



مجلة البحوث المالية والتجارية

المجلد (26) – العدد الثاني – أبريل 2024



التنبؤ بمخصص التعويضات تحت التسوية باستخدام شبكات الانحدار العصبية
المعممة (GRNN) في التأمين البحري (فرع النقل البحري)

Predicting Outstanding Claims Reserves Using Generalized Regression Neural Networks (GRNN) in Marine Insurance (Marine Cargo Branch)"

إعداد

الباحثة/ سماح سيد بيومي خليل

مدرس بكلية الاقتصاد والإدارة – جامعه 6 أكتوبر

ahmed.kasper2022@gmail.com

2024-11-14	تاريخ الإرسال
2024-12-29	تاريخ القبول
رابط المجلة: https://jst.journals.ekb.eg/	

ملخص البحث:

يعد مخصص التعويضات تحت التسوية من أهم المخصصات لشركات التأمين، حيث يرتبط ارتباطاً وثيقاً بسياسات الاكتتاب، والتسعير، وتسوية المطالبات، بالإضافة إلى تأثيره الكبير على عمليات الاستثمار وإعادة التأمين. يهدف هذا البحث إلى تطبيق نموذج شبكات الانحدار العصبية المعممة (GRNN) لتقدير مخصص التعويضات تحت التسوية في فرعي التأمين البحري على البضائع، باستخدام بيانات شركة مصر لتأمينات الممتلكات والمسؤوليات خلال الفترة من (2007/2008) إلى (2023/2022). وقد أظهرت نتائج الدراسة أن النموذج حقق دقة عالية في التنبؤ بمخصص التعويضات تحت التسوية، حيث أظهرت مقاييس الأداء نتائج ممتازة، فقد بلغ MSE (متوسط مربع الخطأ) 10,755,960، مما يشير إلى دقة النموذج في التنبؤ حيث يعكس هذا المقياس متوسط مربعات الفروق بين القيم الفعلية والمتنبأ بها. كما كان RMSE (جذر متوسط مربع الخطأ) 3,279.63، وهو مقياس يعكس حجم الخطأ بوحدات البيانات نفسها، ويعد مؤشراً على دقة النموذج في التنبؤ. بالإضافة إلى ذلك، أظهرت الدراسة أن MAPE (النسبة المئوية للخطأ المطلق المتوسط) بلغ 0.76%، مما يشير إلى أن نسبة الخطأ في التنبؤ كانت منخفضة جداً، وهو ما يعكس الأداء الممتاز للنموذج. أما R^2 (معامل التحديد) فقد بلغ 0.9958، مما يشير أن النموذج الجديد قادر على تفسير 99.58% من التباين في القيم الفعلية، مما يجعله أكثر ملاءمة وفعالية للتنبؤ بمخصصات التعويضات. وعليه، أوصت الدراسة بضرورة الاعتماد على نموذج شبكات الانحدار العصبية المعممة لما له من مزايا في سرعة التدريب، وبساطته، ودقته في تقدير مخصص التعويضات تحت التسوية، مما يساهم في تحسين استراتيجيات شركات التأمين في إدارة احتياطياتها.

الكلمات الافتتاحية: شبكات الانحدار العصبية المعممة، مخصص التعويضات تحت التسوية، التأمين البحري فرع النقل البحري.



Abstract:

The provision for outstanding claims is one of the most important provisions for insurance companies, as it is closely related to underwriting, pricing, and claims settlement policies, in addition to its significant impact on investment and reinsurance operations. This research aims to apply the Generalized Regression Neural Networks (GRNN) model to estimate the provision for outstanding claims in the marine cargo insurance branches, using data from Misr Property and Liability Insurance Company during the period from (2008/2007) to (2022/2023). The results of the study showed that the model achieved high accuracy in predicting the provision for outstanding claims, as the performance metrics showed excellent results, as the MSE (Mean Square Error) reached 10,755,960, indicating the accuracy of the model in prediction, as this metric reflects the average square of the differences between the actual and predicted values. The RMSE (Root Mean Square Error) was 3,279.63, which is a metric that reflects the size of the error in the same data units, and is an indicator of the model's accuracy in prediction. In addition, the study showed that the MAPE (mean absolute percentage error) was 0.76%, indicating that the prediction error was very low, reflecting the excellent performance of the model. The R2 (coefficient of determination) was 0.9958, indicating that the new model is able to explain 99.58% of the variance in actual values, making it more suitable and effective for predicting compensation provisions. Accordingly, the study recommended the need to rely on the generalized neural regression network model due to its advantages in training speed, simplicity, and accuracy in estimating the compensation provision under settlement, which contributes to improving insurance companies' strategies in managing their reserves.

Keywords: Generalized Regression Neural Networks, Outstanding Claims Reserves, Marine insurance transportation branch

أولاً- الدراسات السابقة:

1-الدراسات العربية:

▪ دراسة للباحثين خلف سيد محمد، أسماء وعلي شعيب، نادية، واخرون، (2023)، بعنوان " التنبؤ بمخصص التعويضات تحت التسوية بفرع تأمين البترول باستخدام نموذج الشبكات العصبية الموائم بالفازية"، ولقد هدفت الدراسة الي استخدام نموذج الشبكات العصبية الموائم بالفازية في التنبؤ الدقيق بقيمة مخصص التعويضات تحت التسوية لفرع تأمين البترول وتقييم النتائج من خلال مقاييس دقة التنبؤ، ولقد توصلت الدراسة الي ان النموذج يتمتع بدقة عالية في التنبؤ، وذلك وفقا لمقاييس دقة التنبؤ (RMSE، MAPE) في تقدير مخصص التعويضات تحت التسوية، ولقد اوصت الدراسة باستخدام نموذج الشبكات العصبية الموائم بالفازية في تقدير مخصص التعويضات تحت التسوية وأيضا في الاككتاب والتسعير وتقدير الخسائر المستقبلية نظرا للنتائج عالية الدقة التي يقدمها النموذج

التعليق: تسم الدراسة السابقة بالتنشابه مع الدراسة الحالية في استخدام أحد نماذج الشبكات العصبية للتنبؤ بمخصص التعويضات تحت التسوية، إلا أنها تختلف في استخدام "النموذج الموائم بالفازية" بدلاً من "شبكات الانحدار العصبية المعممة (GRNN)" التي تم استخدامها في الدراسة الحالية. بالإضافة إلى ذلك، تم تطبيق الدراسة السابقة على فرع تأمين البترول، في حين أن الدراسة الحالية تركز على فرع التأمين البحري (النقل البحري)، مما يعكس الاختلاف في سياقات التطبيق بين الباحثين.

▪ دراسة للباحث هاشم، محمد محمود، (2020)، بعنوان " استخدام الشبكات العصبية الاصطناعية الجينية الوراثية في تقدير هامش ربح الاككتاب في شركات تأمينات الممتلكات والمسئولية في السوق المصري بالتطبيق على تأمين أجسام السفن"، ولقد هدفت الدراسة الي تحليل العوامل المؤثرة على هامش ربح الاككتاب في فرع تأمين أجسام السفن وكذلك تقدير هامش ربح الاككتاب لهذا الفرع وذلك باستخدام نموذجي الشبكات العصبية الاصطناعية (ANNS) والخوارزميات الجينية الوراثية، ولقد توصلت الدراسة الي أن استخدام نموذج الخوارزميات الجينية الوراثية اكثر دقة وملائمة بالنسبة



للقطاع الخاص في تقدير هامش ربح الاككتاب بينما نموذج الشبكات العصبية الاصطناعية ANN's اكثر دقة في تقدير هامش ربح الاككتاب لفرع تأمين أجسام السفن بالنسبة للقطاع العام، ولقد اوصت الدراسة باستخدام نموذج الخوارزميات الجينية الوراثية بصفة عامة للإجمالي السوق ككل نظرًا لجودته وملاءمته في التقدير. التعليق: تتسم الدراسة السابقة بالتشابه مع الدراسة الحالية في استخدام تقنيات متقدمة مثل الشبكات العصبية الاصطناعية، لكن الاختلاف يكمن في أن الدراسة السابقة ركزت على استخدام الخوارزميات الجينية الوراثية كأداة رئيسية، في حين أن الدراسة الحالية تعتمد على شبكات الانحدار العصبية المعممة (GRNN). بالإضافة إلى ذلك، تم تطبيق الدراسة السابقة في سياق تأمين أجسام السفن بشكل عام، بينما تركز الدراسة الحالية على فرع التأمين البحري للنقل البحري، مما يعكس الاختلاف في نطاق التطبيق بين الباحثين

▪ دراسة للباحث محمد محمد محمد عطا ، (2007)، بعنوان " توصيف نموذج كمي لتقدير مخصص التعويضات تحت التسوية بالتطبيق على قطاع التأمينات العامة في سوق التأمين المصري"، ولقد هدفت الدراسة الى استخدام نموذج جاما في تقدير مخصص التعويضات تحت التسوية ولقد توصلت الدراسة الي ان نموذج جاما يتمتع بدقة أكبر في حساب المخصصات، ولقد اوصت الدراسة بان على شركات التأمين استخدام النماذج الكمية لحساب المخصص حتى تستطيع الشركة الوفاء بالتزاماتها. التعليق: تتسم هذه الدراسة بتشابه مع الدراسة الحالية في الإشارة إلى أن الطرق التقليدية المستخدمة في حساب مخصص التعويضات تحت التسوية قد لا تكون دقيقة بما فيه الكفاية. ومع ذلك، توجد اختلافات جوهرية بين الدراستين في الأساليب المستخدمة؛ إذ اعتمدت الدراسة الحالية على شبكات الانحدار العصبية المعممة (GRNN) في التنبؤ بمخصص التعويضات تحت التسوية، بينما اعتمدت الدراسة السابقة على نموذج جاما في تقدير المخصصات. كما أن الدراسة الحالية تستهدف فرع التأمين البحري، في حين أن الدراسة السابقة تناولت التأمينات العامة في سوق التأمين المصري.

▪ دراسة للباحث الخواجة، حامد عبد القوي محمد (2014)، بعنوان "نموذج كمي لتقدير مخصص التعويضات تحت التسوية بسوق التأمين السعودي"، ولقد هدفت الدراسة الي إلى استخدام نماذج السلاسل الزمنية والانحدار المتعدد للتنبؤ بمخصص التعويضات تحت التسوية في سوق التأمين التعاوني السعودي. توصلت الدراسة إلى أن استخدام أسلوب السلاسل الزمنية كان أكثر دقة في التنبؤ من أسلوب الانحدار المتعدد، وذلك بناءً على تقارب القيم الفعلية مع القيم المتنبأ بها. وأوصت الدراسة باستخدام أسلوب السلاسل الزمنية في التنبؤ بالمخصصات، لضمان حماية حقوق والتزامات حملة الوثائق في شركات التأمين السعودية.

التعليق: تتفق الدراسة الحالية مع الدراسة السابقة في أهمية التنبؤ بمخصص التعويضات تحت التسوية لضمان دقة التقديرات وحماية حقوق حملة الوثائق. ومع ذلك، تختلف الدراسات في الأساليب المستخدمة؛ حيث اعتمدت الدراسة الحالية على الشبكات العصبية المعممة للتنبؤ بمخصص التعويضات، في حين اعتمدت الدراسة السابقة على نماذج السلاسل الزمنية والانحدار المتعدد. بالإضافة إلى ذلك، تم تطبيق الدراسة السابقة في سوق التأمين السعودي، في حين أن الدراسة الحالية تركز على سوق التأمين المصري، مما يبرز الفروق في السياقين الجغرافي والتنظيمي بين الدراستين.

▪ دراسة للباحثة البنداري، شيماء جمال جودة محمد، (2023)، بعنوان " نموذج إحصائي مقترح للتسعير في التأمين البحري فرع أجسام السفن في السوق المصري"، ولقد هدفت الدراسة الي تطوير نموذج إحصائي باستخدام نموذج الانحدار الخطي المتعدد للتسعير في مجال التأمين البحري، وبالتحديد فرع أجسام السفن في السوق المصري، مع الاعتماد على معدل الخسارة الفني. تم تطبيق النموذج على بعض الشركات العاملة في السوق المصري. توصلت الدراسة إلى وجود قصور في السياسة المتبعة للتسعير في الشركات محل الدراسة، وأوصت باستخدام نموذج الانحدار الخطي المتعدد لتقدير القسط الصافي المتوقع، بالإضافة إلى ضرورة تبني الأساليب الإحصائية في عملية التسعير.



التعليق: تختلف الدراسة السابقة عن الدراسة الحالية في أن الدراسة السابقة اعتمدت على الأساليب الإحصائية التقليدية مثل الانحدار الخطي المتعدد للتسعير، بينما اعتمدت الدراسة الحالية على شبكات الانحدار العصبية المعممة في التنبؤ مخصص التعويضات تحت التسوية. كما أن الدراسة السابقة تناولت التسعير وتقدير القسط الصافي المتوقع، بينما تركز الدراسة الحالية على تقدير مخصص التعويضات تحت التسوية في التأمين البحري.

▪ دراسة للباحث محمد، مروان جابر احمد، (2020)، بعنوان " نموذج انحداري موائم بالشبكات العصبية لتقدير معدل السعر للتأمينات العامة"، ولقد هدفت الدراسة استخدام نموذج شبكات الانحدار العصبية المعممة (GRNN) في تسعير مخاطر قروض الائتمان المصرفي، وذلك بالتطبيق على شركتي مصر للتأمين وشركة ضمان مخاطر الائتمان. توصلت الدراسة إلى أن السعر الحالي المطبق مغالى فيه مقارنة مع السعر المقترح وفقاً لنتائج الدراسة. أوصت الدراسة بضرورة تعديل أسعار تأمين الائتمان الحالية، التي تم اعتبارها مبالغاً فيها، واستخدام الأسعار المقترحة بناءً على نتائج الدراسة. كما أكدت الدراسة على ضرورة مراجعة الإحصائيات المستخدمة في حساب أسعار تأمين الائتمان الذاتي والتجاري بشكل دوري لضمان دقة التسعير.

التعليق: تتشابه الدراسة السابقة مع الدراسة الحالية في استخدام نموذج شبكات الانحدار العصبية المعممة (GRNN) كأداة إحصائية للتنبؤ. ومع ذلك، تختلف الدراسة السابقة عن الدراسة الحالية في أن الدراسة السابقة استخدمت النموذج في تسعير مخاطر قروض الائتمان المصرفي، بينما تستخدم الدراسة الحالية النموذج في مجال التأمين البحري فرع النقل البحري، مما يعكس اختلافاً في مجال التطبيق على الرغم من استخدام النموذج نفسه.

2-الدراسات الاجنبية:

▪ دراسة للباحثين Liviana Picech، Patrizia Gigante واخرون (2013)، بعنوان

"Claims reserving in the hierarchical generalized linear model framework "

هدفت الدراسة إلى تقديم إطار عملي لشركات التأمين لتقدير مخصص التعويضات تحت التسوية باستخدام النموذج الخطي المعمم الهرمي (HGLM). كما سعت إلى تقديم حلول للتعامل مع الهياكل المعقدة والمتداخلة في البيانات، مثل اختلاف المنتجات أو الخدمات التي تقدمها شركة التأمين أو فترات بوليصة التأمين. توصلت الدراسة إلى أن استخدام النماذج الخطية العامة الهرمية يوفر إطارًا مرناً ودقيقاً لتوقع مخصص التعويضات، حيث تأخذ هذه النماذج في اعتبارها العوامل العشوائية التي قد تؤثر على البيانات، مما يحسن دقة التنبؤات المتعلقة باحتياجات المطالبات مقارنة بالنماذج التقليدية. أوصت الدراسة بالاعتماد على النماذج الخطية العامة الهرمية نظرًا لقدرتها على التعامل مع البيانات المعقدة التي تتضمن تأثيرات عشوائية وطبقات متعددة، مما يؤدي إلى تحسين دقة التوقعات وتقليل عدم اليقين في تقدير الاحتياطيات.

التعليق: تتشابه الدراسة السابقة مع الدراسة الحالية في أهمية التنبؤ بمخصص التعويضات تحت التسوية. ومع ذلك، تختلف الدراسة السابقة عن الدراسة الحالية في استخدام النماذج الخطية العامة الهرمية كأداة إحصائية، بينما اعتمدت الدراسة الحالية على استخدام شبكات الانحدار العصبية المعممة. كما أن البحث السابق تم تطبيقه على التأمينات العامة بينما تم تطبيق البحث الحالي على التأمين البحري فرع النقل البحري.

▪ دراسة للبحثيين Aysen Apaydin و Furkan Baser (2009)، بعنوان

"Hybrid fuzzy least-squares regression analysis in claims reserving with geometric separation method".

ولقد هدفت الدراسة حسين عملية تقدير مخصص التعويضات تحت التسوية باستخدام منهجية هجينة تعتمد باستخدام تقنيات التحليل الضبابي (fuzzy analysis) ومنهجية المربعات الصغرى (least-squares regression). حيث ان هذه المنهجية توفر طريقة أكثر دقة ومرونة للتعامل مع عدم اليقين والتقلبات الموجودة في البيانات المتعلقة بالمطالبات. ، ولقد توصلت الدراسة الي استخدام منهجية هجينة تعتمد على التحليل الضبابي والانحدار المربعات الصغرى، يؤدي إلى تحسين دقة تقديرات مخصص التعويضات في التأمين مما يعزز من دقة إدارة المخاطر المالية لشركات التأمين، ولقد اوصت الدراسة باستخدام تقنيات التحليل الضبابي في تقدير



المطالبات، حيث توفر هذه التقنيات طريقة فعالة للتعامل مع عدم اليقين في البيانات، مما يؤدي إلى تحسين دقة التوقعات.

التعليق: تتشابه الدراسة السابقة مع الدراسة الحالية في أهمية التنبؤ بمخصص التعويضات تحت التسوية ولكن اختلفت عنها في استخدام منهجية هجينة تعتمد على التحليل الضبابي والانحدار المربعات الصغرى عوضاً عن شبكات الانحدار العصبية المعممة.

▪ دراسة للباحث Mohamed Ahmed Maait (2023)، بعنوان "

Estimating Claims Reserves in Insurance Industries Evidence from the Egyptian Market"

ولقد هدفت الدراسة الي تقدير المخصص الخاص بالمطالبات التي حدثت بالفعل ولكن لم يتم الإبلاغ عنها بعد لشركة التأمين (IBNR) باستخدام طريقة السلم المتسلسل (Chain Ladder Method) مع تحليل طرق مختلفة لحساب عوامل التطوير من سنة لأخرى بعد وقوع الحادث، ولقد توصلت الدراسة الي إلى أنه لا يوجد اختلاف كبير في دقة تقدير الاحتماليات عندما يتم استخدام طرق مختلفة لحساب عوامل التطوير. هذا يشير إلى إمكانية الاعتماد على أساليب متعددة دون التأثير الكبير على نتائج التقديرات، ولقد اوصت الدراسة إلى أنه لا يوجد اختلاف كبير في دقة تقدير المخصصات عندما يتم استخدام طرق مختلفة لحساب عوامل التطوير. هذا يشير إلى إمكانية الاعتماد على أساليب متعددة دون التأثير الكبير على نتائج التقديرات.

التعليق: تتشابه الدراسة السابقة مع الدراسة الحالية في أهمية التنبؤ بمخصص التعويضات تحت التسوية ولكن اختلفت عنها في استخدام السلم المتسلسل (Chain Ladder Method) كأسلوب احصائي للتنبؤ بمخصص التعويضات تحت التسوية عوضاً عن شبكات الانحدار العصبية المعممة (GRNN).

▪ دراسة للباحثين Atta، Mohamed، Youssef، وRehab، (2024)، وآخرون،

بعنوان "

A Comparison between Prediction Methods of Incurred but Not Paid "IBNP" Reserve: A Theoretical and Applied Study."

هدفت الدراسة إلى مقارنة طرق التنبؤ بمخصصات المطالبات التي تم الإبلاغ عنها ولكن لم يتم تسويتها (IBNP). تضمنت الدراسة استعراضاً للطرق المختلفة المستخدمة في تقدير احتياطات IBNP وتحليل فعاليتها في السياقات المختلفة. تركزت هذه الطرق على التنبؤ بالمطالبات المستقبلية بناءً على البيانات التاريخية والتوجهات الحالية. توصلت الدراسة إلى أن اختيار الطريقة المناسبة لتقدير احتياطات IBNP يمكن أن يؤثر بشكل كبير على التوقعات المالية لشركات التأمين، مما يتطلب تقييماً دقيقاً لكل طريقة وفقاً للسياق المحدد. كما أوصت الدراسة بضرورة استفادة شركات التأمين من الأساليب الإحصائية والتطور التكنولوجي في الأساليب الحديثة للتنبؤ باحتياطي IBNP بدلاً من الاعتماد على طريقة سلم السلسلة التي تستخدم على نطاق واسع في تقدير المخصص. التعليق: تختلف الدراسة السابقة مع الدراسة الحالية في طريقة الأسلوب الإحصائي المستخدم. حيث استخدمت الدراسة السابقة مقارنة بين الأساليب الإحصائية المختلفة مثل نموذج ARIMA ونموذج MLP-ANN، بينما تركزت الدراسة الحالية على استخدام شبكات الانحدار العصبية المعممة. كما أن الدراسة السابقة اهتمت بمخصصات المطالبات التي تم الإبلاغ عنها ولكن لم يتم تسويتها فقط (IBNP)، بينما تركزت الدراسة الحالية على التنبؤ بمخصصات التعويضات تحت التسوية بشكل عام.

▪ دراسة للباحثة Amanda، Custódio Tavares، (2023)، بعنوان "

A Machine Learning Approach for Predicting Claims Reserving"

ولقد هدفت الدراسة إلى استخدام أحد تقنيات الذكاء الاصطناعي وهو تعلم الآلة لتحسين التنبؤ بمخصص التعويضات في شركات التأمين لتقديم نموذج دقيق وقوي يمكنه التعامل مع كميات كبيرة من البيانات المعقدة، ولقد توصلت الدراسة إلى أن تقنيات تعلم الآلة، وخاصةً الشبكات العصبية



العميقة (Deep Neural Networks)، توفر دقة أكبر ومرونة أعلى في تقدير احتياطات المطالبات مقارنة بالأساليب التقليدية مثل طريقة السلم المتسلسل (Chain Ladder)، ولقد أوصت ان علي شركات التأمين ان تقوم بدمج تقنيات تعلم الآلة في أنظمتها لتقدير احتياطات المطالبات، حيث أظهرت هذه التقنيات فعالية أكبر في التعامل مع البيانات المعقدة مقارنة بالأساليب التقليدية.

التعليق: تشابهت الدراسة السابقة في أهمية التنبؤ بمخصص التعويضات تحت التسوية ولكن اختلفت في استخدام الشبكات العصبية العميقة في التنبؤ بمخصص التعويضات ولكن اختلفت في عوضاً عن شبكات الانحدار العصبية المعممة.

▪ دراسة للباحثين Novita، Ria، Purwono، Yogo، (2021)، بعنوان "

Implementation of Gaussian Process Regression in Estimating Reserve for Motor Vehicle Insurance Claims"

ولقد هدفت الدراسة الي حساب مخصصات التعويضات تحت التسوية باستخدام بيانات التأمين على السيارات التاريخية الخاصة بشركة PT XYZ، وذلك من خلال أسلوب الانحدار المبني على العمليات الغاوسية (Gaussian Process Regression)، ومقارنته مع أسلوب "Chain Ladder" الشائع في تقدير المخصصات. توصلت الدراسة إلى أن أسلوب الانحدار المبني على العمليات الغاوسية أظهر مرونة عالية وإمكانية تطبيق دون الحاجة لتعديلات كبيرة، وكان أكثر دقة من أسلوب "Chain Ladder". وأوصت الدراسة بإعطاء الأولوية لأسلوب الانحدار المبني على العمليات الغاوسية كخيار فعال في تقدير مخصصات التعويضات.

التعليق: تشابهت الدراسة السابقة مع الدراسة الحالية في أهمية التنبؤ بمخصص التعويضات تحت التسوية، إلا أنها اختلفت في الأسلوب الإحصائي المستخدم؛ حيث اعتمدت على الانحدار المبني على العمليات الغاوسية بدلاً من شبكات الانحدار العصبية المعممة (GRNN) المستخدمة في الدراسة الحالية. كما أن التطبيق تم على فرع تأمين السيارات، بينما ركزت الدراسة الحالية على التأمين على النقل البحري.

الفجوة البحثية: من خلال استعراض الدراسات السابقة، يتضح أن الباحثين اهتموا بتقدير مخصص التعويضات تحت التسوية باستخدام مجموعة من الأساليب الكمية المختلفة، بما في ذلك الشبكات العصبية الاصطناعية. ومع ذلك، لم تتناول الدراسات استخدام شبكات الانحدار العصبية المعممة (GRNN) في التنبؤ بالمخصصات، على الرغم مما تتمتع به هذه الشبكات من مميزات عديدة، أبرزها الدقة العالية في التنبؤ، وسهولة الاستخدام، وقدرتها على التعميم. هذه الخصائص تجعل شبكات الانحدار العصبية المعممة أداة فعالة تصلح للتنبؤ بالمخصصات في مختلف مجالات التأمين.

ثانياً- مشكلة الدراسة:

تواجه شركات التأمين تحدياً كبيراً في تقدير مخصص التعويضات تحت التسوية باستخدام الطرق التقليدية، حيث تكون هذه التقديرات في كثير من الأحيان غير كافية لتغطية التعويضات الفعلية. يؤدي هذا النقص في الدقة إلى مواجهة الشركات لمخاطر مالية غير متوقعة قد تؤثر على استقرارها المالي. من هنا، تبرز الحاجة إلى استخدام نماذج أكثر دقة وواقعية لتقدير مخصص التعويضات تحت التسوية. بناءً على ذلك، سيتم اللجوء إلى استخدام الشبكات العصبية المعممة (GRNN)، لتقديم تقديرات أكثر دقة وتعكس بشكل أفضل المطالبات الفعلية، مما يساهم في تحسين دقة التقديرات وحماية الشركات من المخاطر المالية المحتملة.

ثالثاً- الهدف من الدراسة:

تهدف هذه الدراسة إلى تحقيق عدة أهداف رئيسية من خلال استخدام الشبكات العصبية المعممة (GRNN) لتقدير مخصص التعويضات تحت التسوية في مجال التأمين البحري، وتشمل هذه الأهداف:

1- تطبيق تقنية GRNN بفاعلية: استغلال إمكانيات الشبكات العصبية المعممة (GRNN)

لتقدير مخصصات التعويضات بشكل دقيق وفعال في قطاع التأمين البحري، مما يعزز قدرة شركات التأمين على إدارة المخاطر المرتبطة بالتأمين على السفن والشحن.



2- تقديم تقديرات موثوقة للمخصصات: تطوير نموذج يتيح تقدير مخصصات التعويضات تحت التسوية في التأمين البحري بشكل موثوق، مما يساهم في تعزيز استقرار الشركات المالية وتمكينها من تلبية التزاماتها تجاه العملاء بفعالية.

3- تقديم أدوات عملية: توفير أداة تحليلية يمكن أن تستخدمها شركات التأمين البحري في قراراتها الاستراتيجية بشأن تخصيص الموارد المالية اللازمة لتغطية المطالبات المرتبطة بالحوادث البحرية.

4- الإسهام في تطوير المعرفة: تعزيز الفهم الأكاديمي لتطبيقات التعلم الآلي في صناعة التأمين البحري، مما يساهم في تحسين الابتكار والبحث في هذا المجال.

5- تحسين استراتيجيات إدارة المخصصات البحرية: تقديم رؤى عميقة تساعد شركات التأمين في تحسين استراتيجياتها لإدارة المخصصات المالية المرتبطة بالمطالبات البحرية، مما يعزز قدرتها على التكيف مع التغيرات في السوق، مثل تقلبات أسعار الشحن والحوادث البحرية والاضطراب الجيوسياسية.

رابعاً- أهمية الدراسة:

تعتبر دراسة التنبؤ بمخصص التعويضات تحت التسوية باستخدام الشبكات العصبية المعممة (GRNN) أمراً بالغ الأهمية في مجال التأمين البحري، نظراً للتحديات المتزايدة التي تواجهها الشركات في إدارة المخاطر المالية. يساهم هذا البحث في تحسين استراتيجيات تقدير المخصصات من خلال تقديم نموذج متطور يعتمد على تقنيات الذكاء الاصطناعي، مما يعزز دقة التنبؤات ويساعد الشركات على اتخاذ قرارات مستنيرة من خلال:

1. تحسين دقة التقديرات: يوفر استخدام الشبكات العصبية المعممة (GRNN) دقة أكبر في تقدير مخصصات التعويضات تحت التسوية في التأمين البحري مقارنة بالطرق التقليدية، مما يمكن الشركات من تخصيص الموارد المالية بدقة أعلى لتغطية المطالبات المستقبلية بدقة أعلى.

2. تخفيف المخاطر المالية: من خلال التنبؤ الدقيق بمخصصات التعويضات، يمكن لشركات التأمين تقليل خطر نقص الاحتياطيات، مما يعزز قدرتها على الوفاء بالتزاماتها تجاه العملاء، خاصة في حالات الطوارئ والحوادث البحرية غير المتوقعة.
3. دعم اتخاذ القرار: وفر البحث إطارًا منهجيًا لتحسين استراتيجيات إدارة المخاطر في قطاع التأمين البحري، مما يؤدي إلى تحسين الأداء المالي للشركة وزيادة قدرتها التنافسية.
4. تلبية احتياجات السوق المتغيرة: مع التغيرات المستمرة في سوق التأمين البحري، يوفر هذا البحث أداة مرنة تتكيف مع البيانات الجديدة، مما يساعد الشركات على الاستجابة بشكل أفضل للتغيرات الاقتصادية والاجتماعية التي تؤثر دقة وصحة التنبؤ بمخصص التعويضات.
5. الإسهام في الأدبيات العلمية: يعزز هذا البحث من فهم العلاقة بين استخدام تقنيات الشبكات العصبية الاصطناعية في صناعة التأمين البحري، ويضيف إلى الأدبيات الحالية من خلال تقديم بيانات ونتائج تحليلية تدعم تطبيقات GRNN في هذا المجال.

خامسًا-منهج الدراسة:

1. الأسلوب النظري: يعتمد هذا الأسلوب على الاستفادة من المصادر الأكاديمية العربية والأجنبية، إضافة إلى المعلومات المتاحة على الشبكة الدولية للإنترنت والدوريات المتخصصة في مجال التأمين والذكاء الاصطناعي. يتم من خلال هذا الأسلوب تحليل المفاهيم الأساسية لمخصص التعويضات تحت التسوية وفهم النظريات والمبادئ التي تم تطويرها في هذا السياق.
2. الأسلوب التطبيقي: يتمثل في استخدام تقنيات الذكاء الاصطناعي، وبالتحديد الشبكات العصبية الاصطناعية. تم في هذه الدراسة اختيار شبكة الانحدار العصبية المعممة (GRNN)، وهي نوع من الشبكات العصبية التي تُستخدم للتنبؤ. تم تطبيق هذا النموذج



على بيانات مخصص التعويضات تحت التسوية في فرع التأمين البحري، بهدف تحسين دقة التنبؤ بمخصص التعويضات وتقليل الانحرافات بين التقديرات والتعويضات الفعلية. سادساً-حدود الدراسة:

1. الفترة الزمنية. تم إجراء الدراسة خلال الفترة الزمنية من عام 2008/2007 الي 2023/2022

2. الفروع: فرع التأمين البحري

3. شركة التأمين: يتم التطبيق على شركة مصر للتأمين حيث استحوذت الشركة حوالي

70% خلال فترة الدراسة من حصة السوق المصري.

-المبحث الأول: مخصص التعويضات تحت التسوية.

تعد العملية الأساسية التي تقوم بها شركات التأمين هي فرض أقساط تأمين مقابل تقديم وعدها بتعويض المؤمن لهم في حال وقوع أضرار مغطاة بموجب وثيقة التأمين ذات الصلة، ويتم جمع القسط إما في بداية فترة الوثيقة أو من خلال أقساط مجدولة خلال فترة الوثيقة والتي تكون في اغلب الاحول لمدة عام. مع ذلك، قد تتم تسوية التعويضات إما خلال فترة الوثيقة، أو في بعض الحالات قد يتم الدفع بعد عدة سنوات من انتهاء فترة الوثيقة. على الرغم من أن المطالبات عادةً ما تكون مغطاة فقط إذا حدثت خلال فترة وثيقة التأمين، إلا أنه غالبًا ما يحدث تأخير بين تاريخ وقوع الحادث وتاريخ إبلاغ المؤمن له بالمطالبة. كما قد يستغرق الأمر وقتًا لشركة التأمين لتحديد المبلغ الكامل الذي ستدفعه عن المطالبة، ويمكن أن يحدث هذا التأخير لعدة أسباب وهي:

1. قد يكون هناك تأخير بين تاريخ وقوع الحادث وتاريخ إبلاغ المؤمن عليه بالمطالبة.

2. حتى لو تم الإبلاغ عن المطالبة بسرعة بعد تاريخ الحادث، قد يستغرق الأمر بين نشؤ الحق في التعويض وتاريخ تسوية التعويض.

3. قد يتم دفع بعض التعويضات كمدفوعات متكررة تمتد لفترة زمنية طويلة.

هذه العوامل تجعل من الضروري لشركات التأمين تقدير إجمالي المطالبات التي تتوقع دفعها عند إعداد التقارير المالية السنوية، نظرًا لأنه لا يمكن معرفة القيمة الدقيقة للمطالبات في تاريخ معين، فإن عملية تحديد مخصص التعويضات تحت التسوية تتطلب تقديرًا مستقبليًا. يتم تخصيص مبلغ يُحتفظ به لتغطية المطالبات المستقبلية غير المسددة، وهو ما يُعرف بـ "مخصص التعويضات تحت التسوية" لتغطية المطالبات المحتملة التي لم تُسدّد بعد، وعند إضافة هذا المخصص إلى المبالغ التي تم دفعها فعليًا، يتم حساب ما يُعرف بـ "إجمالي المطالبات النهائية"، وهو إجمالي المبلغ المتوقع أن تدفعه شركة التأمين فيما يتعلق بمجموعة محددة من الوثائق أو المطالبات. في الماضي، كان يتم تحديد مخصص التعويضات باستخدام أساليب بسيطة نسبيًا، مثل جمع جميع المبالغ المقدرة لكل مطالبة معلقة بشكل فردي. ولكن منذ السبعينيات في المملكة المتحدة، تطورت الأساليب إلى تقنيات إحصائية تعتمد على بيانات المطالبات المجمعة. في الوقت الحاضر، سواء في المملكة المتحدة أو غيرها، تعتمد معظم عمليات تحديد المخصصات على هذه الأساليب، وهو ما يجعل عملية تقدير المخصصات تبدو علمًا دقيقًا. ومع ذلك، فإن هذه العملية تتطلب أيضًا قدرًا من المهارة والحكم الشخصي، حيث إن هناك دائمًا درجة من عدم اليقين في تقدير المخصصات المستقبلية. السبب الأساسي لهذا الغموض هو أن شركات التأمين لا تعرف القيمة النهائية للمطالبات التي ستدفعها في تاريخ معين. هذا الغموض يؤدي إلى عدم اليقين بشأن دقة المخصصات المحسوبة، إذ أن المخصصات قد لا تتطابق تمامًا مع المطالبات الفعلية في المستقبل. لهذا السبب، يُقال إن "الشيء الوحيد المؤكد حول المخصصات المقدرة هو أنها ستكون خاطئة"، بمعنى أنها لن تتطابق تمامًا مع الواقع. جزء مهم من عملية تقدير المخصصات هو محاولة فهم مدى الانحراف المحتمل عن القيمة الفعلية، وتوصيل هذا الغموض للأطراف المعنية بالشركة. ومما سبق نجد أن مخصص التعويضات تحت التسوية هو مبلغ مالي يُحتفظ به من قبل شركات التأمين لتغطية التعويضات المحتملة التي قد تنشأ عن الحوادث التي تم الإبلاغ عنها ولكن لم يتم تسويتها بعد. يُعتبر هذا المخصص جزءًا من الالتزامات المالية التي تتحملها شركات التأمين تجاه حملة الوثائق.



أولاً: الجوانب الرئيسية لمخصص التعويضات تحت التسوية (قيس السيد علي، 2010):

1. الاحتمال: يُحتسب مخصص التعويضات تحت التسوية بناءً على تقديرات دقيقة للتعويضات المحتملة عن الحوادث التي وقعت خلال الفترة المالية، حيث يتم تقدير المبالغ التي قد تكون مستحقة الدفع في المستقبل.
2. التأخير الزمني: تنشأ الحاجة لتكوين هذا المخصص نتيجة لفترة الفاصل بين تاريخ حدوث الخطر وتاريخ تسوية التعويضات. قد تشمل هذه الحوادث تلك التي تم الإبلاغ عنها ولكن لم يتم تسويتها بعد، بالإضافة إلى الحوادث التي وقعت ولم يتم الإبلاغ عنها بعد.
3. الأهمية المالية: يُعد مخصص التعويضات تحت التسوية مؤشراً على القدرة المالية لشركة التأمين على الوفاء بالتزاماتها. إذا تم تقدير هذا المخصص بصورة دقيقة، فإنه يعكس قدرة الشركة على التعامل مع المخاطر المالية المرتبطة بالتعويضات.
4. التحديات في التقدير: تقدير مخصص التعويضات تحت التسوية يعد مهمة صعبة، حيث يتطلب تحليلاً دقيقاً للبيانات التاريخية، وفهماً عميقاً للمخاطر المحتملة والتغيرات الاقتصادية. عدم الدقة في هذا التقدير قد يؤدي إلى انحرافات بين التعويضات الفعلية والتقديرات، مما يؤثر سلباً على الأداء المالي للشركة.

ثانياً: وتتمثل أهمية مخصص التعويضات تحت التسوية فيما يلي (أمل أحمد، 1999، ص: 25):

- 1- تلبية الالتزامات المالية: يساهم مخصص التعويضات تحت التسوية في ضمان قدرة شركات التأمين على الوفاء بالتزاماتها تجاه حملة الوثائق. يضمن هذا المخصص وجود أموال كافية لتغطية التعويضات المستحقة في المستقبل.
- 2- تحسين دقة التقديرات: يساعد في تقدير التعويضات بشكل دقيق، مما يقلل من الانحرافات بين التعويضات الفعلية والتقديرات. هذا يمكن أن يساعد في تحسين التخطيط المالي واستراتيجيات الأعمال.

- 3- إدارة المخاطر: يُعتبر مخصص التعويضات تحت التسوية أداة مهمة في إدارة المخاطر. يمكن أن يساعد في تحديد المخاطر المحتملة وتقدير الأثر المالي لها، مما يعزز من استقرار شركة التأمين.
 - 4- تحقيق الشفافية: يعزز الشفافية في التقارير المالية لشركات التأمين. تقديم معلومات دقيقة حول المخصصات يمكن أن يزيد من ثقة العملاء والمستثمرين في أداء الشركة واستراتيجياتها.
 - 5- تلبية المتطلبات التنظيمية: تُعتبر مخصصات التعويضات تحت التسوية جزءاً من المتطلبات التنظيمية التي تفرضها الهيئات الرقابية على شركات التأمين. الالتزام بهذه المتطلبات يمكن أن يحمي الشركة من العقوبات ويعزز من سمعتها في السوق.
 - 6- تحليل الأداء المالي: يتيح مخصص التعويضات تحت التسوية إجراء تحليلات مالية دقيقة، مما يساعد في تقييم الأداء المالي لشركة التأمين وتحديد الاتجاهات في المطالبات والتعويضات.
 - 7- تعزيز التخطيط الاستراتيجي: يساهم في توفير بيانات قيمة تدعم عملية اتخاذ القرارات الاستراتيجية. يمكن استخدام التحليلات المرتبطة بالمخصصات لتوجيه الاستثمارات وتحديد الاتجاهات المستقبلية.
- وبناء على ما سبق نجد ان مخصص التعويضات تحت التسوية يتكون من نوعين من المخصصات وهما:

- 1- مخصص التعويضات تحت التسوية للحوادث التي تم الإبلاغ عنها.
 - 2- مخصص التعويضات تحت التسوية للحوادث والتي لم يتم الإبلاغ عنها.
- ثالثاً: مخصص التعويضات تحت التسوية للحوادث التي تم الإبلاغ عنها:
- تقوم شركات التأمين بحجز مبالغ معينة من الإيرادات الجارية لتغطية الخسائر الناجمة عن الحوادث التي وقعت خلال العام المالي وقبل إعداد الحسابات الختامية، في بند مخصص التعويضات تحت التسوية واجه شركات التأمين عدة سيناريوهات فيما يتعلق بهذه الحوادث:



1- حوادث وقعت وتم الإبلاغ عنها وتسويتها ولكن لم يتم السداد: وهي حوادث قد تم الإبلاغ عنها وتسويتها وتم تحديد التعويض الواجب دفعه بشكل نهائي، ولكن لم يتم دفع التعويض قبل إعداد الحسابات الختامية. ، وفي هذه الحالة، لا توجد أي مشكلة في تقدير الأموال الواجب حجزها لمواجهتها، حيث إن مبلغ التعويض الواجب السداد قد تم تحديده بصورة نهائية وتم تحديد حجم مسئولية المؤمن، وفي ضوء ذلك يتم تعديل مخصص التعويضات الخاص بهذه الحوادث، سواء بإضافة أو خصم الفروقات الناتجة عن التقديرات السابقة. ، والذي تم حجزه لهذا الغرض، هذه المبالغ تمثل جزءًا من إجمالي مخصص التعويضات تحت التسوية الواجب تكوينه.

أ- الطريقة الفنية المستخدمة لحساب هذا المخصص: ان طرق إعداد مخصص التعويضات تحت التسوية عن الحوادث المبلغ عنها والتي تم تسويتها فعلا، ولكن لم تسدد حتى تاريخ إقفال الميزانية، لا توجد أي مشكلة عند إعداد مخصص التعويضات تحت التسوية عن الحوادث التي وقعت وتم الإبلاغ عنها . وتم تسويتها فعلا . ولكن لم تسدد بعد؟ لأن قيمة الخسائر عن هذه الحوادث تم تقديرها بالفعل من قبل الشركة، وأصبحت نهائية ومستحقة السداد لأصحاب المطالبات ولكن الشركة لم تقم بسدادها حتى تاريخ إقفال الميزانية، فيتم حجز القيمة الفعلية المقدرة بالكامل في حساب مخصص التعويضات تحت التسوية إلى أن يتم سدادها.

3- حوادث تم الإبلاغ عنها ولم يتم تسويتها بعد: في حالات أخرى، قد تقع حوادث خلال العام، وتبلغ بها شركة التأمين، لكن لم يتم التوصل إلى تسوية نهائية بشأنها قبل إعداد الحسابات الختامية، في هذه الحالات، من الحوادث تكون المطالبات في مرحلة التسوية ولم يتم التوصل لاتفاق بشأنها ويلزم إجراء تقدير معين بخصوص قيمته، حيث يتم حجز مبلغ مناسب في حساب مخصص التعويضات تحت التسوية للوصول للمبلغ الإجمالي للمخصص الواجب إظهاره في الحسابات الختامية لشركة التأمين (بخيت، محمد، 2007). في هذه الحالات، تكون المطالبات في مرحلة التسوية ولم يتم الاتفاق على قيمتها بعد. لذلك، يتطلب الأمر تقديرًا تقريبًا لقيمة التعويض، وحجز مبلغ مناسب في حساب مخصص التعويضات تحت التسوية للوصول إلى المبلغ الإجمالي الذي يجب إظهاره في الحسابات الختامية لشركة التأمين.

أ- الطريقة الفنية المستخدمة لحساب هذا المخصص:

حيث تلتزم شركة التأمين بحجز المبالغ المناسبة لمواجهة المطالبات عن الحوادث التي لم يتم الإبلاغ عنها وفق خبرة الشركة في السنوات السابقة تضاف إلى مخصص التعويضات تحت التسوية لينتج الرقم الإجمالي لهذا المخصص ٠ والذي يظهر في ميزانية الشركة. وفيما يأتي أهم الطرق المستخدمة:

1- الطريقة الأولى: الطريقة الفردية:

وهي طريقة التقدير لكل حالة على حده ، وبمقتضى هذه الطريقة يتم فحص كل حالة على حده لتقدير التعويض المناسب لها، ويجمع قيم التعويضات للحوادث غير المسواة جميعا في رقم واحد ينتج عنه الرقم الإجمالي لمخصص التعويضات تحت التسوية.

▪ مزايا هذه الطريقة: تعتبر هذه الطريقة طريقة دقيقة جدا؟ حيث يتم دراسة كل حالة على حدة

▪ عيوب هذه الطريقة: مكلفة وتتطلب مجهودا ووقت كبيرا وعددا كبيرا من المتخصصين وفنيين على درجة عالية من الكفاءة لإتمام عملية المعاينة، كما يظهر فيها الجانب الشخصي القائم بعملية التقدير فهي تختلف من شخص لآخر، (سلامة، عبد الباري، 1993).

2- الطريقة الثانية: طريقة القيمة المتوسطة: (محمد نادي وطارق عزت، 1999)

تعتمد هذه الطريقة على خبرة السنوات السابقة بالنسبة لهيئة التأمين وذلك بالنسبة لكل فرع من فروع التأمين، حيث يتم إيجاد قيمة متوسطة للمطالبة الواحدة . ويمكن تصنيفها داخل الفرع الواحد حسب طبيعة الخطر وحدته، وهذه الطريقة يمكن إتباعها بدرجة عالية من الثقة إذا كان محدد المطالبات كبيرا ومنتظما، وتتحدد قيمة متوسط التعويض عن الحالة الواحدة على أساس خبرة هيئة التأمين ونظرتها لما تتوقعه بالنسبة للمستقبل، ويتم تحديد مخصص التعويضات كما يلي:

مخصص التعويضات = عدد المطالبات التي لم يتم تسويتها خلال العام X متوسط قيمة المطالبة الواحدة.



ويتم حساب متوسط قيمة المطالبة الواحدة من واقع الخبرات السابقة، أي من واقع المطالبات الفعلية التي حدثت خلال عدد من السنوات السابقة ويمكن حساب متوسط قيمة المطالبة الواحدة من خلال المعادلة الآتية:

$$\text{متوسط قيمة المطالبة الواحدة} = \text{اجمالي قيمة المطالبات خلال فترة كبيرة من الماضي} \div \text{عدد المطالبات خلال الفترة نفسها}$$

4. مميزات هذه الطريقة: تتميز هذه الطريقة بتوفر الوقت والجهد والتكاليف وتساعد في سرعه

إفقال الحسابات الختامية

5. عيوب هذه الطريقة: يعاب على هذه الطريقة أنها تعطي نتائج غير دقيقة في حالة كون

عدد المطالبات محدودا، كما أن وجود تباين كبير في قيم المطالبات يؤدي لنتائج مضللة.

ومن ثم فإنها تصلح في حالة إذا كان عدد المطالبات كبيرا ويحقق قانون الأعداد الكبيرة،

فهي لا تستخدم عادة إلا كاختبار لطرق أخرى أكثر تقدما (الخواجة، 2014).

3- الطريقة الثالثة: طريقة معدل الخسارة المتوقع (عبد الهادي، 2001، ص: 71-121)

تعتمد هذه الطريقة أيضاً على نفس الأسس المتبعة بشأن طريقة القيمة المتوسطة، وفيها يتم

حساب معدل الخسائر لكل فرع من فروع التامين على أساس الخبرة الماضية، ومن ثم فإنه يتم

حساب مخصص التعويضات تحت التسوية بإيجاد حاصل ضرب الأقسام المكتسبة التي تخص العام

وفي معدل الخسارة المتوقع والذي تم تقديره من قبل، وتوضح المعادلة الآتية كيفية تكوين مخصص

التعويضات تحت التسوية من خلال المعادلة الآتية:

$$\text{مخصص التعويضات تحت التسوية} = (\text{معدل الخسارة المتوقع} \times \text{الأقساط المكتسبة}) - \text{التعويضات المسددة}.$$

وللتوصل إلى مخصص التعويضات تحت التسوية آخر العام يضاف قيمة التعويضات التحميلية

المتوقعة التي تخص العام الى قيمة التعويضات تحت التسوية أول العام ويطرح من مجموعة

قيمة التعويضات المسددة خلال العام وحتى إعداد الميزانية، وذلك من خلال المعادلة الآتية:

$$\text{مخصص التعويضات تحت التسوية آخر العام} = (\text{التعويضات التحميلية المتوقعة التي تخص العام} + \text{مخصص التعويضات تحت التسوية أول العام}) - \text{التعويضات المسددة خلال العام}$$

ولحساب التعويضات التحميلية من المعادلة الآتية:

$$\text{التعويضات التحميلية} = \text{التعويضات المسددة خلال العام} + \text{مخصص التعويضات تحت التسوية آخر} \\ \text{المدة} - \text{مخصص التعويضات تحت التسوية أول المدة}.$$

ويتوقف نجاح هذه الطريقة على دقة حساب معدل الخسارة المتوقع، فكلما اقترب من معدل الخسارة الفعلي كانت نتائج مخصص التعويضات تحت التسوية أكثر دقة.

▪ مميزات طريقة معدل الخسارة المتوقع:

تصلح هذه الطريقة في حالة كون فرع التأمين جديداً، أو تكون الشركة في السنوات الأولى من عمرها وليس لديها خبرة عن المطالبات، كما تستخدم هذه الطريقة في حالة وجود طرق تقدير متقدمة كاختبار مناسب وسهل، وهذا ما يحدث في السوق المصري.

▪ عيوب طريقة معدل الخسارة المتوقع

على الرغم من بساطة هذه الطريقة فإنها تنطوي على عدد من القيود منها. عدم قدره استخدامها على مستوى محافظة الشركة ككل، كما أن تدخل الإدارة . في تقدير معدل الخسارة المتوقع سيؤدي إلى تقدير بأقل مما يجب حتى تظهر الشركة كفاءتها في الاكتتاب؟ مما قد يترتب عليه تقدير مخصص التعويضات تحت التسوية بأقل مما يجب، ومن ثم فإن هذه الطريقة تتطلب عناية كبيرة من جانب المسؤولين في الشركة.



4- الطريقة الرابعة: طريقة الجداول

تلجأ هيئات التأمين إلى استخدام بعض الجداول الخاصة في تقدير قيمة المخصصات المطلوب تكوينها لمواجهة التعويضات المتوقعة، حيث تستخدم هذه الطريقة الشائعة الاستخدام في تأمينات الحياة أما في مجال التأمينات العامة فأنها تستخدم في تأمينات الحوادث الشخصية وتأمين العجز.

رابعاً: الطرق الفنية المستخدمة بالنسبة للحوادث التي وقعت ولم يتم الإبلاغ عنها بعد (I.B.N.R)

نتناول فيما يلي أهم الطرق المستخدمة لتقدير مخصص التعويضات تحت التسوية عن الحوادث غير المبلغ عنها حتى تاريخ إعداد الميزانية، وذلك كما يلي:

1- الطريقة الأولى: طريقة نسبة تعويضات الحوادث غير المبلغ عنها في السنة السابقة إلى إجمالي التعويضات المحققة عن نفس السنة:

تعتمد هذه الطريقة على استخدام بيانات السنة السابقة كأساس لتقدير قيمة تعويضات الحوادث غير المبلغ عنها. حيث يتم حساب نسبة تعويضات الحوادث غير المبلغ عنها إلى إجمالي التعويضات المحققة في تلك السنة، ثم تُضرب هذه النسبة في قيمة التعويضات عن الحوادث المحققة خلال العام الحالي. تُعد هذه الطريقة مناسبة للشركات الكبيرة التي تتميز بعدد وحجم كبير من المطالبات، مما يسمح بوجود نسبة محددة لهذه التعويضات لكل فرع تأمين على حدة. كما يمكن تعديل هذه النسبة وفقاً لأي ظروف أو تغيرات جديدة تطرأ على أعمال شركة التأمين.

2- الطريقة الثانية: طريقة نسبة التعويضات المحققة فعلاً والتي لم تبلغ بعد في السنة السابقة إلى مجموع الأقساط المحصلة في تلك السنة

ترتكز هذه الطريقة على استخدام بيانات السنة السابقة كأساس للتقدير. حيث تُحسب قيمة الخسائر الناتجة عن الحوادث التي وقعت في السنة السابقة ولم يتم الإبلاغ عنها إلا في العام الحالي، ثم تُنسب هذه القيمة إلى إجمالي الأقساط المحصلة في تلك السنة. يتم استخدام هذه

النسبة لتقدير مخصص التعويضات للعام الحالي. تُعد هذه الطريقة ملائمة للشركات الكبيرة ذات العدد الضخم من المطالبات، ويمكن للمختصين تعديل النسبة بما يتماشى مع تطور الشركة واتجاهاتها لضمان دقة التقدير.

3- الطريقة الثالثة: طريقة تقدير عدد الحوادث المتوقعة وغير المبلغ عنها حتى إعداد الميزانية:

تعتمد هذه الطريقة على حساب متوسط التعويض عن الحادث الواحد استنادًا إلى الخبرات السابقة، وكذلك تقدير عدد الحوادث المتوقعة وغير المبلغ عنها حتى نهاية العام، ويتم ذلك كما يلي:

تحسب الشركة أولاً متوسط التعويض عن كل حادث بناءً على البيانات التاريخية. ثم يقوم المختصون بتقدير عدد المطالبات المتوقعة من خلال تقدير عدد الحوادث التي وقعت خلال العام الحالي ولم يتم الإبلاغ عنها بعد، وذلك باستخدام متوسط عدد الحوادث غير المبلغ عنها في السنوات السابقة.

بعد ذلك، يُحسب مخصص التعويضات تحت التسوية للحوادث غير المبلغ عنها من خلال ضرب متوسط قيمة التعويض في عدد الحوادث المتوقعة. تعتمد دقة هذا المخصص على مدى دقة تقدير عدد المطالبات المتوقعة ومتوسط قيمة التعويض لكل حادث. تُعد هذه الطريقة فعالة بشكل خاص للشركات الكبيرة

4- الطريقة الرابعة — طريقة إبقاء حساب المخصص مفتوحًا لمدة كافية خلال السنة الجديدة

لتسجيل المطالبات عن الحوادث غير المبلغ عنها

تقوم هذه الطريقة على إبقاء حساب المخصص مفتوحًا خلال السنة المالية الجديدة لفترة زمنية كافية، بحيث يُسجل في هذا الحساب المطالبات المتعلقة بالحوادث التي وقعت في السنة السابقة ولم يُبلغ عنها حتى بداية السنة الجديدة. وتُعد هذه الطريقة من أكثر الطرق دقة في تقدير مخصص التعويضات، حيث تسمح بتسجيل المطالبات الفعلية عن الحوادث غير المبلغ عنها في



السنة السابقة، وبالتالي تقديم تقدير حقيقي للمخصص. تناسب هذه الطريقة الحالات التي يكون فيها عدد الحوادث غير المبلغ عنها صغيراً ومحدوداً.

– المبحث الثاني: مفهوم الشبكات العصبية.

سوف تتناول الباحثة في هذا الجزء من البحث مفهوم الذكاء الاصطناعي ومفهوم الشبكات العصبية بوجه عام ومن ثم شرح الشبكة العصبية المستخدمة في الدراسة:

اولاً: مفهوم الذكاء الاصطناعي:

الذكاء الاصطناعي بصفة عامة يعني انه الذكاء الذي يصنعه أو يصطنعه العقل البشري في الآلة أو الحاسب الآلي، وهو بذلك يعتبر أحد علوم الحاسب الآلي الحديثة التي تبحث عن أساليب متطورة للقيام بأعمال واستنتاجات، ويهدف الذكاء الاصطناعي إلى تمكين الآلات من أداء مهام تتطلب عادةً قدرات معرفية شبيهة بتلك التي يتمتع بها الإنسان، مثل التعلم، والتخطيط، واتخاذ القرار، وحل المشكلات، أي أن الذكاء الاصطناعي هو علم من علوم الحاسب الآلي التي تهتم بتصميم نظم آلية تشابه خصائص الذكاء في السلوك الإنساني (Barr, & Feigenbaum, 1980)، هذا وقد عرف الكثير من المتخصصين والباحثين والخبراء الذكاء الاصطناعي تعريفات عديدة ومختلفة وفقاً لوجهات نظرهم ومنها تعريف قاموس أكسفورد الإنجليزي للذكاء الاصطناعي بأنه "نظرية وتطوير نظام كمبيوتر قادر على أداء المهام التي تتطلب عادةً ذكاءً بشرياً مثل الإدراك البصري والتعرف على الكلام واتخاذ القرار والترجمة بين اللغات". كما عرفة (أبو بكر خلدون وآخرون، 2012)، بانه "مجموعة الجهود المبذولة لتطوير نظم المعلومات المحوسبة بطريقة تستطيع أن تتصرف فيها وتفكر بأسلوب مماثل للبشر، هذه النظم تستطيع أن تتعلم اللغات الطبيعية، وإنجاز مهام فعلية بتنسيق متكامل، أو استخدام صور وأشكال إدراكية لترشيد السلوك الإنساني، كما تستطيع في نفس الوقت تخزين الخبرات والمعارف الإنسانية المتراكمة واستخدامها في عملية اتخاذ القرار".

ويمكن تعريفه على انه: أحد علوم الحاسب الآلي الحديثة التي اساليب متطورة من البرمجة للقيام بأعمال واستنتاجات بطريقة تشابه ذكاء الإنسان؛ حيث تقوم هذه التطبيقات بفهم العمليات

التي يقوم بها العقل البشري ومن ثم برمجتها تمهيدا لاتخاذ القرار المناسب بشأنها(محمد أحمد المعداوي، 2012)، يتميز الذكاء الاصطناعي بوجه عام بالعديد من الخصائص المشتركة وهي التعلم من البيانات: قدرة النظم الذكية على تحليل البيانات واستخلاص المعلومات منها لتحسين أدائها.

- التفكير المنطقي واتخاذ القرارات: تمكين الآلة من اتخاذ قرارات منطقية بناءً على البيانات والمعطيات المتاحة.
 - التفاعل الطبيعي: تفاعل النظم الذكية مع البشر بشكل طبيعي عبر اللغة أو الصوت أو غيرها من الوسائل.
 - التكيف والتعميم: قدرة الذكاء الاصطناعي على التكيف مع بيئات مختلفة وتطبيق معرفته على مهام جديدة.
 - حل المشكلات: القدرة على معالجة مشكلات متعددة الخطوات للوصول إلى حلول مرضية.
- هذه الخصائص تساعد الذكاء الاصطناعي في محاكاة مجموعة واسعة من القدرات البشرية وتعزيزها، ما يساهم في تطوير تطبيقات قادرة على التعامل مع تحديات معقدة بمرونة وكفاءة عالية. إن الذكاء الاصطناعي وخاصة في مجال التأمين 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 حلاً 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. يمكن للذكاء الاصطناعي مساعدة القائمين على صناعة التأمين في توفير التكاليف وزيادة الإيرادات، نظراً لقدرته على فهم احتياجات العملاء وتقديم حلول مخصصة لهم تناسب احتياجاتهم. كما يمكن لشركات التأمين استغلال أدوات الذكاء الاصطناعي لتحليل المخاطر بشكل دقيق، الأمر الذي يؤثر إيجابياً على تسعير الوثائق وتحديد نوعية التغطية التأمينية. علاوة على ذلك، يتيح الذكاء الاصطناعي تطوير نماذج متقدمة للتنبؤ بالمخاطر وتقدير الاحتماليات بشكل

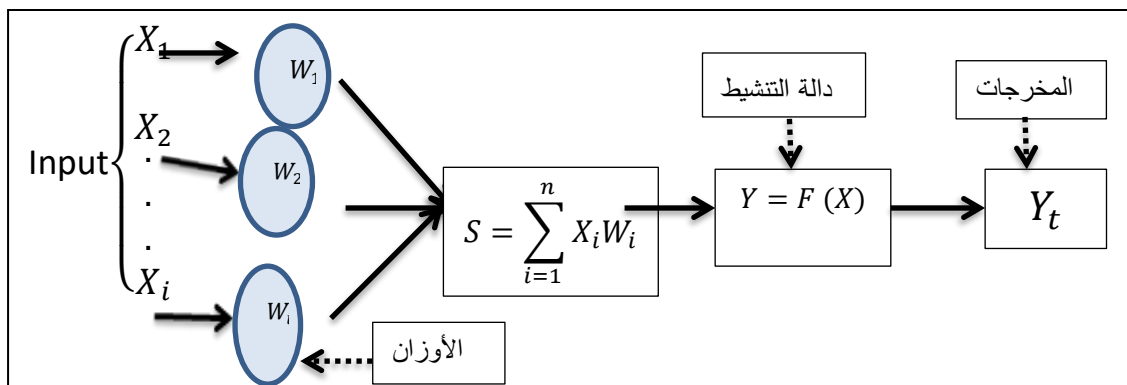


ادق، بما في ذلك التنبؤ بمخصصات التعويضات تحت التسوية لمختلف فروع التأمين، مما يضمن تخصيصًا أكثر دقة لهذه المخصصات.

ثانياً: الشبكات العصبية الاصطناعية (Artificial Neural Network)

تعتبر الشبكات العصبية الاصطناعية فرعاً أساسياً من الذكاء الاصطناعي، إذ تمثل نموذجاً حسابياً مستوحى من طريقة عمل الدماغ البشري في تنفيذ المهام (Haykin، 2009). تتميز الشبكات العصبية بقدرتها على معالجة البيانات بشكل متوازي باستخدام وحدات معالجة بسيطة تُعرف بالعقد أو النيرونات (Neurons or nodes)، التي تتصل ببعضها عبر أوزان تُعرف بالأوزان التشابكية. تمتاز العقد بقدرتها على تخزين المعلومات والخبرات المكتسبة وجعلها متاحة للاستخدام، مما يُتيح لها تعلم الأنماط واكتساب المعرفة مع مرور الوقت، وذلك من خلال تعديل الأوزان بناءً على المدخلات بطريقة تكيفية. الشبكات العصبية الاصطناعية تحاكي طريقة معالجة المعلومات في الشبكات العصبية البيولوجية من حيث قدرة الشبكة على التعلم والتكيف وتحليل البيانات المعقدة. يتضح من مكونات الشبكة العصبية أن العمليات الحسابية تتوزع عبر شبكة من العقد، تتصل فيها العقد بالأوزان التي تُحدث بناءً على القواعد التكيفية حسب المدخلات. يمكن للشكل التالي أن يوضح هذه المكونات بتفصيل، حيث تُظهر الشبكة ارتباطات العقد والأوزان فيما بينها، مشكّلة نظاماً شبكياً معقداً يحاكي الدماغ البشري في معالجة المعلومات والتنبؤ بالنتائج بناءً على البيانات المدخلة.

شكل (1) يوضح الشكل الرياضي للشبكة العصبية الاصطناعية



المصدر: من اعداد الباحثة بناء على (Samarasingha، 2007)

من الشكل السابق نجد ان النموذج الأساسي للخلية العصبية في الشبكات العصبية الاصطناعية يتكون من ثلاث طبقات رئيسية تعمل بشكل تكاملي لتحقيق عملية التعلم، وهي:

▪ طبقة المدخلات Input Layer

يتم من خلال هذه الطبقة تغذية شبكة البيانات من العالم الخارجي، وتقوم باستقبال البيانات (X_1, X_2, \dots, X_n) ، تمرر هذه الطبقة البيانات عبر الوصلات (الأوزان) إلى الطبقة التالية في الشبكة، وقد تتألف الشبكة من وحدة معالجة واحدة أو أكثر على حسب تركيبية الشبكة. كما انه لا تتم أي معالجات حسابية على المدخلات، بل تقوم بنقل البيانات المدخلة من هذه الطبقة عبر الوصلات البينية (الأوزان) الى وحدات المعالجة في الطبقة الخفية أو مباشرة الى وحدات المعالجة في طبقة المخرجات إذا كانت الشبكة لا تحتوي على طبقة خفية مباشرة في الشبكات البسيطة.

6. الطبقة الخفية: Hidden Layer

تقع الطبقة الخفية بين طبقة المدخلات وطبقة المخرجات، وتقوم بمعالجة المدخلات من خلال مجموعة من الخلايا العصبية التي تمنح كل مدخل وزناً نسبياً. تحتوي الطبقة الخفية على دوال تنشيط تساعد على تحسين النموذج عن طريق تعديل الأوزان النسبية لتحقيق أقرب نتيجة ممكنة إلى النتائج المرجوة. ويعد عدد الطبقات الخفية وعدد الخلايا العصبية داخل كل طبقة أمراً غير ثابت، إذ يتم تحديده بناءً على التجربة ونتائج التدريب، حيث يتم ضبطها لضمان أن الشبكة تستطيع التعرف على الأنماط بشكل فعال دون زيادة تعقيد النموذج.

7. طبقة المخرجات (Output Layer):

وهي الطبقة النهائية للشبكات العصبية، حيث تقوم كل خلية فيها باستقبال مدخلاتها من كل خلية في الطبقة الخفية السابقة لها. بناءً على المعلومات المُعالجة في الطبقة الخفية، وقد ترسل هذه الطبقة النتائج كإخراج نهائي أو تقوم بإعادة هذه المخرجات كمدخلات مرة أخرى للشبكة إلى المزيد من التحسين. ويتحدد عدد خلايا طبقة المخرجات وفقاً للنتائج المطلوبة من الشبكة، وقد تحتوي الشبكة عادة على طبقة مخرجات واحدة فقط، كما يتحدد عدد خلايا هذه الطبقة بعدد فئات المخرجات أو النتائج المطلوبة.

8. الأوزان النسبية (Weights):

تُعد الأوزان النسبية بمثابة الروابط بين وحدات المعالجة أو العقد العصبية، حيث تحدد مدى قوة العلاقة بين المدخلات والمخرجات. وتكون الأوزان النسبية بمثابة عوامل مضاعفة لكل مدخل من المدخلات لتحديد أهميته النسبية، حيث يتم تعديل الأوزان النسبية باستمرار أثناء عمليات التدريب لتعكس أنماط البيانات.



9. دالة التجميع (Summation Function):

تعمل دالة التجميع على حساب النتيجة المركبة من المدخلات، وذلك عن طريق جمع حاصل ضرب كل مدخل في وزنه النسبي. يمكن تمثيل هذه العملية بالمعادلة الرياضية:

$$S = \sum_{i=1}^n X_i W_i$$

حيث SS هو الناتج المجمع، و X_i يمثل كل مدخل، و W_i هو الوزن النسبي لكل مدخل. تقوم هذه الدالة بتحديد مستوى التأثير التراكمي للمدخلات المختلفة على النتيجة النهائية.

10. دالة التنشيط (Activation Function)

يطلق عليها أيضاً دالة التحول (Transfer Function)، حيث تقوم بإجراء المعادلات الرياضية على القيم الخارجة من دالة التجميع، وتعديل الأوزان النسبية باستمرار طوال فترة تدريب الشبكة، وأكثر دوال تنشيط الشبكات العصبية انتشاراً هي الدالة الخطية لتنشيط الشبكات العصبية، ودالة الحد الفاصل لتنشيط الشبكات العصبية، ودالة سيجمويد لتنشيط الشبكات العصبية. حيث تُستخدم هذه الدوال لتحويل القيم الخارجة من دالة التجميع إلى مخرجات محددة النطاق، مما يساعد الشبكة في تحقيق توازن بين الدقة والتعميم.

11. مقاييس الأداء

لقياس جودة أداء الشبكة العصبية ومدى دقة التنبؤات، يتم استخدام عدة معايير، مثل:

(MAPE): يقيس متوسط نسبة الخطأ المطلق.

(MAE): يقيس متوسط الخطأ المطلق بين القيم المتوقعة والقيم الحقيقية.

R^2 : معامل تحديد يقيس مدى مطابقة النموذج للبيانات.

RMSE: يقيس الجذر التربيعي لمتوسط مربعات الأخطاء.

تساهم هذه المقاييس في تحسين كفاءة الشبكة وزيادة دقتها، مما يجعلها أداة قوية للتنبؤات المدعومة بالذكاء الاصطناعي.

1- تعلم وتدريب الشبكات العصبية (Neural Networks Learning & Tanning):

الخاصية المميزة والاساسية للشبكات العصبية هي قدرتها العالية على التعلم من بيئتها وتحسين أدائها، تعد دراسة Hebb في عام 1949 (Hebb, 1949) من الدراسات الأولى المبكرة التي

اقترحت القاعدة الأساسية لطريقة تعلم النيرونات، ثم قام العديد من الباحثين بتطبيق قاعدة Hebb ووجدوا أن التدريب والتعلم هما اللذان يحددان قيم الأوزان النسبية، حيث يعبر الوزن النسبي عن القوة النسبية أو الأهمية النسبية للبيانات المدخلة، فالشبكات العصبية لا تبرمج ولكنها تقوم بالتدريب والتعلم فقط، حيث يتم تدريب الشبكات العصبية على مجموعة من البيانات التاريخية، وهو ما يساهم في سرعة تعلم تلك الشبكات العصبية التي تم تدريبها، وبالتالي ضبط الأوزان النسبية، وتحقيق أفضل النتائج. ومع تكرار التدريب، تزيد الشبكة من كفاءتها وسرعة تعلمها، كما يقلل تكرار عمليات التدريب من نسبة الخطأ في النتائج.

ومما سبق نجد هناك ثلاثة أمور تحدث داخل النيرونات (Bishop, 2006):

أ- ضرب كل مدخل في وزن خاص به: يتم ضرب كل مدخل من المدخلات بالوزن النسبي الخاص به، مما يعكس الأهمية النسبية لكل مدخل. المعادلات تكون على النحو التالي:

$$(X_1 = X_1 * W_1) ، (X_2 = X_2 * W_2) \dots\dots\dots ، (X_i = X_i * W_i)$$

ب: جمع المدخلات الموزونة وإضافة معامل الانحياز (Bias): بعد عملية الضرب، يتم جمع المدخلات الموزونة مع إضافة معامل الانحياز. تُكتب المعادلة كالتالي:

$$\sum = (X_1 * W_1) + (X_2 * W_2) + b$$

ج: تمرير المجموع إلى دالة التنشيط: (Activation Function)

يتم استخدام دالة التنشيط لتحويل المجموع الناتج إلى مخرجات ضمن نطاق معين، مما يجعلها مناسبة للتنبؤ والتحليل.

$$y = f (X_1 * W_1) + (X_2 * W_2) + b$$

دالة التنشيط، مثل دالة السيجمويد (Sigmoid Function)، تحول القيم المدخلة إلى مخرجات يمكن التنبؤ بها ضمن نطاق محدد، حيث تقيد الناتج، مما يساعد في اتخاذ قرارات قابلة للتفسير ضمن النظام.



2- وتنقسم الشبكات العصبية الى نوعين رئيسيين على النحو التالي:

أ- الشبكات العصبية ذات التغذية الأمامية Feed-Forward- Network، (ليث حليم، 2022)

في هذا النوع، تنتقل البيانات باتجاه واحد فقط من طبقة المدخلات إلى طبقة المخرجات عبر الطبقة أو الطبقات المخفية (في حال وجودها). وتنقسم هذه الشبكات من حيث عدد الطبقات إلى نوعين:

12. شبكات وحيدة الطبقة: (Single-Layer Network) تتكون من طبقة واحدة فقط بين المدخلات والمخرجات.

13. شبكات متعددة الطبقات (Multi-Layer Network): تحتوي على طبقات متعددة بين المدخلات والمخرجات، مما يزيد من قدرتها على معالجة العلاقات المعقدة بين البيانات.

ب- الشبكات العصبية ذات التغذية المرتجعة (Feedback Network)

تتميز هذه الشبكات بقدرتها على إعادة تغذية بعض أو كل مخرجاتها وإعادة استخدامها كمدخلات مرة أخرى. وتستخدم في الحالات التي تتطلب معالجة البيانات بشكل تكراري (علي، أحمد عبد الوهاب أحمد، 2022)، 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.

وتتم عملية التدريب وفق هذه الإجراءات المنطقية من خلال مرحلتين تتألفان من مجموعة من الخطوات المتتالية:

1-مرحلة أمامية (Forward Pass): خلال هذه المرحلة، تتدفق البيانات من المدخلات

إلى المخرجات عبر الطبقات الوسطى، حيث تنتج مخرجات الشبكة بناءً على الأمثلة التدريبية المقدمة.

2- مرحلة تراجعية (Backward Pass): تُقارن مخرجات الشبكة المتوقعة بالمخرجات الفعلية المستهدفة. ويُحسب خطأ التنبؤ الناتج، ويستخدم لتعديل الأوزان بهدف تحسين دقة الشبكة. يتم تعديل الأوزان المرجحة لقيمة كل مدخل W_{ij} وفق المعادلة التالية:

$$W_{ij} = W_{ij} + LR \times e_j \times X_i$$

حيث W_{ij} الوزن السابق بين المدخل i والعقدة j ، و LR معدل التعلم، و e_j هو حد الخطأ، و X_i قيمة المدخل i .

ومما تجدر الإشارة إليه ان هناك عدة انواع للتعلم يعتمد كل منها بحسب طبيعة وحاجة البيانات التي يتم معالجتها ومن ثم نوع الشبكة المستخدمة ومن أشهر انواعه (Pacelli et al, 2011)

14. أسلوب التدريب الإشرافي (الموجه) (Supervised Learning): يتضمن تدريب الشبكة باستخدام بيانات تحتوي على مدخلات معروفة ومخرجات مستهدفة، حيث تتعلم الشبكة العلاقات بينهما. من أمثلة هذا الأسلوب: شبكات Back Propagation و Hopfield Network.

15. أسلوب التدريب غير الإشرافي (غير الموجه) (Unsupervised Learning)، (أحمد عبد الوهاب، 2022): وفيه تكون النتائج أو المخرجات المتعلقة بالمدخلات غير معروفة، وتكون الشبكة بالتالي ذاتية التنظيم، ومن أمثلة هذا النوع من التدريب (Kohonen self-organizing feature map، Adaptive resonance theory).

16. أسلوب التدريب بإعادة التدعيم (Reinforcement Training): الذي يجمع بين الأسلوبين السابقين، حيث لا يتم تحديد القيم الحقيقية للمخرجات، في حين يتم تحديد مدى صحة النتائج من الشبكة.

ويتم مقارنة المخرجات الفعلية مع المخرجات المطلوبة وتحديد حد الخطأ e_j والذي بناءً عليه يتم تعديل الأوزان المعطاة لمدخلات الخلايا بمعدل التعلم (LR)، وحساب العلاقات بين مدخلات ومخرجات الخلايا من جديد، واستنتاج مخرج جديد يتزايد في الاتجاه الذي يقلل من حد الخطأ، وتستمر عملية التدريب بتكرار هذه الخطوات عدة مرات دورياً حتى الوصول إلى أدنى درجة مقبولة من الخطأ أو أقصى درجة مقبولة من الدقة. ويعد من الضروري هنا تحديد معدل التعلم المناسب



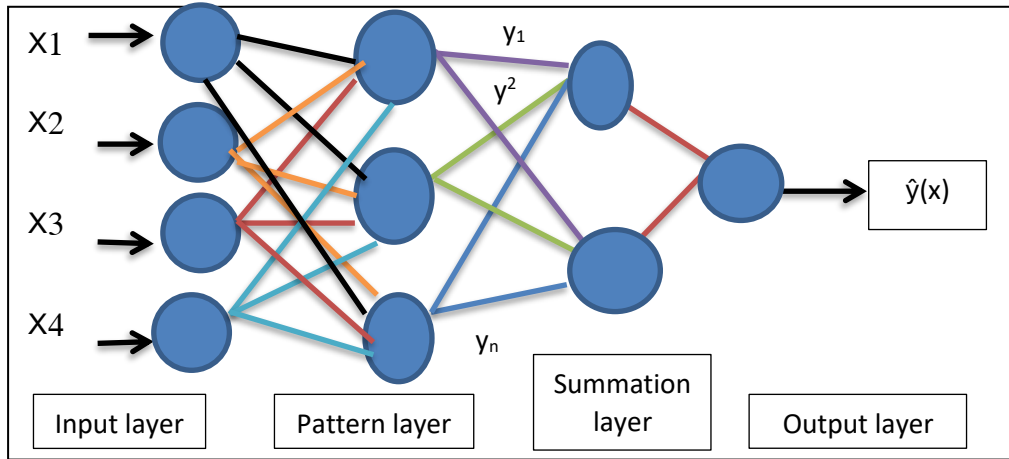
وثابت للتدريب LR الذي تتراوح قيمته بين الصفر والواحد، وبعد الانتهاء من عملية التدريب والاختبار يتم التعامل مع الشبكة المدربة كصندوق مغلق يتضمن علاقات محسوبة ومختزنة بين متغيرات كل طبقة ومتغيرات الطبقة التالية لها. ومع إدخال مجموعة جديدة من البيانات إلى الشبكة المدربة والمختبرة، يتم الحصول على مخرجات جديدة هي النتائج المطلوبة والمرتبطة بهذه البيانات الجديدة.

ثالثا: شبكة الانحدار العصبية المعممة (Generalized Regression Neural Networks)

لا تزال الشبكة العصبية وخاصة ذات التغذية المرتجعة تحتاج الي التدخل البشري، أي أن تحديد الطبقة المخفية وعدد الخلايا العصبية للطبقة المخفية لا يزال يعتمد على المستخدم. هناك طريقة بديلة لتجنب هذه المشكلة وهي شبكة الانحدار العصبية المعممة (GRNN)، هذا النوع من الشبكات العصبية يحتوي على طبقتين ثابتتين ويُدعا طبقتي الأنماط (patterns) وطبقة الجمع (summation)، تم اقتراح شبكة الانحدار العصبية المعممة من قبل العالم (Specht) وذلك في عام 1991، لإنجاز الانحدار العام سواء كان خطيًا أم غير خطي، إذ تستخدم لحل أنواع متعددة من المسائل كالتنبؤ (Prediction) والسيطرة (Control)، وقد استندت خوارزمية هذه الشبكة الى نظرية الانحدار اللاخطي من جهة والشبكات العصبية الاحتمالية من جهة اخري (A. Konate & N. Khan, 2015)، يتم مرور البيانات في طريق واحد؛ ولا يلزم إجراء تكراري؛ ويقتصر التقدير على الحد الأدنى والحد الأقصى للبيانات، وبالتالي فإن هيكل هذه الشبكة ثابت وبسيط، وتتميز هذه الشبكة بإمكانية التدريب السريع مما يلغي الحاجة إلى التكرار أو العمليات الحسابية المعقد، وتتضمن شبكة الانحدار العصبية المعممة في تركيبها علي دالة (Radial Basis Function) دالة الأساس الشعاعي، وهي دالة كثافة احتمالية شائعة مثل دالة غاوس (Gaussian Function)، التي تمكن الشبكة من التعامل بفعالية مع التصنيفات غير الخطية، حتى في الحالات التي تكون فيها بيانات التدريب محدودة، تعمل شبكة الانحدار العصبية المعممة (GRNN) عبر مقارنة متجهات بيانات الإدخال مع بيانات التدريب باستخدام خلايا عصبية متعددة. في هذه الشبكة، يتم مقارنة التشابه بين متجهات الإدخال وبيانات التدريب، مما يساعد في تصنيف

البيانات استنادًا إلى قيم التشابه الناتجة. تقوم الشبكة باستخدام دالة الأساس الشعاعي (RBFNs) كخلايا عصبية لإجراء عملية المقارنة. تقوم دالة الأساس الشعاعي بإعطاء أوزان متفاوتة للمدخلات، وبالتالي يتم حساب مجموع الأوزان لإنتاج قيمة التشابه (Similarity). فإذا كانت قيمة متجه بيانات الإدخال قريبة من متجه بيانات التدريب، فسيتم تعيين قيمة تشابه عالية. على العكس، إذا كانت القيمة بعيدة عن بيانات التدريب، فلن يتم تعيين قيمة تشابه عالية لها. تُستخدم مقارنة قيم التشابه لتصنيف البيانات غير الخطي استنادًا إلى التشابه بين المدخلات وبيانات التدريب (Hilmi Berk, 2006). يُعتبر استخدام دالة كثافة الاحتمال (RBFNs) مفيدًا بشكل خاص نظرًا لقدرتها العالية على التكيف مع الوظيفة الأساسية للبيانات، حتى في حالة وجود بيانات تدريب محدودة. في الشكل التالي توضيح للهيكل العام لشبكة الانحدار العصبية المعممة

المصدر: (Konaté, Ahmed, 2014)



الشكل (2) يوضح الهيكل العام لشبكة الانحدار العصبية المعممة

ومن الشكل السابق نجد ان هيكل GRNN يتكون من عدة طبقات، اولاً: طبقة الإدخال وهي مرتبطة تمامًا بالطبقة المخفية والتي تسمى بـ "طبقة النمط". وفي طبقة النمط، وتمثل كل خلية عصبية نمطًا تدريبيًا، ويعكس ناتج الخلية مقياسًا للمسافة بين البيانات المدخلة والأنماط المخزنة. ومن ثم ترتبط الطبقة المخفية (طبقة النمط) بالكامل بالطبقة الثالثة المسماة "طبقة التجميع". وتتألف طبقة التجميع من نوعين من الخلايا العصبية:



1. الخلايا العصبية التجميعية: S تجمع المخرجات المرجحة القادمة من طبقة النمط.

2. الخلايا العصبية التجميعية: D تحدد المخرجات غير المرجحة للخلايا العصبية النمطية.

اي تقوم خلية عصبية تجميعية (S) بتحديد مجموع المخرجات المرجحة القادمة من الطبقة المخفية، بينما تقوم الخلية عصبية تجميعية (D) بتحديد المخرجات غير المرجحة للخلايا النمط العصبية، يمثل الوزن بين الخلية العصبية في الطبقة المخفية وخلية التجميع (S) قيمة المخرجات المستهدفة (y_i). وتقوم طبقة الجمع والطبقة الأخيرة من الشبكة وهي "طبقة المخرجات، معًا بتدريب الشبكة حيث تستخدم دالة الأساس الشعاعي (Gaussian)، ومما سبق نجد ان

1- مزايا شبكة الانحدار العصبية المعممة (GRNN) (زكريا يحيى، عمر صابر، 2012):

توجد العديد من المزايا لشبكة الانحدار العصبية المعممة مما يجعلها خيارًا ممتازًا للتنبؤ بدقة عالية بمخصص التعويضات تحت التسوية وهي كالاتي:

أ- قدرة قوية على التعميم: GRNN قادرة على التنبؤ ببيانات جديدة بناءً على معلومات من عينات تدريبية محدودة، مما يجعلها فعالة في التنبؤ في حالة وجود بيانات قليلة أو غير متوازنة.

ب- بساطة التنفيذ: تتسم GRNN بسهولة التدريب والتنفيذ مقارنة ببعض النماذج الأخرى. فهي لا تتطلب ضبط معاملات معقدة أو تدريب مكثف كما هو الحال في الشبكات العصبية التقليدية.

ج - استجابة سريعة: تعتمد GRNN على حسابات محلية لكل نقطة جديدة بناءً على عينات التدريب، مما يجعلها قادرة على الاستجابة بسرعة لأي تغييرات في البيانات المدخلة.

د- التعامل مع الضوضاء: GRNN تتعامل بشكل جيد مع البيانات الضوضائية أو غير المكتملة، حيث أنها تعتمد على العمليات الإحصائية التي تساعد في تقليل تأثير القيم الشاذة على النتائج النهائية.

هـ- مرونة في التعامل مع التوزيعات المختلفة: يمكن لـ GRNN التعامل مع بيانات ذات توزيعات مختلفة بشكل فعال، دون الحاجة إلى فرض افتراضات محددة حول توزيع البيانات.

و- عدم الحاجة إلى إعدادات مسبقة: بخلاف بعض النماذج الأخرى التي تتطلب ضبط معايير متعددة، GRNN تعتمد بشكل كبير على الهيكل الافتراضي للنموذج، مما يقلل من تعقيد عملية الإعداد.

ي- التقارب نحو القيم المثلى: بفضل الطبيعة الاحتمالية للنموذج، تتميز GRNN بقدرتها على التقارب نحو الحل الأمثل للتنبؤات حتى في حالات البيانات المعقدة.

2- مكونات نموذج شبكة الانحدار العصبية المعممة (GRNN)، (Sanjay, et al,2015)

تعتمد شبكة الانحدار العصبية المعممة (GRNN) على معادلات رياضية أساسية تشتمل على الاحتمالات ودالة الأساس الشعاعي (RBF). وفيما يلي شرح للمعادلات الرئيسية التي يعتمد عليها هذا النموذج :

نفترض أن لدينا دالة الاحتمال المشتركة $f(x, y)$ لتقدير القيمة التنبؤية اعتمادا على مجموعة من المدخلات X ، والمخرجات y الهدف هو تقدير القيمة الشرطية $E[y|x]$ أي القيمة التنبؤية للمخرج y ، وتكتب أيضا (انحدار y بمعلومية x). ويتم تعريفها بواسطة المعادلة الآتية:

$$E[y|x] = \frac{\int_{-\infty}^{\infty} y f(x,y) dy}{\int_{-\infty}^{\infty} f(x,y) dy} \dots\dots\dots (1)$$

حيث $E[y|x]$: هي التوقع الشرطي للقيمة y عندما تكون قيمة X معروفة.

$f(x, y)$: هي الكثافة الاحتمالية المشتركة بين x و y .

$$x \text{ هو التوقع الشرطي لعدد القيم } y \text{ بالنظر إلى قيمة } x : \int_{-\infty}^{\infty} y f(x, y) dy$$

$$x \text{ هو الكثافة الاحتمالية الهامشية } f(X) \text{ للمتغير } x : \int_{-\infty}^{\infty} f(x, y) dy$$



عندما تكون دالة الكثافة $f(x, y)$ غير معلومة، فإنه يمكن تقديرها باستخدام عينة من المشاهدات الخاصة للمتغيرين x و y ، للحصول على تقدير غير معلمي لدالة الكثافة، يتم استخدام توزيع بارزن (Parzen)، الذي لا يفترض أي شكل مسبق للدالة، وتعتبر هذه الطريقة مناسبة لتقدير دالة الكثافة الاحتمالية f ، وتأخذ الدالة المقدر الشكل الآتي:

$$\hat{f}(x, y) = \frac{1}{(2\pi)^{\frac{p+1}{2}} \sigma^{p+1}} \times \frac{1}{n} \sum_{i=1}^n \exp \left[-\frac{(x-x^i)^T (x-x^i)}{2\sigma^2} \right] \times \exp \left[-\frac{(y-y^i)^2}{2\sigma^2} \right] \dots \dots \dots (2)$$

حيث: $\hat{f}(x, y)$ هو تقدير الكثافة الاحتمالية المشتركة وتعتمد تقدير الكثافة على قيم التدريب العينية X^i لعينة المدخلات (X) ، وقيم التدريب العينية للمخرجات Y^i لعينة المخرجات (Y) ، كما تشير n الي هو عدد العينات التدريبية.، كما تشير p الي عدد أبعاد المدخلات X ، و (σ) هو معلم عرض النواة (*bandwidth*) الذي يحدد مدى تأثير كل عينة على التقدير

ان التفسير الفيزيائي لتقدير الاحتمال $\hat{y}(x, y)$ هو أنه يخصص احتمالاً لكل عينة بناءً على عرض محدد (σ) لكل قيمة من قيم X^i وأيضا لكل قيمة من قيم Y^i ، ويتم الحصول على التقدير الكلي للاحتمال من خلال جمع هذه الاحتمالات لكل عينة. لذلك عند استبدال تقدير الكثافة المشترك $\hat{f}(x, y)$ ، في المعادلة 2 داخل صيغة المتوسط الشرطي في المعادلة 1، فننا نحصل على المتوسط الشرطي المطلوب لـ y بالنظر إلى X ، يؤدي دمج المعادلتين 1 و 2 الي الحصول علي الحصول على (تقدير) قيمة y المجهولة بمعلومية قيمة x كالآتي:

$$\hat{y}(x) = \frac{\sum_{i=1}^n \exp \left[-\frac{(x-x^i)^T (x-x^i)}{2\sigma^2} \right] \int_{-\infty}^{\infty} y \exp \left[-\frac{(y-y^i)^2}{2\sigma^2} \right] dy}{\sum_{i=1}^n \exp \left[-\frac{(x-x^i)^T (x-x^i)}{2\sigma^2} \right] \int_{-\infty}^{\infty} \exp \left[-\frac{(y-y^i)^2}{2\sigma^2} \right] dy} \dots \dots \dots (3)$$

ولحساب "المسافة" أو الفرق بين عينة التدريب ونقطة التنبؤ (المسافة الإقليدية المربعة) في مرحلة الإدخال من خلال المعادلة التالية:

$$D_i^2 = (x - x^i)^T (x - x^i) \dots \dots \dots (4)$$

ولتبسيط المعادلة رقم (3) ودمجها مع المعادلة رقم (4) $\hat{y}(x)$ لتصبح كالآتي:

$$\hat{y}(x) = \frac{\sum_{i=1}^n y^i \exp\left[-\frac{D_i^2}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{D_i^2}{2\sigma^2}\right]} \dots\dots\dots(5)$$

تُمثل التنبؤات باستخدام شبكة الانحدار العصبية المعممة (GRNN)، حيث يعمل العامل الأسّي ($\exp\left[-\frac{D_i^2}{2\sigma^2}\right]$) كمعامل وزن (weighting parameter) لكل نقطة تدريب بناءً على المسافة الإقليدية D_i ، بين نقطة الإدخال X نقطة التدريب X_i وهذه الدالة تُظهر كيف تتأثر التنبؤات بناءً على قرب نقطة التدريب من نقطة التنبؤ، كما يلي:

كلما كانت نقطة التدريب X_i أقرب إلى نقطة الإدخال X ستكون المسافة الإقليدية D_i صغيرة، وبالتالي ستزداد قيمة العامل الأسّي هذا يعني أن العينات الأقرب سيكون لها تأثير أكبر في تقدير التنبؤ. في المقابل، كلما كانت المسافة أكبر، سيكون تأثير نقطة التدريب أقل على التنبؤ. لذا، العينات البعيدة ستساهم في التقدير بشكل ضعيف.

كما ان معامل التنعيم (σ) اذا كان صغيراً، قد تتأثر التقديرات بشكل كبير بالقيم البعيدة، مما قد يؤدي إلى نتائج غير دقيقة، وعلي العكس اذا كان معمل التنعيم كبيراً فان ذلك يؤدي إلى تنعيم أكبر للكثافة الاحتمالية. وبالتالي، القيم ستكون أكثر انتشاراً ويقل التأثير المباشر للعينات البعيدة، مما يؤدي إلى "تنعيم" التقديرات وجعلها أكثر سلاسة.

ونجد ان الحد الأسّي في البسط يمثل وزن كل قيمة ملاحظة Y^i ، بينما المقام يجمع جميع الحدود الأسية لتوفير عملية التطبيع المناسبة. وبالتالي يؤدي ذلك إلى أن تكون النتيجة النهائية تقديراً مرجحاً يعتمد على قرب نقطة التدريب من نقطة التنبؤ، مما يجعل التقديرات أكثر دقة وملائمة لنمط البيانات. وتُعتبر GRNNs من أنواع الشبكات العصبية التتابعية، حيث تنتقل الإشارات من الطبقة الأولى الادخال مرورا بطبقة النمط، وطبقة الجمع إلى الطبقة الأخيرة وهي طبقة الإخراج، وترتبط عدد الخلايا العصبية في طبقتي الإدخال والإخراج بعدد المتغيرات المستقلة P والمتغيرات التابعة Q ، تلعب طبقة الإدخال دوراً في نقل البيانات إلى طبقة النمط، حيث تتساوى عدد الخلايا العصبية مع عدد عينات التدريب. تُستخدم دالة التنشيط الأساسية الشعاعية لقياس المسافة بين



المدخلات وعينات التدريب، مما يُعزز من فعالية النموذج. تأخذ دالة التنشيط الشكل التالي
(2022،Kopal., et al)

$$\varphi_i(x, x_i) = \exp [-(D_i(x, x_i) \times b)^2] \dots \dots \dots (6)$$

حيث b يمثل تحيز الخلايا العصبية وهو الذي يلعب دور التباين σ^2 في دالة التنشيط Gaussian φ_i ، بتعديل حساسية الخلايا العصبية لطبقة النمط، ويمكن حسابه مباشرة من المعادلة الآتية
(2020،Sharkawy)

$$b = \frac{\sqrt{-\ln(0.5)}}{\sigma} \approx \frac{0.8236}{\sigma} \dots \dots \dots (7)$$

إذا كانت قيمة b كبيرة، ستكون دالة التنشيط شديدة الحساسية لتغيرات صغيرة في المسافة بين X و X_i مما يجعل الشبكة أكثر حساسية للبيانات القريبة. بينما إذا كانت قيمة b صغيرة، سيكون التأثير أوسع على البيانات البعيدة، مما يجعل الشبكة أكثر استقرارًا لكن أقل دقة في التنبؤات التي تعتمد على بيانات قريبة جدًا.

ونجد ان كل خلية عصبية في طبقة النمط تتصل بنوعين من الخلايا العصبية في طبقة الجمع: أولاً خلية الجمع S_N ، وهي التي تقوم بحساب مجموع المخرجات المرجحة من خلايا طبقة النمط. تُستخدم خلية S_N لتجميع المعلومات وتحويلها إلى ناتج نهائي، مما يعزز فعالية نموذج الشبكة العصبية من خلال المعادلة الآتية:

$$S_N = \sum_{i=1}^n y_i \varphi_i \dots \dots \dots (8)$$

خلية الجمع S_D ، التي تحسب ببساطة المجموع غير المرجح لمخرجات كل خلية عصبية في طبقة النمط، تلعب دورًا مهمًا في عملية تجميع المعلومات. بينما تركز خلية S_N على المخرجات المرجحة، تتيح خلية S_D تقييم جميع المخرجات بشكل متساوٍ. هذا يساهم في تحسين دقة النموذج ويزيد من فعالية عملية اتخاذ القرار النهائية.

$$S_D = \sum_{i=1}^n \varphi_i \dots \dots \dots (9)$$

وفي النهاية تقوم طبقة الإخراج ببساطة بقسمة ناتج خلية الجمع SN على ناتج خلية الجمع SD، مما ينتج عنه القيمة المتوقعة

$$y(x) = \frac{S_N}{S_D} \dots \dots \dots (10)$$

على عكس الشبكات العصبية المعتمدة على أسلوب التراجع الخاطئ، التي تتطلب التدريب التكراري لعدة جولات لتحديد أوزان الاتصالات بين الخلايا العصبية في الطبقات المختلفة، تُحدد بنية وأوزان الشبكات العصبية المعممة (GRNN) عند إدخال البيانات. يتم التعامل مع كل عينة بيانات كمتوسط لتوزيع طبيعي (Huang & Liao, 2020).

3- مقاييس الأداء

تبدأ هذه الخطوة مباشرة بعد انتهاء عملية التدريب، إذ يجري اختبار أداء النموذج المدرب للشبكة العصبية عن طريق تطبيقه على بيانات من خارج عينة التدريب للتحقق من دقة الأداء، ويفترض بنموذج الشبكة GRNN أن يكون أداؤه معمماً على عينة الاختبار للحكم على دقته (Specht, 1991)، إذ تُشير دقة الأداء إلى مدى قدرة نموذج الشبكة العصبية في تقدير عينة الاختبار، وعلى الرغم من ذلك، فإن دقة التنبؤ لا تعني بالضرورة أن تكون النتائج دقيقة كلياً، فمهما بلغت دقة الأساليب المستخدمة في التنبؤ يبقى هنالك احتمالاً لوجود بعض الانحرافات في القيمة المتوقعة عن القيم الحقيقية وهذا ما يدعى بخطأ (Forecasting Error)، إذ يُعرف خطأ التنبؤ بأنه الفرق بين القيمة الحقيقية والقيمة المتنبأ بها وفقاً للمعدلة التالية:

$$\varepsilon_i = (\alpha - \gamma) \dots \dots \dots (11)$$

حيث α يُمثل القيمة الحقيقية، γ يُمثل القيمة المتوقعة.

وعلى أساس ذلك يتم تقييم أداء نموذج انحدار الشبكة العصبية المعممة وفقاً لمقاييس الأداء المعروفة كمقياس متوسط مربعات الخطأ (MSE)، وجذر متوسط مربعات الخطأ (RMSE)، فضلاً عن معامل الارتباط (R) لقياس العلاقة بين القيم الحقيقية والقيم المتنبأ بها، إذ كلما



انخفضت قيمة مقاييس الخطأ وارتفعت نسبة معامل الارتباط دل ذلك على زيادة دقة النموذج، وتحسب مقاييس الأداء وفقاً للمعادلات الآتية.

أ- متوسط مربع الأخطاء (MSE) Mean Squared Error (الهاشيمي، 2022):

يُحسب متوسط مربعات الخطأ عن طريق تربيع الأخطاء وقسمتها على عدد المشاهدات، إذ يُستخدم هذا المقياس لتجاوز إزالة القيم السالبة ولكن يأخذ عليه تضخيم قيمة الخطأ، ويحسب كما في المعادلة الآتية:

$$MSE = \frac{1}{n} \times \sum_{i=1}^n \varepsilon_i^2 \dots \dots \dots (12)$$

ب- جذر متوسط مربع الأخطاء (RMSE) Root Mean Squared Error (De Mauro، 2021):

بغرض تجاوز مشكلة تضخيم الأخطاء في المقياس السابق، يُستخدم الجذر التربيعي لقيمة (MSE) ويحسب كما في المعادلة الآتية:

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n \varepsilon_i^2} \dots \dots \dots (13)$$

ج- معامل الارتباط (R) Correlation Coefficient (Kaaria، 2012):

يُعرف معامل الارتباط بأنه مقياس إحصائي يقيس قوة واتجاه العلاقة بين متغيرين، وتتراوح قيمته ما بين (1+ و 1-)، إذ كلما اقتربت درجة الارتباط من الواحد كلما كان الارتباط قوياً وموجباً ويحسب معامل التحديد وفقاً للمعادلة الآتية:

$$R = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \dots \dots \dots (14)$$

- المبحث الثالث- الدراسة التطبيقية: تقدير مخصص التعويضات تحت التسوية

باستخدام نموذج شبكات الانحدار العصبية المعممة (GRNN):

أولاً: بيانات البحث:

تعتمد الباحثة في هذا البحث على بيانات التأمين البحري فرع النقل البحري لشركة مصر للتأمين بوصفها الرائدة في هذا المجال بسوق التأمين المصري خلال الفترة من عام 2008/2007 إلى عام 2023/2022 للتنبؤ بمخصص التعويضات تحت التسوية، ثم مقارنة النتائج المتوقعة بالنتائج الفعلية لنموذج ويمثل الجدول الآتي القيم الفعلية لكل من: (الأقساط المكتسبة، والتعويضات المسددة، ومخصص التعويضات تحت التسوية) عن النشاط المباشر لفرع النقل البحري لشركة مصر للتأمين.

جدول (1) تطور الأقساط المكتسبة والتعويضات المسددة ومخصص التعويضات تحت التسوية خلال الفترة من 2008/2007 الي 2023/2022

السنة	الأقساط المكتسبة	التعويضات المسددة	مخصص التعويضات تحت التسوية
2008/2007	115422	28864	199945
2009/2008	122375	35781	186120
2010/2009	118721	11380	138568
2011/2010	101774	19757	188421
2012/2011	96524	46177	180608
2013/2012	110786	23948	210008
2014/2013	117059	85160	183972
2015/2014	166984	67292	146751
2016/2015	168969	44095	181822
2017/2016	205511	96512	423034
2018/2017	279568	61534	276384
2019/2018	254174	72760	317093
2020/2019	240798	50382	287310
2021/2020	196471	45997	201965
2022/2021	220988	90506	184295
2023/2022	306004	185163	124648

المصدر: من اعداد الباحثة بناء على الكتاب الاحصائي السنوي لنشاط التأمين من سنة 2008/2007 الي 2023/2022



من الجدول السابق نجد ان الاتي:

1- الأقساط المكتسبة:

من الجدول، يظهر أن الأقساط المكتسبة شهدت نموًا عامًا على مر السنوات، حيث ارتفعت من (115,422) في عام 2008/2007 إلى (306,004) في عام 2023/2022. يعكس هذا النمو توسعًا مستمرًا في نشاط التأمين على النقل البحري وزيادة في حجم الأعمال، كما يتضح أن هناك بعض التقلبات الواضحة في معدل النمو السنوي للأقساط، مثل الزيادة الكبيرة بين عامي 2022/2021 و 2023/2022. ومع ذلك، فإن الاتجاه العام للسنوات 2017-2023 يظهر زيادة في حجم الاقساط.

2- التعويضات المسددة:

بالنسبة للتعويضات المسددة، نلاحظ زيادة عامة على مر الفترة محل الدراسة، حيث بدأت بـ (28,864) في عام 2008 ووصلت إلى (185,163) في عام 2023، ورغم هذا النمو العام، تخللت هذه الفترة بعض التغيرات السنوية الحادة، خاصة في عام 2023/2022 حيث بلغت التعويضات (185,163)، مما قد يعكس تأثير العوامل الجيوسياسية أو تغيرات في السوق البحري. شهدت التعويضات المسددة تقلبات كبيرة بين عامي 2017 و 2023، وهو ما قد يدل على ارتفاع في عدد المطالبات أو قيمتها. تبرز هذه التقلبات الحاجة إلى تقييم مستمر لإستراتيجيات الشركة وتحديد نهج إدارة المخاطر لضمان كفاية المخصصات المالية لتغطية هذه المطالبات.

أ- نسبة الأقساط المكتسبة إلى التعويضات المسددة: تظهر علاقة طردية بين الأقساط المكتسبة والتعويضات المسددة، حيث يزداد حجم التعويضات مع ارتفاع الأقساط المكتسبة. مما يعكس ذلك ازدياد المخاطر أو توسع قاعدة المؤمن عليهم، مما يؤكد على ضرورة إعداد استراتيجيات مالية تغطي هذه العلاقة.


ب- الارتباط بين التعويضات المسددة ومخصص التعويضات تحت التسوية: يشير الارتباط بين التعويضات المسددة ومخصص التعويضات تحت التسوية إلى أن ارتفاع التعويضات يتطلب زيادة

مخصص التعويضات لتغطية المطالبات المحتملة. وتبرز البيانات أن التغيرات في التعويضات تتزامن مع تذبذب المخصص، مما يستدعي دراسة وتحليل مدى كفاية المخصص.

3- مخصص التعويضات تحت التسوية:

بدأ مخصص التعويضات تحت التسوية بمبلغ (199,945) في 2008 وشهد تقلبات ملحوظة خلال فترة الدراسة، ففي الفترة من 2008 إلى 2012، كانت هناك زيادة تدريجية، تلتها فترات من الانخفاض حتى 2017، ثم شهد المخصص زيادة ملحوظة في 2016/2017 حيث بلغ (423,034)، وهو أعلى مستوى سجل خلال فترة الدراسة. يمكن أن يُعزى هذا الارتفاع إلى زيادة عدد المطالبات أو ارتفاع قيمة الأضرار في تلك الفترة، كما هو موضح في الرسم البياني التالي:

المصدر: من اعداد الباحثة بناء على الجدول رقم (1) باستخدام برنامج الاكسيل



شكل بياني (3) يوضح تطور مخصص التعويضات تحت التسوية لشركة مصر للتأمين خلال فترة الدراسة

ومن الرسم البياني نجد أيضا ان مخصص التعويضات تحت التسوية شهد انخفاضا ملحوظا في السنوات التالية ليصل إلى أدنى مستوى له عند (124,648) في 2022/2023. قد يعكس هذا الانخفاض تحسنا في إدارة المخاطر أو انخفاضا في حجم المطالبات، إلا أن التغيرات الكبيرة، خاصة انخفاض المخصص في 2023/2022 مع زيادة التعويضات، تشير إلى احتمال عدم كفاية الاحتياطات لمواجهة المطالبات.



كما يُظهر الجدول رقم (1) كما يُظهر الجدول بعض الحالات التي كانت فيها التعويضات المسددة أعلى من مخصص التعويضات مثل عام 2013/2014، حيث بلغت قيمة التعويضات المسددة (85,160) مقابل مخصص تعويضات تحت التسوية بقيمة (183,972)، مما يدل على إدارة أكثر تحفظاً لمخصص في تلك الفترة. وعلى النقيض، في 2023/2022 انخفض المخصص إلى (124,648) بينما ارتفعت التعويضات إلى (185,163)، مما يشير إلى اختلال محتمل في تخصيص في قيمة هذا المخصص. ولذلك كان من المهم تحديد دقيق لمخصص التعويضات تحت التسوية.

ثانياً: الإحصاءات الوصفية لمخصص التعويضات تحت التسوية:

قمنا بتحليل احصائي وصفي لبيانات مخصص التعويضات تحت التسوية باستخدام برنامج الاكسيل كما يلي:

جدول (2) يوضح الإحصاء الوصفي لمخصص التعويضات تحت التسوية خلال فترة الدراسة

الاحصائيات	النتائج
عدد المشاهدات	16
الحد الأدنى	124,648
الحد الأقصى	423,034
الوسيط (Median)	187,270.5
المتوسط (Mean)	214,434
الانحراف المعياري (Standard Deviation)	76,379.36
الخطأ المعياري (Standard Error)	19,094.84
التباين (Sample Variance)	5,833,806,487
التفرطح (Kurtosis)	2.65
الالتواء (Skewness)	1.56

المصدر: من اعداد الباحثة بناء على الجدول (1)

تشير قيمة الوسيط البالغة (187,270.5) إلى أن غالبية البيانات تتوزع في نطاق أقل من المتوسط (214,434)، مما يعني أن هناك بعض القيم العالية التي أدت إلى رفع المتوسط. وهذا يعكس وجود سنوات محددة، مثل عام 2017/2016، التي شهدت ارتفاعاً كبيراً في المخصص،

مما أثر على المتوسط العام للبيانات. ويمكن تفسير هذا الارتفاع بوجود قيم متطرفة تؤثر على المتوسط وتدفعه للزيادة. كما بلغ الانحراف المعياري (76,379.36)، مما يعكس درجة كبيرة من التباين في بيانات المخصص. يشير هذا التشتت العالي إلى أن القيم لا تتمحور بشكل كبير حول المتوسط البالغ (214,434)، بل تتوزع على نطاق واسع، مما يدل على وجود تفاوت ملحوظ في مستويات المخصص بين السنوات. هذا التباين قد يكون مرتبطاً بتغيرات موسمية أو عوامل أخرى تؤثر على حجم المطالبات بمرور الوقت. تظهر قيمة الخطأ المعياري البالغة (19,094.84) تشتتاً مرتفعاً نسبياً في البيانات، مما يجعل من الصعب استنباط تقدير دقيق للمخصص المستقبلي دون تصفية القيم المتطرفة. ولذلك، ينبغي التخلص من القيم الشاذة أو تحليلها بشكل منفصل لتوفير تقديرات أكثر استقراراً وموثوقية للمخصصات المستقبلية. أما التفرطح الذي بلغت قيمته (2.65)، فيشير إلى توزيع ذي قمة حادة وذيل طويلة، مما يعني أن بيانات المخصص تتضمن تقلبات حادة وغير اعتيادية في بعض السنوات. يعكس هذا التوزيع وجود سنوات ذات مطالبات مرتفعة بشكل ملحوظ، وهو ما يجب أخذه بعين الاعتبار في التخطيط المالي للشركة. يمكن أن يكون هذا التباين الحاد مؤثراً على حاجات مالية متغيرة عبر السنوات وتفاوت في المخاطر التي يجب استيعابها. قيمة الالتواء الموجبة البالغة (1.56) تدل على وجود انحراف نحو القيم الأعلى، مما يشير إلى أن بعض السنوات، مثل تلك التي تضمنتها أحداث غير متكررة، شهدت مخصصات تعويضات مرتفعة مقارنة بالسنوات الأخرى. يُرجع ذلك غالباً إلى حدوث أزمات أو ظروف استثنائية أدت إلى زيادة عدد المطالبات أو قيمتها. ويعد تحليل هذا الالتواء ضرورياً لتحديد الاستراتيجيات المالية الملائمة لمواجهة الارتفاعات المفاجئة في المطالبات.

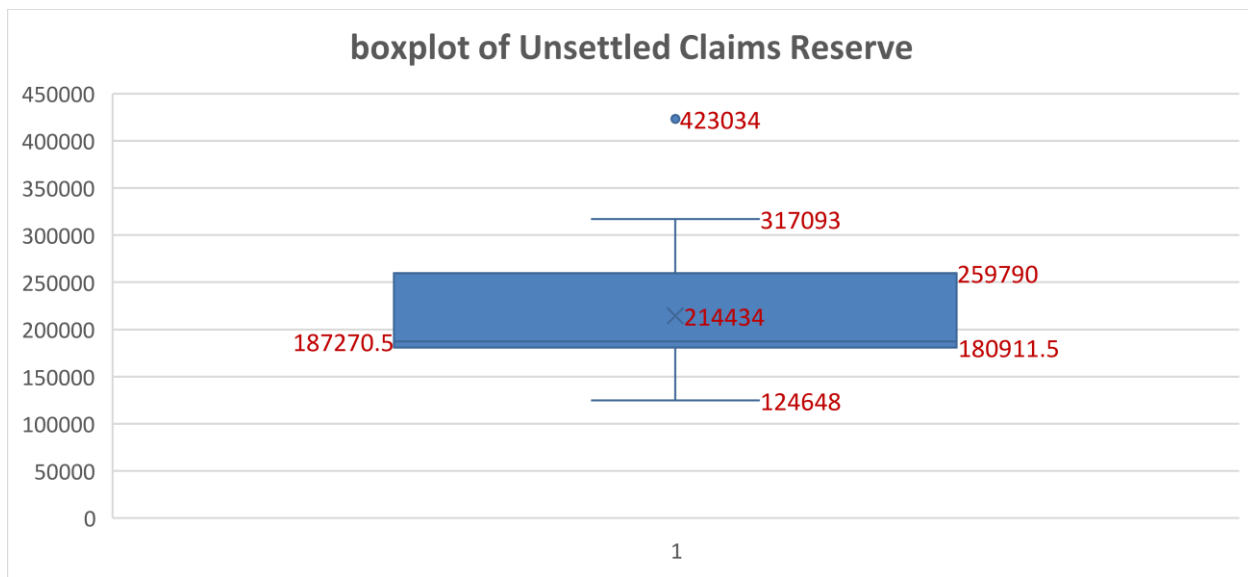
لذلك إن وجدود قديم شاذة بالسلسلة الزمنية يؤثر على مخرجات التنبؤ للنماذج الاحصائية المستخدمة (، أحمد عبد الرحيم خليل ، وآخرون، 2020)، ولمعرفة ما إذا كانت هناك قيم شاذة ببيانات السلسلة الزمنية لمعدل الخسارة لفرع تأمين النقل البحري خلال فترة الدراسة سوف يتم استخدام مخطط الصندوق (Box Plot)، لمعرفة القيم الشاذة داخل المخصص

1- تحليل مخطط الصندوق (Box Plot) لتحديد القيم الشاذة داخل مخصص التعويضات تحت التسوية



يُعد مخطط الصندوق (Box Plot) أداة قوية لتحليل البيانات، حيث يقدم تصوراً شاملاً لنطاق البيانات وتوزيعها، حيث يمثل الخط الأوسط داخل الصندوق الوسيط، في حين تحدد حدود الصندوق نطاق الربعين الأول والثالث. مما يساعد في توضيح نطاق القيم المعتادة، وأي قيمة تقع خارج هذا النطاق تُعتبر غير نمطية أو قيمة شاذة. وعند تحليل مخصص التعويضات تحت التسوية باستخدام مخطط الصندوق (Box Plot)، تبين أن القيمة (423,034)، تعتبر قيمة شاذة وتقع خارج نطاق الصندوق، مما يشير إلى تباعدها عن باقي القيم كما هو موضح في الشكل التالي:

المصدر: من اعداد الباحثة من الجدول رقم (1) باستخدام برنامج الاكسيل



شكل (4) يوضح تحليل مخطط الصندوق (Box Plot) لمخصص التعويضات تحت التسوية لفرع تأمين النقل البحري لشركة مصر للتأمين خلال فترة الدراسة.

ونظراً لأن القيمة (423,034) تُعد قيمة شاذة وتبعد عن القيم الأخرى في بيانات مخصص التعويضات تحت التسوية، فإن إدراجها في التحليل التنبؤي دون تعديل قد يؤدي إلى انحراف النتائج ورفع المتوسط بشكل غير واقعي. وللحصول على تقديرات دقيقة وأكثر استقراراً للتنبؤ بالمخصصات المستقبلية، يُفضل استبدال هذه القيمة إما بـ المتوسط أو الوسيط، حيث نجد أن المتوسط يكون مفيداً إذا كانت البيانات موزعة بشكل طبيعي وبدون قيم شاذة كثيرة، لأن المتوسط يتأثر بالقيم العالية أو المنخفضة بشدة. استخدام المتوسط يكون مناسباً في حال كانت القيمة الشاذة حالة منفردة وغير بعيدة جداً عن بقية البيانات. أما الوسيط يكون أفضل إذا كانت البيانات تحتوي على قيم شاذة متعددة أو كانت غير موزعة توزيعاً طبيعياً، لأن الوسيط أقل حساسية للقيم الشاذة ويوفر تمثيلاً أكثر استقراراً للمركز (Avanzi, et al, 2024). وحيث ان لدينا قيمة شاذة تمثل

حالة فريدة وبعبارة عن باقي البيانات، فإن الوسيط قد يكون خياراً أفضل لأنه يحافظ على استقرار البيانات ويقلل من التأثيرات غير المرغوبة. وبالتالي يصبح مخصص التعويضات تحت التسوية لفرع النقل البحر لشركة مصر للتأمين خلال الفترة من 2008/2007 الي 2023/2002 كما يلي:

جدول (3) يوضح مخصص التعويضات بعد معالجة القيم الشاذة

السنة	مخصص التعويضات تحت التسوية
2008/2007	199945
2009/2008	186120
2010/2009	138568
2011/2010	188421
2012/2011	180608
2013/2012	210008
2014/2013	183972
2015/2014	146751
2016/2015	181822
2017/2016	* <u>186120</u>
2018/2017	276384
2019/2018	317093
2020/2019	287310
2021/2020	201965
2022/2021	184295
2023/2022	124648

المصدر: من اعداد الباحثة بعد اجراء التعديل (* تمثل القيمة بعدل التعديل)

الجدول السابق (3) يوضح استبدال قيمة (423034) بالقيمة الوسيطة (187270.50)، التي تعكس بشكل أفضل تمثيل البيانات العامة. يُعتبر الوسيط خياراً مناسباً في هذه الحالة نظراً لأنه أقل تأثراً بالقيم الشاذة، مما يتيح نتائج أكثر دقة وموثوقية في التحليل. هذا التعديل يضمن تحسين جودة النتائج ويساهم في تعزيز مصداقية البحث.



2-الإحصاء الوصفي بعد تعديل القيمة الشاذة:

وتم اجراء إحصاء وصفي بعد القيم الشاذة وتم الحصول على النتائج الاتية

جدول (4) يوضح الإحصاء الوصفي بعد تعديل القيم الشاذة

الاحصائيات	النتائج
عدد المشاهدات	16
الحد الأدنى	124,648
الحد الأقصى	317,093
الوسيط (Median)	186,120
المتوسط (Mean)	199,626.88
الانحراف المعياري (Standard Deviation)	52,463.83
الخطأ المعياري (Standard Error)	13,115.96
التباين (Sample Variance)	2,752,453,645
التفرطح (Kurtosis)	0.74
الالتواء (Skewness)	1.02

المصدر: من اعداد الباحثة بناء على الجدول (3)

تم اجراء التحليل الوصفي للجدول رقم (3) بعد استبدال القيمة الشاذة، لتقليل التأثيرات السلبية للقيم الشاذة التي قد تؤدي إلى تشوه النتائج، نلاحظ ان انخفاض المتوسط من (214,434) إلى (199,626)، يمثل هذا الانخفاض تحسناً في دقة البيانات المتوسطة، مع توجه القيم نحو التوزيع العام للبيانات، وتقليل احتمالية التحريف الناتج عن القيم غير الطبيعية. وعند النظر إلى القيم القصوى، نجد أن الحد الأقصى أصبح (317,093)، ويشير هذا الانخفاض إلى أن القيمة (423034) كانت تمثل قفزات كبيرة في البيانات، والتي تم التعامل معها لإعادة القيم إلى نطاق أقرب إلى باقي العينات، مما يقلل من التباين ويجعل البيانات أكثر تمثيلاً. كما انخفضت قيمة كلا من الانحراف المعياري والتباين يعكس هذا الانخفاض الملحوظ على تقليل انتشار القيم حول المتوسط، وبالتالي تعزيز تجانس البيانات وجعلها أقل عرضة للتأثيرات الكبيرة للقيم الخارجة عن النطاق. وأيضاً فقد انخفض التفرطح من (2.65) إلى (0.74)، مما يشير إلى أن التوزيع أصبح

أقل حدة وأقرب إلى التوزيع الطبيعي، كما انخفض الانتواء من (1.56) إلى (1.02)، مما يدل على أن التوزيع أصبح أقل انحرافاً نحو القيم العالية، مما يعزز التوازن في توزيع البيانات.

بعد الانتهاء من معالجة البيانات من القيمة الشاذة وفقاً لما سبق، سوف نقوم بتطبيق شبكات الانحدار العصبية المعممة في التنبؤ بمخصص التعويضات تحت التسوية لفرع تامين النقل البحري لشركة مصر للتأمين وذلك باستخدام برنامج (MATLab) الإصدار (R2024) باعتماد على القيم الفعلية لمتغيرات الدراسة (الأقساط المكتسبة، التعويضات المسددة، مخصص التعويضات تحت التسوية) من الفترة 2008/2007 الي 2023/2022 كما يلي:

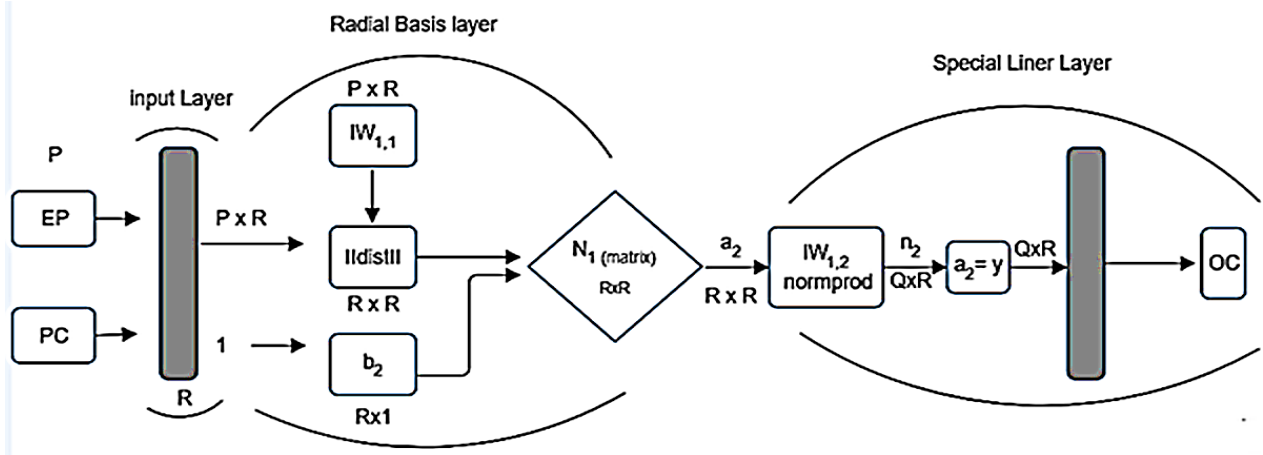
ثالثاً: تطبيق النموذج المقترح:

سوف نقوم بتطبيق نموذج انحدار الشبكة العصبية المعممة باستخدام حزمة برنامج ال (MATLAB) الإصدار 2024 المزود بأداة Neural Network Toolbox والتي توفر عددًا من الأدوات المدمجة للعمل بفعالية وسهولة مع الشبكات العصبية الاصطناعية من مختلف الأنواع والهياكل. تم استخدام الشبكة العصبية العامة للانحدار (GRNN) للتنبؤ بمخصص التعويضات تحت التسوية لا سيما بسبب معدل تعلمها العالي للغاية وقدرتها على الوصول السريع إلى مستويات الانحدار المثلى، حتى في حالة وجود كمية صغيرة من بيانات التدريب، وتتكون البنية الطوبولوجية لنموذج GRNN المطور باستخدام أداة MATLAB® Neural Network Toolbox من ثلاث طبقات عصبية فقط: طبقة الإدخال، وطبقة RBF المخفية، وطبقة الإخراج الخطية الخاصة كما هو موضح في الشكل التالي:



الشكل (5) يوضح طبقات نموذج الشبكة العصبية العامة للانحدار (GRNN)

1-خطوات تدريب نموذج GRNN:



المصدر: من إعداد الباحثة بناءً على نموذج GRNN المستخدم في برنامج MATLAB

من الشكل السابق نجد ان عملية تدريب GRNN تتضمن الخطوات التالية:

أ-طبقة الإدخال (Input Layer):

في شبكة GRNN، تتلقى طبقة الإدخال مصفوفة بيانات التدريب المدخلة Inputs التي تكون بحجم $P \times 2$ ، حيث يشير P إلى عدد العينات في بيانات التدريب ويمثل الرقم 2 المتغيران المستخدمان في التدريب وهي: الأقساط المكتسبة (EP)، التعويضات المسددة (PC).

1. الأقساط المكتسبة: (Earned Premiums)

يعكس هذا المتغير الأموال التي حصلت عليها شركة التأمين من الأقساط، وهو يعبر عن مستوى المخاطر التي تتحملها الشركة. حيث ان هذه البيانات مفيدة لتوقع حجم التعويضات المطلوبة أو المتوقع تسويتها في المستقبل.

2. التعويضات المسددة: (Paid Claims)

هذا المتغير يمثل التعويضات التي تم دفعها بالفعل على المطالبات. يُستخدم هذا المتغير لتحليل العلاقة بين المطالبات المدفوعة ومخصص التعويضات المتبقي تحت التسوية. يشير سلوك

التعويضات المدفوعة إلى نمط يساعد على توقع ما إذا كانت هناك تعويضات إضافية لازمة أو إذا كانت المخصصات الحالية كافية.

3. مخصص التعويضات تحت التسوية: (Outstanding Reserves)

هذا هو المتغير الذي نسعى إلى التنبؤ به باستخدام المتغيرات الأخرى. يتم استخدام البيانات التاريخية لمخصصات التعويضات السابقة لتمكين الشبكة العصبية من التنبؤ بالمخصصات المستقبلية بناءً على الأنماط المكتشفة في البيانات.

تم إدخال بيانات التدريب من الجدول (3) وهذه البيانات تشكل المصفوفة المدخلة للشبكة **Inputs**، حيث يتم تمثيل كل عينة تدريبية بالقيم المدخلة للأقسط المكتسبة، التعويضات المسددة، ومخصص التعويضات تحت التسوية في نقطة زمنية محددة. ويكون شكل المصفوفة كما يلي:

$$input = \begin{pmatrix} EP_1 & PC_1 \\ \vdots & \vdots \\ EP_2 & PC_2 \\ \vdots & \vdots \\ EP_n & PC_n \end{pmatrix} \dots\dots\dots(15)$$

ب- عملية التدريب:

توجد عدة طرق لتدريب نموذج GRNN، وفي هذا البحث سوف نقوم باستخدام طريقة التدريب باستخدام خوارزمية (GRNN)، التي تعتمد على حساب المسافات الإقليدية بين النقاط وتطبيق دالة كثافة الاحتمالية لتقدير القيم المتوقعة. يُعتبر دمج بيانات الأقسط المباشرة مع بيانات التعويضات خطوة استراتيجية لتحسين دقة التنبؤات. كما ان العلاقة المتبادلة بين حجم الأقسط والمخصصات تعكس طبيعة المخاطر المرتبطة بالنشاط التأميني، ويساهم هذا النهج في تقييم أداء النموذج بدقة باستخدام مجموعة بيانات مستقلة، مما يقلل من خطر **overfitting** ويحسن دقة التقديرات (Sanchez et al., 2018)، بالإضافة إلى تساعد على اختيار بارامتر التنعيم (σ)، تم تقسيم البيانات المستخدمة في هذا البحث إلى مجموعتين:



-استخدام 80% من البيانات لتدريب النموذج،

- بينما تم الاحتفاظ بنسبة 20% المتبقية كبيانات للتحقق (Validation Set).

تم إدخال البيانات عدة مرات خلال عملية التدريب لضمان تحسين أداء النموذج، يُستخدم هذا التقسيم لتقييم أداء النموذج بدقة، حيث يمكن اختبار دقة التنبؤات باستخدام مجموعة بيانات مستقلة. يساعد هذا النهج في تقليل احتمالية زيادة التدريب (Overfitting).

وبمجرد أن تتلقى الخلايا العصبية (P) في طبقة الإدخال إشارة الإدخال من المتجهات الفردية التي تمثل بيانات الأقساط المكتسبة (EP)، والتعويضات المسددة (PC)، يتم معالجة هذه البيانات من خلال مصفوفة بيانات التدريب المدخلة بحجم (P × R) كما هو موضح في المعادلة رقم (15)، ومن ثم، يتم استخدام دالة الوزن المدمجة في برنامج MATLAB لحساب المسافة الإقليدية "dist" وفقاً للمعادلة رقم (4)، والتي تُحسب بين كل زوج من العناصر المقابلة في مصفوفة وزن الإدخال (IW_{1,1}) ومصفوفة البيانات المدخلة (Inputs). ان العلاقة الرياضية لحساب هذه المسافة الإقليدية تكون على النحو التالي

$$\|dist\| = \|IW_{1,1} - Inputs\| = dist(IW_{1,1}, Inputs)$$

ج- حساب المدخلات الصافية

يتم تعيين مصفوفة الوزن IW_{1,1} في طبقة RBF مع النيرونات (R) بحيث تتناسب مع مصفوفة بيانات التدريب المدخلة التي تم نقلها (transposed). بعد ذلك، يتم ضرب مصفوفة المسافة ||dist|| عنصراً بعنصر في المتجه الثابت الانحيازي b₁ والذي يتم حسابه من المعادلة رقم (7) بحجم R×1. يتم ذلك من خلال استخدام دالة الإدخال الشبكي "netprod"، مما ينتج عنه إدخال صافي بحجم R×R. يُمثل بالعلاقة التالية:

$$n1 = \|dist\| .* b_1 = netprod(\|dist\|, b_1)$$

بعد حساب إدخال صافي الطبقة الثانية n₁، يتم تمريره إلى دالة النقل RBF المعروفة باسم "radbas" المعادلة رقم (5)، مما ينتج عنه إخراج بحجم R×R من طبقة RBF. ومن ثم يتم استخدام دالة الوزن المتجهة المنسوخة "normprod" في طبقة الإخراج الخاصة بصافي اخر

والتي تحتوي على Q نيرونات، حيث ترجع هذه الدالة المنتج النقطي بحجم $Q \times R$ وفقا للمعادلة الاتية:

$$n_2 = \frac{LW_{2,1} \cdot a_1}{\text{sum}(a_1)} = \text{normprod}(LW_{2,1}, a_1)$$

تُستخدم مصفوفة الوزن $LW_{2,1}$ كبيانات تدريب مستهدفة بحجم $Q \times R$ في طبقة الإخراج بحيث تتوافق مع مصفوفة البيانات المدخلة a_1 مما يسهم في تحقيق النتائج المرجوة من عملية التنبؤ. ومن ثم يتم تطبيق دالة النقل الخطية "purelin" على المدخل الصافي (n_2)، المعادلة السابقة) لإنتاج مصفوفة الإخراج $RQ \times R$ لطبقة الإخراج، كما هو موضح بالعلاقة التالية:

$$a_2 = n_2 = \text{purelin}(n_2)$$

د - طبقة المخرجات

يمكن الحصول على مخرجات نموذج الشبكة العصبية الانحدارية العامة (GRNN) المبني على MATLAB® باستخدام دالة "newgrnn"، حيث يعتمد هذا النموذج على عدد النيرونات في طبقة الإدخال وطبقة RBF المخفية وطبقة الإخراج الخطية. يتم محاكاة النموذج باستخدام دالة "sim"، حيث يتم إعادة إدخال بيانات التدريب إلى طبقة الإدخال في الشبكة المدربة، وتتم مقارنة المخرجات المطلوبة مع الأهداف التدريبية في طبقة الإخراج. تتيح هذه المقارنة تقييم أداء النموذج وقدرته على التنبؤ بدقة بالمخصصات بناءً على بيانات التدريب المقدمة.

هـ - تحديد معامل التنعيم (σ):

أثناء عملية التدريب على مجموعة البيانات التدريبية، يتم تعيين معامل التنعيم GRNN القابل للتعديل σ بواسطة طريقة التجربة والخطأ لتحقيق الحد الأدنى من خطأ التنبؤ للنموذج المدرب المُحاكي بمجموعة البيانات الاختبارية وكانت قيمة معامل التنعيم لهذا النموذج هو (0.7).



رابعاً: نتائج تطبيق نموذج شبكة الانحدار العصبية المعممة

1-تحضير البيانات:

وصف البيانات: تم جمع البيانات التاريخية من عام 2008 حتى 2023، وتشمل المتغيرات: الأقساط المكتسبة (EP) ، التعويضات المسددة (PC) ، والمخصصات تحت التسوية (OC)

تنظيف البيانات: قامت الباحثة بالتنبؤ قبل وبعد خلو البيانات من القيمة شاذة في بيانات OC وهي (423034)، تم استبدالها بقيمة الوسيط (187,270.50) لتقليل التأثير على النموذج.

أ- تقسيم البيانات إلى تدريب واختبار:

تم تقسيم البيانات بنسبة 80% للتدريب و20% للاختبار. كما تم تثبيت الحالة العشوائية: لضمان استقرار النتائج عند كل تشغيل للنموذج، تم تثبيت الحالة العشوائية (random seed) باستخدام قيمة ثابتة الي قيمة وهي (1).

ب-تدريب النموذج باستخدام:GRNN

قمنا بإنشاء شبكة GRNN باستخدام مكتبة الشبكات العصبية، مع تحديد معامل الانتشار spread، والذي تم ضبطه إلى 0.01 لتحقيق التوازن بين الدقة والتعميم. ومن ثم تم تدريب النموذج: باستخدام بيانات التدريب، تم تدريب الشبكة على تعلم العلاقة بين المدخلات (EP و PC) والهدف (OC) من خلال تخصيص القيم المناسبة بناءً على مسافات الإدخال.

2- التنبؤ باستخدام الشبكة المدربة:

بعد تدريب النموذج، تم استخدامه لتوليد تنبؤات بناءً على بيانات الاختبار سواء كان قبل القيمة الشاذة او بعد معالجتها وكانت النتائج كالآتي:

أ- قيم مخصص التعويضات تحت التسوية قبل تعديل القيم الشاذة

جدول (5) يوضح مخصص التعويضات تحت التسوية الفعلية والمنتبأ بها لفرع النقل البحري لشركة مصر للتأمين قبل معالجة القيمة الشاذة

السنة	مخصص التعويضات تحت التسوية الفعلي	القيم المتنبئ بها
2008/2007	199945	201250
2009/2008	186120	187090
2010/2009	138568	138670
2011/2010	188421	191240
2012/2011	180608	180610
2013/2012	210008	205710
2014/2013	183972	183970
2015/2014	146751	146750
2016/2015	181822	181820
2017/2016	423034	421340
2018/2017	276384	317090
2019/2018	317093	317090
2020/2019	287310	317090
2021/2020	201965	181820
2022/2021	184295	185990
2023/2022	124648	124650

المصدر: من اعداد الباحثة بناء على مخرجات برنامج المات لاب.

من الجدول السابق نجد ان نجد أن هناك تطابقًا عامًا بين القيم الفعلية والمتنبأ بها عبر السنوات المختلفة. فنلاحظ الاتي:

- في السنوات (2010/2009) و (2014/2013) و (2015/2014)، كانت القيم المتنبأ بها قريبة جدًا من القيم الفعلية، مما يعكس قدرة النموذج على التنبؤ بشكل دقيق. في المقابل، نلاحظ بعض الاختلافات الطفيفة في بعض السنوات الأخرى، حيث تباينت القيم المتنبأ بها عن القيم الفعلية بمقدار أكبر.
- في سنة (2017/2016)، كانت القيمة الفعلية 423,034 في حين كانت القيمة المتنبأ بها 421,340، وهذا يشير إلى فارق بسيط ولكنه لا يعتبر كبيرًا بالقدر الذي يؤثر بشكل جوهري على دقة التنبؤ.



▪ في كلا من سنة (2018/2017) وسنة (2021/2020)، يظهر تباين أكبر بين القيم المتنبأ بها والفعلية، حيث كانت القيمة هذا الفرق يمكن أن يكون ناتجاً عن تغيرات غير متوقعة في البيانات بسبب عوامل خارجية التي لم يلتقطها النموذج بدقة او بسبب القيم الشاذة في النموذج.

ب- تحليل مؤشرات أداء النموذج:

فيما يتعلق بتقييم دقة النموذج التنبؤي، تم استخدام مجموعة من مؤشرات الأداء المعروفة في تحليل الأخطاء، والتي توفر رؤى شاملة حول مدى قدرة النموذج على التنبؤ بمخصصات التعويضات تحت التسوية. وقد أظهرت نتائج المؤشرات ما يلي:

▪ بلغت قيمة (RMSE)، لجميع البيانات 13,658.3، وهذا يدل على أن متوسط الخطأ بين القيم الفعلية والمتنبأ بها هو 13,658.3 وحدة. RMSE هو مقياس حساس للغاية للخطأ ويعكس دقة النموذج. بالنظر إلى أن البيانات تتراوح ضمن نطاقات كبيرة، فإن هذا الرقم يعتبر مؤشراً جيداً على أن النموذج قادر على التنبؤ بدقة معقولة، لكن يظل هناك مجال لتحسينه.

▪ كما بلغت قيمة (R^2) للنموذج 0.9659، مما يعني أن النموذج يفسر 96.59% من التباين في البيانات. هذه القيمة عالية جداً وتُعتبر من المؤشرات القوية على أن النموذج قادر على تفسير التباين الكبير في مخصصات التعويضات تحت التسوية. إن تفسير 96.59% من التباين يعكس دقة عالية للنموذج.

▪ وبلغت قيمة (MAPE) للنموذج 2.57%، مما يعني أن النموذج يحقق دقة عالية في التنبؤ بالقيم، حيث أن متوسط الخطأ بالنسبة للقيم الفعلية لا يتجاوز 2.57%. يشير هذا إلى أن النموذج يتنبأ بمخصصات التعويضات بدقة كبيرة وأن الأخطاء بين القيم الفعلية والمتنبأ بها منخفضة جداً.

▪ بلغت قيمة MAE للنموذج 6,469.53، مما يعني أن الخطأ المطلق المتوسط بين القيم الفعلية والمتنبأ بها هو 6,469.53. يُعتبر MAE مقياساً قوياً لأن قيمه لا تتأثر بالقيم

الشاذة بشكل كبير، مما يوفر فكرة أكثر استقرارًا حول دقة النموذج. هذه القيمة تشير إلى

أن النموذج قادر على تقديم تنبؤات موثوقة ومعقولة.

ج- قيم مخصص التعويضات تحت التسوية بعد تعديل القيم الشاذة:

جدول (6) يوضح مخصص التعويضات تحت التسوية الفعلية والمنتبأ بها لفرع النقل البحري لشركة مصر للتأمين بعد معالجة القيمة الشاذة

السنة	مخصص التعويضات تحت التسوية الفعلي	القيم المنتبأ بها
2008/2007	199945	198539
2009/2008	186120	187991
2010/2009	138568	138248
2011/2010	188421	196919
2012/2011	180608	180290
2013/2012	210008	200329
2014/2013	183972	184079
2015/2014	146751	146944
2016/2015	181822	181680
2017/2016	*186120	185745
2018/2017	276384	276773
2019/2018	317093	317091
2020/2019	287310	287067
2021/2020	201965	201998
2022/2021	184295	184623
2023/2022	124648	124648

المصدر: من اعداد الباحثة بناء على مخرجات برنامج المات لاب.

من الجدول السابق نلاحظ أن:

- التعديل في سنة (2017/2016) كان له أثر بشكل كبير على الدقة الكلية للنموذج. فبعد استبدال القيمة الشاذة السابقة (423,034) بالقيمة المعدلة (186,120)، أصبح التنبؤ بالبيانات أكثر دقة، حيث تم تقريب الفجوة بين القيم المنتبأ بها (185,745) والفعلية

(* هي القيمة المتطرفة بعد التعديل



(186,120). لذلك هذا التعديل حسن من أداء النموذج بشكل ملحوظ، مما يتيح للنموذج

التنبؤ بشكل أفضل ويعكس دقة أكثر في حساب مخصصات التعويضات تحت التسوية.

■ في الجدول السابق بجد ايضاً، وجود تقارب بين القيم الفعلية والمنتبأ بها عبر السنوات المختلفة. في معظم الحالات، كانت الفجوة ضئيلة بين القيمتين، مما يدل على دقة النموذج في التنبؤ. على سبيل المثال: في (2008/2007) و (2019/2018)، كانت القيم المنتبأ بها قريبة جداً من القيم الفعلية، مما يعكس تنبؤاً دقيقاً.

■ في السنوات الأخيرة، كان التقارب بين القيم الفعلية والمنتبأ بها يعكس قدرة النموذج على التنبؤ بالمخصصات بشكل موثوق. على سبيل المثال، في (2023/2022)، كانت القيم المنتبأ بها والفعلية 124,648، مما يشير إلى قدرة النموذج على التنبؤ بشكل دقيق حتى في السنوات الأخيرة، التي غالباً ما تكون أكثر تعقيداً بسبب تغيرات السوق أو عوامل أخرى.

د- تحليل مؤشرات أداء النموذج:

فيما يتعلق بتقييم دقة النموذج التنبؤي، تم استخدام مجموعة من مؤشرات الأداء المعروفة في تحليل الأخطاء، والتي توفر رؤى شاملة حول مدى قدرة النموذج على التنبؤ بمخصصات التعويضات تحت التسوية. وقد أظهرت نتائج المؤشرات ما يلي:

■ بلغت قيمة (RMSE) للنموذج 3279.63، مقابل 13658.3، وهذا يظهر أن متوسط

انحراف القيم المنتبأ بها عن القيم الفعلية قد انخفض بشكل كبير هذا يشير إلى أن النموذج المحسن أصبح أكثر دقة، حيث تقترب التنبؤات بشكل أكبر من القيم الفعلية.

■ انخفضت قيمة (MSE) من 53627678.56 إلى 10755960.00 مما يؤكد أن النموذج الحالي يقلل من حجم الأخطاء المربعة، مما يعكس أداءً أفضل في التنبؤ، ويقلل من التباين الكبير في الأخطاء.

■ كما انخفضت قيمة (MAPE) إلى 0.76% يشير إلى انخفاض كبير في نسبة الخطأ بالمقارنة مع القيم الفعلية. هذا يدل على أن النموذج الحالي يقدم تنبؤات أكثر دقة، حيث يكون الخطأ النسبي أقل بكثير من النموذج السابق.

- تحسن قيمة (R^2) لتصل إلى 0.9958 مما يعكس قدرة النموذج الجديد على تفسير 99.58% من التباين في القيم الفعلية، مقارنة بـ 96.59% في النموذج السابق. هذا يعني أن النموذج الجديد يوفر تفسيراً أفضل للعوامل المؤثرة على مخصصات التعويضات تحت التسوية، مما يجعله أكثر دقة وموثوقية.
- انخفضت أيضاً قيمة (MAE) من 6469.53 إلى 1493.78 يظهر تقليلاً كبيراً في متوسط الفروق المطلقة بين القيم المتنبأ بها والقيم الفعلية، مما يؤكد أن النموذج الجديد أقل عرضة للأخطاء وأكثر كفاءة في تقديم تنبؤات دقيقة.

خامساً- مناقشة النتائج

أظهرت النتائج المستخلصة من نموذج التنبؤ باستخدام الشبكات العصبية المعممة (GRNN) قدرة النموذج على استيعاب العلاقة المعقدة بين مكونات مخصص التعويضات تحت التسوية. وقد تم تحليل القيم الفعلية مقابل القيم المتنبأ بها للسنوات من 2008/2007 إلى 2023/2022، حيث كشفت النتائج عن اتجاهات مهمة تشير إلى فعالية النموذج في محاكاة وتوقع هذه العلاقة بمرونة ودقة.

1. تشير النتائج إلى وجود تفاوتات ملحوظة بين القيم المتنبأ بها والقيم الفعلية لبعض السنوات. على سبيل المثال، في عام 2016، كان هناك تباين كبير، حيث تم تقدير مخصص التعويضات تحت التسوية بـ 185,745 بينما كانت القيمة الفعلية 423,034، مع فارق يبلغ حوالي 237,289. قد يعكس هذا الانحراف أحداثاً غير متوقعة في السوق أو تغييرات في سلوك المطالبات، مما يُبرز أهمية التحديث المستمر للنماذج التنبؤية للتكيف مع مثل هذه التغييرات.
2. في كلا من عام (2018/2017)، (2022/2021)، (2023/2022): كانت القيمة الفعلية والقيمة المتنبأ بها كانت قريبة جداً ما يشير إلى أن النموذج كان دقيقاً في هذه السنوات.
3. اتجاه القيم: تشير البيانات إلى تذبذب في القيم الفعلية لمخصص التعويضات تحت التسوية في السنوات الأخيرة، مع ارتفاعات ملحوظة في بعض السنوات، مما قد يعكس تغييرات في حجم المطالبات أو تعديلات في السياسات التأمينية. هذه النتائج تبرز الحاجة إلى أن تقوم شركات



التأمين بمراجعة دورية لاستراتيجياتها لضمان توفير احتياطات كافية للتكيف مع التقلبات المحتملة."

4. تشير الفجوات بين القيم المتنبأ بها والفعلية إلى إمكانية تحسين النموذج عبر جمع بيانات إضافية تشمل العوامل الاقتصادية والاجتماعية ذات التأثير المحتمل، وتجربة نماذج تعلم آلي أكثر تعقيداً لزيادة دقة التنبؤ، إضافة إلى إجراء تحليل للعوامل المؤثرة لفهم الأسباب الجذرية للتباين بين القيم، ما يساهم في ضبط النموذج ليعكس العلاقة بدقة أكبر ويحقق استقراراً أعلى في تقدير مخصصات التعويضات.

5. أظهرت النتائج أيضاً أن مخصص التعويضات تحت التسوية الخاص بالنقل البحري في شركة مصر للتأمين يواجه تقلبات ومخاطر متعددة تؤثر على استقرار الوضع المالي للشركة، رغم اعتماد التدابير الوقائية المتنوعة. لذا، تُعد عملية تقدير مخصص التعويضات من أهم وأدق العمليات التي تؤديها شركات التأمين، نظراً لأثرها المباشر على قدرة الشركة على الوفاء بالتزاماتها المستقبلية. أثبتت نتائج الدراسة التطبيقية أن نموذج الشبكات العصبية المعممة (GRNN) تفوق على النموذج التقليدي في التنبؤ بمخصص التعويضات تحت التسوية، حيث حقق النموذج العصبي دقة عالية في التنبؤات، مع وصول قيمة R^2 إلى 0.9958، مما يدل على قدرة النموذج على تفسير معظم التغيرات في البيانات. بالإضافة إلى ذلك، كانت مؤشرات الدقة الأخرى، مثل RMSE التي بلغت 3279.63 و MAE البالغ 1493.78، و MAPE المنخفض بنسبة 0.76%، تشير إلى تقارب جيد بين القيم الفعلية والمتنبأ بها، مما يعزز موثوقية التنبؤات ويقلل من أثر الأخطاء. وفقاً لهذا النموذج،

6. كان متوسط المخصص المقترح للتعويضات تحت التسوية أقل من القيم المطبقة حالياً، مما قد يشير إلى وجود مخصصات زائدة عن الحاجة. بناءً على هذه النتائج.

سادساً-التوصيات:

1. الاستفادة من النموذج العصبي المعمم (GRNN) في العمليات التنبؤية: نظراً لارتفاع دقة التنبؤات التي حققها نموذج الشبكات العصبية المعممة، توصي الدراسة بالاعتماد على هذا

النموذج لتقدير مخصصات التعويضات المستقبلية. يساهم هذا النموذج في تقليل الأخطاء وتقديم تقديرات أكثر موثوقية، مما يساعد على تعزيز الاستقرار المالي.

2. تحديث النموذج بصورة دورية: لتجنب تأثير التقلبات الطارئة والأحداث الاستثنائية، من الضروري إعادة تدريب النموذج وتحديثه باستمرار مع بيانات حديثة. يمكن أن يؤدي ذلك إلى تحسين دقة التنبؤات وتقديم صورة أفضل للوضع المالي المتوقع.

3. مراجعة استراتيجيات إدارة المخاطر: أظهرت النتائج احتمالية وجود مخصصات زائدة في بعض السنوات، مما يعكس حاجة إلى تحسين إدارة المخاطر لتحديد قيمة المخصصات بدقة. ينبغي لشركات التأمين مراجعة استراتيجيات إدارة المخاطر لتحديد مخصصات تتماشى مع مستويات المخاطر الفعلية، بما يعزز من كفاءة رأس المال.

4. تحسين جودة البيانات وإدارة البيانات الشاذة: لاحظت الدراسة وجود بعض القيم الشاذة التي أثرت على أداء النموذج. يوصى بتطبيق طرق تنقية البيانات للتأكد من التخلص من القيم الشاذة أو استبدالها بأسلوب إحصائي متزن، مما يجعل النموذج أكثر استجابة.

5. استخدام مؤشرات الأداء بشكل دائم لمراقبة الأداء المالي: توصي الدراسة بمتابعة مؤشرات مثل RMSE و MAE و MAPE بشكل منتظم كجزء من استراتيجيات تقييم الأداء، مما يساعد على التحقق من دقة التنبؤات وضبط النموذج بمرور الوقت.

6. اختبار نماذج تنبؤية إضافية: يمكن مقارنة نتائج نموذج الشبكات العصبية مع نماذج أخرى مثل أشجار القرار العشوائية أو الانحدار المتعدد. يساعد ذلك في ضمان أن النموذج المستخدم هو الأكثر ملاءمة للبيانات المتاحة، مما قد يؤدي إلى نتائج أكثر دقة واستقرارًا.



المراجع

1- المراجع العربية:

أبو بكر خلدون وآخرون، "أنظمة المعلومات المعتمدة على الذكاء الاصطناعي بين المفاهيم النظرية والتطبيقات العملية في المؤسسة الاقتصادية"، الملتقى الوطني العاشر حول أنظمة المعلومات المعتمدة على الذكاء الاصطناعي ودورها في صنع قرارات المؤسسة الاقتصادية، جامعة سكيكدة، الجزائر، 2012.

أحمد عبد الوهاب أحمد علي، "التنبؤ بمعدل الاحتفاظ الأمثل لأقساط التأمين المكتسبة باستخدام نموذج إحصائي مدمج: دراسة تطبيقية على فروع التأمينات العامة بسوق التأمين المصري"، مجلة الدراسات المالية والتجارية، مجلد 32، عدد 3، 1071 - 1121، 2022.

أحمد عبد الرحيم خليل، صفية أحمد أبو بكر، و(آخرون) "التنبؤ بمعدل الخسارة لفرع تأمين الطيران باستخدام الشبكات العصبية الفازية بالتطبيق على شركة مصر للتأمين" المجلة العلمية لكلية التجارة، جامعة (أسيوط)، المجلد 40، العدد 68، 93-116، 2020.

أمل أحمد حسن الدالي، "مخصص التعويضات تحت التسوية لفرع السيارات" في جمهورية مصر العربية" (رسالة ماجستير، كلية التجارة). جامعة أسيوط، (1999). متاح على:

http://www.eulc.edu.eg/eulc_v5/Libraries/Thesis/BrowseThesisPages.aspx?fn=ThesisPicBody&BibID=9562607&TotalNoOfRecords=172&PageNo=1&PageDirection=First

زكريا يحيى، الجمال، د. عمر صابر قاس، نوري.. "مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار"، المجلة العراقية للعلوم الإحصائية، مجلد 12، عدد 21، ص. 234-245، 2012

قيس السيد علي، "دور تشكيل المخصصات الفنية في قدرة الشركة على مواجهة التزاماتها" رسالة ماجستير، كلية الاقتصاد، جامعة دمشق، 2010.

ليث حليم مالك الهاشمي، " التنبؤ بأسعار الأسهم باستخدام الشبكات العصبية الاصطناعية: دراسة لعينة من الشركات المدرجة في سوق العراق للأوراق المالية"، رسالة ماجستير غير منشورة، مجلة العلوم المالية والمحاسبية، العدد الخاص بمؤتمر القطاع المصرفي، جامعة القادسية، 469 – 504، 2022.

محمد أحمد المعداوي عبدربه، "المسؤولية المدنية عن الروبوتات ذات الذكاء الاصطناعي" دراسة مقارنة". المجلة القانونية، مجلد 9 عدد 2، 283-392، 2021، doi: 10.21608/jlaw.2021.190631

د. محمد محمود هاشم، "استخدام الشبكات العصبية الاصطناعية الجينية الوراثية في تقدير هامش ربح الاككتاب في شركات تأمينات الممتلكات والمسئولية في السوق المصري" بالتطبيق على تأمين أجسام السفن". المجلة العلمية للدراسات التجارية والبيئية، مجلد 11، العدد3، صفحات: 64-165. (2020).

محمد محمد عطا، علي سيد بخيت، " توصيف نموذج كمي لتقدير مخصص التعويضات تحت التسوية بالتطبيق على قطاع التأمينات العامة في سوق التأمين المصري". مجلة البحوث التجارية المعاصرة، جامعة سوهاج، مجلد 21، عدد 1، 177-209، 2007.

محمد نادي عزت حسين وطارق عزت محمد عبد الباري، "استخدام التحليل بالشبكات العصبية في تقدير مخصص التعويضات تحت التسوية لفروع التأمينات العامة"، المجلة المصرية للدراسات التجارية، كلية التجارة ، جامعة القاهرة ، المجلد 23 ، العدد 1، 1999.

3- المراجع الأجنبية

Ahmed Konaté, & Pan, Heping & Khan, Nasir & Jie, & Yang, Huai,
"Generalized regression and feed-forward back propagation neural networks in modelling porosity from geophysical well logs. Journal of Petroleum Exploration and Production Technology, 2014
<https://doi.org/10.1007/s13202-014-0137-7>.



Avanzi, B., Lavender, M., Taylor, G., & al., et, “On the impact of outliers in loss reserving”, *European Actuarial Journal*, 14(2),2024 257–296. <https://doi.org/10.1007/s13385-023-00356-2>.

Barr, A., & Feigenbaum, E. A. *The handbook of artificial intelligence*. William Kaufmann, Inc, (1980)

Bishop,C.,M., “Pattern Recognition and Machine Learning” , Springer Science + Business Media ,LLC, Singapore, (2006).

De Mauro, A, “ Data analytics made easy: Analyze and present data to make informed decisions without writing any code”. (p. 45). Packt Publishing, 2021.

Hebb, D. O, “*The organization of behavior: A neuropsychological theory*. John Wiley & Sons, 1949.

Hilmi Berk Celikoglu, (2006),” Application of radial basis function and generalized regression neural networks in non-linear utility function specification for travel mode choice modelling, *Mathematical and Computer Modelling*, Volume 44, Issues 7–8, Pages 640-658, ISSN 0895-7177.

Huang, Y.-C., & Liao, H.-S., “Building prediction model for a machine tool with genetic algorithm optimization on a general regression neural network. *Journal of Intelligent & Fuzzy Systems*”, 38(2), 2347–2357, 2020.

Kaaria, G. “The impact of credit information sharing on bank asset quality: A case of Kenyan commercial banks (Master's thesis)”. United States International University,2012. <https://www.usiu.ac.ke/handle/11732/1234>.

Kopal, I., et al. (2022).”A generalized regression neural network model for predicting the curing characteristics” of carbon black-filled rubber blends. *Polymers*, 14(4), 653. <https://doi.org/10.3390/polym14040653>.

Mohamed Ahmed Maait,” Estimating Claims Reserves in Insurance Industries Evidence from the Egyptian Market”, *Scientific Journal*

- for Financial and Commercial Studies and Research, Faculty of Commerce, Damietta University, 4(1)1, 967- 984. 2023.
- Samarasingha, S., “Neural Networks for Applied Sciences and Engineering”, Tayler & Francis Group, LLC. , NY, (2007).
- Sanchez, A., Rodriguez, J. G., & Lema, L,” A review of machine learning techniques for the prediction of insurance claims. *Expert Systems with Applications*, 104, 218-230, 2018.
- Sanjay R. Patil & V. N. Ghate, “A Generalized Regression Neural Network Based on Soft Sensor for Multicomponent Distillation Column” , *International Journal*, 2015.
<https://doi.org/10.4236/jilsa.2011.32012>
- Sharkawy, A. N. (2020). “Principle of neural network and its main types: Review”. *Journal of Advances in Applied & Computational Mathematics*, 7(1), 8–19. <https://doi.org/10.15377/2409-5761.2020.07.2>.
- Simon Haykin, "Neural networks and learning machines" ,Third Edition ,Prentice Hall ,New York Boston San Francisco, 2009
(<https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>)
- Specht DF, A general regression neural network. *IEEE Trans Neural network* 2(6):568–576, 1991.
- Pacelli, V., & Azzollini, M. “An artificial neural network approach for credit risk management”. *Journal of Intelligent Learning Systems and Applications*, 3(2), 103–112, 2011.



ملحق (1)

الأكواد المستخدمة في برنامج المات لاب (MATLAB)

%استيراد البيانات قراءة البيانات من ملف Excel

```
data = readtable('c:/data/البحري.xlsx');
```

%عرض جميع البيانات للتأكد من صحتها

```
disp('عرض جميع البيانات:');
```

```
disp(data);
```

%تحضير المدخلات والمخرجات

```
X = data{:, {'EP', 'PC'}};
```

```
y = data{:, 'OC'};
```

%تطبيع البيانات

```
X = zscore(X);
```

%تقسيم البيانات إلى تدريب واختبار بنسبة 80% تدريب و 20% اختبار

```
cv = cvpartition(size(X, 1), 'HoldOut', 0.2);
```

```
XTrain = X(training(cv), :);
```

```
yTrain = y(training(cv), :);
```

```
XTest = X(test(cv), :);
```

```
yTest = y(test(cv), :);
```

%بناء نموذج GRNN باستخدام دالة newgrnn

```
spread = 0.7;
```

```
net = newgrnn(XTrain', yTrain', spread);
```

%إجراء التنبؤ باستخدام مجموعة الاختبار

```
yPredTest = net(XTest');
```

%إنشاء جدول لعرض القيم الفعلية والمنتبأ بها لمجموعة الاختبار

```
resultsTest = table(yTest, yPredTest', 'VariableNames', {'القيمة الفعلية', 'القيمة المنتبأ بها'});
```

%عرض نتائج مجموعة الاختبار

```
disp('نتائج مجموعة الاختبار:');
```

```
disp(resultsTest);
```

%حساب RMSE لمجموعة الاختبار

```
mseTest = mean((yPredTest' - yTest).^2);
```

```
rmseTest = sqrt(mseTest);
```

```
fprintf('RMSE 2.%\n', rmseTest);
```

% تنبؤ بجميع البيانات (الـ 16 قيمة) باستخدام النموذج المدرب

yPredAll = net(X');

% إنشاء جدول لعرض القيم الفعلية والمنتبأ بها لجميع البيانات

resultsAll = table(y, yPredAll', 'VariableNames', {'القيمة الفعلية', 'القيمة المنتبأ بها'});

% عرض النتائج لجميع البيانات

disp('نتائج جميع البيانات');

disp(resultsAll);

% حساب RMSE لجميع البيانات

mseAll = mean((yPredAll' - y).^2);

rmseAll = sqrt(mseAll);

fprintf('RMSE 2.% لجميع البيانات: \n', rmseAll);

% القيم الفعلية والمتوقعة

yActual = y; % القيم الفعلية

yPredicted = yPredAll'; % القيم المنتبأ بها

% حساب متوسط القيم الفعلية

meanActual = mean(yActual);

% حساب SST و SSE

SSE = sum((yActual - yPredicted).^2); % مجموع مربعات الأخطاء

SST = sum((yActual - meanActual).^2); % مجموع مربعات الانحرافات الكلية

% حساب R^2

R2 = 1 - (SSE / SST);

% عرض النتيجة

fprintf('R^2: %.4f\n', R2);

mape = mean(abs((y - yPredicted) ./ y)) * 100;

fprintf('MAPE: %.2f%%\n', mape);

% حساب MAE لجميع البيانات

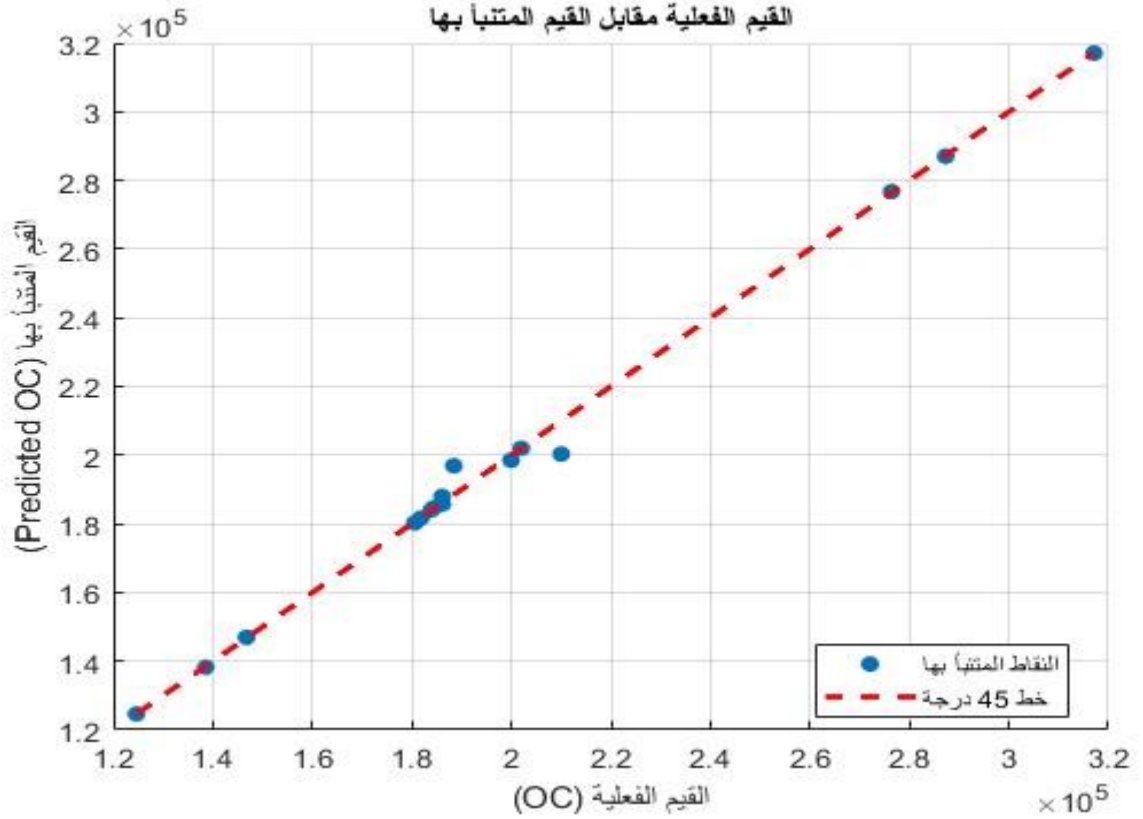
MAE = mean(abs(yActual - yPredicted));

% عرض نتيجة MAE

fprintf('MAE 2.% لجميع البيانات: \n', MAE);




المصدر: من اعداد الباحثة بناء على مخرجات برنامج المات لاب



شكل بياني يوضح نتائج النموذج بعد حذف القيمة المتطرفة ومقارنة القيم الفعلية بالقيم المتنبأ بها

الشبكة المدربة:

المصدر: من مخرجات برنامج المات لاب بناء على الشبكة المدربة



شكل بياني يوضح تركيب الشبكة العصبية المعممة في التنبؤ