثر دقة وفعالية من النماذج الفردية.

وسوف يتناول هذا المبحث بالدراسة والتحليل النماذج الإحصائية الفردية، والنموذج الإحصائي المدمج بينهما، وذلك كالآتي:

النموذج الأول: نموذج (ARIMA) باستخدام منهجية Box-Jenkins

من المؤكد أن تحليل السلاسل الزمنية على المستوى العالمي قد شهد في النصف الثاني من القرن العشرين تطوراً بالغ الأهمية خاصةً في العقود الثلاثة الأخيرة، وهذا التطور يعزى إلى المنهجية الحديثة التي قدمها العالمان بوكس وجينكنز في مطلع السبعينات من نفس القرن، والتي أصبحت منذ ذلك الوقت الأداة الأكثر قبولاً وشيوعاً في الأوساط العملية والنظرية والتطبيقية خاصة في العالم المتقدم حيث أثبتت هذه المنهجية كفاءة عالية في نمذجة البيانات الزمنية والتنبؤ حيث يتميز هذا الأسلوب بما يلي: (شعراوي، ٢٠٠٥)

(١)- أنه نظام نمذجة وتنبؤ منظم وشامل وموثوق به، حيث يقدم حلاً شاملاً لجميع مراحل تحليل السلاسل الزمنية في شكل منظومة أكثر عملية ومنطقية من الأساليب الأخرى لبناء النماذج وتشخيصها وتقدير معالمها للتنبؤ بالمشاهدات المستقبلية.

(٢)- أنه لا يفترض الاستقلالية بين مشاهدات السلسلة الزمنية بل يستغل أنماط الارتباط الكامنة في البيانات من خلال نماذج ARIMA التي تتميز بقوتها وقدرتها على عكس أنماط الكثير من السلاسل الزمنية التي نصادفها في التطبيقات العملية.

(٣)- أنه يعطي تنبؤات أدق من تلك التي نحصل عليها باستخدام أي أسلوب آخر، خاصة إذا توافرت البيانات الكافية لتغطيتها.

(٤)- أنه يعطي فترات ثقة ملائمة للمشاهدات المستقبلية للبيانات الموسمية وغير الموسمية بينما تفشل أساليب أخرى في ذلك.

وفي بعض الأحيان قد تكون السلسلة الزمنية الأصلية غير مستقرة، مما يجعل تحليل السلاسل الزمنية والتنبؤ بها أمراً في غاية الصعوبة، وإزالة عدم الاستقرار يتعين الحصول على فروقات السلسلة d من المرات للسلسلة الزمنية الأصلية، أي لها وسط حسابي ثابت تتجمع حوله البيانات، وتباين وتغاير مشترك ثابتان: (Enders, 2015)

وتنقسم نماذج (Box-Jenkins) في حالة السلاسل الزمنية المستقرة إلى:

(أ) - نموذج الانحدار الذاتي: Autoregressive Model AR (P)

ويعبر هذا النموذج عن علاقة المتغير التابع بالمتغيرات المستقلة المتمثلة في القيم الماضية لنفس المتغير التابع ولعدد محدد من فترات الإبطاء، بحيث يرمز $AR(p)$ إلى انحدار ذاتي من الدرجة p ويأخذ الشكل التالي: (Hamilton, 1994)

$$y_t = \delta + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

حيث أن:

δ هي الحد الثابت، P رتبة الانحدار الذاتي، i_t مشاهدات السلسلة الزمنية في الفترة الحالية t ، ε_t هي حد الخطأ العشوائي في الفترة الحالية t ، $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ قيم المتغير في الفترات السابقة، $\phi_1, \phi_2, \dots, \phi_p$ معاملات الانحدار الذاتي.

ويشير نموذج الانحدار الذاتي إلى أن القيم الحالية للمتغير y_t تعتمد على قيم المتغيرات السابقة $y_{t-1}, y_{t-2}, \dots, y_{t-p}$

(ب) - نموذج المتوسطات المتحركة: Moving Average Model MA(q)

الأوساط المتحركة هي عبارة عن الوسط الحسابي لمجموعة من قيم الظاهرة، حيث يتم إعطاء أوزان متساوية لكافة المشاهدات، ويعبر عن المتغير التابع كدالة للمتوسط المتحرك للقيم السابقة للحد العشوائي MA إلي الفترة q ويأخذ الشكل التالي: (Madsen, 2007)

$$y_t = \theta_0 + \varepsilon_t + \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

حيث أن:

q : رتبة نموذج المتوسطات المتحركة.

$\theta_0, \theta_1, \theta_2, \dots, \theta_q$: تمثل معاملات نموذج المتوسطات المتحركة.

$\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$: متوسطات متحركة لقيم البواقي في الفترة t والفترات السابقة.

(ج) - نموذج الانحدار الذاتي والمتوسطات المتحركة: ARMA(p,q)

هناك الكثير من السلاسل الزمنية لا يمكن تمثيلها بنموذج الانحدار الذاتي (AR) فقط أو نموذج المتوسطات المتحركة (MA) فقط لأن هناك ظواهر تفشل في وصفها لوحدها، لذلك يمكن

دمج النموذجين السابقين بنموذج واحد يسمى Autoregressive Moving Average (ARMA) ويأخذ النموذج الشكل التالي: (Enders, 2015)

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \alpha_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

• منهجية (Box-Jenkins) لبناء نموذج إحصائي مناسب للتنبؤ:

تعتمد منهجية بوكس-جينكينز (Box-Jenkins) على عدد من المراحل التكرارية لبناء نموذج مناسب يمكن أن يستخدم في التنبؤ بقيم المتغير للظاهرة محل الدراسة وهي كالتالي:
- أولاً: تحديد النموذج الإحصائي المناسب للبيانات: وتبدأ عملية تحديد النموذج الإحصائي المناسب لتمثيل السلسلة الزمنية المستقرة للظاهرة محل الدراسة من خلال:

(١) - استخدام دالة الارتباط الذاتي (ACF) Autocorrelation Function :

وتقيس قوة الارتباط بين مشاهدات المتغير نفسه عند فترات زمنية مختلفة، أي الكشف عن الارتباطات الداخلية للسلسلة الزمنية ويعتبر وسيلة مهمة لتمييز استقرارية السلاسل الزمنية من خلال قيم معاملات الارتباط الذاتي التي تعرف كالتالي:

$$\hat{P}_k = \frac{\gamma_k}{\gamma_0} = \frac{Cov(y_t, y_{t+k})}{\text{var}(y_t)} = \frac{\sum_{i=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{i=1}^{n-k} (y_t - \bar{y})^2} \quad K=0, \pm 1, \pm 2, \dots$$

حيث أن:

y_t قيم مشاهدات السلسلة، \bar{y} يمثل الوسط الحسابي، n حجم العينة، k طول الفجوة الزمنية، وتتراوح قيمة معامل الارتباط $-1 \leq P_k \leq 1$ (أحمد و يونس، ٢٠١٤).

(٢) - استخدام دالة الارتباط الذاتي الجزئي (PACF) Partial Autocorrelation Function

يمكن إيجاد قيم معامل الارتباط الذاتي الجزئي عن طريق دالة الارتباط، وتستخدم دالة الارتباط الذاتي الجزئي (PACF) في تحليل السلاسل الزمنية، وتستخدم كذلك لتشخيص النموذج المناسب من مجموعة نماذج العمليات العشوائية المستقرة وتحديد درجته وفحص ملائمة لبيانات العينة من خلال اختبار عشوائية أخطاء البواقي (درويش، ٢٠١٨).

ثانياً: تقدير معلمات النموذج المقترح بالخطوة الأولى Model Estimation

بعد التعرف على النموذج الإحصائي المقترح الذي يمثل بيانات السلسلة الزمنية للظاهرة محل الدراسة وتحديد رتبة النموذج يتم تقدير معلمات النموذج المقترح، ولكي يحقق النموذج الهدف الأساسي من بنائه وهو التنبؤ الجيد والدقيق فيجب ضمان جودة تقديره وملائمته للسلسلة الزمنية للظاهرة محل الدراسة، وهناك عدة طرق لتقدير معالم النموذج مثل:

١- طريقة المربعات الصغرى الخطية Linear Least Square Method

٢- طريقة المربعات الصغرى الاعتيادية Non-Linear Least Square Method

٣- طريقة دالة الإمكان الأعظم Maximum Likelihood Method

ثالثاً: فحص النموذج المقترح Diagnostic Checking of Model

ويكون الفحص عن طريق اختبار ما إذا كان النموذج المقدر يتوافق مع الشروط النظرية الموضوعية للنموذج، وذلك من خلال: (نقار و العواد، ٢٠١١)

(١)- اختبار معنوية معالم النموذج وذلك باستخدام إحصاء الاختبار (t-student) وذلك للتحقق من معنوية معاملات النموذج إحصائياً أي لا تختلف عن الصفر.

(٢)- تحليل الارتباطات الذاتية للبواقي (الأخطاء العشوائية) والتي ينبغي أن تكون متغيرات عشوائية غير مترابطة وذلك بطريقتين: (Makridakis, Wheelwright, & Hyndman, 1998)

(أ)- طريقة اختبار Ljung-Box (Q) :

والهدف من هذا الاختبار هو التأكد من عدم وجود ارتباط ذاتي للبواقي (أي اختبار معنوية معاملات الارتباط الذاتي) اعتماداً على الارتباطات الذاتية للبواقي، وأن السياق المولد لها عشوائي تماماً، وبمقارنة قيم Q بقيمة X^2 الجدولية يمكن اختبار معنوية معاملات الارتباط الذاتي، وتحسب إحصائية الاختبار من العلاقة التالية:

$$Q = n(n+2) \sum_{k=1}^k (r_k^2(e_i) / (n-K))$$

حيث أن k : تمثل عدد معاملات الارتباط الذاتي المستخدمة.

n : تمثل عدد المشاهدات المتاحة بعد استقرار السلسلة.

$r_k^2(e_i)$: هي معاملات الارتباط الذاتي للبواقي بمدة تباطؤ k

(ب) - طريقة الارتباطات الذاتية:

وتعتمد فيها على حدود الثقة للارتباطات الذاتية للبواقي المقدرة α_t والتي يجب أن تقع بين الحدين $(\pm 1.96\sqrt{n})$ باحتمال 95% فإذا تحقق ذلك فهذا يدل على أن البواقي تتوزع عشوائياً وأن الارتباطات الذاتية للبواقي تتوزع طبيعياً بوسط حسابي صفر وتباين $1/n$.

رابعاً: اختبار الدقة التنبؤية للنموذج: Forecasting Accuracy

هناك العديد من الاختبارات والمقاييس الإحصائية المستخدمة في قياس دقة التنبؤ وتقييم النماذج المتنبأ بها، وأهم هذه المقاييس: (Cummins, & Powel, 1980), (Merh & Prakash &), (Pardasani, 2010)

(أ) - متوسط القيم المطلقة للأخطاء (MAE): Mean Absolute Error

ويمكن إيجاده بالصيغة الآتية:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|$$

حيث أن: n عدد المشاهدات، e_t تمثل الخطأ أو البواقي، Y_t تمثل القيم الحقيقية للمتغير، \hat{Y}_t تمثل القيم المتنبأ بها للمتغير Y_t .

وكما كانت قيمة (MAE) صغيرة كان النموذج المستخدم الأفضل في تمثيل البيانات.

(ب) - متوسط مربع الأخطاء المطلقة (MSE): Mean Squared Error

ويمكن إيجاده من خلال الصيغة التالية:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$$

وكما كانت قيمة (MSE) صغيرة كان النموذج المستخدم الأفضل في تمثيل البيانات.

(ج) - متوسط الانحرافات النسبية المطلقة للأخطاء: Mean Absolute**Percentage Error (MAPE)**

ويأخذ الصورة التالية:

$$MAPE = \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100$$

وتستخدم للمقارنة بين عدة نماذج تنبؤية، ويدل صغر نسبته على أفضلية النموذج.

(د) - الجذر التربيعي لمتوسط نسبة الخطأ (RMSE) : Root Mean Square Error

ويحسب بالصورة التالية:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \times 100$$

وكما كانت قيمة (RMSE) صغيرة كان النموذج المستخدم الأفضل في تمثيل البيانات.

(هـ) - معيار المعلومات البيزي (BIC) : Bayesian Information Criterion

ويمكن إيجاده بالصيغة الآتية:

$$BIC = x^2 + K \log(n)$$

حيث أن: n عدد المشاهدات، K عدد معلمات النموذج، وكلما كانت قيمة (BIC) كبيرة كان النموذج المستخدم الأفضل في تمثيل البيانات.

(و) - الخطأ المعياري للتنبؤ : Standard Error of Prediction (SEP)

ويأخذ الصيغة التالية:

$$SEP = \frac{100}{\bar{Y}} \sqrt{\frac{\sum (Y_t - \hat{Y}_t)^2}{n}}$$

حيث \bar{Y} : يمثل الوسط الحسابي للملاحظات.

وكما كانت قيمة (SEP) صغيرة كان النموذج المستخدم الأفضل في تمثيل البيانات.

خامساً: مرحلة التنبؤ : Forecasting

وهي المرحلة الأخيرة، فبعد تقدير معالم النموذج المختلط $ARIMA(p,d,q)$ واختبار الأفضل من بينها، نقوم باستخدام هذا النموذج في عملية التنبؤ بالقيم المستقبلية للسلسلة الزمنية باستخدام النموذج الناتج من الخطوات السابقة عن طريق إحلال التعويض بالقيم المعلومة الحالية وقيم المعلومة السابقة، وكذلك قيم البواقي للحصول على تنبؤ لقيمة الظاهرة محل الدراسة.

النموذج الثاني: نموذج الشبكات العصبية الاصطناعية (ANN)


١- تعريف الشبكات العصبية الاصطناعية. (Bishop, 2006)

تعد الشبكات العصبية الاصطناعية إحدى مجالات الذكاء الاصطناعي، وهي نظام حسابي معتمد على الخوارزميات الرياضية ومكون من عدد من الوحدات المترابطة، ويمكن للشبكات العصبية أن تعالج العديد من البيانات الخطية (Linear) وغير الخطية (Non-Linear) بالإضافة إلى البيانات الناقصة Incomplete والبيانات المشوشة Noisy.

٢- مكونات الشبكات العصبية الاصطناعية:

تتكون الشبكة العصبية من مجموعة مركبة من عدة عناصر معالجة يطلق عليها اسم عصبونات (Neurons)، والموازية للخلايا العصبية البشرية في دماغ الإنسان وتتكون الشبكة على الأقل من ثلاث مستويات وكل مستوى يتضمن عدداً من العقد (Nods). (Gupta, 2013)، (Aires, Prigent, & Rossow, 2004).

والشكل التالي يوضح نموذجاً للشبكة العصبية الاصطناعية:



شكل (1) : الشبكة العصبية الاصطناعية

نلاحظ من الشكل السابق أن الشبكة العصبية تتكون من ثلاثة مستويات يسمى المستوى الأول بالمدخلات (Input) ويحتوي على عدد من العقد المساوية لعدد المتغيرات المستقلة التي تعتبر مدخلات النموذج وتشمل قيم $X : X_1, X_2, \dots, X_n$ ، والمستوى الثاني يسمى بالطبقة الوسيطة (Hidden) وقد يحتوي على عدد من العقد المخفية (Hidden Nodes) ولكل عقدة وزن W : W_1, W_2, \dots, W_n يربطها مع مستوى المدخلات، أما المستوى الأخير وهو عبارة عن المخرجات (Output) وتشمل قيم Y . (Grothmann, 2003)

٣- نماذج الشبكات العصبية الاصطناعية: (Neural Network Models)

تتقسم نماذج الشبكات العصبية الاصطناعية الى نوعين رئيسيين وهما: (البدراني وصليو، 2014)، (Shen & Chang, 2013).

(أ) - الشبكات العصبية ذات التغذية الأمامية: (Feed-Forward-Network)

وتنتقل فيها العمليات الحسابية في اتجاه واحد إلي الأمام من طبقة المدخلات الى طبقة المخرجات مروراً بالطبقات المخفية في حال استخدامها، وتصنف من حيث (طبقاتها) إلى شبكات وحيدة الطبقة (Single-Layer Network) وشبكات متعددة الطبقات (Multi-Layer Network).

(القاسمي، ٢٠١٣)، (Gupta, Sharma, Bansal, 2006)

(ب) - الشبكات العصبية ذات التغذية المرتجعة:

وفي هذه الشبكات من الممكن أن يعاد تغذية (كل أو بعض) الإشارات الخارجة من الشبكة وتحويل اتجاهها لتصبح إشارة داخلة أيضاً (إعادة تغذية).

٤- مزايا استخدام الشبكات العصبية الاصطناعية في التنبؤ:

(أ) - القدرة على حل الأنواع المختلفة من تحليل البيانات التي تحتوى على قيم متطرفة، والتي يصعب على الطرق التقليدية حلها. (مشعال، ٢٠١٥)

(ب) - تتميز بالسرعة العالية في الأداء من حيث التشغيل والتحليل السريع للبيانات الكبيرة الحجم. (Idown, Osakwe, Kayode, & Adagunodo, 2012)

(ج) - يمكن استخدامها للتغلب على معظم المشكلات التي تقابل بعض الشركات مثل العشوائية في ادخال البيانات، ونقص الخبرة، وبعض الأعمال التي تتطلب صياغة نماذج رياضية معقدة. (Yoon, & Swales, 1991)

(د) - تتميز بالمرونة وسهولة تكيفها مع المتغيرات البيئية والتعلم من الخبرة وإيجاد علاقات بين المتغيرات المختلفة، وتعمل على تحسين أدائها. (جاء الله، ٢٠٠٤)

(هـ) - تمتلك قدرة عالية ودقيقة على التنبؤ المستقبلي لنتاهي قيمة الخطأ القياسي في النتائج المتحصل عليها. (زريقة، ٢٠٠٩)

٥- البنية (الهيكليّة) للشبكات العصبية الاصطناعية:

ويقصد بالبنية المعمارية الطريقة التي ترتبط بها العصبونات مع بعضها البعض لتشكيل الشبكة، وترتبط كل مركبة من مركبات متجه الإدخال بكل عصبون، وكل عصبون يرتبط مع العصبونات الأخرى بأداة ربط مباشرة وكل أداة ربط ترفق بوزن معين Weights، وهذه الأوزان تمثل المعلومات التي ستبدأ بها الشبكة بحل المشكلة. (Engelbrecht, 2002)

٦- معالجة المعلومات في الشبكات العصبية الاصطناعية:

ويقصد بمعالجة المعلومات مرور البيانات بمرحلة أساسية هي مرحلة التعلم أو التدريب وهي عملية تعديل أوزان الاتصال لجعل الخلية تطلق إشارة استجابة للمدخلات، وذلك بهدف تقليل الخطأ في مخرجات الشبكة، أي أن الخلية تغير سلوك الإدخال إلى سلوك الإخراج وفقاً لاستجابتها للظروف المحيطة. (حاجي، ١٩٩٩). (كرودي، ٢٠١٥).

٧- استخدام الشبكات العصبية الاصطناعية في التنبؤ: Forecasting

استخدمت حديثاً الشبكات العصبية الاصطناعية كأسلوب بديل أو موازي للأساليب الإحصائية التقليدية التي تستخدم في المعالجات الإحصائية للتنبؤ بالسلاسل الزمنية، كالمتوسطات المتحركة المرجحة، والتمهيد الأسي، ونماذج الانحدار الذاتي والمتوسطات المتحركة التكاملية، وغيرها من الأساليب الإحصائية. (Kihoro, Otieno, & Wafula, 2004)

وتمر عملية التنبؤ باستخدام الشبكات العصبية بعدة مراحل بدءاً من تجهيز ومعالجة البيانات ثم تجزئتها إلى مجموعات وهي مجموعة التدريب ومجموعة الاختبار ومجموعة التقويم. (عبد العزيز والساعدي، ٢٠١٦) (كرودي و قدور، ٢٠١٧)

٨- تحديد نموذج الشبكة العصبية الاصطناعية:

لتحديد نموذج الشبكة يتم تحديد عدد عُقد الإدخال، وذلك بالاعتماد على معاملات الارتباط الذاتي المعنوية للسلسلة الزمنية المستقرة ثم يتم تحديد عدد الطبقات المخفية ويعتمد تحديدها على قيمة الخطأ المستخدم في الشبكة، وأخيراً يتم تحديد عُقد الإخراج.

النموذج الثالث: النموذج المدمج بين نموذجي ARIMA والشبكات العصبية الاصطناعية (ANN)

للتوصل إلى طريقة ذات كفاءة عالية في التنبؤ بمعدل الاحتفاظ الأمثل للأقساط المكتسبة في التأمينات العامة تم استخدام الطرق الإحصائية المدمجة عن طريق دمج نموذج ARIMA باستخدام منهجية Box-Jenkins مع نموذج الشبكات العصبية الاصطناعية ANN، حيث أن طريقة Box-Jenkins تعالج الصفات الخطية في السلسلة الزمنية، بينما طريقة الشبكات العصبية الاصطناعية تعالج الصفات غير الخطية للسلسلة الزمنية، ومن ثم فإن هذا الدمج بين النموذجين سيؤدي إلى تقليل نسبة الخطر الناتجة عن استخدام النماذج الفردية مما يترتب عليه تنبؤ دقيق بالظاهرة محل الدراسة. (Kaastra & Boyd, 1996)

وتتقسم الأساليب التي يمكن استخدامها لتوليف نموذج مدمج بين الشبكات العصبية الاصطناعية (ANN) و ARIMA إلى أسلوبين رئيسيين وهما:

الأسلوب الأول: الدمج باستخدام البواقي (الأخطاء العشوائية) السابقة والقيم المقدرة من نموذج ARIMA واعتبارها عناصر مدخلات في نموذج الشبكات العصبية الاصطناعية (Khashei & Bijari, 2010)

وتتمثل خطوات هذا الأسلوب كالاتي:

(١)- بناء نموذج ARIMA وفقاً لمنهجية Box-Jenkins لبيانات السلسلة الزمنية بدءاً من مرحلة التعرف على النموذج وصولاً إلى مرحلة التنبؤ، وذلك لتمثيل الجزء الخطي للسلسلة الزمنية ومن ثم إيجاد القيم المقدرة لمعدلات الاحتفاظ، حيث أن الأخطاء العشوائية المقدرة (البواقي) المستخرجة من نموذج ARIMA ضرورية لبناء النموذج غير الخطي والمتمثل في نموذج الشبكات العصبية ANN، وتحسب البواقي من المعادلة الآتية:

$$e_t = Z_t - \hat{Z}_t$$

حيث Z_t هي القيم الفعلية ، \hat{Z}_t هي القيم المقدرة.

ولاستخدام البواقي (الأخطاء العشوائية) في تحليل السلاسل الزمنية يجب أن يتوافر فيها الشروط التالية: (أبو النصر، ٢٠١٣)

(أ) - أن يكون الوسط الحسابي للبواقي مساوياً للصفر والتباين مقدار ثابت (أي أن هناك تجانس بين الأخطاء).

(ب) - أن يكون تغاير الخطأ لا يساوي الصفر بمعنى ارتباط الأخطاء مع بعضها البعض.

(ج) - أن يكون التوزيع الاحتمالي للأخطاء العشوائية توزيعاً طبيعياً.

(د) - أن تكون الأخطاء العشوائية متغيرات غير مستقلة.

٢- بناء نموذج الشبكات العصبية الاصطناعية ANN بالاعتماد على قيم البواقي والقيم المقدرة من نموذج ARIMA الذي تم بناؤه في الخطوة الأولى.

٣- يتم اختبار القدرة التنبؤية للنموذج المدمج المقترح في الخطوة السابقة وذلك بمقاييس دقة التنبؤ المختلفة ($MSE, MAPE, R^2$) للتأكد من مدى قدرة النموذج على التنبؤ.

٤- استخدام النموذج المدمج المقترح في التنبؤ بمعدلات الاحتفاظ عن الفترة الزمنية المقترحة (٢٠١٤-٢٠١٨)، وذلك لمقارنتها بمعدلات الاحتفاظ الفعلية (الأصلية) عن نفس الفترة.

الأسلوب الثاني: الدمج باستخدام القيم المقدرة من نموذج الشبكات العصبية

الاصطناعية ANN واعتبارها عناصر مدخلات في نماذج ARIMA

وتتمثل خطوات هذا الأسلوب كالاتي:

١- بناء نموذج الشبكات العصبية الاصطناعية ANN لبيانات السلسلة الزمنية بدءاً من مرحلة التعرف على النموذج وصولاً إلى مرحلة التنبؤ بمعدلات الاحتفاظ، وذلك لتمثيل الجزء غير الخطي للسلسلة الزمنية ومن ثم إيجاد القيم المقدرة لمعدلات الاحتفاظ.

٢- بناء نموذج ARIMA بالاعتماد على القيم المقدرة من نموذج ANN الذي تم بناؤه في الخطوة الأولى.

٣- يتم اختبار القدرة التنبؤية للنموذج المدمج المقترح في الخطوة السابقة وذلك بمقاييس دقة التنبؤ المختلفة ($MSE, MAPE, R^2$) للتأكد من مدى قدرة النموذج على التنبؤ.

٤- استخدام النموذج المدمج المقترح السابق في التنبؤ بمعدلات الاحتفاظ عن الفترة الزمنية المقترحة (٢٠١٤-٢٠١٨).

المبحث الثالث

تطبيق النموذج الإحصائي المقترح

تركز الدراسة على التنبؤ بحد الاحتفاظ الأمثل للأقساط المكتسبة في شركات التأمين المباشر بفروع التأمينات العامة في سوق التأمين المصري مستخدماً في ذلك سلسلة زمنية خلال الفترة (١٩٨٩-٢٠١٨م)، ولتحقيق هدف البحث يتم اتباع الخطوات التالية:

أولاً: بناء نموذج ARIMA باستخدام منهجية (Box-Jenkins) بالاعتماد على الفرضية بأن السلسلة الزمنية المقترحة تحوي فقط المركبة الخطية للسلسلة الزمنية لمعدلات الاحتفاظ، حيث يتم بناء النموذج وتقدير معلماته، ثم تطبيقه في التنبؤ بمعدلات الاحتفاظ عن الفترة الزمنية محل الدراسة.

ثانياً: بناء نموذج الشبكات العصبية الاصطناعية (ANN) بالاعتماد على الفرضية بأن السلسلة الزمنية المقترحة تحوي فقط المركبة غير الخطية للسلسلة الزمنية لمعدلات الاحتفاظ، حيث يتم بناء النموذج وتقدير معلماته، ثم تطبيقه في التنبؤ بمعدلات الاحتفاظ عن الفترة الزمنية محل الدراسة.

ثالثاً: بناء النموذج المدمج بين نموذج (ARIMA) ونموذج (ANN) بناء على فرضية أن السلسلة الزمنية تحوي المركبتين الخطية وغير الخطية.

رابعاً: إجراء مقارنة بين القيم المقدرة لمعدلات الاحتفاظ الناتجة من النماذج الفردية (ARIMA) و(ANN) والنموذج المدمج بينهما.

وسوف يتم تناول النقاط السابقة كما يلي:

أولاً: بناء نموذج ARIMA باستخدام منهجية (Box-Jenkins) لبيانات السلسلة الزمنية:


لبناء نموذج إحصائي كفاء باستخدام منهجية (Box-Jenkins) نتبع عدة مراحل كالتالي:

١ - مرحلة التعرف على النموذج الإحصائي المناسب لبيانات السلسلة الزمنية:

تبدأ هذه المرحلة بالتعرف على نموذج أو أكثر من نماذج ARIMA ويتضح ذلك من خلال رسم شكل السلسلة الزمنية لمعدلات الاحتفاظ لفروع التأمينات العامة خلال فترة الدراسة (1989-2018) كما هو مبين في شكل رقم (٢).

شكل رقم (٢)

السلسلة الزمنية لمعدلات الاحتفاظ بفروع التأمينات العامة




المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

ومن الشكل رقم (٢) يتضح أن السلسلة الزمنية لمعدلات الاحتفاظ غير مستقرة، ويؤكد ذلك أن دالة الانحدار الذاتي (ACF) ودالة الانحدار الذاتي الجزئي (PACF) كما في الشكلين التاليين رقمي (٣) و (٤) لا تتحدران نحو الصفر حيث تقع قيم بعض معاملات الارتباط الذاتي والارتباط الذاتي الجزئي تقع خارج حدي الثقة، مما يدل على عدم استقرار السلسلة الزمنية خلال فترة الدراسة.

شكل رقم (٣)


دالة الارتباط الذاتي (ACF) لمعدلات الاحتفاظ بفروع التأمينات العامة



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

شكل رقم (٤)

دالة الارتباط الذاتي الجزئي (PACF) لمعدلات الاحتفاظ بفروع التأمينات العامة




المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

وحيث أن السلسلة الزمنية لمعدلات الاحتفاظ بفروع التأمينات العامة تعاني من عدم استقرارها في المتوسط فهي بحاجة إلى أخذ الفروق الموسمية للتوصل إلى حالة الاستقرار والحصول على سلسلة جديدة يمكن التنبؤ بها بطريقة أكثر كفاءة، ولتحويل السلسلة الزمنية إلى سلسلة مستقرة يتم أخذ الفروق الأولى وإعادة حساب قيمة دالة الانحدار الذاتي (ACF) ودالة الانحدار الذاتي الجزئي (PACF)، ويظهر ذلك في الأشكال التالية:

شكل رقم (5)


الاتجاه العام للسلسلة الزمنية بعد أخذ الفروق الأولى



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

شكل رقم (6)


دالة الارتباط الذاتي (ACF) للسلسلة الزمنية بعد أخذ الفروق الأولى



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

شكل رقم (7)

دالة الارتباط الذاتي (PACF) للسلسلة الزمنية بعد أخذ الفروق الأولى



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

ومن الشكل رقم (5) يتضح استقرارية السلسلة الزمنية لبيانات الدراسة وذلك بعد أخذ الفروق الأولى للسلسلة، ومن خلال فحص كل من دالتي الارتباط الذاتي (ACF) والارتباط الذاتي الجزئي (PACF) كما في الشكلين رقم (6) و (7) يتضح أن معاملات كل منهما تتحدر نحو الصفر مما يدل على استقرارية السلسلة الزمنية خلال فترة الدراسة.

٢- مرحلة تقدير معلمات النموذج الإحصائي:

ويتم في هذه المرحلة تقدير معلمات النماذج المقترحة لملائمة بيانات السلسلة الزمنية، حيث اعتمد برنامج SPSS في تقدير المعلمات على طريقة دالة الإمكان الأعظم Maximum Likelihood Method ويتضح ذلك من خلال الجدول رقم (3) التالي:

جدول رقم (3)

تقديرات معلمات نماذج ARIMA المقترحة لبيانات السلسلة الزمنية

Models	Parameters	Estimate	SE	T-ratio	Sig
ARIMA (2,1,2)	Constant	0.004	0.004	0.935	0.361
	θ_1	-0.609	30.293	-0.020	0.984
	θ_2	-0.999	99.721	-.010	0.992
	ϕ_1	-0.345	0.453	-0.762	0.455
	ϕ_2	-0.588	0.607	-0.969	0.345
ARIMA (0,1,2)	Constant	0.004	-.005	0.739	0.468
	θ_1	-0.245	0.208	-1.177	0.252
	θ_2	-0.272	0.216	-1.264	0.220
ARIMA (1,1,1)	Constant	0.003	0.004	0.886	0.386
	θ_1	-.058	1.814	0.032	0.975
	ϕ_1	0.193	1.810	0.107	0.916
ARIMA (2,1,0)	Constant	0.003	0.004	0.803	0.431
	ϕ_1	0.129	0.224	0.578	0.569
	ϕ_2	0.080	0.241	0.333	0.743

المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

ومن خلال نماذج ARIMA التي تم تقديرها في الجدول السابق نلاحظ بأن النموذج الأفضل هو نموذج ARIMA (2,1,2) حيث له أكبر قيمة لـ T-ratio وبالتالي هو أفضل نموذج للتنبؤ بمعدلات الاحتفاظ لفروع التأمينات العامة في سوق التأمين المباشر المصري.


٣- فحص النموذج الإحصائي المقترح:

يتم اختبار النموذج الإحصائي المقترح ARIMA (2,1,2) عن طريق الآتي:

(أ) - فحص كل من دالة الارتباط الذاتي (ACF) ودالة الارتباط الذاتي الجزئي (PACF) للبواقي العشوائية للسلسلة الزمنية، ومن الملاحظ في الشكل رقم (8) التالي أن جميع معاملات الارتباط الذاتي والارتباط الذاتي الجزئي تقع داخل حدود الثقة مما يعني أن سلسلة البواقي العشوائية مستقرة، وتسلق نفس سلوك السلسلة الزمنية للبيانات.

شكل رقم (8)

بيانات السلسلة الزمنية للبواقي العشوائية



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

(ب) - فحص قيمة احصائية مقياس Ljung-BoxQ لنماذج ARIMA المقترحة حيث كانت $Q = 17.096$ بمعنوية (Sig=0.251) وعند مقارنة هذه القيمة بقيمة X^2 عند درجة حرية 24 ومستوي معنوية 5% والتي تساوي 36.42 أي عدم وجود فرق معنوي بين القيم الفعلية والقيم المقدرة مما يؤكد كفاءة النموذج للتنبؤ.

٤- اختبار الدقة التنبؤية للنموذج الإحصائي المقترح:

لاختبار الدقة التنبؤية لنماذج ARIMA المقترحة لاختيار أفضلها يتم استخدام العديد من المقاييس الإحصائية لقياس دقة التنبؤ كما هو مبين بالجدول رقم (4) التالي:

جدول رقم (4)

نماذج ARIMA المقترحة ومعايير المفاضلة بينها

Models	Model Fit statistics						
	R ²	RMSE	MAPE	MAE	BIC	MSE	SEP
ARIMA A (2,1,2)	0.86	.016	2.583	0.012	-7.6°	0.00018	3.091
ARIMA A (0,1,2)	0.84	.016	2.734	0.012	-7.88	0.00023	3.431
ARIMA A (2,1,0)	0.83	.016	2.753	0.012	-7.85	0.00024	3.492
ARIMA A (1,1,1)	0.83	.016	2.718	0.012	-7.84	0.00023	3.433

المصدر: من إعداد الباحثان، مخرجات برنامج SPSS وبرنامج Excel

وبتحليل الجدول السابق يتضح الآتي:

- ١- أكبر قيمة لـ R-Squared كانت للنموذج ARIMA(2,1,2).
- ٢- أقل قيمة لمتوسط الانحرافات المطلقة (MAPE) كانت للنموذج ARIMA(2,1,2).
- ٣- أكبر قيمة لمعيار المعلومات البيزي (BIC) كانت للنموذج ARIMA (2,1,2).
- ٤- أقل قيمة لمتوسط مربع الأخطاء المطلقة (MSE) كانت للنموذج ARIMA(2,1,2).
- ٥- أقل قيمة للخطأ المعياري للتنبؤ (SEP) كانت للنموذج ARIMA(2,1,2).
- ٦- اتفقت جميع النماذج المقترحة في قيمة متوسط القيمة المطلقة (MAE).
- ٧- اتفقت جميع النماذج في قيمة الجذر التربيعي لمتوسط نسبة الخطأ (RMSE).

ومما سبق نستنتج أن نموذج $ARIMA(2,1,2)$ يتحقق فيه معظم الشروط اللازم توافرها في المقاييس الإحصائية لدقة التنبؤ، وبالتالي يكون هو النموذج الأفضل والملائم للتنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة بفروع التأمينات العامة بشركات التأمين المباشر.

٥ - مرحلة التنبؤ بمعدلات الاحتفاظ بفروع التأمينات العامة:

بعد تحديد النموذج الملائم لبيانات السلسلة الزمنية وهو نموذج $ARIMA(2,1,2)$ ولتقييم القدرة التنبؤية لهذا النموذج تم التنبؤ بمعدلات الاحتفاظ للخمس سنوات التالية من السلسلة وهي الفترة (2014-2018)، ويبين الجدول رقم (6) التالي القيم الأصلية والقيم المتنبأ بها لمعدلات الاحتفاظ بالأقساط المكتسبة في فروع التأمينات العامة وفقاً لنماذج $ARIMA$ وذلك عن الفترة (2018-2014).

ويمكن المفاضلة بين نماذج $ARIMA$ المختلفة عن طريق المقارنة بين القيم الفعلية والقيم المقدرة لمعدلات الاحتفاظ لكل نموذج من النماذج المقترحة، وذلك كما يتضح من خلال جدول رقم (5) التالي:

جدول رقم (5)

القيم الفعلية والمتنبأ بها لمعدلات الاحتفاظ لنماذج $ARIMA$ خلال الفترة (2014-2018)


years	Observed values	Forecast values			
		ARIMA (2,1,2)	ARIMA (0,1,2)	ARIMA (1,1,1)	ARIMA (2,1,0)
2014	0.479	0.470	0.460	0.460	0.460
2015	0.514	0.480	0.460	0.460	0.460
2016	0.533	0.480	0.460	0.470	0.460
2017	0.546	0.480	0.470	0.470	0.470
2018	0.538	0.490	0.470	0.470	0.470

المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

حيث يتضح من الجدول السابق أن القيم المقدرة لمعدلات الاحتفاظ بواسطة نموذج $ARIMA(2,1,2)$ هي الأقرب إلى القيم الفعلية لسنوات السلسلة الزمنية خلال الفترة (2014-2018)، كما يمكن ملاحظة ذلك من خلال الشكل رقم (٩) التالي:

شكل رقم (٩)

بيانات السلسلة الزمنية الأصلية والمقدرة لمعدلات الاحتفاظ



المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

ثانياً: بناء نموذج الشبكات العصبية الاصطناعية (ANN)

لبناء نموذج الشبكات العصبية الاصطناعية (ANN) يمكن اتباع الخطوات التالية:

١- تجهيز البيانات للسلسلة الزمنية لمعدلات الاحتفاظ:

وتتضمن بيانات السلسلة الزمنية معدلات الاحتفاظ عن فترة 30 سنة (1989-2018) لجميع فروع التأمينات العامة بشركات التأمين المباشر بسوق التأمين المصري.

٢- معالجة البيانات: حيث تم تحديد الاتجاه العام للسلسلة الزمنية لمعدلات الاحتفاظ تم تحديد

ذلك عند بناء نموذج ARIMA وفقاً لمنهجية Box-Jenkins.

٣- تجزئة بيانات الدراسة: تم تجزئة بيانات الدراسة الى:

(أ)- مجموعة تدريب للشبكة وهي عبارة عن 25 سنة (1989-2013) وذلك لتقدير الأوزان النسبية لبيانات السلسلة الزمنية.

(ب)- مجموعة الاختبار للشبكة وهي عبارة عن جزء من بيانات السلسلة الزمنية محل الدراسة وهي عبارة عن 5 سنوات (2014-2018).

٤- تحديد نموذج الشبكة العصبية الاصطناعية:

تم استخدام الشبكة ذات الانتشار الخلفي متعددة الطبقات، وهي من أهم أنواع الشبكات العصبية الاصطناعية (ANN) المستخدمة في التنبؤ بالسلاسل الزمنية، وقد تم تحديد معمارية الشبكة من خلال تدريب عدد من التراكيب المختلفة حيث تتكون الشبكة المستخدمة من ثلاث طبقات متكاملة فيما بينها من حيث الترابط وذلك بواسطة الأوزان النسبية، حيث تحتوي الطبقة الأولى على عنصر

معالجة واحد تم تقديره بناءً على عدد مدخلات الشبكة، والطبقة الثانية هي الطبقة الخفية وتتكون من 6 عناصر (عقد عصبونية)، وتحتوي الطبقة الثالثة على عنصر معالجة واحد تم تحديده بناءً على المخرجات.

ويصبح النموذج ANN(1,6,1) هو النموذج المناسب لبيانات الدراسة، ويوضح الجدول رقم (6) التالي القيم المتنبأ بها لمعدلات الاحتفاظ باستخدام هذا النموذج.

جدول رقم (6)

القيم المتنبأ بها لمعدل الاحتفاظ باستخدام نموذج ANN(1,6,1)

Years	2014	2015	2016	2017	2018
Forecast values	0.458	0.457	0.457	0.457	0.457

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

ثالثاً: بناء النموذج الإحصائي المدمج Combined المقترح:

للقيام بعملية الدمج المقترحة تكون وفقاً لما يلي:

(أ) - أن أفضل نموذج يمكن استخدامه لتمثيل السلسلة الزمنية وفقاً لمنهجية Box-Jenkins هو نموذج ARIMA(2,1,2).

(ب) - أن أفضل نموذج يمكن استخدامه من نماذج الشبكات العصبية الاصطناعية والذي اجتاز مقاييس دقة التنبؤ هو نموذج ANN(1,6,1).

ويتم الدمج بين النموذجين السابقين بأحد الأساليب التالية:

الأسلوب الأول: يتم الدمج وفقاً للخطوات التالية:

(أ) - يتم تقدير قيم السلسلة الزمنية باستخدام نموذج ARIMA (2,1,2)، وهي كما يوضحها الجدول رقم (7) التالي:

جدول رقم (7)

القيم المتنبأ بها لمعدل الاحتفاظ باستخدام نموذج ARIMA(2,1,2)

ARIMA(2,1,2)	2014	2015	2016	2017	2018
Forecast values	0.470	0.480	0.480	0.480	0.490

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

(ب) - يتم إيجاد القيم التنبؤية للبواقي (الخطأ العشوائي) الناتجة من استخدام نموذج $ARIMA(2,1,2)$ وهي كما يوضحها الجدول رقم (8) التالي:

جدول رقم (8)

القيم التنبؤية للخطأ العشوائي باستخدام نموذج $ARIMA(2,1,2)$

$ARIMA(2,1,2)$	2014	2015	2016	2017	2018
Errors	0.009	0.034	0.053	0.066	0.050

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

(ج) - يتم استخدام نتائج الخطوات السابقة كمدخلات في نموذج $ANN(1,6,1)$ ، حيث أن البيانات الأولية للشبكة العصبية الاصطناعية بعد عملية الدمج كانت كالآتي:

(أ) - تحتوي الطبقة الأولى في النموذج على عنصرين من عناصر المعالجة ويتمثل العنصر

الأول في القيم المقدره للسلسلة الزمنية، والعنصر الثاني ويتمثل في قيم البواقي.

(ب) - الطبقة الثانية وهي الطبقة الخفية وتتكون من 10 عناصر (عقد عصبونية).

(ج) - الطبقة الثالثة: وتتمثل في معدلات الاحتفاظ الفعلية خلال الفترة (2018-2014).

(د) - مما سبق وباستخدام برنامج Matlab نستنتج النموذج المدمج بين النموذجين

$ARIMA(2,1,2)$ ونموذج $ANN(1,6,1)$ وهو نموذج $ARAN(2,10,1)$ ، ويعرض

الجدول رقم (9) التالي نتائج التنبؤ بمعدلات الاحتفاظ بهذا النموذج.

جدول رقم (9)

القيم المتنبأ بها من خلال النموذج المدمج $ARAN(2,10,1)$

Years	2014	2015	2016	2017	2018
Observed Values	0.479	0.514	0.533	0.546	0.538

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

(هـ) - اختبار الدقة التنبؤية للنموذج المدمج المقترح (2,10,1) ARAN وذلك باستخدام المقاييس الإحصائية MSE, MAPE كما يوضحه الجدول رقم (10) التالي:

جدول رقم (10)

اختبار دقة التنبؤ للنموذج الإحصائي المدمج (2,10,1) ARAN

ARAN (2,10,1)	MSE	MAPE
	٠,٠٠٠٠٠٢٢	٠,٠٠٠٨٦

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

يتضح من الجدول السابق انخفاض قيمة متوسط مربع الأخطاء المطلقة للنموذج (MSE=0.000022) وقيمة متوسط الانحرافات المطلقة للنموذج (MAPE=0.0086).

الأسلوب الثاني: يتم الدمج وفقاً للخطوات التالية:

(١) - يتم تقدير قيم معدلات الاحتفاظ خلال الفترة الزمنية (٢٠١٨-٢٠١٤) باستخدام نموذج 1 ANN(1,6) وهي كما يوضحها الجدول رقم (11) التالي.

جدول رقم (11)

القيم المنتبأ بها لمعدل الاحتفاظ باستخدام نموذج ANN(1,6,1)

Years	2014	2015	2016	2017	2018
Forecast values	0.458	0.457	0.457	0.457	0.457

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

(٢) - نستخدم القيم التقديرية لمعدلات الاحتفاظ كعناصر مدخلات في نماذج ARIMA، ونحصل على نماذج إحصائية مدمجة تسمى ARAN (ARIMA مع ANN).

(٣) - التعرف على نموذج أو أكثر من نماذج ARAN المدمجة، حيث تبين من خلال مخرجات برنامج SPSS أن هناك أكثر من نموذج مدمج لـ ARAN وهي {ARAN(2,1,2), ARAN(0,1,2), ARAN(1,1,1), ARAN(2,1,0)}

(٤) - التعرف على نموذج ARAN المناسب لبيانات السلسلة الزمنية من النماذج السابقة.

(٥) - تقدير معاملات نماذج ARAN المدمجة المقترحة بالاعتماد على برنامج SPSS ويتضح ذلك من خلال الجدول رقم (12) التالي:

جدول رقم (12)

تقديرات معاملات نماذج ARIMA المقترحة لبيانات السلسلة الزمنية

Models	Parameters	Estimate	SE	T-ratio	Sig
ARAN (2,1,2)	Constant	0.017	0.045	0.367	0.718
	θ_1	0.947	24.284	0.039	0.969
	θ_2	-0.999	51.130	-0.020	0.985
	ϕ_1	1.171	0.190	6.163	0.000
	ϕ_2	-0.940	0.207	-4.548	0.000
ARAN (0,1,2)	Constant	0.000	0.059	0.002	0.998
	θ_1	-0.386	0.212	-1.826	0.083
	θ_2	-0.338	0.216	-1.569	0.132
ARAN (1,1,1)	Constant	0.006	0.053	0.106	0.916
	θ_1	-.008	0.863	0.009	0.993
	ϕ_1	0.284	0.862	0.329	0.746
ARAN (2,1,0)	Constant	0.005	0.053	0.100	0.922
	ϕ_1	0.294	0.237	1.242	0.229
	ϕ_2	-0.004	0.252	-0.014	0.989

المصدر: من إعداد الباحثان، مخرجات برنامج SPSS

ومن خلال نماذج ARAN المدمجة التي تم تقديرها في الجدول السابق نلاحظ بأن النموذج الأفضل هو النموذج المدمج ARAN(2,1,2) حيث له أكبر قيمة لـ T-ratio وبالتالي هو أفضل نموذج للتنبؤ بمعدلات الاحتفاظ لفروع التأمين العامة في سوق التأمين المباشر المصري.

(٦) - فحص النموذج الإحصائي المقترح:

تم فحص قيمة إحصائية مقياس Ljung-BoxQ لنماذج ARAN المدمجة المقترحة وتبين من برنامج SPSS أن قيمة إحصائية Q لنموذج ARAN(2.1.2) المدمج هي الأفضل معنوياً مقارنة

بباقي النماذج ، حيث كانت قيمة $Q = 29.414$ بمعنوية ($Sig=0.009$) وعند مقارنة هذه القيمة بقيمة X^2 عند درجة حرية 24 ومستوي معنوية 5% والتي تساوي 36.42 أي عدم وجود فرق معنوي بين القيم الفعلية والقيم المقدرة مما يؤكد كفاءة النموذج المدمج للتنبؤ .

(٧) - اختبار الدقة التنبؤية للنموذج الإحصائي المقترح:

لاختبار الدقة التنبؤية لنماذج ARAN المدمجة المقترحة لاختيار أفضلها يتم استخدام العديد من المقاييس الإحصائية لقياس دقة التنبؤ كما هو مبين بالجدول رقم (13) التالي:

جدول رقم (13)

نماذج ARAN المدمجة المقترحة ومعايير المفاضلة بينها

Compound Models	Model Fit statistics						
	R ²	RMSE	MAPE	MAE	BIC	MSE	SEP
ARAN (2,1,2)	0.90	.013	2.126	0.010	-7.82	0.00015	2.722
ARAN (0,1,2)	0.87	.015	2.449	0.011	-7.89	0.00020	3.188
ARAN (2,1,0)	0.86	.015	2.645	0.012	-7.82	0.00023	3.381
ARAN (1,1,1)	0.86	.015	2.647	0.012	-7.82	0.00023	3.381

المصدر: من إعداد الباحثان، مخرجات برنامج SPSS وبرنامج Excel

وبتحليل الجدول السابق يتضح الآتي:

- ١- أكبر قيمة لـ R^2 كانت للنموذج المدمج ARAN(2,1,2) حيث بلغت $R^2 = 0.90$.
- ٢- أقل قيمة للجذر التربيعي لمتوسط نسبة الخطأ كانت للنموذج المدمج ARAN(2,1,2) حيث بلغت $RMSE=0.013$.
- ٣- أقل قيمة لمتوسط الانحرافات المطلقة كانت للنموذج المدمج ARAN(2,1,2) حيث بلغت $(MAPE=0.013)$.
- ٤- أقل قيمة لمتوسط القيمة المطلقة كانت للنموذج المدمج ARAN(2,1,2) حيث بلغت $MAE=0.010$.

٥- أقل قيمة لمعيار المعلومات البيزي كانت للنموذج المدمج $ARAN(0,1,2)$ حيث بلغت قيمته $BIC=-7.89$.

٦- أقل قيمة لمتوسط مربع الأخطاء المطلقة كانت للنموذج المدمج $ARAN(2,1,2)$ حيث بلغت $MSE=0.00015$.

٧- أقل قيمة للخطأ المعياري للتنبؤ كانت للنموذج المدمج $ARAN(2,1,2)$ حيث بلغت $SEP=2.722$.

ومما سبق نستنتج أن نموذج $ARAN(2,1,2)$ المدمج يتحقق فيه معظم الشروط اللازم توافرها في المقاييس الإحصائية لدقة التنبؤ، وبالتالي يكون هو النموذج الأفضل والملائم للتنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة بفروع التأمينات العامة بشركات التأمين.

(٨)- مرحلة التنبؤ بمعدلات الاحتفاظ بفروع التأمينات العامة:

بعد تحديد النموذج المدمج الملائم لبيانات السلسلة الزمنية وهو نموذج $ARAN(2,1,2)$ ولتقييم القدرة التنبؤية لهذا النموذج تم التنبؤ بمعدلات الاحتفاظ للخمس سنوات التالية من السلسلة وهي الفترة (2014-2018)، ويبين الجدول رقم (14) التالي القيم المتنبأ بها لمعدلات الاحتفاظ بالأقساط في فروع التأمينات العامة وفقاً لهذا النموذج.

جدول رقم (١٤)

القيم المتنبأ بها من خلال النموذج المدمج $ARAN(2,1,2)$

Years	2014	2015	2016	2017	2018
Forecast values	0.460	0.470	0.490	0.500	0.510

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

رابعاً: مقارنة النماذج الثلاث من حيث القدرة التنبؤية بمعدلات الاحتفاظ.

لاختيار النموذج الأفضل في عملية التنبؤ بمعدلات الاحتفاظ لفروع التأمينات العامة، وذلك عن طريق مقارنة القيم المتنبأ بها لمعدلات الاحتفاظ بالقيم الأصلية لجميع النماذج الثلاثة، وكذلك بمقارنة قيم المقاييس الإحصائية المستخدمة في قياس دقة التنبؤ ($MSE, MAPE$) كما هو مبين بالجدول رقم (15) التالي:

جدول رقم (15)

القيم الفعلية والمنتبأ بها لمعدلات الاحتفاظ للنماذج الثلاث عن الفترة (٢٠١٨-٢٠١٤)

السنوات	القيم الفعلية	قيم معدلات الاحتفاظ المنتبأ بها وفقا لكل نموذج مقترح			
		النماذج الفردية		النماذج المدمجة	
		Box-Jenkins	ANN	النموذج الأول	النموذج الثاني
		ARIMA (2,1,2)	ANN (1,6,1)	ARAN (2,10,1)	ARAN (2,1,2)
2014	0.479	0.470	0.458	0.481	0.460
2015	0.514	0.480	0.457	0.494	0.470
2016	0.533	0.480	0.457	0.491	0.490
2017	0.546	0.480	0.457	0.490	0.500
2018	0.538	0.490	0.457	0.505	0.510
	MSE	0.000188	0.0000235	0.000022	0.000146
	MAPE	2.583	0.0094	0.0086	2.126

المصدر: من إعداد الباحثان باستخدام برنامج Matlab

بمقارنة النماذج الإحصائية السابقة كما في الجدول السابق يتضح الآتي:

١- تقترب القيم المنتبأ بها لمعدلات الاحتفاظ لفروع التأمينات العامة من القيم الفعلية وذلك عند استخدام النماذج المدمجة مقارنة بالنماذج الفردية.

٢- عند استخدام النماذج المدمجة يفضل استخدام الأسلوب الأول Compound (2,10,1)

وهو استخدام البواقي (الأخطاء العشوائية) الناتجة من نموذج ARIMA واعتبارها عناصر مدخلات لنموذج الشبكات العصبية الاصطناعية ANN، حيث تبين أنه أكثر دقة في التنبؤ بمعدلات الاحتفاظ من الأسلوب الثاني ARIMA (2,1,2)، وذلك وفقاً للمقاييس الإحصائية للتنبؤ فإنه يعطي:

(أ) - أقل قيمة لمتوسط مربع الأخطاء المطلقة (MSE=0.000022)

(ب) - أقل قيمة لمتوسط الانحرافات المطلقة (MAPE=0.0086)

وبالتالي فإن أفضل نموذج يمكن استخدامه في التنبؤ بمعدلات الاحتفاظ لفروع التأمينات العامة بسوق التأمين المباشر المصري هو النموذج المدمج ARAN (2,10,1) حيث تتحقق فيه كافة شروط المقاييس الإحصائية المستخدمة في قياس دقة التنبؤ، كما أن القيم المنتبأ بها باستخدام هذا النموذج المدمج هي الأقرب بشكل كبير للقيم الأصلية مقارنة بالنماذج الفردية.

النتائج والتوصيات والمراجع

أولاً: النتائج

١- بلغ معدل الاحتفاظ بالأقساط المكتسبة لسوق التأمين المباشر ككل في نهاية عام 2018 حوالي 53.8% من إجمالي الأقساط المباشرة مقارنة بمعدل الاحتفاظ في نهاية عام 1989 حيث كان حوالي 37.7% أي بمعدل نمو حوالي 70% .

٢- ارتفاع نسبة الأقساط غير المستغلة لفروع التأمينات العامة لدى شركات التأمين المباشر في سوق التأمين المصري (إسنادات إعادة التأمين للغير) حيث بلغ متوسط نسبتها لجميع فروع التأمينات العامة في نهاية عام 2018 أي حوالي 46.2% (-100% - 53.8%) من إجمالي الأقساط المباشرة، مما يزيد من تسرب العملة الأجنبية للخارج وخاصةً عند إعادة التأمين لدى شركات تأمين أجنبية.

٣- تم اختبار الفرض الإحصائي الأول القائل:

"لا يؤدي استخدام نموذج تحليل السلاسل الزمنية (ARIMA) باستخدام منهجية (Box-Jenkins) إلي تحسين القدرة التنبؤية بمعدلات الاحتفاظ بالأقساط المكتسبة بفروع التأمينات العامة بسوق التأمين المباشر المصري" وقد تبين من الدراسة الآتي:

(أ) - أن أفضل نموذج مقترح تحققت فيه شروط مقاييس دقة التنبؤ من النماذج ARIMA المختلفة هو نموذج $ARIMA(2,1,2)$.

(ب) - تم تطبيق النموذج المقترح على بيانات الدراسة، وتبين أن هناك تقارب كبير بين القيم المتنبأ بها والقيم الأصلية لمعدلات الاحتفاظ، وبالتالي فإن استخدام نموذج $ARIMA(2,1,2)$ قد أدى إلى تحسين القدرة التنبؤية بمعدلات الاحتفاظ بالأقساط المكتسبة.

٤- تم اختبار الفرض الإحصائي الثاني القائل:

" لا يؤدي استخدام نموذج الشبكات العصبية الاصطناعية (ANN) إلي تحسين القدرة التنبؤية بمعدلات الاحتفاظ بالأقساط المكتسبة بفروع التأمينات العامة بسوق التأمين المباشر المصري"، وتبين من الدراسة الآتي:

(أ) - أن أفضل نموذج مقترح تحققت فيه شروط مقاييس دقة التنبؤ من نماذج الشبكات العصبية الاصطناعية المختلفة هو نموذج $ANN(1,6,1)$.

(ب) - تم تطبيق النموذج المقترح على بيانات الدراسة خلال الفترة الزمنية (٢٠١٨-٢٠١٤) وتبين أن هناك تقارب كبير بين القيم المتنبأ بها والقيم الأصلية لمعدلات الاحتفاظ، وبالتالي فإن استخدام نموذج الشبكات العصبية ANN قد أدى إلى تحسين القدرة التنبؤية بمعدلات الاحتفاظ مقارنة بنموذج ARIMA الذي يستخدم منهجية Box-Jenkins.

٥- تم اختبار الفرض الإحصائي الثالث القائل:

"لا يؤدي الدمج بين نموذجي تحليل السلاسل الزمنية (ARIMA) والشبكات العصبية الاصطناعية (ANN) إلى التنبؤ الدقيق بمعدل الاحتفاظ الأمثل بالأقساط المكتسبة في فروع التأمينات العامة بسوق التأمين المصري"، وتبين من الدراسة الآتي:

(أ) - أن أفضل نموذج مقترح تحققت فيه شروط مقاييس دقة التنبؤ من النماذج المدمجة هو نموذج $ARAN(2,10,1)$.

(ب) - تم الدمج بين نموذجي (ARIMA) والشبكات العصبية الاصطناعية (ANN) وذلك بأسلوبين مختلفين، وإيجاد القيم المتنبأ بها لمعدلات الاحتفاظ في فروع التأمينات العامة على مستوى شركات التأمين المباشر خلال الفترة الزمنية (٢٠١٨-٢٠١٤) وتبين أن الأفضلية في القدرة التنبؤية وفقاً لمقاييس دقة التنبؤ كانت للنموذج الأول $ARAN(2,10,1)$ ، وتبين أنه أكثر دقة في التنبؤ بمعدلات الاحتفاظ من النموذج الثاني $ARAN(2,1,2)$ وكانت القيم المقدره كما يلي:

السنوات	2014	2015	2016	2017	2018
القيم الفعلية	0.479	0.514	0.533	0.546	0.538
القيم المتنبأ بها	0.481	0.494	0.491	0.490	0.505

٦- تم استخدام البواقي (الأخطاء العشوائية) الناتجة من نموذج ARIMA واعتبارها عنصر مدخلات لنموذج الشبكات العصبية الاصطناعية ANN وذلك وفقاً للأسلوب الأول من أساليب دمج النماذج الإحصائية، حيث تبين أنه أكثر دقة في التنبؤ بمعدلات الاحتفاظ.

- ٧- من المقاييس الإحصائية لدقة التنبؤ لعدد من النماذج المختلفة تبين الآتي:
- (أ) - انخفاض قيمة متوسط مربع الأخطاء المطلقة MSE للنموذج الإحصائي المدمج ARAN (2,10,1) مقارنةً بالنماذج الفردية.
- (ب) - انخفاض قيمة متوسط الانحرافات المطلقة MAPE للنموذج الإحصائي المدمج ARAN (2,10,1) مقارنةً بالنماذج الفردية.
- وبالتالي ثبت أفضلية الأساليب الإحصائية المدمجة (نموذج ARIMA ونموذج الشبكات العصبية الاصطناعية ANN) في عملية التنبؤ مقارنةً بالنماذج الفردية.

ثانياً: التوصيات:

- بناءً على النتائج التي تم التوصل إليها من خلال هذه الدراسة يمكن تقديم بعض التوصيات المقترحة، والتي يمكن أن تساهم في تحسين أداء قطاع التأمينات العامة بشركات التأمين المباشر بسوق التأمين المصري، وهي كالاتي:
- ١- ضرورة اهتمام شركات التأمين بدراسة الأساليب والطرق الإحصائية الحديثة في مجالات التنبؤ بمعدلات الاحتفاظ بالأقساط المكتسبة، مما يخلق المزيد من فرص التطوير المستمر والاستغلال الأمثل للطاقة الاستيعابية في قطاع التأمينات العامة بسوق التأمين المصري.
 - ٢- يمكن لشركات التأمين استخدام النماذج الإحصائية المدمجة في عمليات التنبؤ بمعدلات الاحتفاظ مثل نموذج ARAN (2,10,1) الذي يجمع بين نموذج ARIMA ونموذج الشبكات العصبية الاصطناعية ANN، وذلك لما يتوافر في تلك النماذج من دقة عالية في عملية التنبؤ مقارنةً بالنماذج الإحصائية الفردية.
 - ٣- عند تطبيق النموذج المدمج بين ARIMA والشبكات العصبية الاصطناعية ANN يراعى استخدام قيم البواقي (الأخطاء العشوائية) الناتجة من نموذج ARIMA واعتبارها عناصر مدخلات في نموذج الشبكات العصبية الاصطناعية.
 - ٤- ضرورة أن تسعى شركات التأمين لزيادة معدلات الاحتفاظ خلال هذه الفترة في ظل التأمين على المشروعات القومية الضخمة التي تخوضها الدولة، وكذلك التزايد الكبير لمحافظ الأقساط

المكتسبة لشركات التأمين المباشر مما يؤكد ضرورة المحافظة على هذه الأقساط داخل السوق المحلية.

٥- ضرورة إعادة النظر في تقدير معدلات الاحتفاظ بالأقساط المكتسبة في مجال التأمينات العامة بشركات التأمين المباشر خلال فترات زمنية متقاربة، وذلك لمواكبة التغيرات الاقتصادية والسياسية في سوق التأمين المصري بشكل خاص والأسواق العالمية بشكل عام.

٦- يمكن الاستفادة في الدراسات المستقبلية من تطبيق النموذج الإحصائي المدمج المقترح Compound(2,10,1) في عملية التنبؤ في مجالات أخرى بفروع التأمينات العامة مثل التنبؤ بهامش ربح الاكتتاب، أو بمعدلات الخسارة، أو معدلات المصروفات بأنواعها، أو قيم المخصصات والاحتياطيات الفنية وغيرها.

المراجع

(أ) - المراجع العربية:

- ١- إبراهيم، أحمد عبدالرحمن سيد أحمد (٢٠١٣)، "استخدام نموذج تحليل المسار في تحديد أهم العوامل المؤثرة على معدل الاحتفاظ لشركات التأمين المصرية"، المجلة المصرية للدراسات التجارية، جامعة المنصورة، كلية التجارة، مجلد (٣٧)، العدد (٢).
- ٢- إبراهيم، إبراهيم محمد (٢٠١٥)، "دراسة مقارنة للتنبؤ بالسلاسل الزمنية متعددة المتغيرات باستخدام نموذجي دالة التحويل والشبكات العصبية الاصطناعية"، رسالة دكتوراه، الإحصاء التطبيقي، جامعة السودان للعلوم والتكنولوجيا، كلية الدراسات العليا.
- ٣- أبو النصر، منى محمود (٢٠١٣)، "نموذج إحصائي مقترح للتنبؤ باستخدام دمج بعض نماذج الانحدار مع نموذج السلاسل الزمنية"، رسالة ماجستير غير منشورة، كلية التجارة، جامعة المنصورة، قسم الإحصاء التطبيقي والتأمين.
- ٤- أحمد، حسين مصيلحي سيد (٢٠١٧)، "نموذج مقترح لاستخدام الشبكات العصبية في التنبؤ بالآزمات المالية: دراسة تطبيقية على البنوك التجارية"، مجلة كلية الاقتصاد والعلوم السياسية، جامعة القاهرة، مجلد (١٨)، العدد (١).
- ٥- أحمد، أبو ذر يوسف علي و يونس، عادل موسي، (٢٠١٤)، "استخدام السلاسل الزمنية للتنبؤ بإنتاجية الصمغ العربي في سوق محاصيل الأبيض للفترة من (٢٠١٢-١٩٦٠)"، مجلة البحث العلمي للعلوم والآداب، كلية الدراسات العليا والبحث العلمي، جامعة الدننج، مجلد (١٠)، العدد (١٥).
- ٦- البدراني، ظافر رمضان مطر و صليوا، رهاد عماد (٢٠١٤)، "تقييم تنبؤ السلسلة الزمنية لمعدلات درجات الحرارة باستخدام الشبكات العصبية"، المجلة العراقية للعلوم الإحصائية، كلية علوم الحاسبات والرياضيات، جامعة الموصل، المجلد (١٤)، العدد (٢٦).
- ٧- الجراح، نوال علاء الدين (٢٠١١)، "كفاءة طريقتي الشبكات العصبية وطريقة بوكس جينكيز في التنبؤ مع حالات تطبيقية في العراق"، مجلة الإدارة والاقتصاد، كلية الإدارة والاقتصاد، الجامعة المستنصرية، العراق، العدد (٨٩).

- ٨- الحميدي، نور و حسين، حساني (٢٠١٥)، "استخدام معدل الاحتفاظ ونسبة الطاقة الاستيعابية المستغلة في تحليل أخطار المحفظة التأمينية"، مجلة الاقتصاد والمالية، جامعة حسيبة بن بو علي الشلف، الجزائر، مجلد (١)، العدد (١).
- ٩- الغنام، حمد بن عبدالله ناصر (٢٠٠٣)، "تحليل السلسلة الزمنية لمؤشر أسعار الأسهم في المملكة العربية السعودية باستخدام منهجية بوكس-جينكينز"، مجلة جامعة الملك عبدالعزيز للاقتصاد والإدارة، المجلد (١٧)، العدد (٢).
- ١٠- القاسمي، فواز حسن (٢٠١٣)، "استخدام نماذج ARIMA الموسمية والشبكات العصبية ANN للتنبؤ بأسعار النفط الخام في اليمن والمقارنة بين نماذج التنبؤ"، مجلة العلوم الإدارية والاقتصادية، كلية الاقتصاد والعلوم الإدارية، جامعة عدن، العدد (١٢).
- ١١- جاب الله، سامية طلعت عباس (٢٠٠٤)، "استخدام الشبكات العصبية الاصطناعية في مجال المحاسبة والمراجعة"، المجلة العملية للاقتصاد والتجارة، كلية التجارة، جامعة عين شمس، العدد (٢).
- ١٢- حاجي، جعفر محمد (١٩٩٩)، "الشبكة العصبية: التنبؤ بأسعار صرف الدينار الكويتي مقابل الدولار الأمريكي"، المجلة العربية للعلوم الإدارية، مجلد (٦)، العدد (١).
- ١٣- درويش، مروان جمعة (٢٠١٨)، "استخدام منهجية بوكس-جينكينز للتنبؤ بالتدفقات النقدية في البنوك الفلسطينية: دراسة حالة بنك فلسطين"، مجلة جامعة القدس المفتوحة للبحوث الإدارية والاقتصادية، جامعة القدس المفتوحة، المجلد (٣)، العدد (٩).
- ١٤- زريقة، بديع (٢٠٠٩)، "استخدام الشبكة العصبونية للتنبؤ بمقدار الطلب على الطاقة الكهربائية"، مجلة جامعة دمشق للعلوم الهندسية، كلية الهندسة الميكانيكية والكهرباء، جامعة دمشق، المجلد (٢٥)، العدد (٢).
- ١٥- سليمان، أسامة ربيع أمين (٢٠١٠)، "التنبؤ بمعدل الاحتفاظ بالأقساط في سوق التأمين المصري باستخدام السلاسل الزمنية"، مجلة الباحث، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة قاصدي مرباح ورقلة، الجزائر، العدد (٨).
- ١٦- شعراوي، سمير مصطفى (٢٠٠٥)، "مقدمة في التحليل الحديث للسلاسل الزمنية"، مركز النشر العلمي، كلية العلوم، جامعة الملك عبدالعزيز، جدة، المملكة العربية السعودية.

١٧- طاقة، اليومي عوض عوض (٢٠٠٥)، "التنبؤ باستخدام نموذجي ARIMA ودالة التحويل بالتطبيق على أسعار أسهم الشركة المصرية لمدينة الإنتاج الإعلامي"، مجلة التجارة والتمويل، كلية التجارة، جامعة طنطا، العدد (١).

١٨- طه، طارق محمد عبدالحميد (٢٠١٧)، "Forecasting Fire Insurance Loss Ratio in Misr Insurance Company"، مجلة الباحث، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة قاصدي مرباح ورقلة، العدد (١٧).

١٩- عبدالعزيز، بثينة عبد الجابر، و الساعدي، علي أحمد حسن (٢٠١٦م)، "استخدام نماذج السلاسل الزمنية الهجينة وغير الهجينة للتنبؤ بأعداد المسافرين لمطار بغداد الدولي"، مجلة الإدارة والاقتصاد، كلية الإدارة والاقتصاد، الجامعة المستنصرية، العراق، السنة (٣٩)، العدد (١٠٩).

٢٠- كردودي، سهام، (٢٠١٥)، "دور المراجعة التحليلية في تحسين أداء عملية التدقيق في ظل استخدام تكنولوجيا المعلومات دراسة حالة مركب تكرير الملح لوطاية بسكرة"، رسالة دكتوراه، كلية العلوم الاقتصادية والتجارية وعلوم التسيير، جامعة محمد خيضر بسكرة، الجزائر.

٢١- كردودي، سهام و قدور، علي (٢٠١٧)، "المراجعة التحليلية باستخدام الشبكات العصبية الاصطناعية"، دار أسامة للنشر والتوزيع.

٢٢- محمد، رامي محمد طابع (٢٠١٤)، "نماذج الانحدار المقيدة كأداة للتنبؤ، دراسة تطبيقية"، مجلة البحوث المالية والتجارية، كلية التجارة، جامعة بورسعيد، العدد (٢).

٢٣- مشعال، محمود عبدالعال محمد (٢٠١٥)، "استخدام دالة التزاوج الإحصائية المركبة في التنبؤ بأقساط التأمين التعاوني: دراسة تطبيقية على السوق السعودي"، مجلة البحوث المالية والتجارية، كلية التجارة، جامعة بورسعيد، العدد (١).

٢٤- نقار، عثمان و العواد، منذر (٢٠١١)، "منهجية Box-Jenkins في تحليل السلاسل الزمنية والتنبؤ، دراسة تطبيقية علي أعداد تلاميذ الصف الأول من التعليم الأساسي في سورية"، مجلة جامعة دمشق للعلوم الاقتصادية والقانونية، جامعة دمشق، مجلد (٢٧)، العدد (٣).

٢٥- الكتاب الإحصائي السنوي، هيئة الرقابة المالية، الأعداد عن الفترة (٢٠١٨-١٩٨٩).

(ب) - المراجع الأجنبية:

1. **Aires, F., Prigent, C., & Rossow, w. B., (2004),** "Neural network uncertainty assessment using Bayesian statistics with application to remote sensing: 2. Output errors", Journal of Geophysical research, Vol. 109, D10304.
2. **Al-Shayea, Q. K., (2017),** "Neural Networks to Predict Stock Market Price," Proceeding of the World Congress on Engineering and Computer Science, Vol.I, October,25-27, San Francisco, USA.
3. **Bishop, C. M., (2006),** "Pattern Recognition and Machine Learning", Springer Science and Business Media, LLC, Singapore.
4. **Cummins, D., & Powel, A., (1980),** "The performance of Alternative Models for forecasting Automobile Insurance paid claim costs", Asten Bulletin, Vol.11, Issue 2.
5. **Enders, w., (2015),** "Applied Econometric time Series", John Wiley and sons,4th.
6. **Engelbrecht, A.P.,(2007),** "Computational Intelligence: An Introduction" 2nd Edition, John Wiley and Sons, South Africa.
7. **Grothmann, R., (2003),** "Multi-Agent Market Modeling Based On Neural Networks", Thesis presented for the Degree of Doctor of Economics, faculty of Economics, University of Bremen, Germany.
8. **Gupta, C., Sharma, S., & Bansal, M., (2006),**"Implementation of Back Propagation Algorithm (of neural Network) In VHDL", Department of Electronics and Communication Engineering, Thapar Institute of Engineering & Technology, Patiala. (Deemed University), Patiala-147004, India.
9. **Gupta, N., (2013),** "Artificial Neural Networks", ISSN 2225-0603 Vol.3, No.1, 2013-Selected from International Conference on Recent Trends in Applied Sciences with Engineering Applications.

10. **Hamilton, J., D., (1994),** "Time Series Analysis", Princeton Press University, New Jersey, 1st Eedition.
11. **Idown, P.A., Osakwe, C., Kayode, A.A., & Adagunodo, E. R., (2012),** "Prediction of Stock Market in Nigeria Using Artificial Neural Network", International Journal of Intelligent Systems and Applications, 11, Published Online October 2012 in MECS (<http://www.mecs-press.org/>).
12. **Kaasra,L., & Boyd, M., (1996),** "Designing a Neural Network for Forecasting Financial and Economic Time Series", Neurocomputing, Volume 10, Issue 3.
13. **Khashei, M., & Bijari, M., (2010),**"An artificial neural network (p, d, q) model for time series forecasting", Expert Systems with Applications, Volume 37, Issue 1.
14. **Kihoro, J.M, Otieno, R.O., & Wafula, C., (2004),** "Seasonal Time Series Forecasting: a comparative Study of ARIMA and ANN models", African Journal of Science and Technology, Vol.5, No.2.
15. **Lai, k.k., Yu, L., Wang, S., & Huang, w.,(2006),** "Hybridizing Exponential Smoothing and Neural Network for Financial Time Series Predication", V.N. Alexandrov et al. (Eds.): ICCS , Part IV, LNCS 3994, Springer-Verlag Berlin Heidelberg.
16. **Madsen, H., (2007),** "Time Series Analysis ", Chapman & Hall /CRC texts in statistical science series, V.72, New York.
17. **Makridakis, S., G., C.Wheelwright, S., C., & Hyndman, R., J., (1998),** "Forecasting Methods and Applications", 3rd Edition, John Wiley & Sons, Inc. Publication, New York, USA.
18. **Mantri, J., K., & Gahan, P., (2010),** "Artificial Neural Networks - An Application to Stock Market Volatility", International Journal of Engineering Science and Technology, Vol.(2), No.(5).

19. **Merh, N. & Prakash, V., & Pardasani, K., R., (2010),** "A Comparison between hybrid approaches of ANN and ARIMA for Indian Stock trend Forecasting", Business Intelligence Journal, July, Vol.3, No.2.
20. **Shen, H. Y., & Chang, L.C., (2013),** "Online multistepahead inundation depth forecasts by recurrent NARX net works", Hydrology and Earth System Sciences.
21. **Swanson, N.R. & White, H., (1995),** "A Model-Selection Approach to Assessing the Information in the Term Structure Using Linear Models and Artificial Neural Networks", Journal of Business and Economic Statistics, Volume 13, Issue 3.
22. **Yoon, Y., & Swales, G.,) 1996),** "Predicting Stock Price Performance: ANN Approach", Economics Proceedings of the Twenty-Fourth Annual Hawaii International Conference on System Sciences.