



مجلة البحوث الإدارية والمالية والكمية

Journal of Managerial, Financial
& Quantitative Research



استخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي في التنبؤ بحجم المطالبات في
تأمين السيارات التكميلي: دراسة تطبيقية على سوق التأمين المصري

The Use of Artificial Neural Networks with Backpropagation in Predicting Claim Sizes in Supplementary Car Insurance: An Applied Study on the Egyptian Insurance Market

إعداد

د. محمد أحمد فؤاد عبده البرقاوي
مدرس قسم الإحصاء التطبيقي والتأمين
كلية التجارة - جامعة المنصورة

د. سيد محمد جودة محمد
مدرس بقسم العلوم الكمية والحاسب الآلي
كلية التجارة - جامعة السويس

مجلة البحوث الإدارية والمالية والكمية

كلية التجارة - جامعة السويس

المجلد الخامس - العدد الأول

مارس 2025

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

استخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي في التنبؤ بحجم المطالبات في تأمين السيارات التكميلي: دراسة تطبيقية على سوق التأمين المصري

المستخلص:

يشهد قطاع التأمين تطورًا مستمرًا في ضوء التقنيات الحديثة والتحديات المالية المتنوعة لذلك فإن تحسين عمليات تقدير المطالبات وتسعير التأمينات العامة يعد أمرًا أساسيًا لشركات التأمين لتقديم منتجات تأمينية دقيقة ومبتكرة، لذلك تهدف هذه الدراسة إلى تقديم نموذج مقترح لتحسين عمليات التنبؤ بقيم المطالبات باستخدام شبكة العصبية ذات الانتشار العكسي (BP)، مع تطبيقها على شركات التأمين المصرية. تعمل الشبكات العصبية ذات الانتشار العكسي (BP) كأحد أساليب تعلم الآلة على تمثيل العلاقات المعقدة في البيانات من خلال تعلم النمط من البيانات التاريخية، وكذلك من خلال تصميم وتدريب نموذج مبتكر للشبكة العصبية، تمكنت الدراسة من تحقيق تقديرات دقيقة لقيم المطالبات المحتملة، وقد تم تطبيق النموذج المقترح على بيانات المطالبات التاريخية لشركات التأمين المصرية وأظهرت النتائج قدرة عالية على التنبؤ بقيم المطالبات بدقة وثبات. يساهم هذا البحث في تحقيق عدة مزايا أولها، أنه يساهم في تحسين دقة تقديرات المطالبات وتقدير المخاطر في صناعة التأمين، مما يساهم في تحسين عمليات تسعير التأمينات وتحقيق تكاليف مناسبة. ثانيًا، يعزز البحث استخدام تكنولوجيا الشبكات العصبية في صناعة التأمين، مما يمهد الطريق لتقديم خدمات تأمينية مبتكرة ومتقدمة. وأخيرًا، يوفر البحث منهجية عملية لتطبيق النموذج المقترح على سوق التأمين المصري، مما يساهم في تحقيق تطوير ملموس ومستدام في قطاع التأمين في مصر.

كلمات مفتاحية:

التنبؤ بالمطالبات، تسعير التأمينات العامة، الشبكات العصبية، الانتشار العكسي، الذكاء الاصطناعي، تعلم الآلة، شركات التأمين المصرية.

Abstract:

The insurance sector is experiencing continuous evolution considering modern technologies and diverse financial challenges. Enhancing claims estimation processes and general insurance pricing is essential for insurance companies to provide accurate and innovative insurance services. This study aims to present a proposed model for improving claims value prediction processes using the backpropagation neural network (BPNN) as a basis for general insurance pricing, with its application to Egyptian insurance companies.

Backpropagation neural networks (BPNNs) work to represent complex relationships in data by learning patterns from historical data. Through the design and training of an innovative neural network model, this study achieved accurate estimates of potential claims values. The proposed model was applied to historical claims data from Egyptian insurance companies, and the results demonstrated a high ability to predict claims values with precision and consistency.

This research contributes to several advantages. Firstly, it enhances the accuracy of claims estimation and risk assessment in the insurance industry, thereby improving insurance

pricing processes and achieving appropriate costs. Secondly, the research promotes the use of neural network technology in the insurance industry, paving the way for innovative and advanced insurance services. Finally, the research provides a practical methodology for applying the proposed model to the Egyptian insurance market, contributing to tangible and sustainable development in the insurance sector in Egypt.

Key Words:

Claim prediction, General insurance pricing, Neural networks, Backpropagation, Artificial intelligence, Machine learning, Egyptian insurance companies.

1. المقدمة:

تشكل صناعة التأمين أحد القطاعات الحيوية في النظام الاقتصادي المصري، حيث تلعب دوراً مهماً في تقديم الحماية المالية للأفراد والشركات من مختلف المخاطر والتحديات المحتملة، حيث تقدم شركات التأمين مجموعة متنوعة من المنتجات التأمينية المختلفة، بدءاً من التأمين الصحي ووصولاً إلى التأمين على السيارات والممتلكات، وكذلك التأمين على المسؤولية المدنية، وتقديم الحماية اللازمة للمؤمن عليهم ضد الخسائر المالية المحتملة.

من الجوانب الرئيسية التي تؤثر في عمليات التأمين هي تقدير الخطورة المحتملة وتقدير قيم المطالبات المستقبلية، حيث يعتبر تحسين دقة تقديرات المطالبات وتقدير المخاطر تحدياً مهماً لشركات التأمين لتقديم تسعيرات دقيقة وعادلة للعملاء، مع تطور تقنيات تحليل البيانات والذكاء الاصطناعي، أصبح من الممكن استخدام هذه التقنيات لتطوير نماذج تنبؤ متقدمة لتقدير المطالبات والتسعير.

هناك بعض المشاكل التي تواجه شركات التأمين العامة؛ ومنها التنبؤ بحجم المطالبات وخصوصاً فرع تأمين السيارات التكميلي والذي يعتبر من الفروع الهامة في التأمينات العامة حيث يتصدر المركز الأول من حيث حجم الأقساط، فهو يمثل 23% من إجمالي أقساط محفظة التأمينات العامة في السوق المصري، ويمثل 24% من حيث التعويضات المسددة عن العمليات المباشرة.

وبداسة تأمينات الممتلكات والمسؤولية وخصوصاً فرع السيارات التكميلي نجد أن معظم الشركات التي تعمل في سوق التأمين المصرية تحقق معدلات خسارة مرتفعة في هذا الفرع، مما يعرضها إلى خسائر متزايدة عام بعد آخر ولمواجهة هذه المشكلة لابد من محاولة التنبؤ بقيم المطالبات المستقبلية باستخدام بعض الأساليب الحديثة التي توفر دقة أعلى في التنبؤ مما قد يساعد شركات التأمين على تخفيض معدلات الخسارة في هذا الفرع وذلك لأن عملية التسعير في تأمينات الممتلكات والمسؤولية ومنها تأمين السيارات التكميلي يتم تحديد سعر التغطية التأمينية على أساس تقدير حجم الخسارة المتوقعة، أي أنه يتم تحديد سعر التغطية التأمينية على أساس التكلفة المتوقعة، وليس على أساس التكلفة الفعلية لحجم الخسارة.

ومن الطرق الحديثة المستخدمة في التنبؤ بحجم المطالبات المستقبلية هي الشبكات العصبية الاصطناعية ذات الانتشار العكسي "back-propagation artificial neural network" حيث شهدت استخداماً واسعاً من قبل الباحثين لكونها لا تحتاج إلى شروط صعبة في عملية اعداد البيانات المستخدمة في عملية التنبؤ، ومن المجالات التي استخدمت فيها وحقت نجاحاً ملحوظاً التنبؤ بأسعار العملات والمواد الخام، وأحوال الطقس وغيرها.

تسعى هذه الدراسة إلى تقديم نموذج مقترح ومبتكر للتنبؤ بقيم المطالبات باستخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي "back-propagation artificial neural network" كأحد أساليب تعلم الآلة، وذلك ليكون أساساً لعمليات تسعير التأمينات العامة، تستند شبكات BP العصبية إلى مبدأ تشبيه العمليات الحيوية للدماغ البشري، مما يتيح لها فهم العلاقات المعقدة في البيانات وتعلم النمط منها، ويتيح استخدام هذه الشبكات تحسين دقة تقديرات المطالبات وزيادة فعالية عمليات تسعير التأمينات العامة.

1.1. مشكلة الدراسة:

تتعرض معظم شركات التأمين لخسائر كبيرة سنوياً في فرع تأمين السيارات التكميلي حيث تزداد معدلات الخسارة في هذا الفرع بمعدلات تفوق الزيادة في حجم الأقساط الأمر الذي يؤدي إلى خسائر متزايدة قد تمتص ربحية باقي فروع التأمين واستثماراتها، حيث يوضح الجدول التالي معدل تطور الأقساط والتعويضات المباشرة ومعدل الخسائر لفرع تأمين السيارات التكميلي في سوق التأمين المصري خلال الفترة من ٢٠٠٩/٢٠١٠ إلى الفترة ٢٠٢١/٢٠٢٢.

جدول (١): معدل تطور الأقساط والتعويضات المباشرة ومعدل الخسائر لفرع تأمين السيارات التكميلي في سوق التأمين المصري (القيمة بالألف جنيه)

السنة	الأقساط	معدل التطور %	التعويضات	معدل التطور %	معدل الخسائر % 1
٢٠٠٩/٢٠١٠	١٣١٧١١٨	١٠٠	٧١٦٥٥٥	١٠٠	٢,٧٢
٢٠١٠/٢٠١١	١٤٤٢٣٩٤	٥١,٩	٧٩٥٩٧٧	١٠٨,١١	٤,٦١
٢٠١١/٢٠١٢	١٣٦٢٨٤٥	٤٧,٣	٨٧٤٢٢١	١٠٠,٢٢	٧,٦٨
٢٠١٢/٢٠١٣	١٤٢٥١٥٧	٤٧,٨	٩٣٠٤٤٦	١٠٨,٢٩	٦,٦٧
٢٠١٣/٢٠١٤	١٥٧١٩٧٦	٣٤,١٩	٩١٩٩١١	١٣٧,٢٨	٦,٥٥
٢٠١٤/٢٠١٥	١٧٩٦١٦٧	٣٧,٣٦	١٠٩٧٨٠١	٢٠,٥٣	٦,٦٧
٢٠١٥/٢٠١٦	٢٠٤٢٢٩٨	٠٥,٥٥	١١٦٥٧٤٢	٦٨,٦٢	٦,٥٧
٢٠١٦/٢٠١٧	٢٦٩٦٠٢٤	٦٩,١٠٤	١٣٥٩٦٩٦	٧٥,٨٩	٦,٥٦
٢٠١٧/٢٠١٨	٣٢٢٥٣٨٤	٨٨,١٤٤	١٧٢٧٠٠٠	٠١,١٤١	٩,٦١
٢٠١٨/٢٠١٩	٣٧٧١٤٩٩	٣٤,١٨٦	١٩٩٥٤٨٣	٤٨,١٧٨	٩,٥٧
٢٠١٩/٢٠٢٠	٣٩٦٤١٨٢	٩٧,٢٠٠	٢١٤٥٩٣٥	٤٧,١٩٩	٩,٥٦
٢٠٢٠/٢٠٢١	٤٥٢٧٧٥٣	٧٦,٢٤٣	٢٣٧٤١٣٨	٣٢,٢٣١	١,٥٧
٢٠٢١/٢٠٢٢	٥٤٣١١٨٣	٣٥,٣١٢	٢٨١٣٢٥٥	٦٠,٢٩٢	٢,٦٢

المصدر: الكتاب الإحصائي السنوي عن نشاط سوق التأمين في مصر أعداد مختلفة.

يلاحظ من الجدول السابق أن قيمة التعويضات في تزايد مستمر حيث كانت (٧١٦٥٥٥ ألف جنيه) عام ٢٠٠٩/٢٠١٠، بينما أصبحت (٢٨١٣٢٥٥ ألف جنيه) عام ٢٠٢١/٢٠٢٢. ومن الملاحظ أن تزايد معدلات الخسارة في هذا الفرع يفوق الزيادة في حجم الأقساط، ومن المتوقع أيضاً اتجاه معدل الخسارة للزيادة في السنوات المقبلة نتيجة زيادة معدلات التضخم، ومن المعروف أن عملية تقدير تكلفة التأمين تعتمد على قيمة المطالبات المتوقعة، والتي يمكن أن تكون معقدة ومتغيرة باستمرار بسبب تنوع العوامل التي تؤثر عليها، وقد ترتب على هذا احتياج شركات التأمين لوجود نماذج تساعد في التنبؤ بقيمة المطالبات في هذا الفرع بدقة عالية، حيث يعد التحسين المستمر لعمليات التسعير وتقدير المطالبات أمراً ضرورياً لشركات التأمين لضمان توفير تسعير دقيق وعادل للعملاء.

وتواجه شركات التأمين المصرية تحديات كبيرة في تحقيق تقديرات دقيقة لقيم المطالبات المتوقعة، مما يؤثر على عمليات التسعير وتحديد مستويات التأمين المناسبة. وعلى الرغم من التقنيات التقليدية المستخدمة لتقدير المخاطر

1 معدل الخسائر = الخسائر المحققة ÷ الأقساط المكتسبة

الخسائر المحققة = التعويضات + احتياطي تعويضات تحت التسوية آخر العام - احتياطي تعويضات تحت التسوية أول العام ÷ الأقساط المكتسبة = الأقساط + مخصص الأخطار ال سارية أول العام - مخصص الأخطار السارية آخر العام

وتسعير التأمينات، إلا أنها قد تواجه صعوبة في تحليل وفهم والتعامل مع تعقيدات البيانات وعدم اليقين المتزايد، ومع تعدد التحديات والعوامل المعقدة التي تؤثر على حجم وتكاليف المطالبات تجعل من الصعب تقدير تكاليف التأمينات العامة وتحديد قيم المطالبات المحتملة والتسعير الدقيق باستخدام النماذج التقليدية.

1.1.2. الدارسات السابقة:

تناولت العديد من الدارسات العربية والأجنبية استخدام الشبكات العصبية الاصطناعية في التنبؤ في مجال التأمين، حيث نجد أن هناك بعض الدارسات اهتمت باستخدام الشبكات العصبية في التنبؤ بالطلب على التأمين أو تكرار المطالبات أو حجم الأقساط مثل دراسة (محمود مشعال، 2012)، ودراسة (أحمد عبد الرحيم، 2018)، أما دراسة (Wenguang Yu, et al., 2021) اهتمت بتسعير بعض منتجات التأمين عن طريق استخدام بعض نماذج الشبكات العصبية في التنبؤ بحجم المطالبات المستقبلية.

كما تم استخدام الشبكات العصبية في تحديد المزيج الأمثل لعمليات إعادة التأمين الصادر في السوق المصري في دراسة (مظهر، 2004)، كما تم أيضاً استخدامها في التنبؤ بحجم الخسارة في تأمين السيارات في دراسة (Fred L. Ketchens, 2000) وأيضاً في دراسة (يحيى الجمال، عمر صابر، 2012)، وكذلك في دراسة (Julian Lowe, Louise Pryor, 1996)، كما استخدمت الشبكات العصبية التقليدية في دراسة (جيهان المعداوي، مصطفى يوسف، 2017) للتنبؤ بمطالبات تأمين السيارات التكميلي، أما دراسة (مرون جابر أحمد، 2020) فقد استخدمت نموذج الشبكات الانحدار العصبية المعممة لتسعير خطر قروض الائتمان المصرفي كأحد منتجات التأمينات العامة. وتمت مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار في دراسة (عمر صابر، الجمال، ذكريا، 2012)، وهناك دراسات تناولت استخدام الشبكات العصبية في تقدير هامش ربح الاكتتاب وترشيده قرارات الاكتتاب في التأمينات العامة (الدالي، 2015)، و(سعيد، 2013). واهتمت مجموعة أخرى من الدراسات باستخدام الشبكات العصبية في تقدير مخصص التعويضات تحت التسوية وتقدير هامش الملاءة المالية لفروع التأمينات العامة (نادي، عزت، 1999)، (عطية وصالح، 2015).

وأشارت هذه الدراسات إلى أن الشبكات العصبية الاصطناعية تعتبر أفضل من النماذج الاحصائية التقليدية في التنبؤ، حيث وصلت لمعدلات مرتفعة من الدقة والكفاءة في كثير من هذه الدراسات، كما تبين للباحث عدم وجود دراسات سابقة تناولت موضوع استخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي "back-propagation artificial neural network" في مجال التنبؤ بحجم المطالبات المستقبلية في التأمينات العامة كخطوة مهمة لتسعير أخطار هذه التأمينات.

1.3. أهداف البحث:

الهدف العام لهذه الدراسة هو المساهمة ببعض النماذج الحديثة التي تستخدم في دراسة المشكلة الأساسية السابق الإشارة إليها والمتمثلة في التنبؤ بصورة أكثر دقة بحجم المطالبات المستقبلية لتأمين السيارات التكميلي وذلك عن طريق تطوير نموذج مقترح يستند إلى نموذج كمي يستخدم في تصنيف العوامل المختلفة التي تؤثر على حجم المطالبات وتحديد أكثر العوامل المؤثرة ثم استنتاج النموذج الرياضي الذي سوف يستخدم في التنبؤ بحجم المطالبات المستقبلية باستخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي "back-propagation artificial neural network" (BP) للتنبؤ بقيم المطالبات كأساس لتسعير التأمينات العامة في شركات التأمين المصرية. وسيتم تصميم وتطبيق النموذج على بيانات المطالبات والمعلومات التأمينية لشركات التأمين المصرية اعتماداً على بيانات الخبرة الماضية، وستقدم الدراسة تحليلاً دقيقاً لأداء النموذج وقدرته على تقدير المطالبات بدقة وتحسين عمليات التسعير وتقدير المخاطر.

ويمكن تلخيص هدف البحث في النقاط التالية:

- تطوير نموذج مقترح لتحسين عمليات تسعير التأمينات العامة باستخدام شبكة العصبية.
- تحسين دقة تقدير المطالبات وتقدير المخاطر.

- تقديم أسلوب تحليلي مبتكر لصناعة التأمين.
- تحقيق تكنولوجيا تقديرية متقدمة للتأمين.
- تحقيق تطبيق عملي وملموس على سوق التأمين المصري.

1.4. أهمية البحث:

يمكن تلخيص أهمية الدراسة النقاط التالية:

- **تحسين عمليات التسعير والتقدير في صناعة التأمين:**
تعتبر صناعة التأمين من أهم القطاعات الاقتصادية التي تقدم خدمات حماية مالية للأفراد والشركات ويعتمد تقدير تكلفة التأمين والمخاطر المحتملة على دقة التنبؤ بقيم المطالبات، وبالتالي ومن خلال تطبيق النموذج المقترح الذي يعتمد على الشبكات العصبية ذات الانتشار العكسي للتنبؤ بقيم المطالبات، يمكن تحسين دقة عمليات التسعير والتقدير، مما يساهم في توفير تسعيرات تأمينية أكثر عدالة ودقة للعملاء.
- **تعزيز قدرة شركات التأمين على إدارة المخاطر:**
تقوم شركات التأمين بتحمل المخاطر المالية عند حدوث مطالبات من قبل المؤمن عليهم. يمكن لنموذج التنبؤ بقيم المطالبات باستخدام شبكة العصبية أن يساعد هذه الشركات في تقدير المخاطر بشكل أفضل وتحديد احتياطات تأمين مناسبة. هذا بدوره يعزز قدرتهم على التعامل مع الصدمات المالية وتقديم خدمات تأمينية مستدامة للعملاء.
- **تعزيز تكنولوجيا صناعة التأمين:**
يعد تطبيق شبكات العصبية لتحسين عمليات تقدير وتسعير التأمينات تحولاً تكنولوجياً مهماً، يساهم البحث في دمج التقنيات الحديثة في صناعة التأمين وتعزيز التكنولوجيا المستخدمة في تحليل البيانات واتخاذ القرارات الأمر الذي يساهم في تحسين كفاءة العمليات وتقديم خدمات تأمينية أكثر تقدماً وتطوراً.
- **تطبيق محدد لسوق التأمين المصري:**
بالنظر إلى تطبيق البحث على شركات التأمين المصرية، يساهم هذا البحث في تقديم نموذج محدد للسوق المصري، وهذا يعكس الحاجة الملحة لتحسين تقنيات التسعير والتقدير في هذا السوق المتنامي. تكون النتائج أكثر تطبيقية وقابلية للتعميم، مما يمهد الطريق لتحسين وتطوير الخدمات التأمينية في سوق التأمين المصري وتعزيز دور القطاع في الاقتصاد.

1.5. منهج البحث:

استخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي " Back-Propagation Artificial Neural Network" بهدف الوصول إلى نموذج كمي يستخدم في التنبؤ بحجم المطالبات المستقبلية في تأمين السيارات التكميلي.

1.6. فروض البحث:

- تسعى الدراسة إلى اختبار الفرضيات التالية:
- يعتمد تسعير تأمين السيارات التكميلي بصورة أساسية على حجم المطالبات المتوقعة.
 - استخدام الشبكات العصبية الاصطناعية ذات الانتشار العكسي سوف يحسن من دقة التنبؤ بحجم المطالبات.

1.7. حدود البحث:

- تقتصر هذه الدراسة على الفترة الزمنية من 2019 إلى 2023 م.
- تقتصر الدراسة التطبيقية على عينة عشوائية من بيانات المؤمن لهم في إحدى شركات التأمين المصرية حجماً 400 مشاهدة.

2. نموذج الشبكة العصبية ذات الانتشار العكسي (Back Propagation) BP

تعد الشبكة العصبية وفقاً لطريقة (Back Propagation) Bp من أكثر الشبكات العصبية استخداماً حيث تعتمد هذه الخوارزمية على الانتشار العكسي، باستخدام طريقة الهبوط الأكثر انحداراً لتعديل المعامل في الاتجاه المعاكس وفقاً للخطأ بين قيمة المخرجات الفعلية وقيمة المخرجات المتوقعة، حتى يتم تحسين المعامل لجعل الخطأ ضمن المدى المقبول. يمكن للشبكة العصبية BP تعلم الأنماط الثابتة، واستخدام بعض البيانات لتحديد المعلمات المقابلة، ثم عمل تنبؤات بناءً على هذه المعلمات.

سميت بالانتشار العكسي لأنها تبدأ من الطبقة النهائية (طبقة المخرجات) بعد اكتمال مرحلة الاتجاه الأمامي (Feedforward)، وبالاتجاه العكسي من أجل تصحيح الأخطاء الناتجة، حيث يتلخص عمل خوارزمية الانتشار العكسي بحساب الخطأ في المخرجات لتعديل الأوزان بين طبقة المخرجات والطبقة المخفية، ثم بعد ذلك تقوم بتعديل الأوزان بين الطبقة المخفية وطبقة المدخلات، ثم بعد ذلك يتم قياس المخرجات ومقارنتها بالقيم الفعلية التي تم تزويد الشبكة بها ومن ثم حساب الخطأ وتكرار العملية مرة أخرى حتى الوصول إلى أقل خطأ ممكن، حيث يطلق على هذه العملية (التدريب)، والغرض من هذه العملية هو الحصول على الأوزان المثلى التي تعطي أقل قيمة خطأ للشبكة العصبية، حتى يتم بعد ذلك استخدام النموذج في التنبؤ بالبيانات الجديدة.

2.1. طبقات نموذج الشبكة العصبية BP

في هذا البحث تم استخدام نموذج الشبكة العصبية BP المكون من ثلاث طبقات تتمثل في طبقة الإدخال وطبقة الإخراج والطبقة المخفية:

- **طبقة المدخلات Input Layer:** هي الطبقة الأولى في الشبكات العصبية، وتقوم هذه الطبقة باستقبال بيانات المتغيرات المستقلة من المصادر المختلفة، وتحتوي على عدد من النيرونات أو العصبونات أو عناصر المعالجة التي يتوافق عددها مع عدد المتغيرات المستقلة للمدخلات المراد قياسها.
- **الطبقة الخفية Hidden Layer:** هي الطبقة التي تلي طبقة المدخلات، وقد تحتوي الشبكة العصبية على طبقة خفية واحدة أو أكثر، وتقوم هذه الطبقة بتصنيف وتمييز وتحليل المدخلات بإعطاء وزن نسبي لكل منها، ثم استخدام الدوال التحليلية لتعديل هذه الأوزان النسبية، بعد مقارنة النتائج الحالية بالمستهدفة، لتقليل الأخطاء وتحقيق أفضل نتائج.
- **طبقة المخرجات Output Layer:** هي الطبقة النهائية للشبكات العصبية، وتحتوي على عدد من عناصر المعالجة التي يتوافق عددها مع عدد متغيرات الاستجابة، وتقوم هذه الطبقة بعرض النتائج التي وصلت إليها من الطبقة السابقة إلى المستخدم النهائي، وبالتالي عرض النتائج النهائية للشبكات العصبية.

2- يفرض أن نسبة خطأ التقدير (0.05) وبدرجة ثقة (95%) ، فإن حجم العينة يتحدد بالعلاقة:

$$n = \frac{z^2 \times P \times (1-P)}{e^2} = \frac{(1.96)^2 \times 0.5 \times 0.5}{(0.05)^2} = 384.16$$

* استخدام P=0.5 في الصيغة السابقة يؤدي إلى الحصول على أفضل قيمة ممكنة لحجم العينة والتي تعطينا أفضل تقديرات ممكنة.

2.2. دوال نموذج الشبكة العصبية BP

2.2.1. الأوزان النسبية Weights:

تقوم هذه الأوزان بتحديد القوة النسبية أو الأهمية النسبية لكل مدخل من المدخلات، وبالتالي تحدد قوة العلاقة بين عناصر ووحدات المعالجة ومدى فعالية عقد الاتصال، ويمكن تعديل الأوزان النسبية من خلال التدريب والتعلم .

2.2.2. دالة التجميع Summation Function:

تعد هذه الدالة بمثابة المنشط الداخلي أو المحفز للشبكة العصبية، حيث تقوم بحساب الأوزان النسبية للمدخلات، وذلك بضرب كل مدخل من المدخلات في وزنه النسبي للحصول على المجموع .

2.2.3. دالة التحويل Transfer Function :

يطلق عليها أيضا دالة التنشيط Activation 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 sigmoid لتنشيط الشبكات العصبية (وتأخذ ودالة سيجمويد sigmoid قيم الدخل المحصورة بين $-\infty$ و $+\infty$ وتكون المخرجات محصورة بين 0 و 1 وهي أكثر الدوال استخداماً بسبب سهولة اشتقاقه التي تأخذ الصيغة الآتية ضمن المجال (0،1) $f(x) = \frac{1}{1+e^{-x}}$ حيث ان $f(x)$ تمثل حاصل ضرب قيمة الإدخال مع الوزن المناظر لها، وتمثل (μ) ميل الدالة وتكون قيمتها مساوية الى الواحد ومشتقة الدالة $F(x)$ هي $f'(x) = f(x)[1-f(x)]$.

2.2.4. وهناك العديد من دوال التنشيط الأخرى المستخدمة في الشبكات العصبية منها :

2.2.4.1. دالة Step Function

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$

2.2.4.2. دالة Hyperbolic Tangent (Tanh)

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

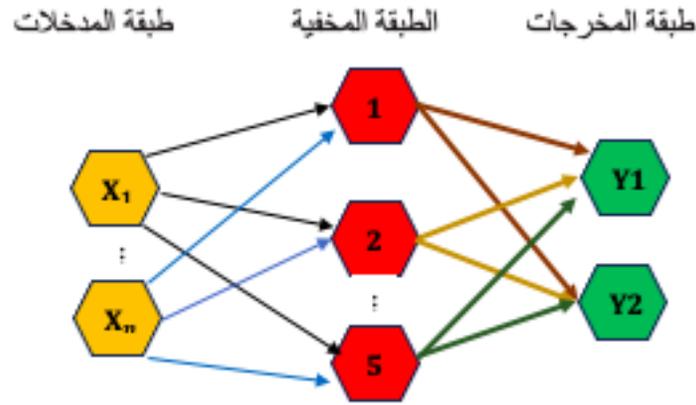
2.2.4.3. دالة SoftMax

$$f(x_i) = \frac{\exp(x_i)}{\sum \exp(x_i)}$$

2.2.4.4. دالة ReLU (Rectified Linear Unit) Function

$$f(x) = \max(0, x)$$

شكل (1): طبقات نموذج الشبكة العصبية وفقاً لطريقة (Back Propagation) Bp



فبفرض أن هناك n من الخلايا العصبية في طبقة المدخلات، وخمس خلايا عصبية في الطبقة المخفية، وخليتين عصبيتين في طبقة المخرجات. $\mathbf{X}_k = (x_{1k}, x_{2k}, \dots, x_{nk})$ تمثل قيم المدخلات حيث $k = 1, 2, \dots, m$ ، α_{ij} هي الأوزان التي تربط بين طبقة المدخلات والطبقة المخفية، β_{jl} هي الأوزان التي تربط الطبقة المخفية وقيمة طبقة المخرجات، حيث $i = 1, 2, \dots, n$ ، $j = 1, 2, \dots, 5$ ، $l = 1, 2$.

الخلايا العصبية التي تكون في نفس الطبقة غير متصلة ببعضها البعض، ولكن كل خلية عصبية بين طبقة الإدخال والطبقة المخفية، والطبقة المخفية وطبقة الإخراج تكون متصلة.

الخوارزمية المحددة لنموذج الشبكة العصبية BP المبنية على الشكل رقم (1) تقوم على افتراض أن دالة التحفيز تستخدم دالة sigmoid، وبشكل متتابع يتم إدخال بيانات m عينة X_1, X_2, \dots, X_m ثم اختيار k عينة عشوائية

$$\mathbf{X}_k = (x_{1k}, x_{2k}, \dots, x_{nk})$$

$$\text{متجه مدخلات الطبقة المخفية } \mathbf{Y}_k = (y_{1k}, y_{2k}, \dots, y_{5k})$$

$$\text{متجه مخرجات الطبقة المخفية هو } \mathbf{Z}_k = (z_{1k}, z_{2k}, \dots, z_{5k})$$

$$\text{متجه المدخلات لطبقة المخرجات } \tilde{\mathbf{Y}}_k = (\tilde{y}_{1k}, \tilde{y}_{2k})$$

$$\text{متجه مخرجات طبقة المخرجات } \tilde{\mathbf{Z}}_k = (\tilde{z}_{1k}, \tilde{z}_{2k})$$

$$\text{متجه المخرجات المتوقع } \mathbf{R}_k = (r_{1k}, r_{2k})$$

ويُشار إلى حدود كل خلية عصبية في الطبقة المخفية على أنها α_j ، ويشار إلى حدود كل خلية عصبية في طبقة المخرجات على أنها b_l ، ودالة التنشيط هي $f(\cdot)$ ، ومعلمة التعلم هي μ و دالة الخطأ هي:

$$E = \frac{1}{2} \sum_{I=1}^2 (r_{Ik}, \tilde{z}_{Ik})^2$$

ويمكن حساب مدخلات ومخرجات كل خلية عصبية في الطبقة المخفية وطبقة المخرجات على النحو التالي:

$$y_{jk} = \sum_{i=1}^n \alpha_{ij} x_{ik} - a_j,$$

$$z_{jk} = f(y_{jk}),$$

$$\tilde{y}_{lk} = \sum_{j=1}^5 \beta_{jl} z_{jk} - b_l,$$

$$\tilde{z}_{lk} = f(\tilde{y}_{lk})$$

باستخدام الناتج المتوقع والناتج الفعلي للشبكة، تكون المشتقة الجزئية لدالة الخطأ لكل خلية عصبية في طبقة المخرجات على النحو التالي:

$$\begin{aligned} \frac{\partial E}{\partial \tilde{y}_{lk}} &= \frac{\partial \left[\left(\frac{1}{2} \right) \sum_{l=1}^2 (r_{lk} - \tilde{z}_{lk})^2 \right]}{\partial \tilde{y}_{lk}} \\ &= \frac{\partial \left[\left(\frac{1}{2} \right) \sum_{l=1}^2 (r_{lk} - f(\tilde{y}_{lk}))^2 \right]}{\partial \tilde{y}_{lk}} \end{aligned}$$

باستخدام وزن الاتصال من الطبقة المخفية إلى طبقة المخرجات، يتم الوصول الي طبقة المخرجات ومخرجات الطبقة المخفية لحساب المشتق الجزئي لدالة الخطأ لكل خلية عصبية من الطبقة المخفية على النحو التالي:

$$\begin{aligned} \frac{\partial E}{\partial y_{jk}} &= \frac{\partial \left[\left(\frac{1}{2} \right) \sum_{l=1}^2 (r_{lk} - \tilde{z}_{lk})^2 \right]}{\partial y_{jk}} \\ &= \frac{\partial \left[\left(\frac{1}{2} \right) \sum_{l=1}^2 (r_{lk} - \tilde{z}_{lk})^2 \right]}{\partial y_{jk}} \cdot \frac{\partial z_{jk}}{\partial y_{jk}} \\ &= \frac{\partial \left[\left(\frac{1}{2} \right) \sum_{l=1}^2 (r_{lk} - f(\sum_{j=1}^5 \beta_{jl} z_{jk} - b_l))^2 \right]}{\partial z_{jk}} \cdot f'(y_{jk}) \\ &= - \sum_{l=1}^2 (r_{lk} - \tilde{z}_{lk}) f'(\tilde{y}_{lk}) \beta_{jl} \cdot f'(y_{jk}), \\ &= - (\sum_{l=1}^2 \delta_{lk} \beta_{jl}) f'(y_{jk}), \quad \triangleq -P_{jk} \end{aligned}$$

ومن خلال الصيغتين أعلاه، يمكننا الحصول على تغيير قيمة الوزن β_{jl} في كل تعديل على النحو التالي:

$$\Delta \beta_{jl} = -\mu \frac{\partial E}{\partial \beta_{jl}} = -\mu \frac{\partial E}{\partial \tilde{y}_{lk}} \cdot \frac{\partial \tilde{y}_{lk}}{\partial \beta_{jl}} = \mu \delta_{lk} z_{jk}$$

وبعد اجراء N تعديل، تكون القيمة (N + 1) على النحو التالي:

$$\beta_{jl}^{N+1} = \beta_{jl}^N + \Delta\beta_{jl}$$

وبالمثل، يمكننا الحصول على تغيير قيمة الوزن α_{ij} في كل تعديل وقيمة (N+1) بعد N تعديل على النحو التالي:

$$-\mu \frac{\partial E}{\partial \alpha_{ij}} = \mu x_{ik} p_{jk} = \Delta\alpha_{ij}$$

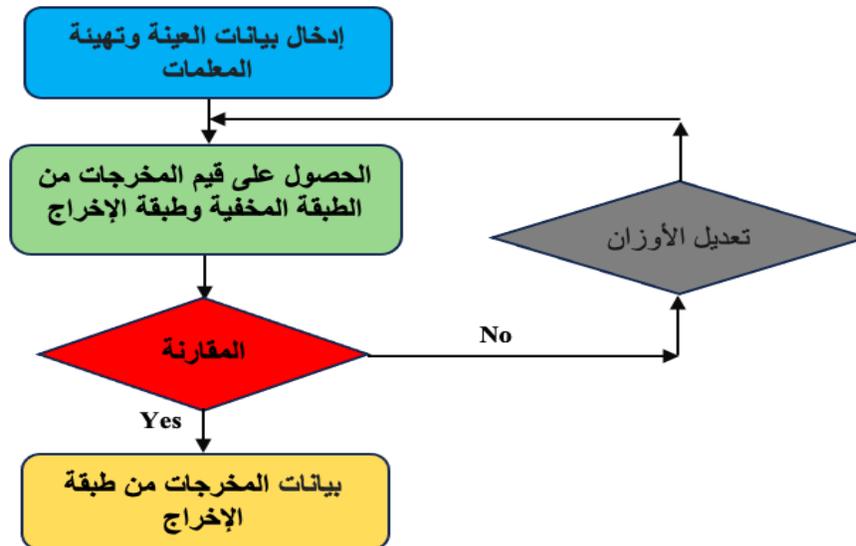
$$\alpha_{ij}^{N+1} = \alpha_{ij}^N + \Delta\alpha_{ij},$$

ويمكن حساب الخطأ العام على النحو التالي:

$$E = \frac{1}{2m} \sum_{k=1}^m \sum_{i=1}^2 (r_{ik} - \tilde{z}_{ik})^2$$

ويتم مقارنة حجم الخطأ العام مع خطأ النموذج، فإذا تجاوز الخطأ العام خطأ النموذج يتم ضبط الأوزان بشكل مستمر حتى يتم تحقيق خطأ النموذج. ويوضح الشكل رقم (٢) الية الحساب في نموذج الشبكة العصبية BP:

شكل (٢): خوارزمية الانتشار العكسي Bp



3. النموذج المقترح وتحليل البيانات:

حققت صناعة التأمين في مصر نموًا ملحوظًا بالتوازي مع التطور المستمر للاقتصاد المصري، مما جعل وجود نظام تسعير عادل وشامل أمرًا ضروريًا لتطوير هذه الصناعة. شهدت أقساط التأمين على السيارات زيادة مستمرة على مدار السنوات الماضية، ففي عام 2013 بلغ دخل أقساط التأمين على السيارات حوالي 1.42 مليار جنيه مصري، ما يمثل 20% من دخل أقساط تأمينات الممتلكات والمسؤوليات. وفي عام 2014 ارتفع دخل أقساط التأمين على السيارات إلى 1.6 مليار جنيه مصري، وهو ما يمثل 22% من دخل أقساط تأمينات الممتلكات والمسؤوليات.

وفي عام 2018، استمر النمو ليصل دخل أقساط التأمين على السيارات إلى 3.22 مليار جنيه مصري، محافظاً على نسبة 21% من دخل أقساط تأمينات الممتلكات والمسؤوليات. بحلول عام 2022، بلغ دخل أقساط التأمين على السيارات 5.4 مليار جنيه مصري، ما يعادل 21% من دخل أقساط تأمينات الممتلكات والمسؤوليات. من هذه الأرقام، يمكن ملاحظة أن دخل أقساط التأمين على السيارات أخذ في الزيادة بشكل مستمر، مع الحفاظ على نسبة مساهمته في دخل أقساط التأمين على الممتلكات عند مستوى يزيد عن 20%.

جدول (٢): الأهمية النسبية لأقساط السيارات الي أقساط تأمينات الممتلكات والمسؤوليات (الأرقام بالآلاف)

السنة	أقساط التأمين فرع السيارات	أقساط تأمينات الممتلكات والمسؤوليات	نسبة أقساط السيارات/ أقساط تأمينات الممتلكات والمسؤوليات
2013	1425157	6953525	20%
2014	1571976	7546710	21%
2015	1796167	8117980	22%
2016	2042298	9009391	23%
2017	2696024	12328622	22%
2018	3225384	15621435	21%
2019	3771499	18112579	21%
2020	3956512	20244778	20%
2021	4527753	21919654	21%
2022	5431183	25658163	21%

المصدر: الكتاب الإحصائي السنوي عن نشاط سوق التأمين في مصر أعداد مختلفة.

وبالتالي تلعب ربحية التأمين على السيارات دوراً حاسماً في تعزيز الكفاءة التشغيلية لشركات التأمين على الممتلكات. ومع ذلك، تواجه معظم شركات التأمين مشكلة رئيسية تتمثل في ارتفاع حجم المطالبات عن التوقعات في فرع تأمين السيارات، وهو ما يعود إلى عدم كفاية أقساط التأمين. فعدم كفاية الأقساط لا يعني بالضرورة أن القسط قد تم تقديره بشكل غير دقيق، بل يشير إلى غياب التمييز الملائم بين الأقساط الخاصة بالمخاطر المختلفة، أو أن الفروق بينها غير مناسبة. هذا الأمر يؤدي إلى اختيارات غير صحيحة وزيادة عدد المطالبات. كما أن ضعف جودة الأعمال يساهم في عدم تناسب دخل الأقساط مع المخاطر التي تتحملها الشركة.

ومن هنا، يتضح دور هذا البحث في تقديم نموذج يهدف إلى تقدير المطالبات، وهو عامل أساسي يؤثر في عملية تحديد قسط التأمين، مما يسهم في تحسين دقة التسعير والتوازن بين الأقساط والمخاطر الفعلية.

3.1. تهيئة وتجهيز البيانات لبناء النموذج

البيانات المستخدمة في هذا البحث تمثل بيانات فعلية تم الحصول عليها من إحدى شركات التأمين المصرية، وتشمل المتغيرات التالية: عمر السائق، جنس السائق، عمر السيارة، السعر السوقي للسيارة، والمطالبات الإجمالية. وقد تم استخدام هذه البيانات بعد تجهيزها ومعالجتها لبناء نموذج الشبكة العصبية وفقاً لطريقة الانتشار العكسي (Back Propagation - BP) داخل برنامج MATLAB. تمت معالجة هذه البيانات وإفراغها في برنامج MATLAB لتدريب النموذج وتحقيق التنبؤ بمطالبات التأمين بدقة عالية. والجدول التالي يعرض جزءاً من هذه البيانات التي تم استخدامها في البحث:

جدول (٣): جزء من قاعدة البيانات المستخدمة لبناء الشبكة العصبية

اسم الماركة	السعر السوقي للسيارة	نوع الوثيقة	نوع الحادث	سنة الصنع	عمر السيارة	عمر السائق	جنس السائق
هيونداالننرا	1250000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2023	1	49	2
اوبترا	570000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2020	4	51	1
مرسيدس c200	3100000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2021	3	40	2
301 بيجو	950000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2023	1	44	1
A7 اوكتافيا	1940000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2023	1	38	1
سكودا اوكتافيا	2150000	تأمين تكميلي سيارات (خصوصي)	Partial Loss	2024	0	35	1

- يشير رقم ١ الى الذكور ورقم ٢ الى الاناث لبيان نوع السائق.

2	52	4	2020	Partial Loss	تأمين تكميلي سيارات (خصوصي)	1250000	A7 اوكتافيا
2	31	3	2021	Partial Loss	تأمين تكميلي سيارات (خصوصي)	3350000	مرسيدس c180
1	44	4	2020	Partial Loss	تأمين تكميلي سيارات (خصوصي)	2750000	مرسيدس c180
1	34	4	2020	Partial Loss	تأمين تكميلي سيارات (خصوصي)	2800000	مرسيدس c300

3.2. هيكل الشبكة العصبية وفقاً لطريقة BP

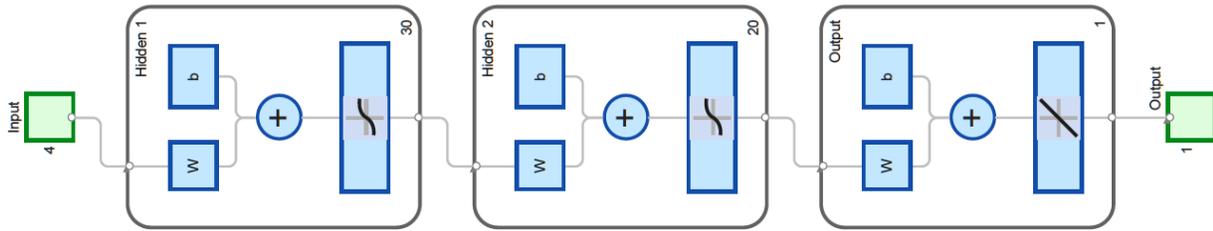
يعتبر اختيار الحجم المناسب للشبكة من أصعب التحديات في تصميم الشبكات العصبية الاصطناعية. بالإضافة إلى تعدد الخيارات المتاحة لدالة التنشيط لكل خلية، هناك تحدي اختيار العدد الأمثل للطبقات في الشبكة وعدد الخلايا العصبية في كل طبقة. جميع هذه الاختيارات يجب اتخاذها قبل بدء عملية التدريب، وأي اختيار غير مناسب لحجم الشبكة قد يؤدي إلى نتائج غير دقيقة أو غير مقبولة.

بشكل عام، لا توجد معايير أو قواعد ثابتة عند تصميم الشبكات العصبية الاصطناعية. ومع ذلك، فإن إحدى أهم مراحل التصميم هي تحديد عدد الطبقات الخفية وعدد العصبونات ضمن تلك الطبقات. لا تزال طريقة المحاولة والخطأ (Trial and Error) من أكثر الطرق شيوعاً وسهولة في اختيار حجم الشبكة، حيث يتم تجربة عدة هياكل مختلفة للشبكات واختيار أفضلها. يُفضل أن يتم هذا التجريب بشكل منهجي لتجنب إهدار الوقت، حيث يبدأ عادةً بشبكة بسيطة، ويتم زيادة حجمها تدريجياً عن طريق إضافة خلايا أو طبقات جديدة حتى يتم الحصول على نتائج مقبولة.

في هذه الدراسة، تم التجريب المستمر والتعديل في حجم الشبكة من خلال تغيير عدد الطبقات الخفية أو إضافة وحذف العصبونات، وذلك من أجل الوصول إلى شبكة عصبية ذات قدرة عالية على التنبؤ وقيم أقل لمتوسط مربع الخطأ (MSE).

تم استخدام برنامج MATLAB لإجراء العمليات الحسابية والتمثيل البياني للمعطيات، ولتحديد هيكل الشبكة المستخدمة في التنبؤ بقيمة المطالبات. يتكون الهيكل النهائي للشبكة من أربع خلايا عصبية في طبقة المدخلات، تمثل المتغيرات المستقلة (جنس السائق X1، عمر السائق X2، عمر السيارة X3، والسعر السوقي للسيارة X4). كما تحتوي الطبقة الخفية على طبقتين، تتكون الأولى من 30 عصبوناً، والثانية من 20 عصبوناً، تم تحديد عدد العصبونات في هذه الطبقات باستخدام طريقة المحاولة والخطأ. تحتوي طبقة المخرجات على خلية عصبية واحدة تمثل قيمة المطالبات الإجمالية (Y). ويظهر تحليل نتائج شبكة التدريب في الشكل رقم 3 التالي.

شكل (٣): هيكل الشبكة العصبية وفقاً لطريقة (Back Propagation) Bp



المصدر: من إعداد الباحث بالاعتماد على برنامج MATLAB

3.3 تدريب الشبكة

تم استخدام دالة التنشيط Hyperbolic Tangent بين طبقة المدخلات والطبقة الخفية، ودالة purelin بين الطبقة الخفية وطبقة المخرجات. كما تم استخدام دالة التدريب trainlm لتحليل وتدريب الشبكة، حيث تعمل هذه الدالة على تصغير متوسط مربع الخطأ (MSE) إلى أدنى مستوى ممكن، وهي إحدى خوارزميات الانتشار العكسي (Backpropagation) لتصحيح الأخطاء.

وبعد إجراء العديد من التجارب، تم التوصل إلى أن الشبكة العصبية الصناعية ذات الهيكلية (1-30-20-1)، التي تم تقسيمها بالشكل التالي: 70% لمرحلة التدريب (Train ratio)، 15% لمرحلة الاختبار (Test ratio)، و15% لمرحلة التحقق (Validation ratio)، هي الشبكة المثلى التي أعطت أقل قيمة لمتوسط مربع الخطأ (MSE)، والتي بلغت $1.8411e-25$ ، كما هو موضح في الجدول رقم (٤) التالي:

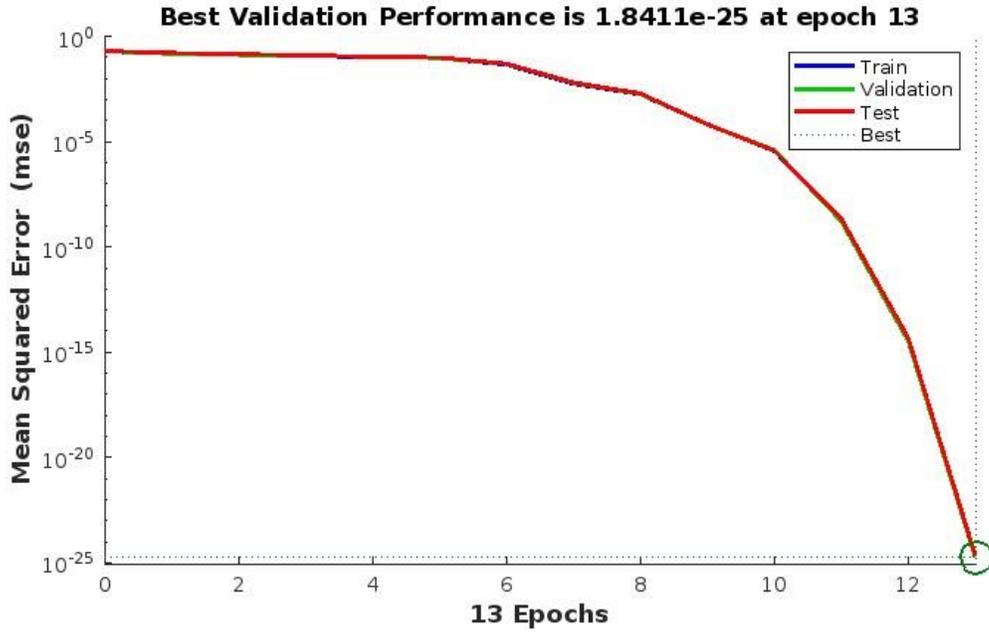
جدول (٤): أفضل أداء للشبكة العصبية عند مختلف معماريات ونسب تقسيم البيانات

Tst-VI-Trn %	NN Architecture (Input-Hidden-output) BP															
	1-10-1		1-20-1		1-30-1		1-10-10-1		1-20-10-1		1-30-20-1		1-20-20-20-1		1-30-20-20-1	
	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R
5-15-80	6.3253e-12	0.4	5.1518e-22	0.44	5.0694e-13	0.76	5.8669e-17	0.77	6.3253e-12	0.4	5.1518e-22	0.44	5.0694e-13	0.76	5.8669e-17	0.77
10-10-80	1.2258e-10	0.05	1.7705e-19	0.78	1.2809e-19	0.27	5.5731e-18	0.72	1.2258e-10	0.05	1.7705e-19	0.78	1.2809e-19	0.27	5.5731e-18	0.72
10-15-75	1.4708e-16	0.76	4.4299e-09	0.9	1.29e-12	0.32	4.1488e-17	0.16	1.4708e-16	0.76	4.4299e-09	0.9	1.29e-12	0.32	4.1488e-17	0.16
10-20-70	5.1282e-11	0.9	1.0708e-16	0.8	0.10423	0.5	3.7674e-16	0.57	5.1282e-11	0.9	1.0708e-16	0.8	0.10423	0.5	3.7674e-16	0.57
20-10-70	1.275e-11	0.32	1.934e-15	0	4.7271e-21	0.72	3.0088e-23	0.36	1.275e-11	0.32	1.934e-15	0	4.7271e-21	0.72	3.0088e-23	0.36
15-15-70	3.4701e-15	0.12	1.8762e-07	0.67	0.0005329	0.9	5.2297e-17	0.8	3.4701e-15	0.12	1.8762e-07	0.9	0.0005329	0.9	5.2297e-17	0.8
10-25-65	4.3363e-24	0.11	3.3628e-15	0.33	0.070889	0.7	2.2116e-22	0.78	4.3363e-24	0.11	3.3628e-15	0.33	0.070889	0.7	2.2116e-22	0.78
10-30-60	2.7339e-21	0.61	9.4278e-21	0.22	4.2492e-16	0.09	5.6639e-22	0.85	2.7339e-21	0.61	9.4278e-21	0.22	4.2492e-16	0.09	5.6639e-22	0.85

3.4. اختبار الشبكة

يوضح الشكل رقم (٤) نتائج عملية التدريب والاختبار والتحقق من صحة الشبكة العصبية، حيث تظهر نقطة توقف التدريب بعد 13 دورة تكرارية، مع متوسط خطأ يساوي $1.8411e-25$ لمجموعة التحقق، وهي قيمة قريبة جداً من الصفر. هذا يشير إلى كفاءة النموذج وقدرته العالية على التنبؤ بالقيم المستقبلية، وتوقع المبلغ الإجمالي لمطالبات تأمين السيارات بشكل دقيق.

شكل (٤): تدريب الشبكة العصبية وفقاً لطريقة (Back Propagation) Bp

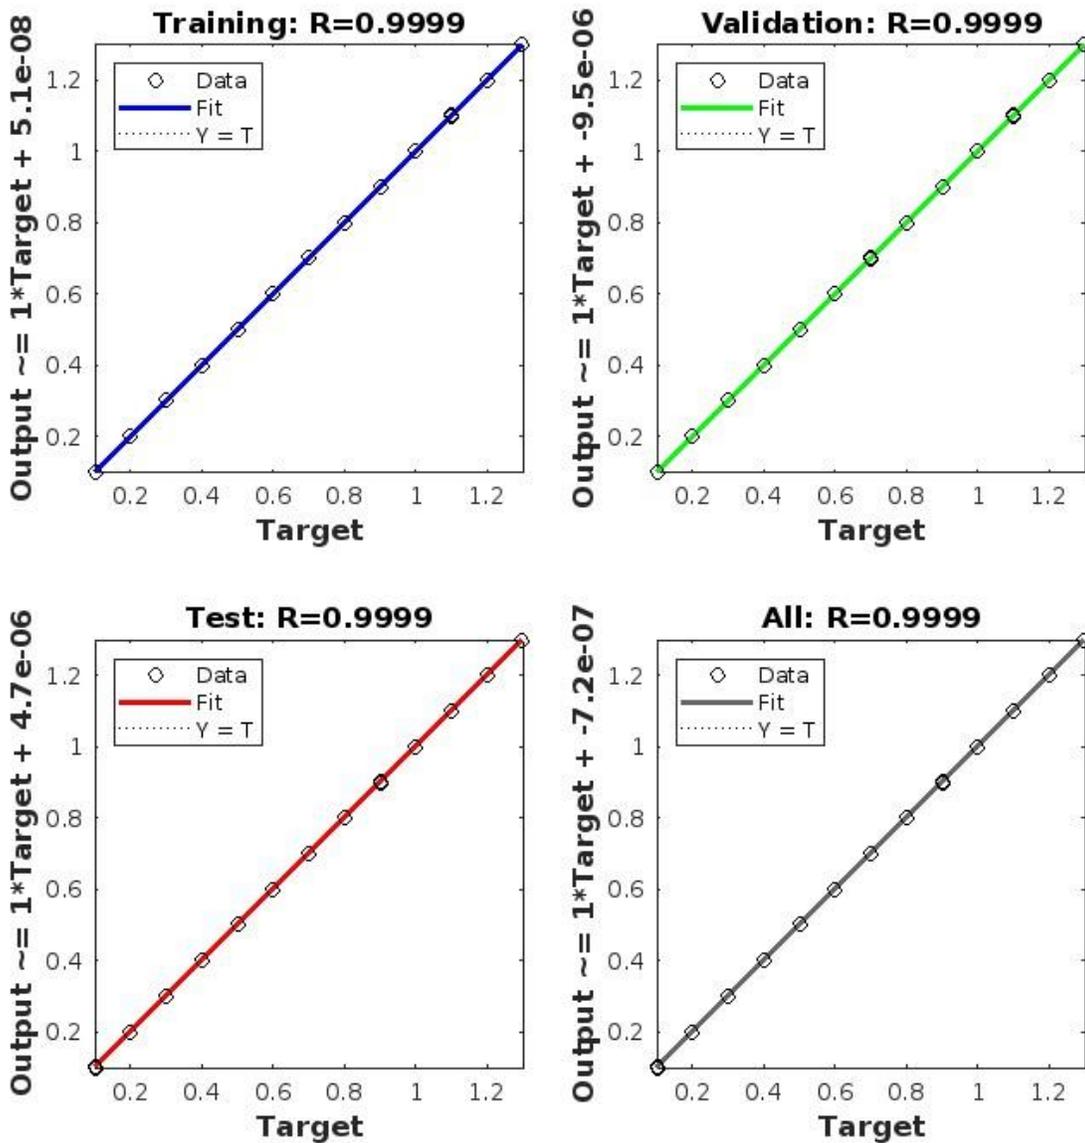


المصدر: إعداد الباحث بالاعتماد على برنامج MATLAB

3.5 تقييم كفاءة تدريب الشبكة

لتقييم كفاءة تدريب الشبكة العصبية، تم الاعتماد على معامل الارتباط (R) الذي يعكس قوة العلاقة بين المخرجات والأهداف. ويوضح الشكل رقم (٥) جودة التوفيق (Goodness of Fit)، حيث بلغ معامل التوفيق (R) قيمة تقترب من واحد صحيح، مما يشير بقوة إلى أن مدخلات الخلية العصبية لها تأثير تفسيري قوي على مخرجاتها. وبالتالي، يعد نموذج الشبكة العصبية مناسباً للغاية لإدخال بيانات مطالبات التأمين على السيارات، ويمكن استخدامه لتقدير مبلغ المطالبة الإجمالي والتنبؤ به بدقة.

شكل (٥): جودة المطابقة Goodness of the fit



المصدر: إعداد الباحث بالاعتماد على برنامج MATLAB

4. النتائج والتوصيات

أولاً: النتائج

1. أظهرت نتائج النموذج دقة عالية في التنبؤ بمطالبات التأمين على السيارات بالاعتماد على بيانات المتغيرات المستقلة مثل جنس السائق، عمر السائق، عمر السيارة، والسعر السوقي للسيارة. حيث بلغ متوسط مربع الخطأ (MSE) $1.8411e-25$ ، وهو رقم قريب جداً من الصفر، ومعامل الارتباط (R) بلغ قيمة تقترب من واحد صحيح، مما يشير إلى إمكانية الاعتماد على النموذج في التنبؤ بمطالبات التأمين.

2. يمكن تطبيق الشبكات العصبية الاصطناعية ذات الانتشار العكسي (BP) للتنبؤ بمطالبات التأمين على السيارات في شركات التأمين المصرية.
3. تتكون الخوارزمية المثلى للشبكة العصبية من طبقتين خفيتين إلى جانب المدخلات والمخرجات، حيث تحتوي الطبقة الخفية على 20 إلى 30 عصبون.
4. تعد نماذج الشبكات العصبية الاصطناعية من أبرز النماذج التي تساهم في التنبؤ نظرًا لقدرتها على التدرب على البيانات الحقيقية قبل إجراء التنبؤات.

ثانياً: التوصيات

1. نوصي شركات التأمين المصرية بالاعتماد على النموذج المبني باستخدام شبكة الانتشار العكسي (BP) نظرًا لكفاءته ودقته العالية في التنبؤ بمطالبات التأمين على السيارات.
2. نوصي شركات التأمين المصرية بدراسة أهم المتغيرات التي تؤثر على مبالغ مطالبات تأمين السيارات، مما يساهم في تحسين التنبؤ بمبالغ المطالبات.
3. نوصي شركات التأمين المصرية بالاستفادة من نماذج الذكاء الاصطناعي وطرق تحليل البيانات الضخمة (Big Data)، كونها من أفضل النماذج وأكثرها كفاءة في إجراء التنبؤات.

5. المراجع

أولاً: المراجع العربية

- الجمال، يحيي، صابر، عمر، (2012)، مقارنة التنبؤ باستخدام شبكة الانحدار العصبية المعممة بأسلوب الشبكات العصبية وتحليل الانحدار، المجلة العراقية للعلوم الإحصائية، كلية علوم الحاسب والرياضيات، جامعة الموصل، عدد 12.
- الدالي، أمل حسن، (2015)، تقدير هامش ربح الاككتاب باستخدام نموذج الشبكات العصبية بالتطبيق على تأمينات الممتلكات والمسئولية بسوق التأمين السعودي، مجلة البحوث التجارية المعاصرة، كلية التجارة - جامعة سوهاج، م 92، ع 2.
- المسلاتي، عبد الله علي، جها، أحمد عبد القادر، (2019)، استخدام الشبكات العصبية للتنبؤ في السلاسل الزمنية باستخدام طريقة التدريب ذات الانتشار الخلفي، International Conference on Technical Sciences (ICST2019)، 04 - 06 March 2019.
- المعداوي، جيهان مسعد، عبد الله، مصطفى يوسف، (2017)، استخدام الشبكات العصبية في التنبؤ بمطالبات تأمين السيارات التكميلي، المجلة المصرية للدراسات التجارية، كلية التجارة - جامعة المنصورة، المجلد 41 العدد الرابع.
- جلول، عطية، صالح، رضا، (2015)، تقدير الملاءة المالية لشركات التأمين باستخدام النماذج الكمية - دراسة تطبيقية على تأمينات الممتلكات والمسئولية بسوق التأمين المصرية، مجلة البحوث التجارية المعاصرة، كلية التجارة - جامعة سوهاج، م 92، ع 1.

حيدر، بادي، غطفان، عمّار، (2015)، نموذج شبكة عصبية صناعية للتنبؤ بالتبخر الشهري في المنطقة السهلية من الساحل السوري اعتماداً على درجة الحرارة الشهرية، مجلة جامعة تشرين للبحوث والدراسات العلمية، سلسلة العلوم الهندسية المجلد 37، العدد 1-2015.

خليل، احمد عبد الرحيم، (2018)، التنبؤ بمعدل الخسارة في التأمينات العامة باستخدام الشبكات العصبية الفازية بالتطبيق على فرعي تأمين الطيران وتأمين اجسام السفن، رسالة ماجستير، كلية التجارة - جامعة أسيوط.

عاشور، مروان عبد الحميد، (2019)، التنبؤ بالتدفق النقدي باستعمال الشبكة الاحتمالية العصبية، مجلة الجامعة العربية الأمريكية للبحوث، مجلد 5، العدد 1/2019.

عثمان، حسام محمد محمد، إسماعيل، طارق محمد حسنين، (2022)، استخدام الشبكات العصبية متعددة الطبقات في التنبؤ بمخاطر الائتمان لمنشآت الأعمال: دراسة تطبيقية، مجلة الدراسات المالية والتجارية، المجلد 32، العدد 1، إبريل 2022، الصفحة 169-219.

غولي، احمد سلطان محمد القره، الحمداني، اسراء عامر، (2010)، استخدام نماذج الشبكة العصبية الاصطناعية للتنبؤ بسعر الفائدة، مجلة ديالى للعلوم الصرفة، مجلد 6، العدد 4/2010.

محمد، مروان جابر أحمد، (2020)، نموذج انحداري موائم بالشبكات العصبية لتقدير معدل السعر للتأمينات العامة، مجلة الدراسات المالية والمحاسبية والإدارية، كلية التجارة - جامعة سوهاج، المجلد 7 العدد الثاني.

محمد، منعم عزيز، ققي، محمد محمود، حمد، اخترخان صابر، (2016)، التنبؤ بوفيات حوادث السيارات باستخدام تقنيتي الانحدار الذاتي المعمم المشروط (GARCH) والشبكات العصبية (ANN)، المؤتمر الدولي العلمي الخامس للإحصائيين العرب (القاهرة - جمهورية مصر العربية - 9-10/2/2016).

مشعال، محمود عبد العال، (2012)، استخدام نموذج الشبكات العصبية للتنبؤ بالطلب على تأمين الحريق بالسوق السعودي، مجلة البحوث التجارية المعاصرة، كلية التجارة، جامعة سوهاج، الع ارق، م 62، ع 2ع.

مظهر، مصطفى كمال، (2004)، أفضل مزيج لسياسات اعادة التأمين في السوق المصري باستخدام المحاكاة بالشبكات العصبية الاصطناعية، مجلة الدراسات والبحوث التجارية، كلية التجارة، جامعة بنها، م 42، ع 1ع

نادي، عزت حسين، محمد، عزت عبد الباري، طارق، (1999)، استخدام التحليل بالشبكات العصبية في تقدير مخصص التعويضات تحت التسوية لفروع التأمينات العامة"، المجلة المصرية للدراسات التجارية، كلية التجارة - جامعة المنصورة، م 32، ع 1.

ثانياً: المراجع الأجنبية

Fred L. Ketchens، (2000) ، "Using Artificial Neural Networks to Predict Losses in Automobile Insurance"، Doctoral Dissertation، University of Mississippi.

L. Z. Zhang and D. Wang، "A research on the rate making of automobile insurance with big data—modeling of automobile insurance claim severity based on SOM neural network," Insurance Studies, no. 9, pp. 56–65, 2018.

- M. V. Wuthrich, “Covariate selection from telematics car driving data,” *European Actuarial Journal*, vol. 7, no. 1, pp. 89–108, 2017.
- T. Mzhavia, *Vehicle Insurance Claim Data Study and Forecasting Model Using Artificial Neural Networks*, Tallinn University of Technology, Tallinn, Estonia, 2016.
- Y. C. Lin, J. Li, M.-S. Chen, Y.-X. Liu, and Y.-J. Liang, “A deep belief network to predict the hot deformation behavior of a ni-based superalloy,” *Neural Computing and Applications*, vol. 29, no. 11, pp. 1015–1023, 2016.
- Yu, W., Guan, G., Li, J., Wang, Q., Xie, X., Zhang, Y., Huang, Y., Yu, X., & Cui, C. (2021). Claim amount forecasting and pricing of automobile insurance based on the BP Neural Network. *Complexity*, 2021(1). <https://doi.org/10.1155/2021/6616121>