



التنبؤ بمعدلات الخسارة لشركات تأمينات الممتلكات باستخدام منهجية Box-Jenkins والشبكات العصبية الاصطناعية (بالطبيق على التأمين الهندسي)

إعداد

د. دينا طلعت حمدي نيل

مدرس التأمين والرياضيات والإحصاء
كلية إدارة الأعمال، جامعة حورس، مصر
dtalaat@horus.edu.eg

د.محمد أحمد عبد النبي

مدرس التأمين والرياضيات والإحصاء
أكاديمية السادات للعلوم الإدارية
mohamed.abdelnaby@sadatacademy.edu.eg

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد الخامس - العدد الثاني – الجزء الرابع - يوليو ٢٠٢٤

التوثيق المقترح وفقاً لنظام APA:

عبد النبي، محمد أحمد؛ نيل، دينا طلعت حمدي (٢٠٢٤). التنبؤ بمعدلات الخسارة لشركات تأمينات الممتلكات باستخدام منهجية Box-Jenkins والشبكات العصبية الاصطناعية (بالطبيق على التأمين الهندسي)، *المجلة العلمية للدراسات والبحوث المالية والتجارية*، كلية التجارة، جامعة دمياط، ٥(٢)٤، ٣٦١-٣٩٣.

رابط المجلة: <https://cfdj.journals.ekb.eg/>

التنبؤ بمعدلات الخسارة لشركات تأمينات الممتلكات باستخدام منهجية Box-Jenkins والشبكات العصبية الاصطناعية (بالطبيق على التأمين الهندسي)

د. محمد أحمد عبد النبي؛ د. دينا طلعت حمدي نيل

ملخص:

تتبع أهمية معدل الخسارة في شركات التأمين من ارتباطه بشكل مباشر بكفاءة العديد من الوظائف الرئيسية في شركات التأمين، من اكتتاب وتسعير وتسوية واستثمار وإعادة التأمين، كما أنه يساعد شركات التأمين في رسم السياسات التأمينية بشكل سليم مما يساعدها في تحقيق أهدافها. ولقد زادت أهمية التأمينات الهندسية في الآونة الأخيرة نظراً لزيادة المشروعات والاستثمارات الانشائية وبشكل خاص في المدن الجديدة، وانشاء الطرق، حيث تركز هذه المشروعات في تنفيذها على وثائق التأمينات الهندسية لتغطية جميع أخطار المقاولين والانشاء خلال فترة التنفيذ، مما دعي الى وجود نموذج جيد للتنبؤ بمعدل الخسارة بما أنه اللبنة الأساسية للعديد من القرارات داخل شركات التأمين منها إعادة التأمين، حيث لن يتم تحديد حد الاحتفاظ دون معدل الخسارة المتوقع، كما أنه يساعد معيد التأمين في تحديد مسؤوليته عن العمليات التي تعرض عليه، بالإضافة الى أن التسعير يعتمد أيضاً على معدلات الخسارة المتوقعة. وبالتالي تتمثل مشكلة البحث في التنبؤ بمعدل الخسارة لثلاث شركات تأمين لفرع التأمين الهندسي وذلك باستخدام أسلوبين من أساليب التنبؤ، كل على حدى، نموذج Box-Jenkins باعتباره أحد النماذج التقليدية، وأسلوب آخر حديث يتمثل في نماذج الشبكات العصبية الاصطناعية Artificial Neural Network ANN والتي أظهرت بعض تطبيقاتها الإحصائية نتائج جيدة في عملية التنبؤ.

الكلمات المفتاحية: التأمينات الهندسية، معدل الخسارة، منهجية بوكس – وجينكز، الشبكات العصبية الاصطناعية

المقدمة وطبيعة المشكلة

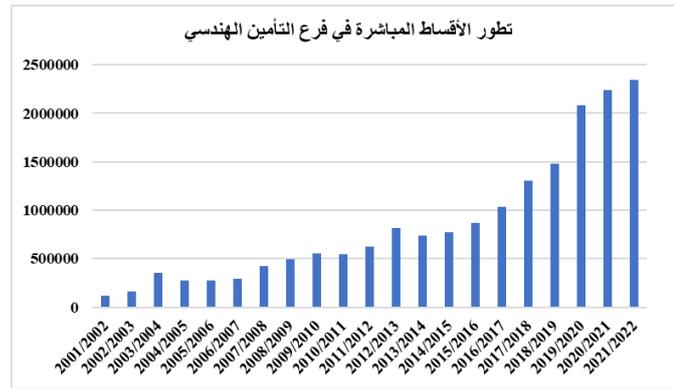
تتبع أهمية معدل الخسارة في شركات التأمين من ارتباطه بشكل مباشر بكفاءة العديد من الوظائف الرئيسية في شركات التأمين، من اكتتاب وتسعير وتسوية واستثمار وإعادة التأمين، كما أنه يساعد شركات التأمين في رسم السياسات التأمينية بشكل سليم مما يساعدها في تحقيق أهدافها.

ونظراً لما لقطاع التأمين من أهمية بين القطاعات الاقتصادية المؤثرة على اقتصاديات الدول، ولما له من مزايا تتمثل في مواجهة الأخطار والخسائر المالية التي قد يتعرض لها الفرد أو أي منشأة، بالإضافة الى تجميع المدخرات واستثمارها في المجالات المختلفة، فان أهمية هذا القطاع ظهرت مع التطور الصناعي والعقاري والأخطار المصاحبة له.

وبناء عليه ظهرت حاجة شركات التأمين الى وجود تغطية تأمينية من شأنها توفير الضمانات اللازمة لتغطية المشروعات بدءاً من مرحلة الانشاء والتشييد حتى انتهاء مرحلة التجارب ودخول المشروعات حيز العمل، هذا بالإضافة الى تغطية مرحلة التشغيل فظهر التأمين الهندسي.

ويعرف التأمين الهندسي " بأنه مجموعه من تأمينات الممتلكات والمسؤولية المدنية التي تهدف الى حماية المشروعات الصناعية المختلفة سواء كانت انشائية أو تحويلية أو استخراجية من الخسائر المادية الناشئة عن الأضرار التي قد تتعرض لها الآلات والمعدات والأجهزة والتركيبات والمباني سواء كان ذلك في مرحلة الانشاء والتجارب أو في مرحلة التشغيل الفعلي". ويعتبر تأمين الغلايات أقدم أنواع التأمينات الهندسية على الإطلاق فقد ارتبط ظهوره ببدء الثورة الصناعية واكتشاف قوة البخار في منتصف القرن الثامن عشر في أوروبا، غير أنه لم يطبق بشكل عام الا بعد منتصف القرن التاسع عشر، غير أن التأمينات الهندسية في ظهرت مصر عام ١٩٦٠م نتيجة التوسع في انشاء المصانع واستخدام الآلات بعد ثورة يوليو ١٩٥٢م. (عجوة وعبد الحميد، ٢٠١٧)

زادت أهمية التأمين الهندسي في الآونة الأخيرة نظراً لزيادة المشروعات والاستثمارات الانشائية وبشكل خاص في المدن الجديدة، وانشاء الطرق، حيث تركزت هذه المشروعات في تنفيذها على وثائق التأمينات الهندسية لتغطية جميع أخطار المقاولين والانشاء خلال فترة التنفيذ، ويوضح شكل رقم (١) التالي تطور الأقساط المباشرة في التأمين الهندسي للفترة الزمنية من ٢٠٠١ حتى ٢٠٢٢



المصدر: اعداد الباحثان بالاعتماد على بيانات الكتاب الاحصائي السنوي

الشكل رقم (١) تطور الأقساط المباشرة في فرع التأمين الهندسي

حيث يوضح الشكل زيادة الأقساط المباشرة لفرع التأمين الهندسي بشكل مستمر ببرزه الاتجاه العام لارتفاع الأقساط والذي يعززه أيضاً الجدول رقم (١) التالي الذي يعبر عن معدل تطور الأقساط المباشرة لنفس الفرع ولنفس الفترة الزمنية والذي تم الحصول على بياناته من إصدارات متعددة من الكتاب الاحصائي السنوي عن نشاط التأمين، على النحو التالي:

جدول (١) معدل تطور الأقساط المباشرة في التأمين الهندسي للفترة الزمنية (٢٠٠١-٢٠٢٢)

السنوات	الأقساط المباشرة	معدل التطور للأقساط %
2001/2002	117125	10
2002/2003	161778	38.1
2003/2004	355724	119.9
2004/2005	275223	22.6
2005/2006	275223	22.6
2006/2007	293977	6.8
2007/2008	422809	43.8
2008/2009	491846	16.3
2009/2010	554063	12.6
2010/2011	546486	16.8
2011/2012	626540	14.6
2012/2013	815928	30.2
2013/2014	735889	-9.8
2014/2015	774695	5.3
2015/2016	870728	12.4
2016/2017	1033489	18.7
2017/2018	1305408	26.3
2018/2019	1480007	13.4
2019/2020	2078907	40.5
2020/2021	2238333	7.7
2021/2022	2342338	4.6

المصدر: إصدارات متعددة من الكتاب الإحصائي السنوي الصادر عن الهيئة العامة للرقابة المالية.

ويوضح الجدول السابق أن معدل التطور في الأقساط المباشرة للتأمين الهندسي في حالة زيادة مستمرة وان كان أقصى معدل تطور بلغ %119.9 للعام المالي (2003/2004)، في حين نقص معدل التطور في العام (2013/2014) لـ 9.8 ، وذلك مقابل معدل التطور بلغ %4.6 في العام المالي (2021/2022).

وتختلف التأمينات الهندسية عن أنواع تأمين الممتلكات الأخرى والتي تختص بتغطية وحدة معرضة للخطر ضد خطر بعينه، في كونها تشمل مجال تغطية أخطر أوسع من حيث المدى والحجم والمدة، وبناء عليه ظهرت الحاجة الى وجود نموذج جيد للتنبؤ بمعدل الخسارة بما أنه اللبنة الأساسية للعديد من القرارات داخل شركات التأمين منها إعادة التأمين، حيث لن يتم تحديد حد الاحتفاظ دون معدل الخسارة المتوقع، كما أنه يساعد معيد التأمين في تحديد مسؤوليته عن العمليات التي تعرض عليه، بالإضافة الى أن التسعير يعتمد أيضاً على معدلات الخسارة المتوقعة.

بالإضافة إلى ذلك هناك نوع آخر من القرارات الهامة داخل شركات التأمين، والتي تتأثر بمعدلات الخسارة المتوقعة، وهي القرارات المتعلقة بالضوابط والقواعد الخاصة باختيار وانتقاء الأخطار، حيث أن الدقة في تقدير تكاليف الخسائر المستقبلية تلعب دوراً أساسياً في رسم سياسات الاكتتاب في التأمينات العامة، ولذا يعد معدل الخسارة هو أشهر المقاييس التي تعتمد عليها الجهات المسؤولة عن الإشراف والرقابة على النشاط التأميني، فهو بمثابة انذار مبكر للملاءة المالية لشركات التأمين، الذي يمكن من خلاله الحكم على متانة المركز المالي لشركة التأمين. (الخواجة، ٢٠١٤)

وبناء على ما سبق فإن عملية التنبؤ على وجه التحديد أداة هامة من أدوات اتخاذ القرار والتخطيط للمستقبل، حيث يتم الاعتماد على تحليل سلسلة بيانات في الماضي لرسم ما قد يكون عليه المستقبل، يوجد العديد من الطرق التي تستخدم في بناء نماذج التنبؤ، منها تحليل السلاسل الزمنية وهي أكثر الطرق استخداماً، بالإضافة إلى طرق أخرى تنسم بالحدثة كالشبكات العصبية، وبالتالي تتمثل مشكلة البحث في التنبؤ بمعدل الخسارة بالتطبيق على شركات تأمينات الممتلكات وبشكل خاص فرع التأمين الهندسي وذلك باستخدام أسلوبين من أساليب التنبؤ، نموذج Box-Jenkins باعتباره أحد النماذج التقليدية، وأسلوب آخر حديث يتمثل في نماذج الشبكات العصبية الاصطناعية Artificial Neural Network ANN والتي أظهرت بعض تطبيقاتها الإحصائية نتائج جيدة في عملية التنبؤ، ومن ثم المقارنة بين نتائجهما.

الهدف من البحث:

يهدف البحث إلى التنبؤ بمعدل الخسارة لفرع التأمين الهندسي في شركات تأمين الممتلكات العاملة بالسوق المصري، وذلك من خلال تطبيق كلاً من نموذج Box-Jenkins ونماذج الشبكات العصبية الاصطناعية للتنبؤ، والمقارنة بين نتائج النموذجين لتحديد مدى دقة نتائج التنبؤ بكل نموذج واختيار النموذج المناسب لتطبيقه.

أهمية البحث:

تتبع أهمية البحث من أهمية تطبيق نماذج التنبؤ بشكل عام - و نموذج Box-Jenkins ونماذج الشبكات العصبية الاصطناعية بشكل خاص - في تحليل بيانات السلسلة الزمنية، وبالتالي استخدام هذا التحليل في عملية اتخاذ القرار ورسم السياسات المستقبلية لشركات التأمين، مما يساعد في التنبؤ في تحليل الخصائص الاحتمالية أو العشوائية لسلسلة زمنية معينة، بينما تتمثل أهمية التنبؤ بمعدل الخسارة في شركات التأمين بشكل خاص في النقاط التالية:

١. يساعد التنبؤ الدقيق بمعدلات الخسارة في القدرة على التنبؤ بالتعويضات المدفوعة لتحديد أسعار التأمين الملائمة.
٢. يساهم التنبؤ الدقيق في استقرار معدل الخسارة.
٣. التنبؤ بالأقساط المكتسبة مستقبلاً.

الدراسات السابقة

تعرضت العديد من الدراسات لاستخدام نماذج Box-Jenkins ونماذج الشبكات العصبية للتنبؤ بالعديد من الظواهر الاقتصادية التي يتم التعبير عنها في صورة سلسلة زمنية، مع وصف احصائي لخصائص كل نموذج من النموذجين والمقارنة بينهم في أحيان أخرى.

وبناء عليه يمكن تتنوع الدراسات السابقة التي تم الاستناد إليها في اعداد هذا البحث بين دراسات باللغة العربية ودراسات باللغة الإنجليزية، منها ما يهدف الى التنبؤ بمعدل الخسارة في شركات التأمين بوجه عام، أو فرع التأمين الهندسي ولكن باستخدام نماذج إحصائية تقليدية، ومنها ما اهتم بتطبيق نماذج Box-Jenkins ومنها ما استخدم نماذج الشبكات العصبية، وذلك على النحو التالي:

تسعى دراسة (سمري وعلي، ٢٠٢٢) الى التوصل الى نموذج كمي يمكن من خلاله التنبؤ بمعدل الاحتفاظ وبأخذ في اعتباره معظم العوامل الكمية المؤثرة على معدلا الاحتفاظ، وذلك من خلال المفاضلة بين نموذج الشبكات العصبية باستخدام كافة المتغيرات المستقلة المؤثرة على معدل الاحتفاظ، وبين نموذج الشبكات العصبية باستخدام أفضل المتغيرات الناتجة عن نموذج الانحدار المتعدد، وقد توصل البحث الى أن نموذج الشبكات العصبية باستخدام كافة المتغيرات المستقلة المؤثرة على معدلا الاحتفاظ أكثر دقة وكفاءة في التنبؤ بمعدل الاحتفاظ وذلك وفقاً لمعايير القياس. وكان من بين ما أوصت به الدراسة هو توصية متخذ القرار في شركات التأمين الاخذ في الاعتبار المتغيرات التالية عند اتخاذ قرار الاحتفاظ: دخل الأقساط، حقوق المساهمين، المخصصات الفنية، نسبة التحميلات، تكلفة إعادة التأمين، معدلا الخسارة، معدل الاستثمار، معدل كفاية رأس المال، معدل السلامة المالية.

وكان الهدف من دراسة (Kobiela et al,2022) هو تطبيق ومقارنة نتائج نموذجين مختلفين: أحدهما احصائي متمثل في ARIMA والآخر deep learning متمثل في LSTM وذلك بالتطبيق على بيانات NASDAQ "سوق أسهم الكترونية أمريكية" ، حيث تم استخدام النموذجين للتنبؤ بمتوسط الأسعار اليومية والشهرية لبعض الشركات المدرجة بالبورصة، وتوصلت الدراسة الى أن نتائج التنبؤ باستخدام نموذج ARIMA بمعلمات p,q من 0 الي 2 كانت أفضل من نتائج التنبؤ باستخدام نموذج LSTM.

كما تناولت دراسة (محمد وأبو زيد، ٢٠٢١) اختبار مدى معنوية استخدام نماذج Box-Jenkins في التنبؤ بهامش ربح الاكتتاب لقطاع التأمينات العامة بالسوق المصري، وتحديد معلمات نموذج ARIMA المناسب، وتوصل البحث الى قدرة نماذج ARIMA على تقديم وصف دقيق للتقلبات التي تكتنف السلسلة الزمنية لهامش ربح الاكتتاب لفرع الحريق، وأوصت الدراسة بضرورة تبني النموذج المقترح من قبل شركات التأمين لما له من أهمية في عملية التخطيط الجيد للسياسة الاكتتابية، وبما ينعكس على تحديد السعر العادل الذي يتناسب ودرجة الخطورة لكل خطر من الأخطار المكتتب فيها.

أما بالنسبة ل (v. et al 2021) كان الهدف الرئيسي للبحث هو بناء نموذج رياضي للتنبؤ بمجموع مطالبات الطرف الثالث لفئات متخلفة من السيارات وبالاعتماد على بيانات منتقاة، حيث تم استخدام نماذج Machine learning مثل نماذج الانحدار الخطي، نماذج ARIMA، ونماذج الشبكات العصبية ANN، بالإضافة الى نماذج الدمج بين ARIMA و ANN ، وتوصلت الدراسة الى أن نماذج الشبكات العصبية هي أفضل نموذج للتنبؤ من بين النماذج الأخرى، وفي النهاية أوصت بالاعتماد على نماذج Machine learning لتوقع مبالغ المطالبات والتي من شأنها توفير نموذج تنبؤ أفضل يضمن تسوية وإدارة أكثر كفاءة لفئات السيارات المختلفة.

تهدف دراسة (زايد وآخرون، ٢٠٢٠) الى التنبؤ بالطلب على التأمين في الدول العربية بناء على تحديد أهم العوامل المؤثرة فيه كما تسهم في اثراء الدراسات العربية في مجال تطبيقات نماذج السلاسل الزمنية المقطعية متعددة المتغيرات ونماذج الشبكات العصبية الاصطناعية في تقدير الطلب على التأمين، وتم من خلال هذه الدراسة استخدام مجموعة متنوعة من الأساليب الإحصائية من أهمها

اختبار Kao للتكامل المشترك للسلاسل الزمنية المقطعية، اختبار سببية Granger، نماذج الانحدار الخطي، نماذج السلاسل الزمنية ARIMA، نماذج الآثار المختلطة متعددة المستويات MLME Models، والشبكات العصبية ANN، وكانت النتيجة وجود ارتباط بين جميع العوامل الاقتصادية والمالية والاجتماعية والثقافية التي شملتها الدراسة والطلب على التأمين، كما تمثلت أهم توصيات الدراسة في التوسع في استخدام النماذج الإحصائية وخوارزميات علم البيانات لنمذجة مختلف مؤشرات قطاع التأمين والتنبؤ بتطورها مستقبلاً.

تناولت دراسة (هاشم، ٢٠٢٠) تحليل العوامل المؤثرة على هامش ربح الاكتتاب في فرع تأمين أجسام السفن والوصول الى أكثر هذه العوامل تأثيراً من الناحية الفنية سواء في القطاع العام أو القطاع الخاص أو اجمالي السوق، وذلك من خلال استخدام نموذجي الشبكات العصبية الاصطناعية والخوارزميات الجينية الوراثية، ودراسة مدى اختلاف تطبيق كل من النموذجين، وقد توصلت الدراسة فيما يخص موضوع هذه الورقة البحثية الى أنه يمكن تقدير هامش ربح الاكتتاب في تأمين الممتلكات والمسئولية باستخدام تطبيقات الذكاء الاصطناعي مثل نموذج الشبكات العصبية الاصطناعية ANN و نموذج الخوارزميات الجينية الوراثية GA، ومما أوصت به الدراسة ضرورة تطوير نماذج لنظم الذكاء الاصطناعي مع نماذج متقدمة أخرى واستخدامها في شركات التأمين، بالإضافة الى التوصية باستخدام تطبيقات الذكاء الاصطناعي في مجالات أخرى من مجالات التأمين.

بينما تطرقت دراسة (خليل وأخرون، ٢٠٢٠) الي التنبؤ بمعدل الخسارة لفرع تأمين الطيران وذلك باستخدام نظام الشبكات العصبية الموامم بالفازية Adaptive Neuro -Fuzzy Inference System (ANFIS)، وقد أعطى النموذج نتائج جيدة في التنبؤ وذلك وفقاً لمقاييس متوسط مربع الخطأ عن القيم المقدره والمتوسط المطلق لنسبة الخطأ ومتوسط مربع الخطأ عن القيم المتنبأ بها.

في حين كان الهدف من دراسة (المعداوي، ٢٠١٨) تسعير التأمين الهندسي باستخدام نموذج المصدقية الثاني بالتطبيق على بعض شركات التأمين وذلك من خلال تقدير معامل وقسط المصدقية، وكانت من أهم النتائج التي توصلت اليها الدراسة أنه يمكن تقدير سعر التأمين في فرع التأمين الهندسي بمعلومية مبالغ التأمين، كما أوصت الدراسة باستخدام نموذج المصدقية الثاني في تسعير التأمين الهندسي ومقارنته بالأساليب العلمية والاكتوارية المستخدمة في التسعير وذلك بغرض تحقيق العدالة في حساب القسط والحد من تسرب العملات الأجنبية للخارج.

بينما تناولت دراسة (المبارك، ٢٠١٦) استخدام نماذج Box- Jenkins والشبكات العصبية للتنبؤ في السلاسل الزمنية الاقتصادية، حيث كان الهدف من هذه الدراسة هو ابراز العلاقة بين الأساليب المستخدمة للتنبؤ في السلاسل الزمنية ودقة التنبؤات التي تم الوصول اليها، وأوصت هذه الدراسة بأفضلية استخدام نماذج بوكس وجينكز في حالات السلاسل الزمنية الأقل تعقيداً واستخدام الشبكات العصبية كلما زادت درجة تعقيد السلسلة، كما أوصت بأفضلية استخدام الشبكات العصبية في حالة البيانات التي توضح عدم ثبات التباين، وأخيراً استخدام نماذج بوكس وجينكز في حالة ما اذا كانت السلسلة الزمنية بالطوب الكافي الذي يمكن معه رصد كل التغيرات بوضوح.

كما قام كل من (أبو بكر ومحمود، ٢٠١٤) باستخدام الشبكات العصبية الاصطناعية في بناء نموذج كمي من المؤشرات المالية لقياس الملاءة المالية في شركات قطاع التأمين الخاص التي تصدر وثائق تأمينات الممتلكات والمسؤوليات العاملة في سوق التأمين المصري، حيث توصلت الدراسة من بين ما توصلت اليه أن الاعتماد على الشبكات العصبية الاصطناعية في تقييم الملاءة المالية لشركات التأمين يعطي نتائج أفضل من الأساليب الإحصائية الأخرى مثل تحليل التمايز والتحليل اللوجستي.

وتطرقت دراسة (زمران، ٢٠١٤) لأهمية التنبؤ بمعدلات الخسارة في شركات التأمين وذلك بالإجابة على سؤال كيف يتم توظيف السلاسل الزمنية من أجل التقدير الأمثل لمعدلات الخسارة في شركات التأمين؟ فكان الهدف من هذه الدراسة هو وضع نموذج يسهل عملية اتخاذ قرارات تقدير معدلات الخسارة في شركات التأمين، مع الأخذ في الاعتبار خصوصية الوحدات المعرضة للخطر، وأوصت الدراسة بأن تراجع شركات التأمين الإحصاءات السابقة في حساب معدل الخسارة، كما أوصت أيضاً بتعديل متغيرات النموذج بالشكل الذي يسمح بإدراج متغيرات أخرى لها تأثير على معدلات الخسارة.

كما توصل (Adebiyi et al, 2014) أن التنبؤ باستخدام الشبكات العصبية أعطى نتائج أفضل مقارنة بنتائج نماذج ARIMA وذلك بتطبيق كلا النموذجين على سلسلة بيانات من سوق الأوراق المالية في نيويورك.

وفي ذات السياق كان الهدف من دراسة (القاسمي، ٢٠١٣) هو استخدام نماذج ARIMA ونموذج الشبكات العصبية، ومقارنة النموذجين لغرض التنبؤ بأسعار النفط الخام الشهرية في اليمن، وتوصلت هذه الدراسة الى دقة نموذج الشبكات العصبية في عملية التنبؤ.

وبناء على العرض السابق، تنبأت العديد من الدراسات بمعدل الخسارة من خلال استخدام نماذج إحصائية تقليدية قد يشوبها بعض القصور يتعلق بفروض التنبؤ، أو طول السلسلة الزمنية محل الدراسة، فبالتالي ظهرت أهمية استخدام أساليب لها القدرة على تحليل الخصائص العشوائية لسلسلة ما، أو نماذج تكون أكثر دقة وفاعلية وتستخدم المنطق بديل عن فكرة العلاقة الثابتة بين المتغيرات، وبناء عليه يسهم البحث في مجال التنبؤ بمعدل الخسارة لفرع التأمين الهندسي بشكل خاص، باستخدام كل من نموذج Box-Jenkins ونماذج الشبكات العصبية والمقارنة بين دقة نتائج كلا النموذجين.

محددات البحث:

١. مجتمع البحث: يقتصر البحث على التنبؤ بمعدل الخسارة لفرع التأمين الهندسي لثلاث شركات تأمين وهي: مصر للتأمين، والمهندس للتأمين، والدلتا للتأمين.
٢. حدود البحث الزمنية: فترة الدراسة سلسلة زمنية لمعدل الخسارة لثلاث شركات وذلك للفترة الزمنية (٢٠٠١-٢٠٢١) واستخدامها للتنبؤ لخمس سنوات
٣. مصادر البيانات: الكتاب الإحصائي السنوي الصادر عن الهيئة المصرية للرقابة المالية عن نشاط التأمين بالسوق المصري.

منهجية البحث:

تتمثل منهجية البحث في تحليل معدل الخسارة لفرع التأمين الهندسي في ثلاث شركات من الشركات العاملة في السوق المصري للفترة الزمنية (٢٠٠١-٢٠٢١)، ومن ثم التنبؤ بمعدل الخسارة لفرع التأمين الهندسي لثلاث شركات لخمس سنوات (٢٠٢٢-٢٠٢٦) وذلك باستخدام كل من منهجية Box-Jenkins بواسطة برنامج EViews والشبكات العصبية الصناعية ANN وذلك بواسطة برنامج Weka

فروض البحث:

يمكن صياغة فروض البحث الإحصائية في الفروض التالية:

١. يمكن تطبيق نموذج Box-Jenkins في التنبؤ بمعدلات خسارة التأمين الهندسي.
٢. يمكن تطبيق نموذج الشبكات العصبية الصناعية في التنبؤ بمعدلات خسارة التأمين الهندسي.
٣. لا يوجد اختلاف في التنبؤ بمعدلات الخسارة وفق منهجية Box-Jenkins ومنهجية الشبكات العصبية الصناعية ANN.

خطة البحث:

يتم الوصول لهدف البحث من خلال المباحث التالية:

المبحث الأول: منهجية Box-Jenkins

المبحث الثاني: الشبكات العصبية الاصطناعية (ANN) Artificial Neural Network

المبحث الثالث: التنبؤ بمعدل الخسارة.

المبحث الأول: منهجية Box-Jenkins

يتمثل الغرض الأساسي من استخدام منهجية Box-Jenkins في التنبؤ في تحليل الخصائص الاحتمالية أو العشوائية لسلسلة زمنية ما، حيث لا تتبع هذه المنهجية نموذج الانحدار التقليدي، الذي يمكن من خلاله تفسير المتغير التابع وليكن Y_t بمتغيرات تفسيرية أخرى مثل X_1, X_2, \dots, X_n ، بينما تسمح هذه المنهجية بتفسير المتغير التابع بالأخذ في الاعتبار القيم في فترات الخبرة السابقة سواء كانت قيم Y_t نفسها أو القيم الحالية أو المتأخره للبوادي u_t ، والتي هي عبارة عن خطأ عشوائي غير مترابط بمتوسط صفر، وتباين ثابت، أو بشكل عام يمكن القول أنها خطأ الضوضاء البيضاء white noise

تشير منهجية Box-Jenkins الى مجموعه من الإجراءات لتحديد وتقدير السلاسل الزمنية والتي تعرف بنماذج الانحدار الذاتي والمتوسطات المتحركة autoregressive integrated moving average، وتتطلب الطرق التي يتم استخدامها للوصول الى معلمات النموذج العديد من العمليات الحسابية التي تحتاج الى التطبيق بالحزم والبرامج الإحصائية المختلفة.

تعد نماذج ARIMA النموذج الأساسي للتنبؤ، وهي عبارة عن مزيج من عمليتين الانحدار الذاتي Autoregressive (AR)، بينما يعبر عن متوسط التحركات Moving Average (MA)، في حين يعبر حرف (I) في منتصف النموذج عن التكامل بين المتغيرات التي يتم تحليلها. يعتمد بناء نموذج (ARIMA) على الارتباط الذاتي.

ويمكن استخدام ARIMA في حالات السلاسل الزمنية المستقرة أو السلاسل الزمنية غير المستقرة والتي من الممكن أن تصل للاستقرار من خلال اجراء التفاضل. ويتم التعبير عن نموذج ARIMA بالصيغة الرياضية التعارف عليها التالية $ARIMA(p, d, q)$ حيث يتم تعريف كل رمز على النحو التالي:

p : ترتيب الانحدار.

d : ترتيب التفاضل.

q : ترتيب المتوسطات المتحركة.

يتم بناء نموذج ARIMA من خلال ثلاث مراحل تعتمد بالأساس على نموذج Box-Jenkins على النحو التالي:

١. المرحلة الأولى: التعريف رتبة النموذج

يتم من خلال هذه المرحلة التحقق من رتبة النموذج، وذلك من خلال نمذجي الارتباط الذاتي $autocorrelation\ function\ (ACF)$ ودالة الارتباط الجزئي $partial\ correlation\ (PACF)$ وعن طريق إجراء الاختبار الاحصائي $Dickey-Fuller$ و $Augmented\ Dickey\ Fuller$

٢. المرحلة الثانية: تقدير وتشخيص النموذج

يتم وفقاً لهذه المرحلة تقدير النموذج المقترح، حيث يعتمد الاختيار النهائي للنموذج على تحليل معنوية المعلمات النموذج، ومصفوفة الخطأ ومعيار الخطأ سواء كان ب $(Akaike's\ information)$ أو $(Bayesian\ information)$ ، وتتمثل الخطوة التالية في التأكد من تشخيص النموذج والتي تتم عن طريق دراسة خصائص النموذج من خلال عدد بواقي الخطأ التي يتم تحليلها، والتي يمكن بناء عليها استخدام النموذج في التنبؤ، حيث انه اذا وجد فرق معنوي بين قيم كل من ACF أو $PACF$ يتم إعادة عملية التقدير وتشخيص النموذج.

٣. المرحلة الثالثة: التنبؤ

يتم وفقاً لهذه المرحلة إجراء التنبؤ باستخدام النموذج وذلك عن طريق استخدام فترات داخل العينة $in-sample\ period$ وخارجها $out-of-sample\ period$ ، حيث يتم تقسيم مجموعة البيانات الى بيانات داخل العينة تستخدم لتقدير المعلمات الأولية واختيار النموذج، بينما تستخدم العينة الخارجية لتقييم التنبؤ، ومن الجدير بالذكر هنا أن النتائج التي يتم الوصول اليها بناء على القيم الخارجية للعينة تكون أدق من الاعتماد على بيانات العينة الداخلية والتي تتأثر بشكل أكبر بالقيم الشاذة.

يتم التعبير عن نموذج الانحدار الذاتي التكاملي المتوسط المتحرك $ARIMA(p, d, q)$ في الصورة التالية:

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots + e_t \quad (1)$$

حيث:

Z_t, Z_{t-1} : عبارة عن نقاط استقرار البيانات.

e_t, e_{t-1} : عبارة عن أخطاء التنبؤ في الحاضر والماضي.

$\mu, \phi_1, \phi_2, \dots, \theta_1, \theta_2, \dots$: عبارة عن معلمات النموذج المقدر.

ومن الجدير بالذكر هنا توضيح أنه في حالة اذا ما احتوى النموذج الناجح فقط على ϕ_1 أي أن المعادلة تصبح على الصورة التالية:

$$Z_t = \mu + \phi_1 Z_{t-1} + e_t \quad (2)$$

فهنا يمكن القول أن السلسلة الزمنية في هذه الحالة تتبع انحدار ذاتي من الدرجة الأولى أي أن $AR(1)$ ، وبالتالي فإن ϕ_1 تعرف بمعلمة الانحدار الذاتي ويصف النموذج أعلاه تأثير التغيير في قيمة Z_{t-1} على Z_t ، وبالتبعية من الممكن القول أن النموذج التالي:

$$Z_t = \mu + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + e_t \quad (3)$$

هو النموذج المستخدم لتحديد ترتيب معلمة الانحدار الذاتي p ، والذي يجب أن يكون فيه مجموع المعاملات $\phi_i, i = 1, 2, \dots, p$ أقل من الواحد.

أما إذا احتوى النموذج على θ_1 فقط تصبح المعادلة على النحو التالي:

$$Z_t = \mu - \theta_1 e_{t-1} + e_t \quad (4)$$

فهنا تكون درجة المتوسط المتحرك التي تحكم السلسلة الزمنية هي الدرجة الأولى $MA(1)$ ، وتعرف θ_1 أنها معلمة المتوسط المتحرك، وبناء عليه يمكن القول أن النموذج التالي:

$$Z_t = \mu - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} + e_t \quad (5)$$

يعرف بنموذج تحديد درجة المتوسط المتحرك ويرمز له بالرمز $MA(q)$

تعرف النماذج التي تحتوي على كل من الانحدار الذاتي و المتوسط المتحرك بالـ "النماذج المختلطة" ، إذا كان درجة معلمة الانحدار الذاتي ١ و ترتيب المتوسط المتحرك ٢ يتم كتابة النموذج في صورة $ARIMA(1,2)$ ويأخذ الصيغة التالية:

$$Z_t = \mu + \phi_1 Z_{t-1} - \theta_1 e_{t-1} - \theta_2 e_{t-2} + e_t \quad (6)$$

أما في حالة ما إذا تم إجراء التفاضل بغرض الوصول لاستقرار السلسلة الزمنية يأتي هنا دور *integrated* ويصبح نموذج $ARIMA(p,d,q)$.

ويمكن القول مما سبق، أن أسلوب التحليل الحديث للسلاسل الزمنية الذي قدمه العالمان بـ *Box and Jenkins* يعد أحد الأدوات الإحصائية التي يمكن الاعتماد عليها في السلاسل الزمنية وهو أسلوب يختلف عن العديد من أساليب التنبؤ الأخرى، حيث يتميز هذا الأسلوب بما يلي:

١. أنه نظام نمذجة وتنبؤ منظم وشامل وموثوق به، ويعني هذا أنه يقدم حلاً شاملاً لجميع مراحل تحليل السلاسل الزمنية بدءاً من اختيار النموذج المبدئي ومروراً بتقدير معالم هذا النموذج وتشخيصه وانتهاء بالتنبؤ بالملاحظات المستقبلية.
٢. أنه لا يفترض الاستقلال بين مشاهدات السلسلة 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، ويؤدي ذلك في النهاية إلى تنبؤات موثوق بها ومتسقة احصائياً.
٣. أنه يعطي تنبؤات أدق من تلك التي نحصل عليها باستخدام أي أسلوب آخر خاصة إذا توافرت البيانات الكافية لتغطيتها.
٤. أنها تعطي فترات ثقة ملائمة للملاحظات المستقبلية للبيانات الموسمية وغير الموسمية بينما تقشل طرق أخرى في ذلك. (طاقية والوصيفي، ٢٠١٢)

المبحث الثاني: الشبكات العصبية الصناعية (ANN) Artificial Neural Network

تعتبر الشبكات العصبية اللبنة الأساسية للذكاء الاصطناعي المعاصر، وهي مستوحاة من الشبكات العصبية البيولوجية في الدماغ البشري، لقد بدأ الاستغلال الفعلي للشبكات العصبية في الأعمال المالية في مطلع التسعينات، حيث تمت عدة تطبيقات لها، وذلك لحل مشكلات عديدة في مجالات مختلفة والتنبؤ بعجز المؤسسات ومن الأسباب التي جذبت الباحثين الى استخداماتها في تحليلاتهم نذكر ما يلي:

أ. سهولة انشاء النموذج حيث لا يتطلب وقت كبير، وذلك من خلال أجهزة الكمبيوتر المجهزة ببرمجيات حديثة، مما يكسبه قدرة على التكيف مع المعطيات المتجددة.

ب. يتناسب هذا النوع من التحليل بطريقة جيدة مع المشاكل المعقدة أي معالجة المشاكل التي من غير الممكن معرفة العلاقة بين المتغيرات التي تستعمل فيها مسبقاً (الدالي، أمل أحمد حسن شحاته، ٢٠١٥).

وقد تم استخدام الشبكات العصبية كبديل عن نماذج التنبؤ التقليدية، حيث أثبتت نماذج الشبكات العصبية قدرتها على التنبؤ وحل المشكلات وسهولة المقارنة بالأساليب الإحصائية التقليدية (سمري، وعلي ٢٠٢٢)

ان فهم العناصر الأساسية المكونة للشبكة مهم لاستخدامها في التطبيقات المختلفة، كما تعتبر الشبكة العصبية أداة لمعالجة البيانات، حيث أنه من الممكن الحصول على عدد لا نهائي من الشبكات العصبية وذلك من خلال كيفية ربط قنوات الإشارة، حيث تتكون الشبكة العصبية من ثلاث طبقات على النحو التالي:

١. طبقة المدخلات Input Layer

يتم من خلال هذه الطبقة تغذية شبكة البيانات من الخارج وتستقبل البيانات بواسطة وحدات المعالجة (العصبونات) التي تتألف منها الشبكة، وقد تتألف الشبكة من وحدة معالجة واحدة أو أكثر على حسب تركيبية الشبكة.

وقد تكون مدخلات الشبكة بيانات خام (Raw Data) أو مخرجات من عناصر معالجة أخرى. وبدورها تأخذ البيانات المدخلة الى الشبكة احد شكلين: بيانات ثنائية (Binary) أو بيانات متصله (Continuous) حيث يتوقف ذلك على نوع القيم العددية المستخدمة.

لا يتم في وحدات المعالجة لطبقات الادخال أي معالجات حسابية بل يقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البيئية (الأوزان) الى وحدات المعالجة في الطبقة الخفية أو مباشرة الى وحدات المعالجة في طبقة المخرجات اذا كانت الشبكة لا تحتوي على طبقة خفية وأي شبكة عصبية تحتوي على طبقة واحدة فقط من وحدات الادخال.

٢. الطبقة المخفية Hidden Layer

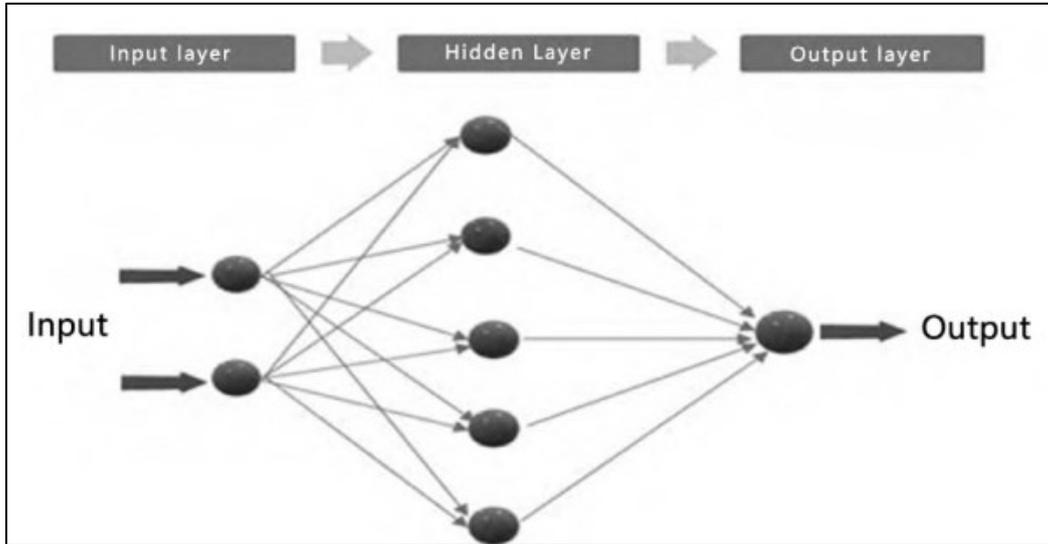
تقع هذه الطبقة بين طبقة المدخلات وطبقة المخرجات وقد لا تحتوي على تراكيب بعض الشبكات على الطبقة الخفية وقد تحتوي الشبكة على طبقة خفية واحدة أو أكثر من طبقة خفية.

تستقبل الطبقة الخفية الإشارات القادمة إليها من طبقة المدخلات عبر الوصلات البيئية فتقوم بمعالجتها وإجراء اللازم عليها ومن ثم إرسالها عبر الوصلات إلى طبقة المخرجات.

٣. وطبقة المخرجات Output Layer

تتكون هذه الطبقة من وحدات المعالجة التي يتم عبرها اخراج الناتج النهائي للشبكة. وقد تحتوي هذه الطبقة على وحدة معالجة المخرجات الإشارات القادمة إليها من طبقة الإدخال مباشرة أو من الطبقة الخفية وبعد إجراء المعالجات اللازمة قد ترسل إشارات بالمخرجات النهائية أو قد تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة وذلك عندما لا تتم المعالجة المطلوبة للبيانات، وقد تحتوي الشبكة عادة على طبقة مخرجات واحدة فقط. (المبارك و آدم، ٢٠١٦)

بالإضافة إلى عناصر معالجة مترابطة عبر قنوات إشارة أحادية الاتجاه تسمى أوزان الاتصال، وتعتبر طبقة المدخلات بمثابة المتغيرات المستقلة، بينما تلعب طبقة المخرجات دور المتغير التابع (متغيرات التنبؤ)، ويوضح الشكل رقم (٢) التالي تصميم طبقات الشبكة العصبية



Source: Predictive Modeling of Insurance Claims Using Machine Learning Approach for Different Types of Motor Vehicles, v.et al, 2021

الشكل رقم (٢) تصميم الشبكة العصبية

ومن الجدير بالذكر أن هذه العناصر لها القدرة على إجراء العمليات الحسابية من خلال الخطوات التالية:

١. معالجة البيانات من خلال عدة عناصر تسمى نيورونات *neurons*
٢. تمر الإشارات *signals* بين النيورونات عبر خطوط ربط تسمى روابط اتصال *Connection Links*

٣. يتم إعطاء وزن ترجيحي معين $Weight$ لكل مدخل بواسطة خطوط الربط ويضرب مع الإشارة الداخلة على اجمالي مدخلاته (مجموع الإشارات الداخلة الموزونة) ليحدد إشارة المخرجات الناجمة منه الى النيورون.

٤. يطبق على نيورون دالة تحفيز معينة أو دالة تحويل عادة غير خطية.

وتعتبر عملية تجميع الإشارات الداخلة للنيورون والمرجحة بالأوزان من أهم العمليات ويتم ذلك من خلال تطبيق دالة التحفيز، وهناك العديد من دوال التحفيز شائعة الاستخدام وهي كما سبق دوال غير خطية من أشهرها دالة السجمويد $function Sigmoid$ ، ويوجد لها دالتان شائعتان هما الدالة اللوجستية $logistic function$ ، ودالة $Hyperbolic Tangent function$ ، على أن يتم انتاج المزيد من المخرجات الموثقة كلما زاد حجم المدخلات داخل الشبكة، حتى يتحسن أداء الشبكة العصبية للوصول الى أفضل جودة توفيق ممكنة بناء على معايير كل من: $R2, U, MAPE, MAE, RMSE$ وذلك من خلال قواعد المعرفة والتدريب المراقب وغير المراقب، والتعلم بخوارزمية الانتشار الخلفي للخطأ $error back propagation$ على ثلاث مراحل هي:

أ. الانتشار الأمامي للخطأ $error forward propagation$

ب. الانتشار الخلفي للخطأ $error back propagation$

ج. توليف أوزان الشبكة العصبية $network weights synthetic$

وتنقسم الشبكات العصبية الى نوعين رئيسيين على النحو التالي:

الأول: الشبكات العصبية ذات التغذية الأمامية **Feed-Forward- Network**

تنتقل فيها العمليات الحسابية في اتجاه واحد على الأمام من طبقة المدخلات الى طبقة المخرجات مروراً بالطبقة المخفية في حال استخدامها، وتصنف من حيث طبقاتها الى شبكات وحيدة الطبقة $Single -Layer -Network$ وشبكات متعددة الطبقات $Multi -Layer - Network$

الثاني: الشبكات العصبية ذات التغذية المرتجعة

يمكن وفقاً لهذه الشبكات إعادة تغذية (كل أو بعض) الإشارات الخارجة من الشبكة وتحويل اتجاهها لتصبح إشارة داخلة أيضاً (إعادة تغذية). (علي، أحمد عبد الوهاب أحمد ٢٠٢٢)

ومن أهم مميزات الشبكات العصبية القدرة على نمذجة العلاقات غير الخطية المعقدة دون افتراضات مسبقة لطبيعة هذه العلاقات، وكذلك إمكانية التعامل مع الحالات التي تكون فيها بيانات المدخلات بها أخطاء أو قيم مفقودة أو قيم غامضة.

ومما سبق يمكن القول أن الشبكات العصبية الاصطناعية تمثل نظاماً متكاملًا يتكون من مجموعه مركبة من عدة عناصر مترابطة معاً (نيرونات) $neurons$ والتي تعمل في انسجام

الخلية العصبية **Neuron**

تسمى أصغر وحدة معالجة في الشبكة العصبية والتي تمثل أساس تشغيل الشبكة " خلية عصبية،" حيث تعمل هذه الوحدة على استقبال المدخلات أو إشارات المخرجات من الوحدات الأخرى وتنتج المخرج الخاص بها. ويتم ضرب إشارات المدخلات في أوزان تمثل قوة الاتصال أو العلاقة بين الوحدة المرسله "i" ووحدة الاستقبال "j" ثم تتم معالجة المدخلات المرجحة وتمريرها كمخرجات يمكن استخدامها كمدخل لوحدة أخرى في نفس الطبقة أو الطبقة التالية.

ويتطلب بناء شبكة عصبية التالي:

١. العثور على المدخلات ذات الصلة، بمعنى، العوامل ذات التأثير المعنوي على البيانات التي سيتم نمذجتها.
٢. تجميع البيانات اللازمة للتدريب واختبار الشبكة العصبية.
٣. تحديد مدى تعقيد النموذج، أي تحديد العدد المناسب من النيورونات المخفية.
٤. تدريب الشبكة لتقدير المعلمات التي تصل بالتكلفة لأقل حد ممكن.
٥. تقييم مدى إمكانية تعميم الشبكة العصبية.

ويتسم استخدام تطبيقات الذكاء الاصطناعي بعدة مزايا منها:

- تخزين البيانات والمعلومات بشكل فعال وإنشاء قاعدة بيانات تمكن للكثير من العاملين الحصول عليها كنص يدوي أو اليكتروني، مما سيؤدي الى تعلم القواعد التجريبية التي قد لا توجد في الكتب، كما أن هذا التخزين يكون وسيلة الشركة المهمة في حماية معرفتها من الضياع جراء تسرب العاملين بالاستقالة أو المعاش أو الوفاة.
- إنشاء الآلية التي لا تخضع للمشاعر البشرية كالتعب أو القلق، وهذا يكون مفيد بشكل خاص عندما تكون الأعمال خطيرة على الأفراد (بيئياً) أو بدنياً، أو ذهنياً وبذلك تكون تلك الأنظمة بمثابة مرشد ناجح في أوقات الأزمات.
- إزالة الاعمال الروتينية وغير الملائمة التي يقوم بها العاملون.
- توليد الحلول للمشكلات المعقدة التي عند تحليلها تكون أصعب مما يستطيع الانسان معالجتها في وقت قصير.
- القدرة على حل المشاكل المعروضة عند غياب المعلومة الكاملة.
- القدرة على التعلم والفهم من التجارب والخبرات السابقة.
- القدرة على استخدام الخبرات القديمة وتوظيفها في مواقف جديدة.
- القدرة على استخدام التجربة والخطأ لاستكشاف الأمور المختلفة.
- القدرة على التعامل مع الحالات الصعبة والمعقدة.
- القدرة على تمييز الأهمية النسبية لعناصر الحالات المعروضة.
- القدرة على التصور والابداع وفهم الأمور المرئية وادراكها.

أما بالنسبة لقطاع التأمين فإن الذكاء الاصطناعي يقوم بتقديم المساعدة لشركات التأمين والوسطاء وحاملي الوثائق من حيث زيادة الكفاءة والفعالية وسرعة وكفاءة وحجم تبادل المعلومات، لاسيما وأن الذكاء الاصطناعي يمكن أن يوفر حلولاً لمعظم المشاكل التي تواجه القطاع وخصوصاً من ناحية التعويضات أو المقاصة بين الشركات، كما أنه يساعد في تقييم الخطر بطريقة دقيقة، وكذلك منع وقوع الأضرار والانتهاك من تسوية المطالبات بشكل أسرع.

ومن ثم فإن الذكاء الاصطناعي يساعد القائمين على صناعة التأمين على توفير المال، وتحقيق إيرادات أكبر، حيث أنه يقوم بمنح العملاء ما يريدونه بالضبط، ويمكن أن تقوم شركات التأمين بتطوير أدوات الذكاء الاصطناعي الخاصة بها لتحليل المخاطر وهو ما سيؤثر بدوره على مبلغ التأمين وتحديد نوع التغطية التأمينية، كما يقدم الذكاء الاصطناعي الفرصة لشركات التأمين لإنشاء نماذج مختلفة للتنبؤ بالمخاطر، وبالتالي تقوم الشركة بتصميم وثائق تأمين ملائمة لاحتياجات العملاء المختلفة، كما يمكن أيضا تقدير مخصصات التعويضات تحت التسوية لفروع التأمين المختلفة وتقدير هامش ربح الاكتتاب. (هاشم، ٢٠٢٠)

وتأخذ دالة الشبكة العصبية المستخدمة في التنبؤ الشكل التالي:

$$Y = F[H_1(x), H_2(x), \dots, H_n(x) + U \quad (7)$$

حيث:

Y : المتغير التابع الذي يناظر مخرجات الشبكة output

X : المتغيرات المستقلة والتي تناظر مدخلات الشبكة input

H : دوال تحفيز الطبقات الخفية في الشبكة العصبية.

F : مخرجات دالة التحفيز في الشبكة.

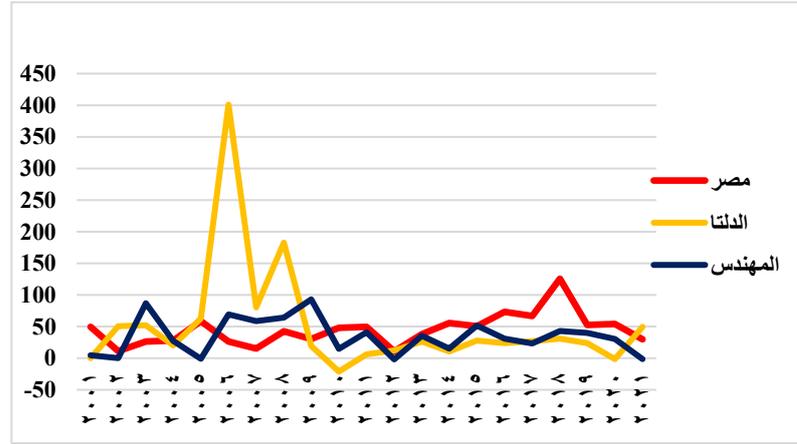
U : حد الخطأ في الدالة.

ومن الجدير بالذكر أن هناك عوامل تؤثر على الشبكة العصبية، حيث يمكن الحصول على جودة التنبؤات المستقبلية لظاهرة معينة تعتمد وبشكل أساسي على مدى كفاءة تدريب الشبكة العصبية الاصطناعية وذلك للبيانات التاريخية لتلك الظاهرة، وهذه العوامل هي:

١. لا يتأثر أداء الشبكة عند ادخال أي مجموعة إضافية من البيانات الجديدة والتي لم تكن موجودة في البداية.
 ٢. لا تتطلب وجود افتراضات قوية بشأن نوعية البيانات والعلاقة بين المتغيرات كما في الأساليب الإحصائية الأخرى.
 ٣. لا تتطلب توافر عدد كبير من البيانات التجريبية.
 ٤. ليس هناك حاجة لترتيب المتغيرات حسب أهميتها، وذلك حيث أن الشبكة تضع تلقائياً أوزان خاصة بها حسب طبيعة البيانات المدخلة إليها.
 ٥. تعطي قرارات واضحة في النماذج المعروفة، كما يمكنها معالجة مشكلات اتخاذ القرارات والتي تنصف بمدخلات غير واضحة stochastic
- ويعاب عليها أنها لا تتعامل مع المشاكل ذات المتغيرات التي لا يمكن صياغتها كمياً، كما أنها تعطي نتائج في بعض الحالات ليس من الممكن تفسيرها. (عبد العاطي وآخرون ٢٠١٨)

المبحث الثالث: التنبؤ بمعدل الخسارة

يتم في هذا الجزء تطبيق كلا من نماذج Box- Jenkins ونماذج الشبكات العصبية ANN على بيانات ثلاث شركات تأمين (مصر – المهندس – الدلتا) وذلك بالتطبيق على السلسلة الزمنية من (٢٠٠١-٢٠٢١) فرع التأمين الهندي، والتي يظهر الشكل التالي تغيرها وذلك بالنسبة للشركات موضع الدراسة لنفس الفترة الزمنية للدراسة:



المصدر: اعداد الباحثان بالاعتماد على بيانات الكتاب الاحصائي السنوي

الشكل رقم (٣) الاتجاه العام لمعدل الخسارة في شركات مصر للتأمين والدلتا للتأمين والمهندس للفترة الزمنية (٢٠٠١-٢٠٢١)

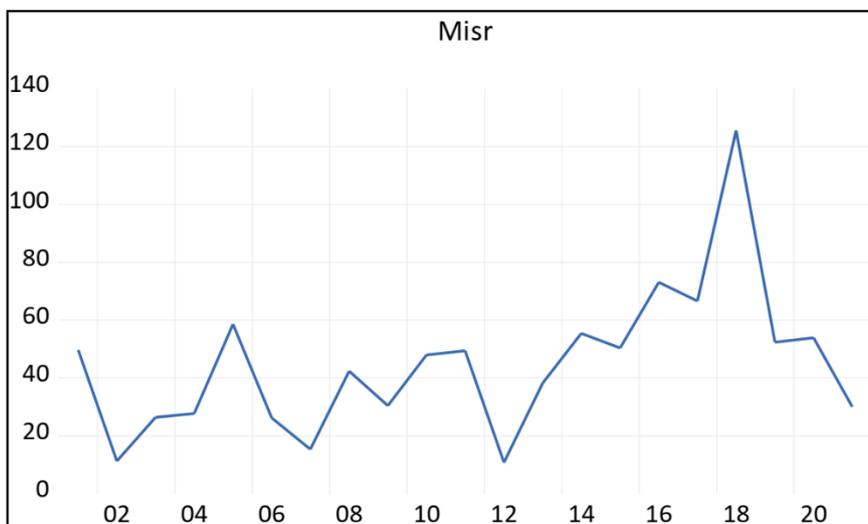
حيث يظهر الشكل السابق التقارب الى حد ما في معدلات الخسائر للشركات الثلاث موضع الدراسة الى أن شركة الدلتا تكبدت أعلى خسائر وذلك للسنوات ٢٠٠٦، و ٢٠٠٧، و ٢٠٠٨ على التوالي. وبالتالي من المهم التنبؤ بمعدل الخسارة لوضع الخطط للتعامل مع ما قد يطرأ من تحول مفاجئ على الاتجاه العام للبيانات كما يوضحها الشكل السابق. وينقسم هذا المبحث الى قسمين على النحو التالي:

القسم الأول: التنبؤ بمعدل الخسارة باستخدام نموذج Box-Jenkins للشركات الثلاثة.

سيتم في هذا الجزء تطبيق منهجية Box-Jenkins وذلك لتحديد أفضل نموذج ARIMA يتم استخدامه للتنبؤ بمعدل الخسارة لكل شركة على حدى، وذلك على النحو التالي:

١. شركة مصر للتأمين

يوضح الشكل رقم (٣) التالي السلسلة الزمنية لمعدل الخسارة في شركة مصر للتأمين وذلك للفترة الزمنية موضع الدراسة



المصدر: مخرجات برنامج EViews

الشكل رقم (٤) السلسلة الزمنية لمعدل الخسارة لشركة مصر للتأمين

حيث يوضح الشكل عدم استقرار السلسلة الزمنية، وبالتالي يجب حساب الفروق وذلك لضمان السلسلة الزمنية، ولكن ذلك بعد إجراء اختبار "Dickey - Fuller" للتأكد من ثبات السلسلة الزمنية، حيث يفحص هذا الاختبار نتائج الفرض الاحصائي بأن السلسلة الزمنية تحتوي جذر الوحدة أي أنها لا تتمتع بالاستقرار، مما يستدعي القيام ببعض التحولات مثل التعامل مع لوغار يتم البيانات والاعتماد على الفروق الأول أو الثاني للسلسلة الزمنية للبيانات محل الدراسة والتأكد من كونها مستقرة، والذي ظهرت نتائجه على النحو التالي:

جدول (٢) نتائج اختبار "Dickey - Fuller" قبل وبعد حساب الفروق

Significant level	P-value	t-statistic	
5%	0.4334	-0.624337	قبل حساب الفروق
5%	0000	-7.226861	بعد حساب الفرق الأول

من الجدول السابق كانت قيمة P-value قبل حساب الفروق تساوي 0.4334 متجاوزة مستوى معنوية (5%)، حيث تشير هذه النتيجة الى عدم وجود أدلة كافية لرفض فرض العدم بوجود جذر للوحدة، مما يدل على عدم الثبات في السلسلة الزمنية الأصلية، ونتيجة لعدم الثبات تم حساب الفروق من الدرجة الأولى للوصول لثبات السلسلة، ومن ثم تم إجراء اختبار Dickey-Fuller مرة أخرى لتقييم ثبات السلسلة الزمنية، فكانت النتيجة P-value تساوي الصفر أي أقل من مستوى المعنوية (5%) مما أدى الى رفض الفرض العدم بوجود جذر الوحدة، مما يؤكد استقرار السلسلة الزمنية بعد حساب فروق الدرجة الأولى.

تأتي بعد ذلك مرحلة تحديد دالة الارتباط الذاتي والارتباط الذاتي الجزئي وذلك لتحديد نموذج ARIMA الأكثر ملائمة والتي كانت نتائجها على النحو التالي:

جدول (٣) الارتباط الذاتي والارتباط الذاتي الجزئي لسلسلة الزمنية لمعدل الخسارة

Date: 04/07/24 Time: 14:51

Sample (adjusted): 2002 2021

Included observations: 20 after adjustments

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.443	-0.443	4.5534	0.033
		2 0.137	-0.074	5.0139	0.082
		3 -0.127	-0.118	5.4310	0.143
		4 -0.023	-0.151	5.4451	0.245
		5 0.131	0.078	5.9512	0.311
		6 -0.194	-0.137	7.1296	0.309
		7 0.028	-0.172	7.1557	0.413
		8 0.032	-0.007	7.1925	0.516
		9 -0.083	-0.126	7.4661	0.589
		10 0.203	0.097	9.2765	0.506
		11 -0.166	-0.002	10.627	0.475
		12 -0.098	-0.294	11.158	0.515

المصدر: مخرجات برنامج EViews

من النتائج السابقة يمكن دراسة نماذج ARIMA المحتملة من بين النماذج التالية:

1. $ARIMA(1,1,1)$
2. $ARIMA(1,1,0)$
3. $ARIMA(0,1,1)$

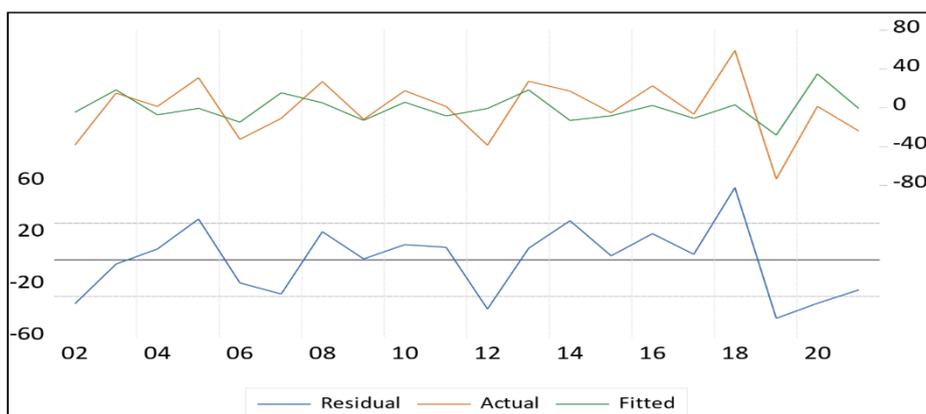
ويخلص الجدول رقم (٤) التالي مقارنة نماذج ARIMA المقترحة وذلك على النحو التالي:

جدول (٤) مقارنة نتائج تحديد نماذج ARIMA المقترحة

Std. Error	P-value	t-statistics	Coefficient	النماذج المقترحة
1.174896	0.1260	1.614318	1.896655	C
0.417769	0.8392	0.206224	0.086154	AR(1)
8598.117	0.9999	-0.000116	-1.000000	MA(1)
4.076350	0.9952	0.006143	0.025041	C
0.179555	0.0225	-2.655985	-0.476896	AR(1)
1.066220	0.0814	1.852155	1.974805	C
11190.73	0.9999	-8.94E-05	-0.999998	MA(1)

بعد إجراء اختبار t-test على معاملات النماذج الثلاثة المقترحة، نجد أن معلمة الانحدار الذاتي في نموذج $ARIMA(1,1,0)$ فقط هي التي وجدت أنها ذات دلالة إحصائية (معنوية). وعلى العكس من ذلك، اعتبرت المعلمات في النماذج الأخرى غير معنوية، وبناء عليه تم اختيار نموذج $ARIMA(1,1,0)$

يأتي بعد ذلك خطوة اختبار مدى توافق القيم الفعلية (Actual Values) مع القيم المقدرة (Fitted Values) والبواقي لنموذج ARIMA المقترح، حيث تم التعبير بيانياً عن هذه القيم على النحو التالي:



المصدر: مخرجات برنامج EViews

الشكل رقم (٥) القيم الفعلية والمتوقعة والبواقي لنموذج $ARIMA(1,1,0)$ لمعدل الخسارة

يتضح من الشكل السابق أن النموذج المقترح يصف الظاهرة محل الدراسة بشكل عالي الدقة، حيث يمثل كل من المنحنى الممثل للقيم الفعلية للسلسلة والقيم المقدرة نفس الاتجاه تقريباً، يأتي بعد ذلك دور الخطوة المتمثلة اختبار مدى استقرار بواقي السلسلة الزمنية وذلك بواسطة فحص دالة الارتباط الذاتي والارتباط الذاتي الجزئي على النحو التالي:

جدول (٥) فحص استقرار السلسلة الزمنية لبواقي نموذج $ARIMA(1,1,0)$ المقترح

Date: 04/07/24 Time: 15:05
Sample (adjusted): 2002 2021
Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.025	-0.025	0.0140	
		2	-0.161	-0.162	0.6503	0.420
		3	-0.161	-0.174	1.3206	0.517
		4	0.004	-0.039	1.3210	0.724
		5	0.066	0.010	1.4506	0.835
		6	-0.186	-0.228	2.5377	0.771
		7	-0.053	-0.079	2.6336	0.853
		8	0.046	-0.021	2.7127	0.910
		9	0.027	-0.074	2.7418	0.950
		10	0.124	0.098	3.4221	0.945
		11	-0.188	-0.188	5.1416	0.882
		12	-0.094	-0.144	5.6264	0.897

المصدر: مخرجات برنامج EViews

يتضح من الجدول السابق وبعد فحص البواقي لنموذج $ARIMA(1,1,0)$ من خلال الارتباط الذاتي والارتباط الذاتي الجزئي، أن أياً من الدالتين لم تتجاوز حدود الثقة البالغة ٩٥٪ مما يشير هذا إلى عدم وجود ارتباط ذاتي كبير أو ارتباط جزئي في بقايا النموذج.

وبناء على ما سبق، يصلح النموذج المقترح للتنبؤ وبالتالي يتم استخدامه للتنبؤ بمعدل الخسارة لشركة مصر للتأمين قطاع التأمين الهندسي، حيث يتم التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)، والتي يمكن تلخيص نتائجها في الجدول التالي:

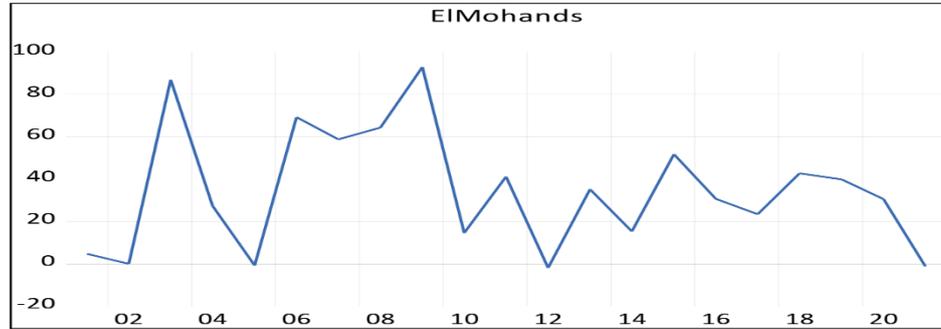
جدول (٦) التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)

السنة	معدل الخسارة لشركة مصر للتأمين
٢٠٢٢	٢٤,٢٠
٢٠٢٣	٢٤,٢٣
٢٠٢٤	٢٤,٢٦
٢٠٢٥	٢٤,٢٨
٢٠٢٦	٢٤,٣٠

٢. شركة المهندس

يتم في هذا الجزء تطبيق نفس الخطوات السابقة للتنبؤ بمعدل الخسارة في شركة المهندس للفترة الزمنية محل الدراسة، وذلك على النحو التالي:

يوضح الشكل التالي عدم استقرار بيانات السلسلة الزمنية لمعدل الخسارة لقطاع التأمين الهندسي لشركة المهندس للتأمين وذلك للفترة الزمنية موضع الدراسة.



المصدر: مخرجات برنامج EViews

الشكل رقم (٦) السلسلة الزمنية لمعدل الخسارة للتأمين الهندسي في شركة المهندس

وبالتالي يتم اجراء اختبار Dickey-Fuller، حيث يتم تلخيص نتائجه في الجدول التالي:

جدول (٧) نتائج اختبار "Dickey - Fuller" قبل وبعد حساب الفروق

Significant level	P-value	t-statistic	
5%	0.2049	-1.191693	قبل حساب الفروق
5%	0000	-7.274144	بعد حساب الفرق الأول

بلغت قيمة P-value قبل حساب الفروق 0.2049 متجاوز مستوى معنوية 5%، مما يدل على عدم وجود أدلة كافية لرفض فرض العدم المتمثل في وجود جذر الوحدة، مما يدل على عدم الثبات في السلسلة الزمنية، وبالتالي يتم حساب الفروق من الدرجة الأولى، ومن ثم اجراء الاختبار لتقييم استقرار السلاسل الزمنية، فكانت النتيجة P-value تساوي الصفر أي أقل من مستوى المعنوية (5%) مما أدى الى رفض الفرض العدم بوجود جذر الوحدة، مما يؤكد استقرار السلسلة الزمنية بعد حساب فروق الدرجة الأولى.

تأتي بعد ذلك مرحلة تحديد دالة الارتباط الذاتي والارتباط الذاتي الجزئي وذلك لتحديد نموذج ARIMA الأكثر ملائمة والتي كانت نتائجها على النحو التالي:

جدول (٨) الارتباط الذاتي والارتباط الذاتي الجزئي لسلسلة الزمنية لمعدل الخسارة

Date: 04/07/24 Time: 14:51
Sample (adjusted): 2002 2021
Included observations: 20 after adjustments

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.443	-0.443	4.5534	0.033
		2 0.137	-0.074	5.0139	0.082
		3 -0.127	-0.118	5.4310	0.143
		4 -0.023	-0.151	5.4451	0.245
		5 0.131	0.078	5.9512	0.311
		6 -0.194	-0.137	7.1296	0.309
		7 0.028	-0.172	7.1557	0.413
		8 0.032	-0.007	7.1925	0.516
		9 -0.083	-0.126	7.4661	0.589
		10 0.203	0.097	9.2765	0.506
		11 -0.166	-0.002	10.627	0.475
		12 -0.098	-0.294	11.158	0.515

المصدر: مخرجات برنامج EViews

من خلال تحليل الدالتين الارتباط الذاتي والارتباط الذاتي الجزئي من الجدول السابق، وتطبيق منهجية Box-Jenkins لتحديد نموذج ARIMA الملائم للبيانات، تم تحديد النماذج التالية:

1. $ARIMA(0,1,1)$
2. $ARIMA(0,1,2)$
3. $ARIMA(1,1,1)$
4. $ARIMA(1,1,2)$
5. $ARIMA(1,1,0)$

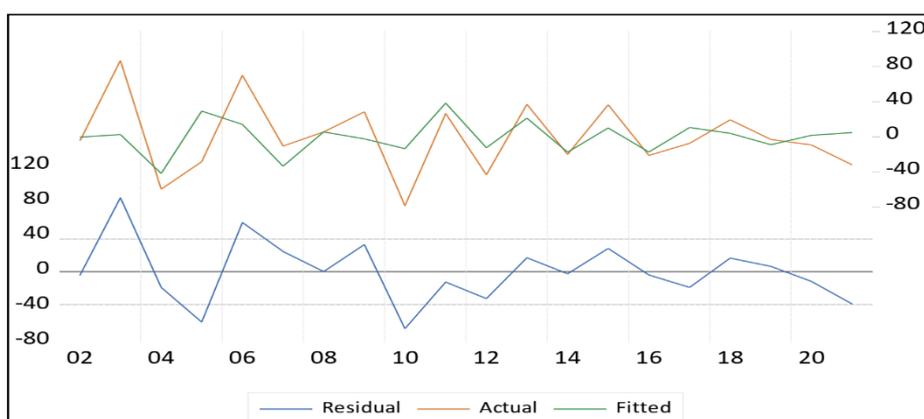
ويخلص الجدول رقم (٩) التالي مقارنة نماذج ARIMA المقترحة وذلك على النحو التالي:

جدول (٩) مقارنة نتائج تحديد نماذج ARIMA المقترحة

Std. Error	P-value	t-statistics	Coefficient	النماذج المقترحة	
1.866036	0.7799	-0.284166	-0.530264	C	
0.452190	0.9829	-0.021738	-1.000000	MA(1)	ARIMA(1,1,1)
14185.92	0.9999	-7.05E-05	-0.009830	AR(1)	
5.430398	0.9550	0.057245	0.310864	C	ARIMA(1,1,0)
0.237722	0.0374	-2.038539	-0.484605	AR(1)	
1.771717	0.7686	-0.298925	-0.529610	C	ARIMA(0,1,1)
10851.32	0.9999	-9.22E-05	-0.999999	MA(1)	
2.235566	0.8149	-0.237948	-0.531949	C	ARIMA(1,1,2)
1.693349	0.5761	-0.570798	-0.966560	AR(1)	
2364.879	0.9997	-0.000423	-0.999963	MA(2)	
9.559605	0.9823	-0.022563	-0.215690	C	ARIMA(0,1,2)
0.263936	0.8944	0.134732	0.035561	MA(2)	

بعد إجراء اختبار t-test على معاملات النماذج الثلاثة المقترحة، نجد أن معلمة الانحدار الذاتي في نموذج $ARIMA(1,1,0)$ فقط هي التي وجدت أنها ذات دلالة إحصائية (معنوية). وعلى العكس من ذلك، اعتبرت المعلمات في النماذج الأخرى غير معنوية، وبناء عليه تم اختيار نموذج $ARIMA(1,1,0)$

يأتي بعد ذلك خطوة اختبار مدى توافق القيم الفعلية (Actual Values) مع القيم المقدرة (Fitted Values) والبواقي لنموذج ARIMA المقترح، حيث تم التعبير بيانياً عن هذه القيم على النحو التالي:



المصدر: مخرجات برنامج EViews

الشكل رقم (٧) القيم الفعلية والمتوقعة والبواقي لنموذج $ARIMA(1,1,0)$ لمعدل الخسارة

يتضح من الشكل السابق أن النموذج المقترح يصف الظاهرة محل الدراسة بشكل عالي الدقة، حيث يمثل كل من المنحنى الممثل للقيم الفعلية للسلسلة والقيم المقدرة نفس الاتجاه تقريبا، وبينهما فروق غير معنوية ضئيلة، مما يدل على وجود قدرة تنبؤية عالية للنموذج، يأتي بعد ذلك دور الخطوة المتمثلة اختبار مدى استقرار بواقي السلسلة الزمنية وذلك بواسطة فحص دالة الارتباط الذاتي والارتباط الذاتي الجزئي على النحو التالي:

جدول (١٠) فحص استقرار السلسلة الزمنية لبواقي نموذج $ARIMA(1,1,0)$ المقترح

Date: 04/07/24 Time: 16:19
Sample (adjusted): 2002 2021
Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1	-0.173	-0.173	0.6933		
2	-0.231	-0.269	2.0027	0.157	
3	0.086	-0.013	2.1925	0.334	
4	-0.127	-0.192	2.6336	0.452	
5	0.026	-0.025	2.6527	0.618	
6	0.128	0.056	3.1713	0.674	
7	-0.094	-0.048	3.4678	0.748	
8	-0.104	-0.118	3.8658	0.795	
9	0.002	-0.094	3.8659	0.869	
10	0.030	-0.025	3.9047	0.918	
11	0.037	-0.004	3.9717	0.949	
12	0.136	0.136	4.9817	0.932	

المصدر: مخرجات برنامج EViews

يتضح من الجدول السابق وبعد فحص البواقي لنموذج $ARIMA(1,1,0)$ من خلال الارتباط الذاتي والارتباط الذاتي الجزئي، أن أياً من الدالتين لم تتجاوز حدود الثقة البالغة ٩٥٪ مما يشير هذا إلى عدم وجود ارتباط ذاتي كبير أو ارتباط جزئي في بقايا النموذج.

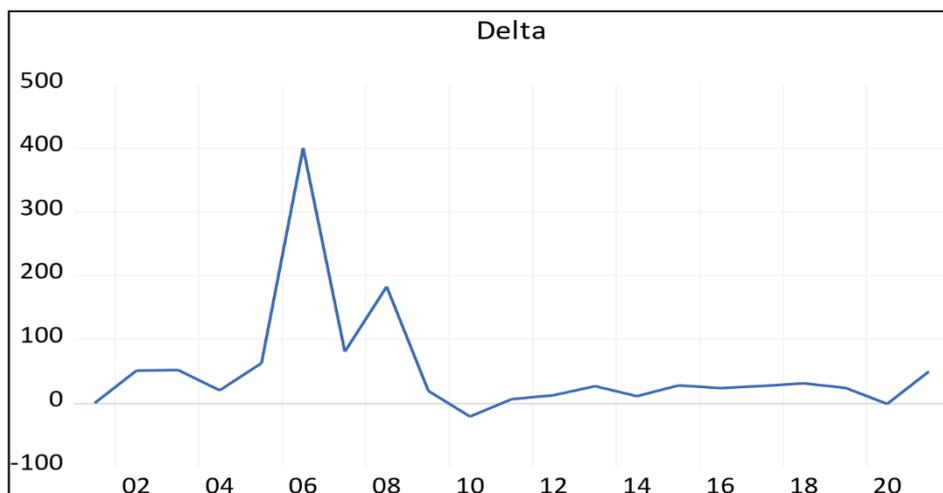
وبناء على ما سبق، يصلح النموذج المقترح للتنبؤ وبالتالي يتم استخدامه للتنبؤ بمعدل الخسارة لشركة المهندس للتأمين قطاع التأمين الهندسي، حيث يتم التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)، والتي يمكن تلخيص نتائجها في الجدول التالي:

جدول (١١) التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)

التنبؤ بمعدل الخسارة	السنة
٧,٨٥	٢٠٢٢
٨,١٦	٢٠٢٣
٨,٤٧	٢٠٢٤
٨,٧٩	٢٠٢٥
٩,١٠	٢٠٢٦

٣. شركة الدلتا للتأمين

يوضح الشكل رقم (٧) التالي السلسلة الزمنية لمعدل الخسارة في شركة مصر للتأمين وذلك للفترة الزمنية موضع الدراسة:



المصدر: مخرجات برنامج EViews

الشكل رقم (٨) السلسلة الزمنية لمعدل الخسارة للتأمين الهندسي في شركة الدلتا

يتضح من الشكل أن السلسلة الزمنية لمعدل الخسارة للفترة محل الدراسة قد تعبر عن عدم الاستقرار، لذلك يجب إجراء اختبار Dickey-Fuller للتأكد من مدى استقرار السلسلة، والذي يتم تلخيص نتائجه في الجدول التالي:

جدول (١٢) نتائج اختبار Dickey-Fuller

Significant level	P-value	t-statistic	
5%	0.0154	-3.602860	قبل الحساب الفروق

عند إجراء اختبار Dickey-Fuller قبل أحساب الفروق، نجد أن قيمة P-value تساوي 0.0154 وهي أقل من مستوى المعنوية (٥٪)، تشير هذه النتيجة إلى وجود أدلة كافية لرفض فرض العدم لوجود جذر الوحدة، مما يدل على الثبات في السلسلة الزمنية الأصلية، وبالتالي لا نحتاج لحساب أي فروق أخرى.

تأتي بعد ذلك مرحلة تحديد دالة الارتباط الذاتي والارتباط الذاتي الجزئي وذلك لتحديد نموذج ARIMA الأكثر ملائمة والتي كانت نتائجها على النحو التالي:

جدول (١٣) الارتباط الذاتي والارتباط الذاتي الجزئي لسلسلة الزمنية لمعدل الخسارة

Date: 04/07/24 Time: 17:30

Sample (adjusted): 2002 2021

Included observations: 20 after adjustments

	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
1			-0.528	-0.528	6.4664	0.011
2			0.197	-0.114	7.4133	0.025
3			-0.091	-0.050	7.6294	0.054
4			-0.061	-0.160	7.7324	0.102
5			-0.006	-0.166	7.7336	0.172
6			0.008	-0.089	7.7354	0.258
7			0.009	-0.041	7.7384	0.356
8			-0.050	-0.121	7.8285	0.450
9			0.026	-0.113	7.8546	0.549
10			0.011	-0.040	7.8604	0.642
11			0.004	-0.018	7.8612	0.726
12			-0.029	-0.087	7.9071	0.792

من خلال تحليل الدالتين الارتباط الذاتي والارتباط الذاتي الجزئي من الجدول السابق، وتطبيق منهجية Box-Jenkins لتحديد نموذج ARIMA الملائم للبيانات، تم تحديد النماذج التالية:

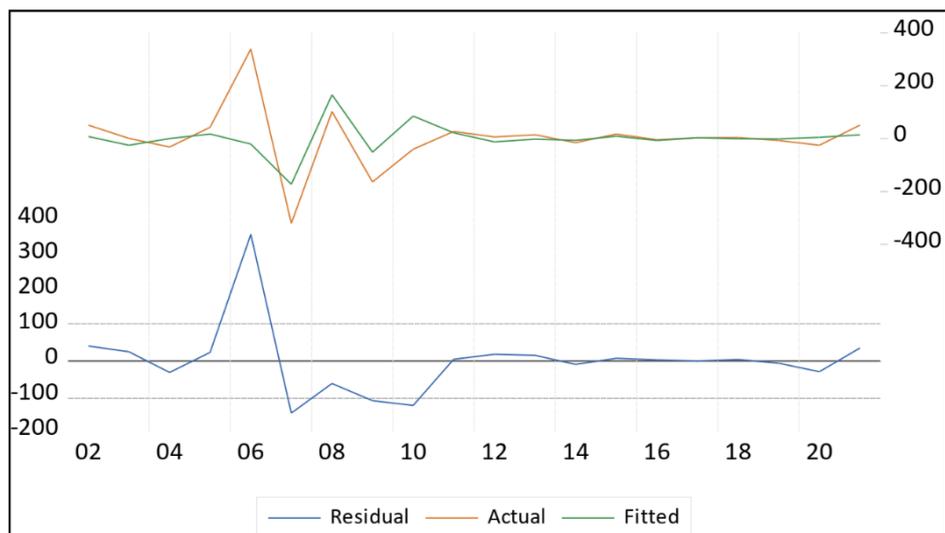
1. $ARIMA(1,1,1)$
2. $ARIMA(1,1,0)$
3. $ARIMA(0,1,1)$

ويلخص الجدول رقم (١٤) التالي مقارنة نماذج ARIMA المقترحة وذلك على النحو التالي:

جدول (١٤) مقارنة نتائج تحديد نماذج ARIMA المقترحة

Std. Error	P-value	t-statistics	Coefficient	النماذج المقترحة
11.25201	0.7617	0.308492	-3.471153	C
0.405597	0.7239	0.359568	0.145840	AR(1)
13644.35	0.9999	-7.33E-05	-1.000000	MA(1)
23.00766	0.9732	0.034040	0.783179	C
0.173284	0.0087	-2.962947	-0.513432	AR(1)
9.455750	0.6954	-0.398273	-3.765974	C
13290.23	0.9999	-7.52E-05	-1.000000	MA(1)

بعد إجراء اختبارات t-test على معاملات النماذج الثلاثة المقترحة، وجد أن معنوية معلمة الانحدار الذاتي في نموذج $ARIMA(1,1,0)$ وعلى العكس من ذلك، اتضح عدم معنوية النماذج الأخرى، وبناء عليه تم اختيار نموذج $ARIMA(1,1,0)$ كأفضل نموذج للتنبؤ من ضمن هذه النماذج، يأتي بعد ذلك خطوة اختبار مدى توافق القيم الفعلية (Actual Values) مع القيم المقدرة (Fitted Values) والبواقي لنموذج ARIMA المقترح، حيث تم التعبير بيانياً عن هذه القيم على النحو التالي:



المصدر: مخرجات برنامج EViews

الشكل رقم (٩) القيم الفعلية والمتوقعة والبواقي لنموذج $ARIMA(1,1,0)$ لمعدل الخسارة

يتضح من الشكل السابق أن النموذج المقترح يصف الظاهرة محل الدراسة بشكل عالي الدقة، حيث يمثل كل من المنحنى الممثل للقيم الفعلية للسلسلة والقيم المقدرة نفس الاتجاه تقريبا، وبينهما فروق غير معنوية ضئيلة، مما يدل على وجود قدرة تنبؤية عالية للنموذج، يأتي بعد ذلك دور الخطوة المتمثلة اختبار مدى استقرار بواقي السلسلة الزمنية وذلك بواسطة فحص دالة الارتباط الذاتي والارتباط الذاتي الجزئي على النحو التالي:

جدول (١٥) فحص استقرار السلسلة الزمنية لبواقي نموذج $ARIMA(1,1,0)$ المقترح

Date: 04/07/24 Time: 17:40
Sample (adjusted): 2002 2021
Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.081	-0.081	0.1511	
		2 -0.092	-0.099	0.3593	0.549
		3 -0.064	-0.082	0.4663	0.792
		4 -0.194	-0.222	1.5010	0.682
		5 -0.047	-0.113	1.5648	0.815
		6 0.016	-0.062	1.5728	0.905
		7 -0.011	-0.079	1.5771	0.954
		8 -0.056	-0.147	1.6940	0.975
		9 0.016	-0.072	1.7040	0.989
		10 0.038	-0.027	1.7689	0.995
		11 -0.007	-0.063	1.7711	0.998
		12 -0.000	-0.072	1.7711	0.999

المصدر: مخرجات برنامج EViews

يتضح من الجدول السابق وبعد فحص البواقي لنموذج $ARIMA(1,1,0)$ من خلال الارتباط الذاتي والارتباط الذاتي الجزئي، أن أياً من الدالتين لم تتجاوز حدود الثقة البالغة ٩٥٪ مما يشير هذا إلى عدم وجود ارتباط ذاتي كبير أو ارتباط جزئي في بقايا النموذج.

وبناء على ما سبق، يصلح النموذج المقترح للتنبؤ وبالتالي يتم استخدامه للتنبؤ بمعدل الخسارة لشركة الدلتا للتأمين قطاع التأمين الهندسي، حيث يتم التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)، والتي يمكن تلخيص نتائجها في الجدول التالي:

جدول (١٦) التنبؤ بمعدل الخسارة للفترة الزمنية (٢٠٢٢-٢٠٢٦)

السنة	معدل الخسائر لشركة الدلتا للتأمين
٢٠٢٢	٤٩,٤٣
٢٠٢٣	٥١,٢١
٢٠٢٤	٥١,٩٩
٢٠٢٥	٥١,٧٧
٢٠٢٦	٥٢,٥٦

القسم الثاني: التنبؤ بمعدل الخسارة باستخدام الشبكات العصبية ANN للشركات الثلاثة.

يتم في هذا الجزء التنبؤ بمعدل الخسارة للشركات الثلاثة وذلك باستخدام الشبكات العصبية الاصطناعية ANN، حيث يتم استخدام معدلات الخسارة للفترة الزمنية محل الدراسة لتدريب نموذج الشبكة العصبية، وبالتالي يتم التعلم من نمط البيانات التاريخية وبالتالي استخدامها في التنبؤ بمعدلات الخسارة المستقبلية، ويتم ذلك من خلال اجراء الخطوات التالية لكل شركة من الثلاث شركات وذلك على النحو التالي:

١. تحضير البيانات: سننظم البيانات لكل شركة، واعداد البيانات للتدريب.
 ٢. تطوير النموذج: سنقوم بإنشاء نموذج شبكة عصبية بسيط لكل شركة، سيكون النموذج بسيطاً نسبياً، نظراً للكمية المحدودة من نقاط البيانات.
 ٣. التدريب: سندرب النموذج على البيانات التاريخية.
 ٤. التنبؤ: بمجرد تدريب النموذج، سنستخدمه للتنبؤ بمعدلات الخسارة للسنوات القادمة.
- تم تقسيم البيانات التاريخية لفترة زمنية (٢٠١٧-٢٠٢١) كمجموعة اختبار وباقي السنوات مجموعة تدريب وبالتالي كانت معدلات الخسارة المنتبأ بها لخمس سنوات على النحو التالي:

جدول (١٧) التنبؤ بمعدل الخسارة للثلاث شركات للفترة الزمنية (٢٠٢٢-٢٠٢٦)

السنة	معدلات الخسارة المتوقعة لشركة مصر للتأمين	معدلات الخسارة المتوقعة لشركة الدلتا للتأمين	معدلات الخسارة المتوقعة لشركة المهندس للتأمين
2022	24.24	47.5	8.11
2023	24.27	45	8.46
2024	24.32	43	8.86
2025	24.36	41.5	9.32
2026	24.4	40	9.76

ويوضح الجدول التالي نتائج التنبؤ باستخدام كلا النموذجين

جدول (١٨) معدلات الخسارة المتنبأ بها بكل من نماذج ANN و Box-Jenkins

السنة	شركة مصر		المهندس		الدلتا	
	ANN	Box-Jenkins	ANN	Box-Jenkins	ANN	Box-Jenkins
2022	24.24	24.20	8.11	7.85	48.5	49.43
2023	24.27	24.23	8.46	8.16	49.43	51.21
2024	24.32	24.26	8.86	8.47	50.26	51.99
2025	24.36	24.28	9.32	8.79	50.89	51.77
2026	24.40	24.30	9.76	9.10	51.25	52.56

حيث أن المعيار الأساسي للحكم على مدى ملائمة النموذج للتنبؤ هي الدقة، وذلك من خلال مقارنة القيم الحقيقية مع القيم المقدرة، فبالتالي يوضح الجدول التالي مقارنة نتائج التنبؤ باستخدام مقياسي الخطأ RMSE و MAPE وذلك للحكم على أي النموذجين أفضل في التنبؤ وفقاً للسلسلة الزمنية المتاحة.

جدول (١٩) قياس الخطأ لكل من ANN و Box-Jenkins

الشركة	النموذج	RMSE	MAPE
شركة مصر للتأمين	Box-Jenkins	0.055	8.5%
	ANN	0.065	10.2%
شركة الدلتا للتأمين	Box-Jenkins	0.045	7.8%
	ANN	0.058	9.5%
شركة المهندس للتأمين	Box-Jenkins	0.060	9.2%
	ANN	0.075	11.3%

يتضح من الجدول أن أخطاء نموذج Box-Jenkins أقل من أخطاء نموذج ANN، مما يدل على أن نموذج Box-Jenkins يوفر تنبؤات أكثر دقة مقارنة بنموذج ANN في هذه الحالة ولهذه النوعية من البيانات ولهذه الفترة الزمنية.

النتائج

١. تأثير طول السلسلة الزمنية على بناء النموذج.
٢. إمكانية تطبيق نموذج Box-Jenkins في التنبؤ بمعدلات خسارة التأمين الهندسي.
٣. إمكانية تطبيق نموذج الشبكات العصبية الصناعية في التنبؤ بمعدلات خسارة التأمين الهندسي.
٤. تتأثر نماذج الشبكات العصبية الاصطناعية بطول السلسلة الزمنية، الذي يؤثر بدوره على درجة التعلم في الشبكة مما يؤدي إلى الوصول لتنبؤات أكثر كفاءة.
٥. مقارنة نتائج التنبؤ للنموذجين عن طريق استخدام نمذجي RMSE و MAPE وجد أن التنبؤات الناتجة عن نموذج Box -Jenkins أدق من تلك الناتجة عن نموذج ANN.

التوصيات

١. ضرورة تطوير نظم وأنواع التغطيات التي يقدمها التأمين الهندسي بشكل يتناسب مع تنوع واختلاف المشروعات الهندسية العملاقة التي يتم تنفيذها داخل جمهورية مصر العربية مؤخراً.
٢. تطوير نماذج الشبكات العصبية ونظم الذكاء الاصطناعي ودمجها مع نماذج أخرى واستخدامها في التنبؤ بعمليات التأمين المختلفة وفي الفروع المختلفة.
٣. ضرورة الدراسة المستمرة للعوامل المؤثرة على مستوى الطلب في التأمين الهندسي.

المراجع

المراجع باللغة العربية

- أبوبكر، عيد أحمد، ومحمود، أسامه حنفي. (٢٠١٤). استخدام الشبكات العصبية الاصطناعية في تقييم الملاءة المالية لشركات التأمين المصرية. مجلة الدراسات المالية والتجارية، كلية التجارة، جامعة بني سويف، العدد الأول.
- الخواجة، حامد عبد القوي محمد. (٢٠١٤). استخدام النموذج البييزي في التنبؤ بمعدلات الخسارة في سوق التأمين السعودي. مجلة البحوث المالية والتجارية، جامعة بورسعيد، كلية التجارة، ٤٤، ٣١٦-٣٣٤.
- الدالي، أمل أحمد حسن شحاته. (٢٠١٥). تقدير هامش ربح الاكتتاب باستخدام نموذج الشبكات العصبية: بالتطبيق على تأمينات الممتلكات والمسئولية بسوق التأمين السعودي. مجلة البحوث التجارية المعاصرة، مج ٢٩، ع ٢٤، ١٣٥-١٧٩.
- 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، ١٢٤، ٩-٤١.
- المبارك، سعيدة خضر أحمد، وأدم، أمين إبراهيم. (٢٠١٦). استخدام نماذج الشبكات العصبية الاصطناعية ونماذج بوكس وجينكنز في التنبؤ بإنتاجية محصول القمح في السودان: دراسة مقارنة (رسالة ماجستير). جامعة أم درمان الإسلامية، أم درمان.
- المعداوي، جيهان مسعد. (٢٠١٨). استخدام نموذج المصادقية الثاني في تسعير التأمين الهندسي. مجلة الدراسات التجارية المعاصرة، ع ٤٤، ٥٢-٦٩.

- خليل، أحمد عبد الرحيم، وفرحات، حمدي فايز، وأبو بكر، صفية أحمد، وعبد الله، هشام عبد المجيد. (٢٠٢٠). التنبؤ بمعدل الخسارة لفرع تأمين الطيران باستخدام الشبكات العصبية الفازية بالتطبيق على شركة مصر للتأمين. مجلة كلية التجارة للبحوث العلمية، كلية التجارة، جامعة أسيوط، ع ٦٨، ٩١-١١٤.
- زايد، محمد عبد اللطيف، حسن، هبة الله عبد الصبور أمين، والأشقر، السيد الشربيني. (٢٠٢٠). استخدام الشبكات العصبية والنماذج المختلطة متعددة المستويات في تقدير الطلب على التأمين بالتطبيق على الدول العربية. مجلة البحوث المالية والتجارية، ع ٣٤، ٩١٢-٩٥١.
- زرمان، كريم. (٢٠١٤). نحو تقدير أمثل لمعدلات الخسارة في شركات التأمين. أبحاث اقتصادية وإدارية، ع ١٦، ١٨١-٢٠٢.
- سمري، حاتم السيد، وعلي، إيمان عماد عبد العليم. (٢٠٢٢). استخدام نموذج الشبكات العصبية للتنبؤ بمعدل الاحتفاظ في التأمينات العامة. مجلة البحوث التجارية، مج ٤٤، ع ١٤، ٥١١-٥٦٢.
- طاقية، البيومي عوض عوض، والوصيفي، الشيماء إبراهيم السيد. (٢٠١٢). التنبؤ باستخدام الدمج بين الشبكات العصبية الاصطناعية ونماذج بوكس وجينكنز: دراسة تطبيقية. المجلة المصرية للدراسات التجارية، مج ٣٦، ع ٢٤، ٥٤٨-٥٢٧.
- عبد العاطي، فاطمة على محمد، عبد المعطي، سعاد محمد سالم، و البلقيني، محمد توفيق إسماعيل. (٢٠١٨). مقارنة للتنبؤ بالسلاسل الزمنية متعددة المتغيرات باستخدام الشبكات العصبية الاصطناعية ونموذج دالة التحويل: دراسة تطبيقية. مجلة الدراسات والبحوث التجارية، س ٣٨، ع ٣٤، ٧٦١-٧٩٠.
- عوجة، أماني محمد عبد المجيد، وعبد الحميد، نها عبد اللطيف. (٢٠١٧). النمذجة الاكتوارية لمطالبات التأمين الهندسي باستخدام بعض التوزيعات الاحتمالية ذات الذي الثقيل. المجلة المصرية للدراسات التجارية، مج ٤١، ع ١٤، ٧٧-١٠٣.
- علي، أحمد عبدالوهاب أحمد. (٢٠٢٢). التنبؤ بمعدل الاحتفاظ الأمثل لأقساط التأمين المكتسبة باستخدام نموذج إحصائي مدمج: دراسة تطبيقية على فروع التأمينات العامة بسوق التأمين المصري. مجلة الدراسات المالية والتجارية، ع ٣٤، ١٠٧١-١١٢١.
- محمد، أحمد محمد فرحان، وأبو زيد، محمد أحمد محمود. (٢٠٢١). استخدام نماذج ARIMA في تقدير هامش ربح الاكتتاب بشركات التأمين بالتطبيق على قطاع تأمينات الممتلكات والمسؤولية بالسوق المصرية. مجلة البحوث المالية والتجارية، ع ٢٤، ١٠٠-١٥٣.
- هاشم، محمد محمود. (٢٠٢٠). استخدام الشبكات العصبية الاصطناعية الجينية الوراثية في تقدير هامش ربح الاكتتاب في شركات تأمينات الممتلكات والمسؤولية في السوق المصري" بالتطبيق على أجسام السفن". المجلة العلمية للدراسات التجارية والبيئية، مج ١١، ع ٣٤، ٦٤-١٦٥.

المراجع باللغة الإنجليزية

- Abhishek S., Mishra G. C. (2015). Application of Box-Jenkins method and artificial neural network procedure for time series forecasting of prices. *statistics in transition, new series*, Spring, Volume 16, No. 1, 83-96.
- Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*, Volume 2014. Hindawi Publishing Corporation.
- Aljandali, A., & Tatahi, M. (2018). Economic and financial modelling with EViews: A guide for students and professionals. *Springer International Publishing AG, part of Springer Nature*.
- Alzaidi, A. A. (2018). Impact of Artificial Intelligence on Performance of Banking Industry in the Middle East. *International Journal of Computer Science and Network Security*, Volume 18, No. 10
- Dreyfus, G.(2004). Neural Networks: Methodology and Applications. *ESPCI, Laboratoire d'Électronique*.
- Kobiela, D., Kreftaa, D., Krol', W., & Weichbrothb, P. (2022). ARIMA vs LSTM on NASDAQ stock exchange data. *Procedia Computer Science*, 207,3830–3839.
- V. Selvakumar, Dipak Kumar Satpathi, P. T. V. Praveen Kumar, V. V. Haragopal (2021). Predictive Modeling of Insurance Claims using Machine Learning Approach for Different Types of Motor Vehicles. *Universal Journal of Accounting and Finance*, 9(1), 1 - 14.

Abstract:

The importance of the loss ratio in insurance companies is that it is connected to many key functions within the company, such as underwriting, pricing, settlement, investment, and reinsurance. It also helps insurance companies formulate insurance policies correctly, aiding them in achieving their objectives. The development in construction projects and investments, especially in new cities and road construction, has made engineering insurance more important recently. Since the loss ratio is the foundation for many decisions made by insurance firms, including reinsurance, these projects rely on engineering insurance policies to cover all risks faced by contractors and construction during the implementation period. This calls for the development of an accurate model to forecast the loss ratio. Thus, the research problem is to forecast the loss ratio for three insurance companies in the engineering insurance branch using two methods. Box-Jenkins model as one of the traditional models, and another modern method represented by Artificial Neural Network (ANN) models, which have shown good statistical results.

Key words: engineering insurance, loss rate, Box-Jenkins, Artificial Neural Networks.