



# التنبؤ بمعدلات الأداء الفني في التأمين التكميلي للسيارات باستخدام الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى

## دراسة تطبيقية

إعداد

د. سماح سيد بيومي خليل

مدرس بكلية الاقتصاد والإدارة – جامعه ٦ أكتوبر

[ahmed.kasper2022@gmail.com](mailto:ahmed.kasper2022@gmail.com)

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد السادس – العدد الثاني – الجزء الرابع – يوليو ٢٠٢٥

التوثيق المقترح وفقاً لنظام APA:

خليل، سماح سيد بيومي (٢٠٢٥). التنبؤ بمعدلات الأداء الفني في التأمين التكميلي للسيارات باستخدام الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى: دراسة تطبيقية، المجلة العلمية للدراسات والبحوث المالية والتجارية، كلية التجارة، جامعة دمياط، ٦(٢)٤، ٣٦١-٤٠١.

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

## التنبؤ بمعدلات الأداء الفني في التأمين التكميلي للسيارات باستخدام الشبكات العصبية

### العميقة ذات الذاكرة طويلة وقصيرة المدى: دراسة تطبيقية

د. سماح سيد بيومي خليل

#### المستخلص:

هدفت هذه الدراسة إلى بناء نموذج تنبؤي باستخدام شبكات عصبية ذات ذاكرة طويلة وقصيرة المدى (LSTM) للتنبؤ بالمؤشرات الفنية (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة) لفرع تأمين السيارات التكميلي، لثماني شركات تأمينات ممتلكات ومسؤوليات في قطاع التأمين المصري. تم تطوير نموذج LSTM بنفس البنية والمعلمات لجميع الشركات، واستنادًا إلى بيانات تاريخية (الفترة الزمنية)، أظهر النموذج قدرة عالية على محاكاة البيانات بدقة والتنبؤ بها لمدة ثلاث سنوات مستقبلية. حيث حققت مؤشرات الأداء قيم RMSE منخفضة (مثال: ٠,٦٢٧٢ لمعدل الاحتفاظ، ٠,٢٥٧٥ لمعدل المصروفات العمومية والإدارية، ٠,١٣٧٥ لمعدل العمولات وتكاليف الإنتاج، ٠,٠٠٥٧ لمعدل الخسارة)، وقيم MAPE منخفضة (مثال: ٠,٩٢٪ لمعدل الاحتفاظ، ١,٠٨٪ لمعدل المصروفات العمومية والإدارية، ٠,٦٥٪ لمعدل العمولات وتكاليف الإنتاج، ٠,٨٣٪ لمعدل الخسارة)، وقيم  $R^2$  مرتفعة (مثال: ٠,٩٧٦٦ لمعدل الاحتفاظ، ٠,٩٧٤٥ لمعدل المصروفات العمومية والإدارية، ٠,٩٨١٩ لمعدل العمولات وتكاليف الإنتاج، ٠,٩٨٥٥ لمعدل الخسارة). توصي الدراسة بتبني نماذج LSTM لدعم اتخاذ القرارات الاستراتيجية وتحسين تقدير التكاليف المستقبلية في قطاع التأمين المصري.

**الكلمات المفتاحية:** تأمين السيارات التكميلي، الشبكات العميقة ذات الذاكرة القصيرة وطويلة المدى، المعدلات الفنية

#### ١- المقدمة

يعد التأمين التكميلي على السيارات من أكثر فروع التأمين تعقيدًا، نظرًا لطبيعة مخاطرة المتنوعة وصعوبة تحليل أدائه المالي بدقة. وذلك لتأثره بعدة عوامل مثل معدلات التعويض، سياسات التسعير، المصروفات التشغيلية، وشروط إعادة التأمين. وتعتمد شركات التأمين على مجموعة من المعدلات الفنية لقياس أدائها وتقييم استدامة عملياتها، ومن أبرز هذه المعدلات: (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة). تساعد هذه المعدلات في تحديد الربحية الفنية، وقياس كفاءة عمليات الاكتتاب والتسعير، وتقييم مدى الحاجة إلى التعديلات في سياسات إعادة التأمين أو تحسين استراتيجيات ضبط المخاطر. على سبيل المثال: معدل الخسارة يساعد في تحديد مدى كفاءة تسعير وثائق التأمين مقارنةً بالتعويضات المدفوعة، كما يؤثر معدل المصروفات الإدارية على كفاءة العمليات التشغيلية وقدرة الشركة على تحقيق هامش ربح مناسب. لذلك فإن التنبؤ الدقيق بهذه المعدلات يتيح لشركات التأمين تحسين سياساتها وضبط أسعارها، وتقليل المخاطر المحتملة. وفي العقود الأخيرة، اعتمدت شركات التأمين بشكل كبير على النماذج الإحصائية التقليدية مثل الانحدار الخطي والنماذج الخطية المعممة (GLM) لتحليل العلاقات بين المتغيرات المختلفة والتنبؤ بالمعدلات المالية والفنية. ومع أن هذه الأساليب تقدم نتائج جيدة عند التعامل مع البيانات ذات العلاقات الخطية والبسيطة، إلا أنها تعاني من قصور واضح عند مواجهة العلاقات غير الخطية والتفاعلات المعقدة بين العوامل المختلفة، مثل تأثير التغيير في أنماط المطالبات، وشروط الاكتتاب المختلفة. مما دفع الباحثين وشركات التأمين إلى تبني تقنيات الذكاء الاصطناعي، وعلى رأسها الشبكات العصبية العميقة، نظرًا لقدرتها على تحليل البيانات الضخمة واكتشاف الأنماط الخفية التي تؤثر على الأداء الفني للشركات. ومن خلال التعلم العميق، يمكن لهذه الشبكات تقديم توقعات أكثر دقة، مما يساعد شركات التأمين على اتخاذ قرارات مالية واستراتيجية أكثر كفاءة، وتقليل المخاطر المحتملة، وتعزيز تنافسيتها في السوق. إن الشبكات العصبية العميقة (Deep Neural Networks - DNNs) التي أثبتت قدرتها الفائقة على معالجة البيانات الضخمة، واكتشاف الأنماط المخفية، وتحسين دقة التنبؤات، يجعلها خيارًا مثاليًا للتنبؤ بهذه المعدلات. وذلك يرجع إلى أن الشبكات العصبية العميقة تعتمد على طبقات متعددة من الوحدات العصبية لمعالجة وتحليل البيانات بشكل تدريجي، حيث تتعلم من العلاقات المعقدة بين المتغيرات وتستخرج المعلومات ذات الصلة بشكل أكثر دقة مقارنةً بالنماذج التقليدية. في سياق التأمين التكميلي على السيارات، يمكن استخدام هذه الشبكات لتحليل البيانات التاريخية المتعلقة بالإقساط، التعويضات،

د. سماح سيد بيومي خليل

المصروفات، وتكاليف الإنتاج، مما يسمح بتطوير نماذج تنبؤ دقيقة للمعدلات الفنية الأساسية. وإلى جانب الدقة العالية، توفر الشبكات العصبية العميقة مرونة وتكيفاً مع التغيرات في البيانات، حيث يمكنها الاستمرار في التعلم من البيانات الجديدة بمرور الوقت، مما يسمح بتحديث النماذج بشكل دوري لتتماشى مع التغيرات السوقية والمخاطر الجديدة. وهذا يعد ميزة هامة لشركات التأمين التي تعمل في بيئة ديناميكية تتغير فيها أنماط المطالبات بمرور الوقت، وهناك العديد من الأنواع في الشبكات العصبية العميقة وكل منها مصمم لحل مشكلة محددة أو معالجة نوع معين من البيانات. ولكننا في هذه الدراسة سوف نقوم باستخدام الشبكات العصبية طويلة المدى وقصيرة المدى (LSTM)، نظراً لقدرتها على معالجة البيانات ذات الأنماط المتغيرة والمعقدة مثل السلاسل الزمنية، كما انها تُستخدم على نطاق واسع في التنبؤ بالمخاطر المالية حيث تستطيع (LSTM) التعرف على الأنماط بين العناصر المتباعدة في البيانات، وهو ما يعزز من دقتها عند التعامل مع بيانات كبيرة أو زمنية. وأيضاً سوف يتم استخدام برنامج MATLAB الإصدار ٢٠٢٤ للإدخال وتدريب الشبكة والتنبؤ بالمخرجات، كما سيتم استخدام مؤشرات الأداء (MAPE، MAE، RMSE) للتحقق من دقة التنبؤات، مما يمكننا من قياس مدى كفاءة النموذج في تقديم نتائج دقيقة يمكن الاعتماد عليها لدعم عمليات اتخاذ القرار في شركات التأمين.

## ٢- الدراسات السابقة

### ٢-١ الدراسات العربية:

- دراسة البلقيني (٢٠٠١) ولقد هدفت الدراسة إلى استخدام نظرية الفئات الفازية لتقدير حجم المطالبات في التأمين التكميلي على السيارات، بهدف التعامل مع عدم اليقين والتقلبات في بيانات المطالبات. وأظهرت النتائج أن هذه النظرية تساعد في تحسين دقة التقديرات وتعزيز كفاءة اتخاذ القرارات الاكتوارية، خاصة في البيانات غير المستقرة.
- دراسة لصالح الدين وآخرون (٢٠٢٣)، تناولت تقدير عدد المطالبات في تأمين السيارات التكميلي باستخدام النماذج التجميعية المعممة (GAMs) مقرونة بأسلوب LASSO، بهدف تحسين دقة التنبؤ وتقليل أثر المتغيرات غير المهمة. وأظهرت الدراسة فعالية النموذج في تقديم تقديرات دقيقة وتبسيط النموذج الإحصائي.
- دراسة الحصري وآخرون (٢٠١٧)، هدفت الدراسة إلى استخدام النماذج الخطية المعممة لتسعير تأمين السيارات التكميلي وفقاً لعوامل الخطر المختلفة. ولقد هدفت الدراسة إلى استخدام النماذج الخطية المعممة في تقديم نموذج مقترح لتسعير تأمين السيارات التكميلي وتوصلت إلى أن النموذج الذي استخدم توزيع بواسون لعدد المطالبات كان أفضل من النموذج الذي استخدم توزيع ثنائي الحدين السالب، وأكدت معنوية النموذج باستخدام توزيع جاما لصياغة قيمة المطالبات وصلاحيته للتنبؤ.
- دراسة حافظ (٢٠١٨)، ولقد هدفت الدراسة إلى التحليل الكمي والتنبؤ بالمعدلات الفنية في فرع التأمين الطبي، مثل معدل الخسارة، ومعدل الاحتفاظ، والمصروفات، والعمولات، خلال ثلاث سنوات باستخدام نماذج رياضية كالدوال الخطية والتربيعية والتكعيبية. توصلت إلى غياب تسعير علمي سليم لعقود التأمين الطبي، وأوصت بمراجعة سياسات الاكتتاب والتسعير لتحسين هذه المعدلات.
- دراسة المعداوي وآخرون (٢٠١٧)، ولقد هدفت الدراسة إلى استخدام الشبكات العصبية للتنبؤ بمطالبات تأمين السيارات التكميلي ودراسة العوامل المؤثرة عليها. توصلت إلى أن نموذج الشبكات العصبية متعددة الطبقات (MLP) يعطي نتائج جيدة عند استخدام ثلاث متغيرات مستقلة: مبلغ التأمين، عدد الحوادث، وعدد حوادث الورش المسواة، وأكدت استقلال بواقي النموذج، مما يعزز من صلاحيته للتنبؤ.
- دراسة عبد الحميد (٢٠١٤)، ولقد هدفت الدراسة إلى تحديد حد الاحتفاظ الأمثل في شركات التأمين باستخدام التوزيعات الاحتمالية، بالتطبيق على فرع تأمين الحريق. توصلت إلى أن توزيع بيتا هو الأنسب لتمثيل إجمالي الخسائر السنوية، وأوصت باستخدام الأساليب الإحصائية عند اتخاذ قرارات الاحتفاظ، مع التأكيد على أهمية المرونة في هذه القرارات وفقاً للظروف والنتائج المحققة.

## ٢-٢ الدراسات الأجنبية:

- دراسة (Isa et al (٢٠٢٤)، ولقد هدفت الدراسة إلى تحسين دقة التنبؤ بمطالبات التأمين من خلال تطوير نموذج تعلم عميق يعتمد على شبكة عصبية متسلسلة. أظهرت النتائج أن الشبكات العصبية العميقة تفوقت على النماذج الإحصائية التقليدية في التنبؤ بالمطالبات بفضل قدرتها على التقاط العلاقات غير الخطية. أوصت الدراسة باعتماد هذه النماذج لتحسين قرارات التسعير وتحديد الاحتماليات بدقة.
- دراسة (Tehraniyazdi (٢٠٢٤)، ولقد هدفت الدراسة إلى تطوير نموذج تنبؤي باستخدام خوارزمية LSTM للتنبؤ بالتزامات شركات التأمين المالية مثل المطالبات والاحتماليات. أظهرت النتائج أن LSTM يمكنها اكتشاف الأنماط والعلاقات غير الخطية في بيانات المطالبات بشكل دقيق، مما يساعد في تحسين التنبؤات. أوصت الدراسة باستخدام تقنيات الشبكات العصبية العميقة مثل LSTM مع بيانات عالية الجودة لتحسين دقة التنبؤ.
- دراسة (Shungube et al (٢٠٢٤)، ولقد هدفت الدراسة إلى تطوير نموذج يعتمد على التعلم العميق لاكتشاف الاحتيال في مطالبات تأمين الرعاية الصحية باستخدام تقنيات مثل CNNs وRNNs. أظهرت الدراسة تفوق هذه النماذج في دقة وكفاءة كشف الاحتيال مقارنة بالطرق التقليدية بفضل قدرتها على اكتشاف الأنماط المعقدة في البيانات. أوصت الدراسة بتبني تقنيات الشبكات العصبية العميقة لتحسين كشف الاحتيال وتقليل الخسائر في قطاع التأمين الصحي.
- دراسة (Saputro et al (٢٠١٩)، ولقد هدفت الدراسة إلى تحليل أداء الشبكات العصبية العميقة (DNNs) في التنبؤ بمطالبات التأمين على السيارات باستخدام بيانات تاريخية تتعلق بالعملاء والمركبات والحوادث. توصلت الدراسة إلى تفوق نماذج الشبكات العصبية العميقة على النماذج التقليدية في دقة التنبؤ بالمطالبات وقيمتها بفضل قدرتها على اكتشاف الأنماط المعقدة في البيانات. أوصت الدراسة باستخدام DNNs لتحسين دقة التنبؤ مع تحسين جودة البيانات وتحديد المعلمات بدقة.
- دراسة (Xia et al (٢٠٢٢)، ولقد هدفت الدراسة إلى تطوير نموذج دمج بين تقنيتين من تقنيات التعلم العميق، الشبكات العصبية التلافيفية (CNN) والشبكات العصبية ذات الذاكرة الطويلة والقصيرة المدى (LSTM)، للكشف عن الاحتيال في تأمين السيارات. تم تصميم النموذج للاستفادة من قوة CNN في استخراج الأنماط المهمة من البيانات التأمينية، وقدرة LSTM في معالجة البيانات الزمنية والأنماط التسلسلية. توصلت الدراسة إلى أن النموذج المختلط بين CNN وLSTM قدم أداءً متميزاً في الكشف عن الاحتيال مقارنة بالنماذج التقليدية، مما أتاح تحديد الأنماط المعقدة في البيانات بشكل أكثر دقة. أوصت الدراسة باستخدام نماذج التعلم العميق المتقدمة مثل CNN-LSTM لتحسين دقة الكشف عن الاحتيال وتقليل الخسائر الناجمة عنه.
- دراسة (Somaratne et al (٢٠٢٢)، ولقد هدفت الدراسة إلى تطوير نموذج يعتمد على الشبكات العصبية ذات الذاكرة القصيرة والطويلة المدى ثنائية الاتجاه (LSTMs) لتحسين دقة التنبؤ بالاحتماليات المالية النهائية لشركات التأمين على الممتلكات والمسؤولية. قامت الدراسة بتحليل بيانات المطالبات التاريخية باستخدام النموذج المقترح، مع التركيز على التعامل مع البيانات الزمنية المعقدة. توصلت الدراسة إلى أن النموذج ثنائي الاتجاه يوفر دقة أعلى في التنبؤ بالاحتماليات المالية مقارنة بالطرق التقليدية، بفضل قدرته على تحليل الأنماط الزمنية في كلا الاتجاهين (الماضي والمستقبل). أوصت الدراسة بتبني نماذج LSTMs ثنائية الاتجاه لتحسين تقدير الاحتماليات المالية، مع التأكيد على أهمية البيانات عالية الجودة لتحسين أداء النموذج.

## ٣- الفجوة البحثية

على الرغم من تزايد استخدام الشبكات العصبية العميقة (DNNs) في قطاع التأمين، فإن معظم الدراسات السابقة ركزت على التنبؤ بالمطالبات التأمينية، وتقدير الاحتماليات المالية، والكشف عن الاحتيال، بينما تناولت بعض الدراسات التنبؤ بمعدلات الأداء الفني في التأمين التكميلي للسيارات ولكن لم تعتمد وتستفيد من إمكانيات الشبكات العصبية العميقة وبالأخص نماذج الذاكرة طويلة وقصيرة المدى (LSTM) في تحليل البيانات الزمنية والتنبؤ بمعدلات الأداء الفني (معدل الاحتفاظ، معدل المصروفات العمومية والإدارية معدل العمولات وتكاليف الإنتاج، معدل الخسارة)

د. سماح سيد بيومي خليل

وهم عناصر أساسية في تحسين عمليات التسعير والاكتتاب وإدارة المخاطر. لذلك تسعى هذه الدراسة إلى سد الفجوة البحثية والتي تتمثل في غياب نموذج دقيق قائم على الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM) لتحليل البيانات الزمنية للمعدلات الفنية الخاصة بالتأمين التكميلي للسيارات، مما يساهم في تحقيق دقة تنبؤية أعلى وتحسين القرارات التشغيلية والمالية لشركات التأمين.

٤- متغيرات الدراسة:

- المتغيرات المستقلة: معدلات الأداء الفني والتي تتمثل في (معدل الاحتفاظ، معدل المصروفات العمومية والإدارية معدل العمولات وتكاليف الإنتاج، معدل الخسارة)
- المتغير التابع: وهو دقة التنبؤ بالمعدلات الفنية لمدة ثلاث سنوات مستقبلية بما يساعد في دعم القرارات الاستراتيجية لشركات التأمين في مجالات التسعير والاكتتاب وإدارة المخاطر.

٥- مشكلة الدراسة:

الجانب	الوضع الحالي القيود	التأثير	الحل المقترح في البحث
التنبؤ بمعدلات الأداء الفني لفرع تأمين السيارات التكميلي	تواجه شركات التأمين صعوبة في التنبؤ الدقيق بمعدلات الأداء الفني (الخسارة، الاحتفاظ، العمولات، المصروفات) باستخدام المنهجيات التقليدية والنماذج الإحصائية غير الكافية للتعامل مع تعقيد البيانات الزمنية	يؤدي ذلك إلى صعوبة في اتخاذ قرارات تسعير واكتتاب فعالة وضعف في إدارة المخاطر المالية.	تطوير نموذج تنبؤي مبتكر يعتمد على الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM) كأداة أكثر فعالية.
استخدام الشبكات العصبية العميقة والفجوة البحثية	على الرغم من تزايد استخدام التعلم العميق في قطاع التأمين، هناك قلة في الدراسات التي تطبق نماذج تنبؤية دقيقة تعتمد على هذه التقنيات، وخاصة LSTM، لتحليل معدلات الأداء الفني في التأمين التكميلي للسيارات.	ينتج عن ذلك عدم استغلال الإمكانات الكبيرة للتعلم العميق في تحسين دقة التنبؤ واتخاذ القرارات.	تطبيق نموذج LSTM بشكل خاص لتحليل البيانات الزمنية لمعدلات الأداء الفني في التأمين التكميلي للسيارات لسد هذه الفجوة..
تحليل البيانات الزمنية والحل المبتكر	يتطلب تحليل البيانات الزمنية نماذج قادرة على استخلاص الأنماط الهامة وتذكر الـ dependencies طويلة المدى، وهو ما تفتقر إليه النماذج التقليدية في هذا السياق الخاص بالتأمين التكميلي للسيارات.	يهدف البحث إلى بناء نموذج LSTM مُحسن وتدريبه وتقييمه للتنبؤ بمعدلات الأداء الفني.	استخدام قدرة LSTM على التعامل مع الذاكرة الطويلة والقصيرة المدى لتقديم حل مبتكر وتحسين دقة التنبؤ في هذا المجال.

تواجه العديد من شركات التأمين صعوبة في التنبؤ الدقيق بمعدلات الأداء الفني الأساسية ((معدل الاحتفاظ، معدل المصروفات العمومية والإدارية معدل العمولات وتكاليف الإنتاج، معدل الخسارة)، على الرغم من التطور المتزايد لتقنيات التعلم العميق، وخاصة الشبكات العصبية العميقة (DNNs)، في قطاع التأمين. ويرجع هذا التحدي جزئياً إلى اعتماد الدراسات السابقة في تحليل هذه المعدلات ضمن قطاع التأمين التكميلي للسيارات بشكل أساسي على منهجيات تقليدية أو نماذج إحصائية، والتي قد لا تكون قادرة على استيعاب تعقيد البيانات الزمنية بشكل كامل. وقد تم تلخيص هذه التحديات والقيود في الجدول أعلاه. ولمعالجة هذه الفجوة المعرفية، يسعى هذا البحث إلى تطوير نموذج تنبؤي مبتكر يعتمد على الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM)، لتمكين شركات التأمين من تحليل البيانات الزمنية بدقة أكبر والتنبؤ بمعدلات الأداء الفني بشكل محسن، مما قد يساهم في نهاية المطاف في تحسين استراتيجيات التسعير والاكتتاب وتعزيز إدارة المخاطر المالية."

## ٦- أهداف الدراسة:

- الهدف من الدراسة هو تحسين دقة التنبؤات الخاصة بمعدلات الاداء الفني والمالي (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة) من خلال استخدام تقنيات التعلم العميق، وتحديدًا الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM)، من خلال تحليل بيانات التأمين للسيارات التكميلي خلال الفترة من عام ٢٠٠٤/٢٠٠٥ الي عام ٢٠٢٢/٢٠٢٣ لعدد ٨ شركات تأمينات ممتلكات ومسؤوليات داخل السوق المصري وهم (مصر للتأمين، شركة قناة السويس للتأمين، شركة المهندس للتأمين، المجموعة العربية المصرية GIG، شركة الدلتا للتأمين، بيت التأمين المصري السعودي، شركة اليانز للتأمين، شركة رويال للتأمين)
- كما تهدف إلى تعزيز قدرة شركات التأمين على تحسين استراتيجيات التسعير والاكتتاب وإدارة المخاطر المالية من خلال الاستفادة من التحليل العميق للبيانات الزمنية لهذه المعدلات.
- التنبؤ بهذه المعدلات خلال ثلاث سنوات المقبلة وذلك للشركات محل الدراسة.

## ٧- أهمية الدراسة:

- تتبع أهمية هذه الدراسة من كونها تسعى إلى تطوير نموذج تنبؤي دقيق يعتمد على تقنيات الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM) لتحليل معدلات الأداء الفني في التأمين التكميلي للسيارات، بما يعزز القدرة على التنبؤ الدقيق بهذه المعدلات لثلاث سنوات مستقبلية. وتكمن أهمية الدراسة في عدة جوانب، من أبرزها:
- سد الفجوة البحثية في الأدبيات التأمينية، حيث لم يتم استكشاف إمكانات نماذج LSTM بشكل كافٍ في التنبؤ بالمعدلات الفنية في التأمين التكميلي للسيارات.
  - تقديم إسهام علمي نوعي من خلال دمج تقنيات التعلم العميق بتحليل البيانات الزمنية في قطاع التأمين، بما يثري المعرفة الأكاديمية في هذا المجال.
  - تطوير نموذج عملي قابل للتطبيق يُمكن شركات التأمين من تحسين دقة تنبؤاتها بالمعدلات الفنية، مما يدعم قرارات التسعير والاكتتاب وإدارة المخاطر المالية.
  - تقديم أسلوب حديث أكثر كفاءة مقارنة بالأساليب التقليدية المستخدمة في التنبؤ وتحليل البيانات، وذلك عبر تطوير نموذج ذكي قادر على التعلم من البيانات وتحقيق نتائج تنبؤية أكثر دقة باستخدام موارد زمنية وبشرية أقل.
  - تحقيق رؤى تنبؤية مستقبلية تسهم في تحسين إدارة العمليات التشغيلية وتقليل الخسائر، ما يعزز من قدرة الشركات التنافسية واتخاذ قرارات استراتيجية أكثر استنارة.

## ٨- منهج الدراسة:

٨-١ **الأسلوب النظري:** يعتمد هذا الأسلوب على الاستفادة من المصادر الأكاديمية العربية والأجنبية، إضافة إلى المعلومات المتاحة على الإنترنت والدوريات المتخصصة في مجالات التأمين والتعلم العميق. يتم من خلال هذا الأسلوب تحليل المفاهيم الأساسية المرتبطة بمعدلات الأداء الفني في التأمين التكميلي للسيارات، (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة)، وفهم النظريات والمبادئ التي تم تطويرها في هذا السياق. كما يشمل تحليل تطور تقنيات التعلم العميق، لا سيما الشبكات العصبية العميقة ذات الذاكرة طويلة وقصيرة المدى (LSTM)، وكيفية تطبيقها لتحسين دقة التنبؤ وتحليل البيانات الزمنية في صناعة التأمين.

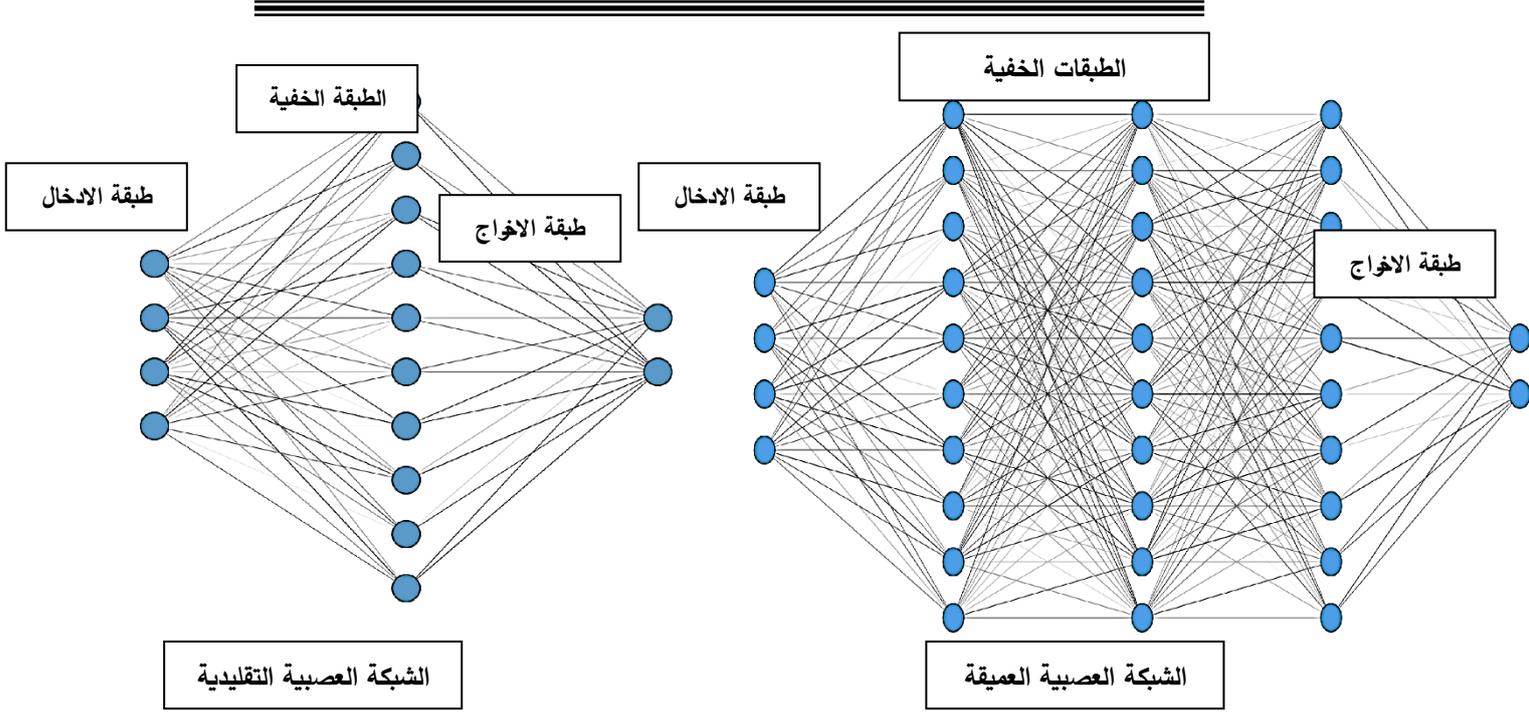
٨-٢ **الأسلوب التطبيقي:** تمثل في استخدام تقنيات الذكاء الاصطناعي، وبالتحديد الشبكات العصبية العميقة، حيث تعتمد هذه الدراسة على نموذج الشبكات العصبية ذات الذاكرة طويلة وقصيرة المدى (LSTM) للتنبؤ بمعدلات الأداء الفني في التأمين التكميلي للسيارات. تم تطبيق هذا النموذج على بيانات تاريخية للمعدلات (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة)، بهدف تحسين دقة التنبؤ بهذه المعدلات وتعزيز قدرة شركات التأمين على اتخاذ قرارات أكثر دقة في التسعير والاكتتاب وإدارة المخاطر.

## ٩- حدود الدراسة:

- الفترة الزمنية: تم إجراء الدراسة خلال الفترة الزمنية من عام ٢٠٠٢/٢٠٠٣ الي ٢٠٢٢/٢٠٢٣
  - الفروع: فرع التأمين السيارات التكميلي
  - شركة التأمين: يتم التطبيق على شركات تأمينات الممتلكات والمسؤوليات والمتوفر عنها بيانات الفترة الزمنية وهي كالاتي:  
(مصر للتأمين، شركة قناة السويس للتأمين، شركة المهندس للتأمين، المجموعة العربية المصرية GIG، شركة الدلتا للتأمين، بيت التأمين المصري السعودي، شركة اليانز للتأمين، شركة رويال للتأمين)
- وقد تم اختيار هذه الشركات تحديداً بناءً على توافر بياناتها التاريخية بشكل متكامل ومنتظم طوال فترة الدراسة، على عكس بعض الشركات الأخرى التي كانت حديثة النشأة أو توقفت عن العمل وخرجت من السوق، مما حال دون إدراجها ضمن نطاق الدراسة.

## ١٠- الشبكات العصبية العميقة

تعدّ الشبكات العصبية الاصطناعية (ANN) نماذج حوسبة مستوحاة من بنية الدماغ البشري، وتعتمد على تعلم الآلة لاكتساب المعرفة من البيانات. ورغم فعاليتها في المهام البسيطة، فإن قدرتها على التعامل مع المشكلات المعقدة تبقى محدودة نظراً لبنيتها التي تقتصر غالباً على طبقة مخفية واحدة. أما التعلم العميق (Deep Learning)، فهو تطور لهذه الشبكات، ويعتمد على شبكات عصبية عميقة (DNN) تحتوي على طبقات مخفية متعددة. تتيح هذه البنية إمكانية تحليل البيانات على عدة مستويات، مما يسمح باستخلاص ميزات معقدة وتمثيل أكثر تجريباً للمعلومات، وهو ما يعزز من قدرتها على التعامل مع تطبيقات معقدة مثل تحليل الصور والنصوص. وكما هو موضح في الشكل (٥)، يكمن الفرق الجوهرى بين الشبكات التقليدية والعميقة في عدد الطبقات المخفية، الأمر الذي ينعكس على قدرتها في تمثيل البيانات.



شكل (٥) مقارنة بين تركيب الشبكات العصبية التقليدية والشبكات العصبية العميقة، من حيث عدد الطبقات المخفية ومدى تعقيد تمثيل البيانات.

المصدر: من اعداد الباحث بناء على (Grégoire et al., 2018)

### ١-١٠ أهمية الشبكات العصبية في الذكاء الاصطناعي

أصبحت الشبكات العصبية العميقة العمود الفقري للعديد من تطبيقات الذكاء الاصطناعي، حيث أثبتت فعاليتها في مجالات متعددة مثل:

- الرؤية الحاسوبية (Computer Vision): تحسين تقنيات التعرف على الصور والتعرف على الوجوه.
- معالجة اللغة الطبيعية (NLP): تطوير نماذج الترجمة الآلية وتحليل النصوص، مثل ChatGPT و BERT.
- التمويل والتنبؤ الاقتصادي: تحليل البيانات المالية والتنبؤ بأسعار الأسهم والمخاطر المالية.
- الصحة والتشخيص الطبي: المساعدة في اكتشاف الأمراض من صور الأشعة وتحليل بيانات المرضى.
- التأمين وإدارة المخاطر: تحسين تقييم المخاطر والتنبؤ بمعدلات الأداء، وهو ما يتماشى مع موضوع البحث الحالي.

### ١٠-٢ الفرق بين أنواع الشبكات العصبية

تعدّ الشبكات العصبية التقليدية (ANN) نماذج أساسية ذات طبقة مخفية واحدة، وهي مناسبة للمشكلات البسيطة ولكنها محدودة في التعامل مع البيانات المعقدة غير الخطية. في المقابل، تحتوي الشبكات العصبية العميقة (DNN) على عدة طبقات مخفية، مما يمكنها من استخراج ميزات معقدة وتحليل البيانات الضخمة بفعالية أكبر. من أبرز أنواع ANN شبكة الإدراك متعدد الطبقات (MLP) المستخدمة في التصنيف والتنبؤ للبيانات غير المتسلسلة. أما DNN، فتتضمن أنواعاً مثل: الشبكات العصبية الالتفافية (CNN) لمعالجة البيانات المكانية كالصور؛ الشبكات العصبية التكرارية (RNN) للبيانات التسلسلية كالنصوص والبيانات الزمنية، والتي تشمل شبكات الذاكرة الطويلة والقصيرة

د. سماح سيد بيومي خليل

المدى (LSTM) والوحدات التكرارية البوابية (GRU)؛ بالإضافة إلى الشبكات التلقائية الترميز (AE) لتقليل الأبعاد واستعادة البيانات، و شبكات الخصوم التوليدية (GAN) لإنشاء الصور والوسائط.

١٠-٣ مفهوم الشبكات العصبية العميقة (DNNs)

الشبكات العصبية العميقة (DNNs) هي نوع متقدم من الشبكات الاصطناعية، وهي جزء من التعلم العميق (Deep Learning)، الذي يعد فرعاً من التعلم الآلي (Machine Learning) في الذكاء الاصطناعي. التعلم الآلي يسمح للألات بتعلم الأنماط من البيانات وتجربة الأداء، مما يتيح لها تحسين أدائها دون الحاجة إلى برمجة مسبقة.

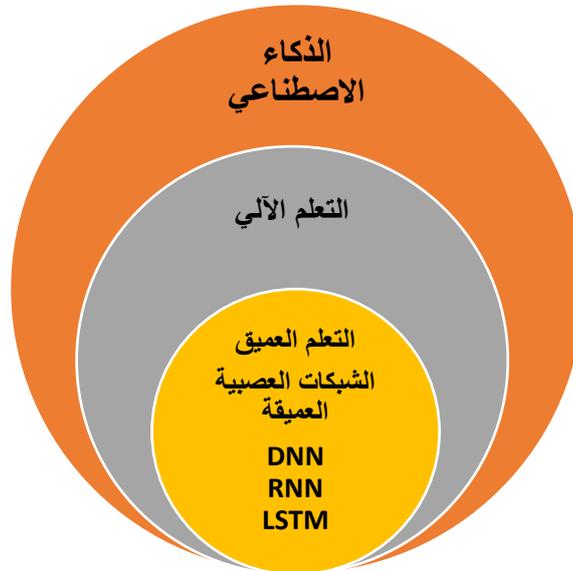
- الذكاء الاصطناعي: الذكاء الاصطناعي، وفقاً لتعريف جون مكارثي في الخمسينيات، هو علم وهندسة إنشاء آلات ذكية قادرة على تحقيق أهداف محددة. يشمل مجالات مثل تمثيل المعرفة، معالجة اللغة الطبيعية، الإدراك البصري، والتعلم الآلي.

- التعلم الآلي: التعلم الآلي هو أحد مجالات الذكاء الاصطناعي الذي يُعنى بتطوير الأنظمة القادرة على التعلم من البيانات. يُتيح للأجهزة اكتساب الأنماط الجديدة من خلال التجربة بدلاً من البرمجة التقليدية.

- الشبكات العصبية الاصطناعية (ANN): الشبكات العصبية الاصطناعية هي نماذج مستوحاة من الدماغ البشري، مكونة من خلايا عصبية اصطناعية لمعالجة البيانات. تُستخدم في مشكلات مثل التصنيف والتنبؤ.

- التعلم العميق: التعلم العميق هو امتداد للتعلم الآلي ويعتمد على الشبكات العصبية العميقة التي تحتوي على طبقات متعددة لاستخلاص ميزات متزايدة التعقيد من البيانات الخام. تُستخدم تقنيات مثل الانحدار التدريجي والانتشار الخلفي لضبط معاملات النموذج تلقائياً، مما يُحسن الأداء مع مرور الوقت.

- الشبكات العصبية العميقة (DNN): الشبكات العصبية العميقة هي امتداد للشبكات العصبية الاصطناعية (ANN)، وتعتمد على تقسيم النموذج إلى عدة طبقات تتعلم كل منها تمثيلات مختلفة للبيانات. هذا الهيكل العميق يُحسن القدرة على التعامل مع المشكلات غير الخطية. يتم التدريب باستخدام خوارزميات مثل الانحدار التدريجي والانتشار الخلفي، مما يساعد الشبكة على تحسين أدائها تلقائياً. (Sze, V. et al., 2017)



شكل (٦) الشبكات العصبية العميقة في ظل الذكاء الاصطناعي

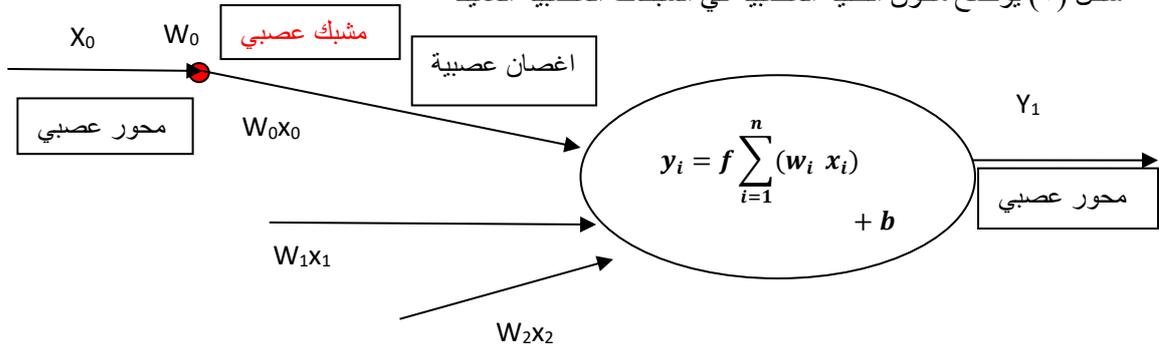
المصدر: من اعداد الباحث بناء على الفقرة السابقة

## ٤-١٠ هيكل الشبكات العصبية العميقة

لشبكات العصبية العميقة تتكون من وحدات حسابية بسيطة تُسمى الخلايا العصبية، التي تقوم بتلقي المدخلات، ضربها في الأوزان، وتجمعها قبل تمريرها عبر دالة تنشيط غير خطية. يؤدي ربط هذه الوحدات في طبقات متتابعة إلى تشكيل الشبكات العصبية العميقة (DNN)، القادرة على استخراج الأنماط المعقدة. يعد فهم هذا النموذج أساسياً لاستيعاب مفاهيم التعلم العميق مثل الأوزان، دوال التنشيط، وعملية التدريب (الانتشار الأمامي والخلفي). كما يتيح هذا الهيكل بناء نماذج متطورة مثل الشبكات العصبية التكرارية (RNNs) للبيانات التسلسلية والشبكات العصبية الالتفافية (CNNs) للصور، كما يوضح الشكل (٧) مكونات النيرون.

الشكل التالي يوضح مكونات النيرون في الشبكات العصبية العميقة

شكل (٧) يوضح مكون الخلية العصبية في الشبكات العصبية العميقة



المصدر: من اعداد الباحثة بناء على (Sze, V. et al., 2017)

## ٥-١٠ مكونات الخلية العصبية العميقة (النيرون):

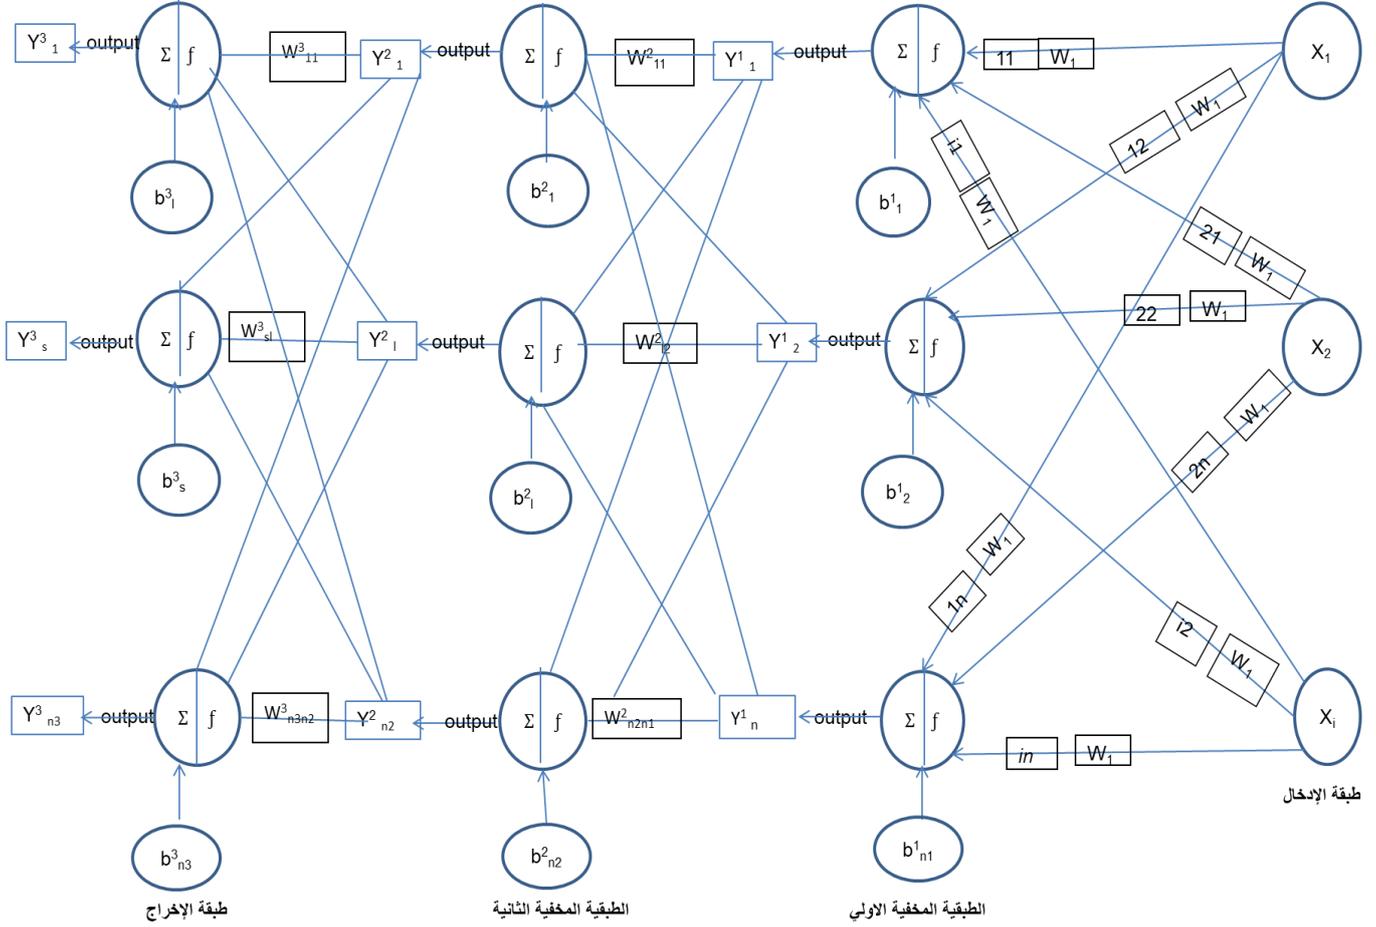
ومن الشكل السابق يوضح تكوين الخلية العصبية (النيرون) وهو البنية الاساسية داخل للشبكة العصبية العميقة حيث تتكون من:

- المدخلات ( $X_i$  - Inputs): البيانات التي تتلقاها الخلية العصبية مثل القيم العددية أو النصوص.
- الأوزان ( $W_i$  - Weights): عاملات عددية تضرب في المدخلات لتحديد تأثير كل مدخل على ناتج الخلية.
- الدالة المجمعة (Summation Function): تجمع الخلية العصبية جميع المدخلات بعد ضربها في الأوزان باستخدام دالة جمع خطية، ويتم حساب المجموع كالتالي:

$$z = \sum_{i=1}^n (w_i x_i) + b$$

- الانحياز ( $b$  - Bias): قيمة ثابتة تضاف إلى المجموع الموزون لتعديل ناتج الخلية.
  - دالة التنشيط (Activation Function): بعد جمع المدخلات الموزونة، يتم تمرير الناتج عبر دالة تنشيط غير خطية (مثل ReLU أو Sigmoid) طبق على المجموع الموزون لإدخال اللاخطية. من أشهرها Sigmoid، ReLU (للإخراج بين ٠ و ١)، و Tanh (للإخراج بين -١ و ١).
  - في الشبكات العصبية العميقة، يتم تمرير ناتج كل خلية عصبية في طبقة معينة إلى الخلايا العصبية في الطبقة التالية كمدخلات جديدة، وفقاً للمعادلة:
- $$y_i = f \sum_{i=1}^n (w_i x_i) + b$$
- المخرجات ( $Y$  - Output): بعد تمرير البيانات عبر جميع الطبقات وتطبيق دوال التنشيط، نحصل على المخرجات النهائية للشبكة العصبية، والتي قد تكون قيمة عددية (Regression) أو تصنيفاً (Classification) بناءً على طبيعة المشكلة التي تعالجها الشبكة.

الشكل التالي (٨) يوضح بنية شبكة عصبية عميقة (DNN) بثلاث طبقات (الانتشار الأمامي - Forward Propagation)



الشكل (٨) بنية شبكة عصبية عميقة (DNN) بثلاث طبقات

المصدر: من اعداد الباحثة بناء على مكونات الشبكة العصبية العميقة

وضح الشكل (٨) بنية شبكة عصبية عميقة بثلاث طبقات وعملية الانتشار الأمامي. ويمكن تمثيل هذه العملية رياضياً باستخدام مصفوفات الأوزان ( $W$ )، ومتجهات الإدخال ( $X$ ) والانحياز ( $b$ )، ودالة التنشيط ( $f$ ). حيث يتم حساب ناتج كل طبقة من خلال ضرب مدخلاتها في مصفوفة الأوزان الخاصة بها، إضافة متجه الانحياز، ثم تطبيق دالة التنشيط. المعادلات (١) و (٢) و (٣) تقدم التمثيل الرياضي لهذه العمليات لحساب مخرجات الطبقات المختلفة في الشبكة.":

$$W = \begin{bmatrix} W_{11} & \cdots & W_{1n} \\ \vdots & \ddots & \vdots \\ W_{n1} & \cdots & W_{in} \end{bmatrix} \dots \dots \dots (1)$$

$$y = \begin{bmatrix} y_1 \\ \vdots \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} f(\sum_{j=1}^i W_{1j} X_j + b_1) \\ \vdots \\ f(\sum_{j=1}^i W_{2j} X_j + b_2) \\ \vdots \\ f(\sum_{j=1}^i W_{nj} X_j + b_n) \end{bmatrix} = f(W \cdot X + b) \dots \dots \dots (2)$$

د. سماح سيد بيومي خليل

$$y^3 = \begin{bmatrix} y_1^3 \\ \vdots \\ y_2^3 \\ \vdots \\ y_{n3}^3 \end{bmatrix} = f(w^3 y^2 + b^3) = f(w^3 f(w^2 y^1 + b^2) + b^3) = f(w^3 f(w^2 (f(w^1 x + b^1)) + b^2) + b^3). (3)$$

### ٦-١٠ دالة التفعيل وعدد الخلايا العصبية

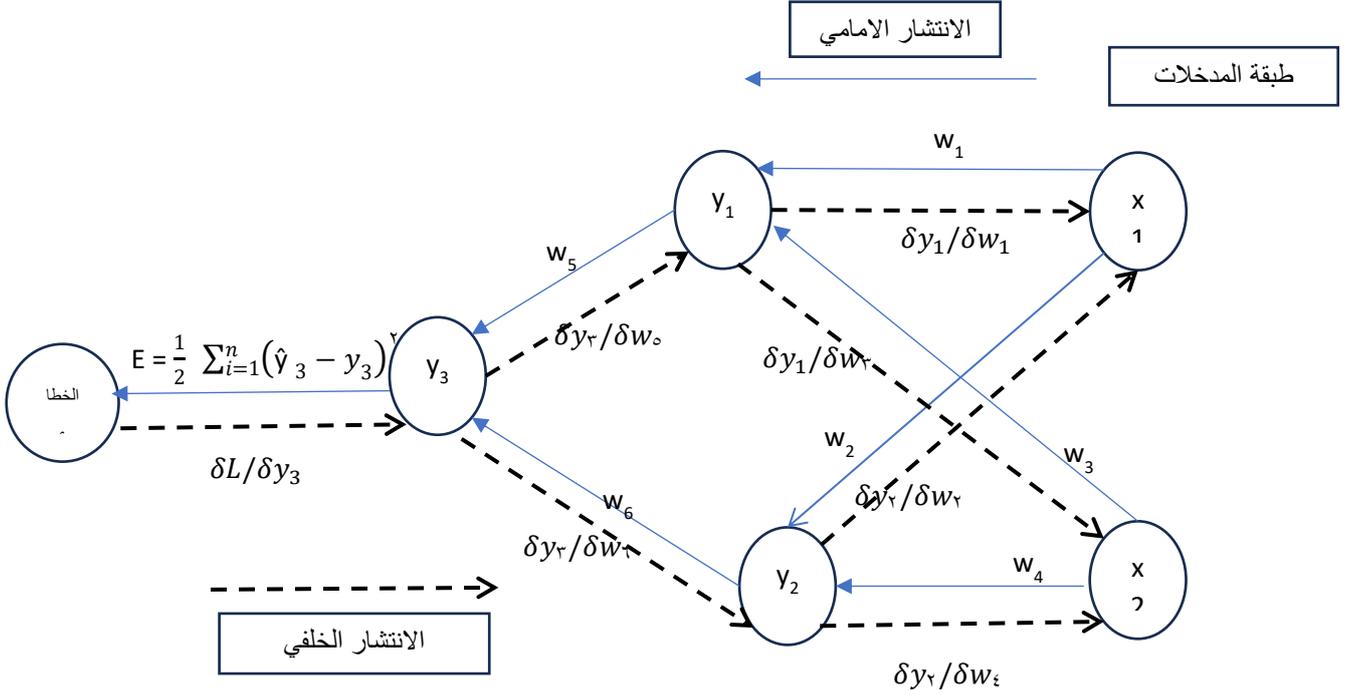
تُستخدم دوال التفعيل مثل ReLU و Sigmoid لإضفاء اللاخطية على الشبكة العصبية، مما يتيح لها التعلّم من العلاقات المعقدة في البيانات. ويؤثر عدد الخلايا العصبية في كل طبقة على قدرة النموذج على التمييز؛ فكل خلية تساهم في تشكيل حدود غير خطية تفصل بين الأنماط المختلفة. زيادة عدد الخلايا تعني قدرة أعلى على التمثيل، لكن قد تؤدي إلى الإفراط في التخصيص (Overfitting) إذا لم تُدعم ببيانات كافية. بالتالي، يُعد اختيار عدد الطبقات والخلايا العصبية أمرًا يعتمد على طبيعة التطبيق وتوازن الدقة مع القدرة على التعميم.

### ٧-١٠ خوارزمية التدريب والتحديث في الشبكات العميقة

تعتمد عملية تدريب الشبكة على تقليل دالة الخطأ بين المخرجات المتوقعة والفعلية باستخدام خوارزميات تحسين مثل التدرج المتناقص (Gradient Descent). وتُعد خوارزمية الانتشار الخلفي (Backpropagation) جوهر عملية التعلّم، حيث تُستخدم لحساب التدرجات وتحديث الأوزان والانحيازات بعد كل تمريرة، مما يُمكن النموذج من تحسين الأداء تدريجيًا وتقليل الخطأ مع كل تكرار.

### ١٠-٧-١٠ الانتشار الخلفي (Backpropagation):

يعتمد تدريب الشبكات العصبية بشكل أساسي على خوارزمية الانتشار الخلفي (Backpropagation)، التي تمكن الشبكة من تعلم أخطائها وتعديل الأوزان. في الشبكات العميقة، يتم تحديد الخطأ في الطبقة الأخيرة، ويقوم الانتشار الخلفي بحساب التدرجات (gradients) بكفاءة عبر الشبكة لتحديد مدى مساهمة كل وزن في هذا الخطأ، وهي مشكلة تُعرف باسم "إسناد الخطأ". بعد كل تمريرة أمامية، تُجري الشبكة تمريرة خلفية لتحديث الأوزان والانحيازات باستخدام تقنيات تحسين مثل التدرج المتناقص (Gradient Descent)، مما يقلل الخطأ ويحسن أداء الشبكة تدريجيًا. الشكل (٩) يوضح هيكل الانتشار الخلفي في الشبكات العصبية العميقة.



الشكل (٩) هيكلية الانتشار الخلفي في الشبكات العصبية العميقة

المصدر: من اعداد الباحثة بناء على (طعيمة، علاء، (٢٠٢٢))

يُقاس أداء الشبكة وحساب الخطأ بين المخرجات المتوقعة والفعلية باستخدام دالة التكلفة) مثل دالة مجموع مربعات الخطأ MSE في المعادلة (٤)

$$MSE = \frac{1}{2} \sum_{i=1}^n (\hat{y}_3 - y_3)^2 \dots\dots\dots (4)$$

بعد حساب الخطأ، ثم يتم التحقق مما إذا كان عدد التكرارات والخطأ المحقق يفيان بالمتطلبات. إذا لم يتم استيفاء المتطلبات، يتم استخدام الانتشار الخلفي (Backpropagation) لحساب معدل الخطأ في كل طبقة كما في المعادلة (٥):

$$\delta^i = \partial J(w, b, x, y) / \partial z_i = (\hat{y}_i - y) \otimes \sigma^i(z_i) \dots\dots\dots (5)$$

حيث  $\delta^i$  تمثل مقدار الخطأ بالنسبة لكل خلية عصبية قبل تطبيق دالة التفعيل في الطبقة  $i$ ، وهي تستخدم في تحديث الأوزان.

$J(w, b, x, y)$ : دالة التكلفة (مثل MSE)، تعتمد على الأوزان والانحيازات والمدخلات والقيم الحقيقية..

$z_i$ : الناتج الخطي قبل تطبيق دالة التفعيل أي  $(z_i = W_{ix} + b_i)$ .

$y$ : القيم الحقيقية (القيم المستهدفة في التدريب).

$\hat{y}_i$ : الناتج بعد تطبيق دالة التفعيل على  $z_i$ .

$\sigma^i(z_i)$ : هي مشتقة دالة التفعيل المستخدمة في الطبقة  $i$ ، والتي تُظهر استجابة الخلايا العصبية للتعديلات في الأوزان.

$\otimes$ : يمثل عملية الضرب العنصري (Element-wise multiplication)، أي أن كل عنصر في المتجه الأول يُضرب في العنصر المقابل له في المتجه الثاني بنفس الموقع.

د. سماح سيد بيومي خليل

حيث يُحسب الخطأ عبر الطبقات المخفية باستخدام المعادلة: (6)

$$\delta^l = (\delta^{l+1} W^{l+1}) \otimes \sigma'(z_l) \dots \dots \dots (6)$$

حيث:

$\delta^l$ : هو خطأ الطبقة l

$W^{l+1}$ : هي مصفوفة الأوزان بين الطبقة l والطبقة التالية l+1.

$\sigma'(z_l)$ : هو مشتق دالة التفعيل في الطبقة l.

وأخيراً، يتم حساب التدرجات الجزئية للأوزان والانحيازات باستخدام المعادلات التالية:

$$\frac{\partial J}{\partial w^l} = \delta^l (a^{l-1})^T \dots \dots \dots (7)$$

حيث  $a^{l-1}$  هو ناتج التفعيل للطبقة السابقة، و  $\delta^l$  هو خطأ الطبقة الحالية.

$$\delta^l = \frac{\partial J}{\partial b^l} \dots \dots \dots (8)$$

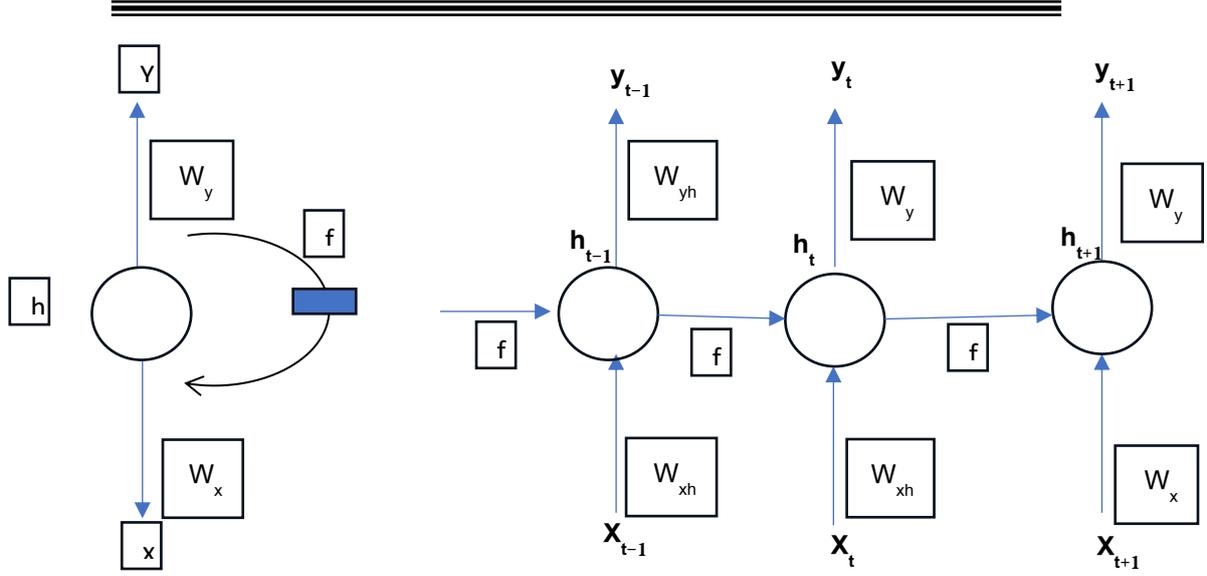
بعد حساب التدرجات الجزئية للأوزان، يتم تحديث الأوزان باستخدام خوارزمية التدرج المتناقص ( Gradient Descent) لتقليل الخطأ. تعتمد الخوارزمية على تعديل الأوزان عن طريق طرح التدرج المحسوب مضروباً في معدل التعلم باستخدام العلاقة التالية:

$$w^l = w^{l-1} - \alpha \sum_{i=1}^n \partial^{i,l} (a^{i,l-1})^t \dots \dots \dots (9)$$

يستمر التدريب حتى يصل الخطأ إلى الحد الأدنى المحدد مسبقاً أو يصل عدد التكرارات إلى القيمة القصوى المحددة. عندها يتم الحصول على النموذج النهائي. في حال لم تتحقق هذه الشروط، يتم إعادة العملية بدءاً من الخطوة الثانية.

### ١٠-٨ الشبكات العصبية المتكررة (RNN)

الشبكات العصبية المتكررة (RNNs) هي نوع من الشبكات العصبية المصممة خصيصاً لمعالجة البيانات المتسلسلة والزمنية، وتستخدم على نطاق واسع في نماذج التعلم العميق. تتميز RNNs بوجود مسارات تغذية راجعة تمكنها من الاحتفاظ بالمعلومات من الخطوات الزمنية السابقة ("ذاكرة") والتأثير على العمليات المستقبلية، على عكس الشبكات العصبية العميقة التقليدية (DNNs). تعتمد RNNs على تقنية الانتشار الخلفي عبر الزمن (BPTT) لتدريبها على البيانات التسلسلية، مما يجعلها فعالة في معالجة السلاسل الزمنية والنصوص والكلام. تتيح آلية التغذية الراجعة لـ RNNs تعلم العلاقات الزمنية المعقدة في البيانات، وباستخدام الحالة الخفية (Hidden State)، يمكنها مراعاة التتابع الزمني للبيانات، وهو أمر ضروري للتنبؤ الدقيق بالبيانات الزمنية مثل معدلات التأمين (Zhang et al., 2016). يوضح الشكل التالي تركيب شبكة عصبية متكررة بسيطة."



شكل (١٠) تركيب شبكة عصبية متكررة بسيطة

المصدر: من اعداد الباحثة بناء على (طعيمة، علاء، (٢٠٢٢))

يوضح الشكل السابق (١٠) بنية RNNs مع التغذية الراجعة والتوسع الزمني. تعتمد RNN على الحالة السابقة ( $h_{t-1}$ ) والمدخل الحالي ( $x_t$ ) لتحديث الحالة الحالية ( $h_t$ )، مما يمكنها من التعلم من التسلسلات الزمنية. يتم تحديث الحالة الخفية عبر حلقة تكرارية (المعادلة ١٠)، حيث تعتمد الحالة الحالية على المدخل الحالي والحالة السابقة، التي تعمل كملخص للمدخلات السابقة. يتم تنفيذ التطور الزمني للحالة خطوة بخطوة باستخدام معاملات الأوزان  $U$  (لتحويل المدخل)،  $W$  (لتحويل الحالة السابقة)، و  $V$  (لتحويل الحالة الحالية إلى الناتج). يمكن تحديد الحالة الداخلية ( $h_t$ ) ومخرجات الشبكة ( $o_t$  و  $y_t$ ) باستخدام المعادلات (١١)، (١٢)، و (١٣)، حيث يتم تطبيق دالة التنشيط غير الخطية ( $\tanh$ ) بعد التحويلات الخطية."

$$h_t = (h_{t-1}, x_t) \dots \dots \dots (10)$$

$$h_t = \tanh (h_{t-1} * W + x_t * U) \dots \dots \dots (11)$$

$$o_t = h_t * V + b_y \dots \dots \dots (12)$$

$$y_t = \tanh (o_t) \dots \dots \dots (13)$$

### ١٠، ٨، ١٠ المشكلات الرئيسية في RNN

تعاني شبكات RNN من مشكلتين رئيسيتين تؤثران على قدرتها في التعامل مع السلاسل الزمنية الطويلة:

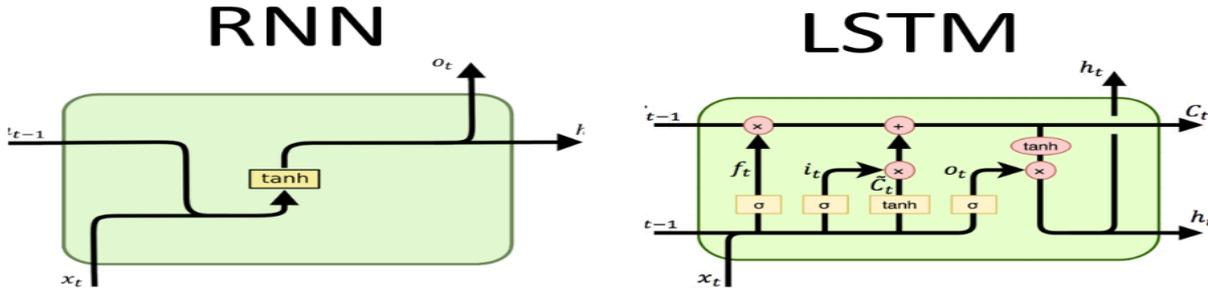
- تلاشي أو انفجار التدرجات أثناء التدريب، مما يعيق تعلم التبعية بعيدة المدى.
- فقدان المعلومات عبر الزمن بسبب اعتمادها على الحالة السابقة فقط.

تحد هذه المشكلات من قدرة RNNs على تعلم العلاقات البعيدة في البيانات الزمنية الطويلة. للتغلب على هذه القيود، تم تطوير شبكات الذاكرة طويلة وقصيرة المدى (LSTM)، التي تتميز ببنية محسنة للوحدات المخفية تسمح لها بالاحتفاظ بالمعلومات لفترات أطول وتحقيق دقة أعلى في التنبؤات.

## ٩, ١٠ الشبكات العصبية ذات الذاكرة طويلة وقصيرة المدى (LSTM):

كما ذكر سابقاً، تواجه الشبكات العصبية المتكررة (RNN) صعوبات في الاحتفاظ بالمعلومات لفترات طويلة بسبب مشكلة تلاشي التدرجات. لحل هذه المشكلة، تم تطوير شبكات الذاكرة طويلة وقصيرة المدى (LSTM) بواسطة (Hochreiter & Schmidhuber) في عام ١٩٩٧. تتميز LSTM بوجود ذاكرة خلوية ( $C_t$ ) وبوابات تحكم (بوابة النسيان، بوابة الإدخال، بوابة الإخراج) تنظم تدفق المعلومات عبر الزمن من خلال إدخال ذاكرة خلوية ( $C_t$ ) تعمل كمسار مباشر لنقل المعلومات عبر الزمن مما يقلل من تأثير تلاشي التدرجات، مما يسمح لها بالتعلم من التبعيات طويلة المدى بشكل أفضل.

يوضح الشكل (١١) الفرق بين بنية RNN و LSTM.



شكل (١١) الفرق بين شبكة RNN وشبكة LSTM

المصدر: من اعداد الباحثة بناء على (طعيمة، علاء، (٢٠٢٢))

يوضح الشكل السابق (١١) الفرق بين RNN و LSTM. تعاني RNN من فقدان المعلومات طويلة المدى بسبب تمرير الحالة المخفية ( $h_t$ ) عبر الزمن دون تحكم. في المقابل، تضيف LSTM آليات تحكم في تدفق المعلومات عبر ثلاث بوابات رئيسية: بوابة النسيان ( $f_t$ ) لحذف المعلومات غير الضرورية، وبوابة الإدخال ( $i_t$ ) لتحديد المعلومات الجديدة المخزنة، وبوابة الإخراج ( $o_t$ ) للتحكم في تمرير المعلومات إلى الحالة المخفية ( $h_t$ )، بالإضافة إلى الذاكرة الخلوية ( $C_t$ ) لتخزين المعلومات لفترات طويلة. هذه البنية تجعل LSTM أكثر كفاءة في التنبؤ بالسلاسل الزمنية ومعالجة البيانات المتتابعة من RNN التقليدية.

## ١٠, ٩, ١٠ النموذج الرياضي لشبكة LSTM

يقوم نموذج LSTM بمعالجة البيانات المتسلسلة باستخدام ثلاث بوابات رئيسية وذاكرة خلوية ( $C_t$ ).

- بوابة النسيان ( $f_t$ ): تحدد المعلومات التي سيتم الاحتفاظ بها أو نسيانها من الذاكرة الخلوية بناءً على المدخلات الحالية ( $x_t$ )، والحالة المخفية السابقة ( $h_t$ ) باستخدام دالة السيجمويد ( $\sigma$ ) من خلال المعادلة التالية:

$$f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \dots \dots \dots (14)$$

- بوابة الإدخال ( $i_t$  و  $a_t$ ): تحدد المعلومات الجديدة التي سيتم إضافتها إلى الذاكرة الخلوية. تحسب ( $i_t$ ) لقيم المراد تحديثها باستخدام السيجمويد، بينما تحسب ( $a_t$ ) لقيم المرشحة الجديدة باستخدام دالة التانج ( $\tanh$ ) من خلال المعادلتين الآتيتين:

$$i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \dots \dots \dots (15)$$

$$a_t = \tanh(W_c h_{t-1} + U_c x_t + b_f) \dots \dots \dots (16)$$

- تحديث الذاكرة الخلوية: يتم تحديث الذاكرة الخلوية بدمج المعلومات القديمة والجديدة بناءً على مخرجات بوابتي النسيان والإدخال عبر المعادلة التالية:

$$c_t = f_t * c_{t-1} + i_t * a_t \dots \dots \dots (17)$$

- بوابة الإخراج ( $o_t$ ) والحالة المخفية ( $h_t$ ): تتحكم بوابة الإخراج في المعلومات التي سيتم تمريرها إلى الحالة المخفية الحالية ( $h_t$ ) بناءً على المدخلات الحالية والحالة المخفية السابقة باستخدام السيجمويد. ثم يتم تطبيق التانج على الذاكرة الخلوية المحدثة وتضرب في مخرج بوابة الإخراج لتحديد الحالة المخفية النهائية من خلال المعدلتين الاتيتين:

$$o_t = \sigma(W_o h_{t-1} + U_o x_t + b_o) \dots\dots\dots(18)$$

$$h_t = o_t * \tanh(c_t) \dots\dots\dots(19)$$

تمكن هذه البنية LSTM من التعلم من التسلسلات الزمنية الطويلة دون مشكلة تلاشي التدرجات، مما يجعلها مناسبة لتطبيقات مثل التنبؤ بالسلاسل الزمنية وتحليل البيانات المتتابعة، وهو أمر مهم لدراسة مؤشرات الأداء الفني في التأمين التكميلي للسيارات."

### ١١ - التنبؤ بالمعدلات الفنية

سيتم في هذا الجزء استخدام شبكات LSTM للتنبؤ بالمعدلات الفنية لعدد ثماني لشركات التأمين ممتلكات ومسؤوليات فرع السيارات التكميلي لمدة ثلاث سنوات مستقبلية، بالاعتماد على البيانات التاريخية (٢٠٠٢/٢٠٠٣ - ٢٠٢٢/٢٠٢٣). تُعد LSTM تقنية فعالة في نمذجة السلاسل الزمنية وقادرة على تخزين المعلومات طويلة الأمد، مما يجعلها مناسبة للبيانات التأمينية. سيتناول الفصل الخطوات المنهجية لبناء وتدريب نموذج LSTM للتنبؤ بالمعدلات الفنية، بدءاً من تحضير البيانات وتقسيمها، مروراً ببناء النموذج وتدريبه، وصولاً إلى تحليل النتائج لتقييم دقته وكفاءته. يهدف هذا النموذج العملي إلى دعم اتخاذ القرارات في شركات التأمين من خلال تحسين تقدير المؤشرات الفنية، وبالتالي المساهمة في استدامة واستقرار أدائها المالي والتشغيلي."

### ١-١١ معالجة البيانات

قبل البدء في استخدام البيانات (معدل الاحتفاظ، معدل العمولات وتكاليف الإنتاج، معدل المصروفات العمومية والإدارية، ومعدل الخسارة)، يجب التحقق من عدة نقاط هامة وهي:

#### - تنظيف البيانات (Data Cleaning)

كخطوة أولى في تحضير البيانات للتنبؤ باستخدام شبكة LSTM، تم تنظيف البيانات لضمان جودتها وخلوها من الأخطاء. شمل ذلك فحص البيانات في برنامج MATLAB والتأكد من اكتمال السجلات وعدم وجود قيم مفقودة أو غير صحيحة، بالإضافة إلى التأكد من صحة الأرقام وعدم وجود مسافات بيضاء أو أحرف غير ضرورية.

- **القيم المتطرفة:** تم التحقق من وجود قيم متطرفة باستخدام طريقة Z-Score (اعتبار القيم التي تتجاوز  $\pm 3$  انحرافات معيارية كقيم متطرفة). أظهرت النتائج عدم وجود قيم متطرفة في البيانات، مع الإشارة إلى أن وجودها يمكن أن يؤثر سلبيًا على تدريب النموذج."

#### - تطبيع البيانات (Normalization)

يعد تطبيع البيانات خطوة أساسية لتحويل القيم العددية إلى نطاق موحد لتحسين استقرار ودقة النموذج. في البداية، تم تجربة تطبيع البيانات باستخدام أسلوب Min-Max (النطاق ٠ إلى ١). إلا أن تحليل النتائج أظهر انحرافاً ملحوظاً بين القيم الحقيقية والمتنبأ بها، مما قلل من التباين النسبي وأضعف دقة التنبؤ ومؤشرات الأداء (RMSE, MAPE,  $R^2$ ).

بناءً على النتائج الضعيفة لطريقة Min-Max Normalization، تم تجربة طريقة Z-Score Normalization (تحويل القيم وفق التوزيع الطبيعي). وقد أدت هذه الطريقة إلى تحسن كبير في دقة النموذج وتقارب القيم المتوقعة مع القيم الحقيقية، بالإضافة إلى تحسن ملحوظ في مؤشرات الأداء. ونتيجة لذلك، تم اعتماد Z-Score Normalization كأسلوب التطبيع الرسمي في هذه الدراسة نظراً لكفاءتها العالية ونتائجها الأكثر دقة، وذلك باستخدام المعادلتين (١) و (٢) للتطبيع وعكس التطبيع على التوالي.

$$Z = \frac{z - \mu}{\sigma} \dots\dots\dots(1)$$

$$z = Z \cdot \sigma + \mu \dots\dots\dots(2)$$

## ٢,١١ بناء النموذج:

يتطلب بناء شبكة LSTM العديد من الخطوات وهي:

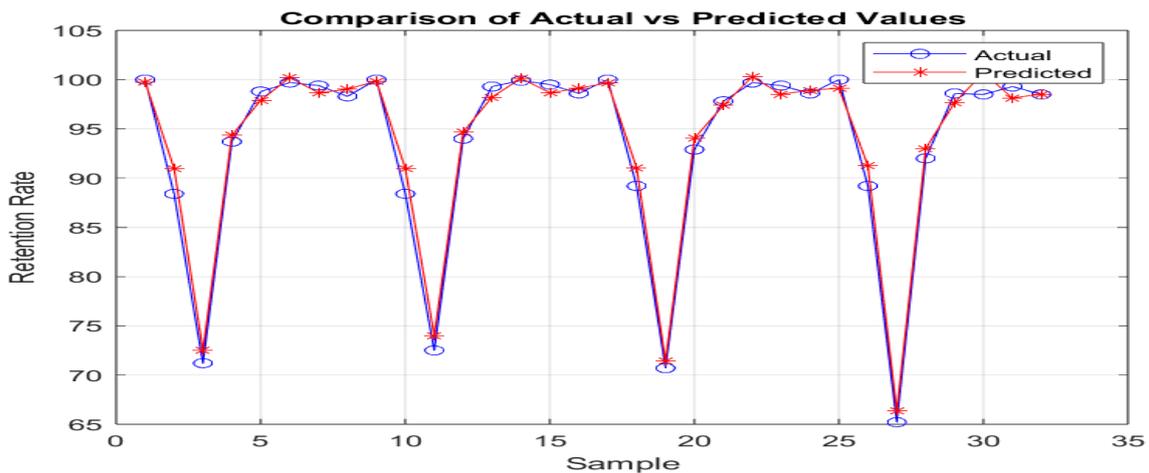
### ١,٢,١١ تحديد هيكل واختيار الطبقات والخلايا العصبية للنموذج

إيجاد المعلمات المثلى لبيانات العينة، تم إجراء تجارب متعددة على عدد الطبقات المخفية والخلايا العصبية داخل الشبكة العصبية العميقة، بهدف تقليل قيمتي MAPE و RMSE وتحسين دقة التنبؤ. في البداية، تم اختبار عدد الطبقات المخفية ضمن النطاق {٢,٣,٤}، وعدد الخلايا العصبية في كل طبقة ضمن النطاق {٣٠,٥٠,٧٠,١٠٠}. الجدول (٦) النتائج التجريبية لأعداد مختلفة من طبقات الشبكة والخلايا العصبية

عدد الطبقات	مقياس الخطأ	٣٠	٥٠	٧٠	١٠٠
2	RMSE	5.415	١,٤١٠	١,٠٤٩	١,٥٤٦
	MAPE	٤,٥٠١	١,٣٣٠	٠,٩٥٣	١,٢٠٥
	R <sup>2</sup>	٠,٦٨٨	٠,٩٧٩	٠,٩٨٨	٠,٩٧٥
3	RMSE	٦,٧٦٧	٧,٩٦٥	٥,١٤٥	٥,٠٥١
	MAPE	٤,٨٨٢	٦,٢٣١	٤,٢٦٣	٤,٢٢١
	R <sup>2</sup>	٠,٥١٣	٠,٣٢٥	٠,٧١٨	٠,٧٢٩
4	RMSE	٨,١٣٠	٨,٦٢٧	٧,٢٤١	٦,٦٨٤
	MAPE	٦,٢٦٣	٦,٧١٤	٥,٢٨٩	٥,٢٠٠
	R <sup>2</sup>	٠,٢٩٧	٠,٢٠٨	٠,٤٤٢	٠,٥٢٥

المصدر: من اعداد الباحثة باستخدام برنامج MATLAB

أظهرت النتائج التجريبية (الجدول ٦) أن أفضل أداء للنموذج تحقق باستخدام شبكة LSTM ذات طبقتين و ٧٠ خلية عصبية في كل طبقة، حيث سجل هذا التكوين أقل خطأ جذر تربيعي ( $RMSE = 1.049$ ) وأقل نسبة خطأ مطلق ( $MAPE = 0.953$ )، بالإضافة إلى أعلى معامل تفسير ( $R^2 = 0.988$ ). بناءً على هذه المؤشرات، تم اعتماد هذا التكوين (طبقتان مع ٧٠ وحدة خفية) باعتباره الأنسب لتحقيق التوازن بين دقة التنبؤ والقدرة على التعميم. ويوضح الشكل (١٢) التقارب بين القيم الحقيقية والمتوقعة."



شكل (١٢) التقارب بين القيم الحقيقية والقيم المتوقعة

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

ومما سبق يمكن بناء الشبكة وفقا للمعايير الآتية:

- طبقة الإدخال (Input Layer): تمثل المرحلة الأولى التي تستقبل البيانات التاريخية لمعدلات الأداء الفني لشركات التأمين. يتم تدريب النموذج لكل شركة تأمين على حدة، بحيث تُعتبر بيانات الشركة متسلسلة زمنية واحدة بطول ٢١ سنة. يتم تنظيم البيانات في مصفوفة ثلاثية الأبعاد بحجم (عدد العينات=١، عدد الخطوات الزمنية=٢١، عدد الميزات=١)، حيث تمثل: عدد العينات (لكل شركة تأمين) = ١: يمثل السلسلة الزمنية الكاملة للشركة. عدد الخطوات الزمنية (Time Steps) = ٢١، يعبر عن التسلسل الزمني للبيانات، سيتم استخدام أجزاء من هذا التسلسل كمدخلات للنموذج أثناء التدريب التراكمي. أي تعتمد كل سنة على السنوات السابقة. عدد الميزات (Features) = ١، حيث يتم التعامل مع المعدل الفني كمتغير وحيد في كل نموذج. يعتمد التدريب على أسلوب التعلم التراكمي، حيث تستفيد كل سنة من جميع السنوات السابقة لالتقاط الاتجاهات طويلة المدى والتنبؤ بالسنة القادمة بدقة.

- طبقات LSTM المخفية (Hidden LSTM Layers):

تضمن الشبكة طبقتين مخفيين من نوع LSTM، كل منهما يحتوي على ٧٠ خلية عصبية تستخدم دالة التنغيم tanh. تعمل هاتان الطبقتان على استخراج الأنماط الزمنية المعقدة والاستفادة من العلاقات الزمنية طويلة وقصيرة الأمد. تعتمد خلايا LSTM على آلية البوابات لتنظيم تدفق المعلومات وتجنب مشكلة تلاشي التدرجات.

- طبقة الإسقاط (Dropout Layer): للحد من الإفراط في التعلم وتحسين التعميم، تم دمج طبقة إسقاط بنسبة ٠,١٪ بعد كل طبقة LSTM مخفية. تعمل هذه الطبقات على إيقاف بعض الوحدات العصبية عشوائياً أثناء التدريب فقط.

- طبقة الإخراج (Output Layer) طبقة كثيفة (Fully Connected Layer): تحتوي على ٢١ وحدة عصبية (بعدد السنوات في التسلسل الزمني) وتستخدم دالة تنشيط خطية (Linear Activation Function) لإنتاج تنبؤات عديدية مستمرة. يتم استخدام التنبؤات بشكل متسلسل لتوليد القيم المستقبلية والتنبؤ بثلاث سنوات قادمة.

### ١١, ٢, ٢ آلية التنبؤ المتسلسل

اعتمدت الدراسة على آلية التنبؤ المتسلسل، حيث تُستخدم القيم التاريخية لتدريب شبكة LSTM، ثم تُمرر القيم المتنبأ بها تدريجياً للحصول على توقعات للفترات المستقبلية. هذا النهج مناسب لتحليل السلاسل الزمنية المالية والتأمينية التي تعتمد على القيم السابقة. للتعامل مع تراكم الأخطاء المحتمل على المدى الطويل، تم اعتماد أسلوب إعادة ضبط النموذج دورياً وتحسين إعدادات التدريب.

### ١١-٣ تدريب نموذج الـ LSTM

بعد بناء النموذج وتحديد هيكله، تأتي مرحلة تدريب النموذج، وهي من أهم المراحل حيث يتم ضبط الأوزان الداخلية للشبكة العصبية العميقة باستخدام البيانات التاريخية لمعدلات الأداء الفني لشركات التأمين. تعتمد عملية التدريب على عدة عوامل رئيسية، مثل خوارزمية التحسين، دالة الخطأ، عدد العصور (Epochs)، وحجم الدفعة (Batch Size)، والتي تؤثر جميعها على أداء النموذج النهائي ودقته في التنبؤ بالقيم المستقبلية.

### ١١-٣-١ تقسيم البيانات (Data Splitting)

قبل تدريب النموذج، تم تقسيم البيانات لكل شركة تأمين بنسبة ٨٠٪ لبيانات التدريب و ٢٠٪ لبيانات التحقق لضمان تعلم النموذج بشكل صحيح وقابل للتعميم وتقييم دقة التنبؤات قبل الاختبار

### ١١-٣-٢ خوارزمية التحسين (Optimization Algorithm)

لتحسين أوزان النموذج نظراً لكفاءتها في معالجة البيانات الزمنية وتوفير تحديثات (Adam) تم اختيار خوارزمية آدم مستقرة. يتم تحديث الأوزان وفقاً للمعادلات التالية

$$M_t = \beta_1 M_{t-1} + (1 - \beta_1) \nabla L_t \dots \dots \dots (٢) \dots \dots \dots \text{لحساب المتوسط المتحرك الأول (متوسط التدرج)}$$

$$V_t = \beta_2 V_{t-1} + (1 - \beta_2)(\nabla L_t)^2 \dots\dots\dots (٣)$$

$$\hat{m}_t = m_t / 1 - \beta_1^t \dots\dots\dots (٤-A)$$

$$\hat{v}_t = v_t / 1 - \beta_2^t \dots\dots\dots (٤-B)$$

$$W_t = W_{t-1} - \alpha (\hat{m}_t) / (\sqrt{\hat{v}_t} + \epsilon) \dots\dots\dots (٥)$$

#### ٤-١١ مقياس دقة الأداء

تم تقييم أداء نموذج الشبكة العصبية في تقدير قيم عينة الاختبار باستخدام مقاييس إحصائية تقيس العلاقة بين القيم الحقيقية والقيمة المتنبأ بها يُعرف الفرق بينهما بخطأ التنبؤ وفقاً للمعادلة التالية:

$$\varepsilon_i = (y_i - \hat{y}_i) \dots\dots\dots (7)$$

حيث  $y_i$ : هي القيمة الحقيقية، و  $\hat{y}_i$  هي القيمة المتوقعة

#### ١-٤-١١ دالة الخسارة (Loss Function)

أثناء تدريب النموذج على مشكلة التنبؤ المستمر (Regression)، تم استخدام دالة متوسط مربعات الخطأ (MSE Mean Squared Error -) لقياس دقة التنبؤات مقارنة بالقيم الحقيقية

$$MSE = \frac{1}{n} \times \sum_{i=1}^n \varepsilon_i^2 \dots\dots\dots (8)$$

#### ٢-٤-١١ متوسط الخطأ المطلق النسبي (Mean Absolute Percentage Error - MAPE):

يتم استخدام مقياس MAPE لقياس نسبة الخطأ بين القيم الحقيقية والقيم المتوقعة، (الهاشيمي، ٢٠٢٢)، ويحسب وفقاً للمعادلة الآتية:

$$MAPE = \frac{1}{n} \times \sum_{i=1}^n \left\{ \frac{|y_i - \hat{y}_i|}{|y_i|} \right\} \times 100 \dots\dots\dots (9)$$

#### ٣-٤-١١ جذر متوسط مربع الأخطاء (RMSE) Root Mean Squared Error (De) (Mauro, 2021):

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

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n \varepsilon_i^2} \dots\dots\dots (10)$$

وكلما كانت قيم MAPE و RMSE منخفضة، دل ذلك على ارتفاع دقة النموذج في التنبؤ بالقيم المستقبلية.

#### ٤-٤-١١ معدل التحديد $R^2$

هو مقياس إحصائي يحدد قوة العلاقة بين القيم الحقيقية والمتوقعة. تتراوح قيمه بين ٠ و ١، وكلما اقتربت القيمة من ١، كان النموذج أفضل في تفسير التباين

$$R^2 = 1 - \frac{(y_i - \hat{y}_i)^2}{(y_i - \bar{y}_i)^2} \dots\dots\dots (11)$$

د. سماح سيد بيومي خليل

٥-١١ التدريب

تم تدريب نموذج الشبكة العصبية العميقة باستخدام خوارزمية الذاكرة طويلة وقصيرة الأجل (LSTM) بهدف التنبؤ بالمعدلات الفنية في التأمين التكميلي للمركبات. جرى تقسيم البيانات إلى ٨٠٪ للتدريب و ٢٠٪ للاختبار، مع تطبيق القيم باستخدام طريقة Z-Score لضمان استقرار عملية التدريب. تمت تهيئة البيانات لتتناسب مع متطلبات النموذج عبر تحويلها إلى مصفوفات خلوية (Cell Arrays) باستخدام دوال cellfun و num2cell في بيئة MATLAB، تم بناء نموذج LSTM يتكون من طبقة إدخال زمنية، طبقتين LSTM مخفيتين (٧٠ خلية لكل منهما) مع طبقتي Dropout (٠,٠٥)، وطبقة Fully Connected مع طبقة Regression في النهاية. تم استخدام خوارزمية Adam (معدل تعلم ابتدائي ٠,٢) مع ٤٠٠ فترة تدريبية، وحجم دفعة ١، وحد تدرج ١. تم تعيين ValidationFrequency كل ٢٠ دفعة مع تطبيق تقنية تقليل معدل التعلم (LearnRateDropFactor 0.5) كل ٥٠ فترة) والتوقف المبكر (ValidationPatience 20).

٦-١١ التنبؤ

بعد إتمام التدريب، تم استخدام النموذج لإجراء التنبؤ على مجموعة الاختبار، مع استعادة القيم إلى نطاقها الأصلي بإلغاء التطبيع (Inverse Z-Score) تم تقييم أداء النموذج باستخدام ثلاثة مقاييس رئيسية، حيث حقق النتائج التالية:

- MAPE = (٠,٨٢٪): يعكس دقة تنبؤ عالية جداً، حيث لم يتجاوز متوسط الخطأ النسبي ١٪.
- RMSE = (٠,٩١٨٨): مما يشير إلى متوسط خطأ تنبؤ أقل من وحدة واحدة، وهو مؤشر جيد بالنظر إلى نطاق البيانات (١٠٠-٠).
- R<sup>2</sup> = (٠,٩٩١٠): يوضح أن النموذج قادر على تفسير ٩٩,١٠٪ من التباين في البيانات.

٧-١١ النتائج

بعد التأكد من جودة النموذج وصلاحيته في التنبؤ بالمعدلات الفنية في التأمين التكميلي للسيارات تم استخدامه للتنبؤ بكل معدل على حدة. حيث بعد تدريب النموذج ببيانات كل معدل على مجموعة التدريب والاختبار، تم دمج البيانات التدريبية والاختبارية معا لإعادة تدريب النموذج (ب- XAII و YAII) كما هو موضح في الاكواد في الملحق (أ)، ومن ثم حساب مؤشرات الأداء مجدداً باستخدام جميع البيانات لكل معدل وكانت النتائج كالآتي:

أولاً: معدل الاحتفاظ

جدول رقم (٧) يوضح الفارق بين القيم الفعلية التاريخية والقيم التي تنبأ بها النموذج لنفس الفترة لمعدل الاحتفاظ

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2003/2002	الحقيقية: 98 المتوقعة: 97,8	98	93,7	67,6	89,5	68,5	99,9	62,6	90,2
2004/2003	الحقيقية: 100,4 المتوقعة: 96	100,4	96,2	68	93,8	68,7	87,2	46,7	97,1
2005/2004	الحقيقية: 100 المتوقعة: 99,7	100	92,5	69,8	91,1	67,5	88,3	50,1	97,3
2006/2005	الحقيقية: 100 المتوقعة: 99,7	100	96,7	68,2	91,5	84,7	92,9	53,3	96,2
2007/2006	الحقيقية: 100 المتوقعة: 99,7	100	93,2	96,3	94,8	71,7	87,1	81,8	95,6
2008/2007	الحقيقية: 100 المتوقعة: 99,8	100	91,1	95	95,6	48,7	96,7	99,2	97
2009/2008	الحقيقية: 100 المتوقعة: 99,8	100	92,3	97	96,4	63,7	96,9	96,8	99
2010/2009	الحقيقية: 99 المتوقعة: 98,9	99	93,6	97	96,2	82,9	98,8	90,1	98,4
2011/2010	الحقيقية: 100	100	89,9	97,4	94,3	98	97,8	94,7	98,4

د. سماح سيد بيومي خليل

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
	المتوقعة	٩٩,٨	٨٩,٩	٩٧	٩٤,٤	٩٧,٧	٩٧,٦	٩٤,٥	٩٨,٣
2012/2011	الحقيقية	100	90.9	96.1	96.7	96.8	99.3	95.4	98.1
	المتوقعة	٩٩,٨	٩١	٩٥,٨	٩٦,٦	٩٦,٦	٩٩,١	٩٥,٣	٩٨,٢
2013/2012	الحقيقية	100	91.9	96.3	97.3	97.5	97.5	91.3	98.8
	المتوقعة	٩٩,٨	٩٢	٩٦	٩٧,١	٩٧,٣	٩٧,٤	٩١,٤	٩٨,٨
2014/2013	الحقيقية	100	90.7	95.9	98.6	97.3	99.6	93.3	98.9
	المتوقعة	٩٩,٨	٩٠,٩	٩٥,٦	٩٨,٣	٩٧,١	٩٩,٤	٩٣,٤	٩٨,٩
2015/2014	الحقيقية	100	92.2	95.6	98.5	99.2	97.1	94.2	99.1
	المتوقعة	٩٩,٨	٩٢,٣	٩٥,٤	٩٨,٥	٩٩	٩٧,١	٩٤,٢	٩٩
2016/2015	الحقيقية	100	92.4	90.6	97.6	97.5	99.5	95.1	99.2
	المتوقعة	٩٩,٨	٩٢,٥	٩٠,٧	٩٧,٤	٩٧,٤	٩٩,٣	٩٥,١	٩٩,٢
2017/2016	الحقيقية	100	91.8	83.6	97.9	98.8	99.5	96.4	99.5
	المتوقعة	١٠٠,١	٩١,٩	٨٤	٩٧,٧	٩٨,٧	٩٩,٣	٩٦,٣	٩٩,٥
2018/2017	الحقيقية	100	92.3	70.3	93.5	97.7	99.6	97.4	99.2
	المتوقعة	٩٩,٩	٩٢,٣	٧٠,٤	٩٣,٨	٩٧,٧	٩٩,٤	٩٧,٤	٩٩,٢
2019/2018	الحقيقية	100	89.5	70.3	93.7	95.5	99.7	98.7	99.1
	المتوقعة	٩٩,٩	٨٩,٦	٧٠,٣	٩٣,٩	٩٥,٥	٩٩,٥	٩٨,٥	٩٩,١
2020/2019	الحقيقية	100	88.4	71.2	93.7	98.8	99.7	99.4	98.3
	المتوقعة	٩٩,٨	٨٨,٥	٧١,١	٩٣,٨	٩٨,٧	٩٩,٩	٩٩,٢	٩٨,٣
2021/2020	الحقيقية	100	88.4	72.5	94	99.3	99.9	99.5	98.6
	المتوقعة	٩٩,٨	٨٨,٥	٧٢,٣	٩٤,١	٩٩,٢	٩٩,٧	٩٩,٢	٩٨,٦
2022/2021	الحقيقية	100	89.2	70.7	92.9	97.8	99.7	99.4	98.6
	المتوقعة	٩٩,٨	٨٩,٣	٧٠,٨	٩٣,١	٩٧,٧	٩٩,٥	٩٩,٢	٩٨,٦
2023/2022	الحقيقية	100	89.2	65.2	92	98.6	98.5	99.3	98.5
	المتوقعة	٩٩,٨	٨٩,٣	٦٥,٥	٩٢,٣	٩٨,٥	٩٨,٣	٩٩,١	٩٨,٥

المصدر من اعداد الباحثة بناء على مخرجات برنامج MATLAB

- تم حساب مقاييس الأداء بناءً على مقارنة القيم الحقيقية والمتنبأ بها: حيث ان قيمة RMSE بلغت (٠,٤٥٩٥)، مما يشير إلى متوسط فرق حوالي ٠,٥ بين القيم. كما ان معامل التحديد  $R^2$  بلغ (٠,٩٩٨٣)، مما يدل على أن النموذج يفسر حوالي ٩٩,٨٣٪ من التباين. متوسط الخطأ النسبي المطلق MAPE بلغ (٠,٣٨٪) وهو مؤشر على دقة عالية في التنبؤ.

- بشكل عام، حقق النموذج أداءً دقيقاً، حيث تتقارب القيم المتوقعة بشدة مع القيم الحقيقية في معظم السنوات والشركات، مما يعكس كفاءة LSTM في تتبع الأنماط الزمنية لمعدل الاحتفاظ. غالبية الفروق تقع في نطاق  $\pm ٠,٢$ ..

- أعلى انحراف نسبي ملاحظ كان في شركة المهندس للتأمين سنة ٢٠٠٤/٢٠٠٥ حيث كان الفرق حوالي ٠,٩ نقطة (٦٩,٨) حقيقية مقابل ٧٠,٧ (متوقعة)، ومع ذلك يظل هذا الانحراف مقبولاً نسبياً نظراً للطبيعة الديناميكية للبيانات. حيث شركات مثل Allianz و Royal و GIG أظهرت تطابقاً شبه تام في التوقعات مما يعكس نمطاً منتظماً ومستقرًا في بياناتها، كما نجد ان شركة "المهندس للتأمين" و "قناة السويس للتأمين" \* أظهرتا تفاوتات بسيطة، ربما بسبب تقلبات في بياناتها أو عوامل خارجية مؤثرة على الأداء. وأداء النموذج في السنوات الأخيرة (٢٠٢٠-٢٠٢٣) كان ممتازاً، مما يعكس أن النموذج لم يفقد كفاءته رغم إدخال بيانات حديثة، وهو مؤشر جيد على قدرته على التنبؤ المستقبلي.

د. سماح سيد بيومي خليل

- بناءً على هذه النتائج عند استخدام النموذج للتنبؤ بمعدل الاحتفاظ لمدة ثلاث سنوات قادمة، بلغ معامل التحديد  $R^2$  حوالي ٩٧,٤٪. هذا الأداء المرتفع يشير إلى قدرة النموذج على تعميم الأنماط، على الرغم من كونه ذلك يرجع إلى إن البيانات التي تُستخدم في التدريب هي التي تمثل المعلومات التاريخية والنمطية التي سيبنى عليها النموذج تعلمه. أما البيانات الجديدة أو المستقبلية فقد تحتوي على قيم لم يُعرض عليها النموذج أثناء التدريب، بناءً على هذه النتائج، تم التنبؤ بمعدل الاحتفاظ لمدة ثلاث سنوات قادمة (٢٠٢٤/٢٠٢٣ - ٢٠٢٦/٢٠٢٥)، وكانت النتائج كما هو موضح في الجدول أدناه:

جدول رقم (٨) يعرض القيم المتوقعة (المستقبلية) لمعدل الاحتفاظ على مدار ٣ سنوات

السنوات	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2024/2023	100	89.4	65.2	92.4	98.9	99.1	99.5	98.6
2025/2024	100	89.3	66.7	93.1	99.1	99.7	99.4	98.8
2026/2025	100	88.9	67.7	93.9	98.5	99.	99.3	99.1

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

الجدول رقم (٨) يعرض التوقعات المستقبلية لمعدلات الاحتفاظ للشركات محل الدراسة خلال الفترة (٢٠٢٣/٢٠٢٤ إلى ٢٠٢٥/٢٠٢٦) حيث يظهر اتجاه عام نحو استقرار أو ارتفاع طفيف في معدلات الاحتفاظ لدى معظم الشركات محل الدراسة. مصر للتأمين تحافظ على نسبة احتفاظ كاملة (١٠٠٪)، ما يعكس ثباتاً في سياساتها على مدى السنوات الثلاث القادمة، وبالمثل، تحافظ شركة بيت التأمين المصري السعودي وشركة اليانز للتأمين على معدلات احتفاظ مرتفعة جداً تقترب من ٩٩٪ خلال فترة التنبؤ. في المقابل، تظهر شركة قناة السويس للتأمين وشركة المهندس للتأمين معدلات احتفاظ أقل نسبياً، مع ملاحظة تحسن طفيف متوقع في معدل احتفاظ لشركة المهندس للتأمين على مدار السنوات القادمة. أما شركة المجموعة العربية المصرية GIG وشركة الدلتا للتأمين وشركة رويال للتأمين فتظهر معدلات احتفاظ قوية تتراوح في الغالب بين ٩٨٪ و ٩٩٪، وتشير مؤشرات أداء النموذج المستخدم في هذا التنبؤ. ( $R^2 = 0.9766$ ،  $MAPE = 0.92\%$ ،  $RMSE = 0.6272$ ) إلى دقة متوقعة عالية للنموذج وبالتالي يعكس هذا التنبؤ قدرة نموذج LSTM على التقاط الاتجاهات طويلة المدى، كما يعزز من الاعتماد عليه في تقديم رؤى مستقبلية تساعد في دعم قرارات الشركات واستراتيجياتها التسويقية.

ثانياً معدل المصروفات العمومية والإدارية

جدول رقم (٩) يوضح الفارق بين القيم الفعلية التاريخية والقيم التي تتنبأ بها النموذج لنفس الفترة لمعدل المصروفات العمومية والإدارية

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	البايز للتأمين	شركة رويال للتأمين
2003/2002	الحقيقية	8	13.7	19.9	17.8	15.8	10.7	24.5	37.4
	المتوقعة	8.3	13.7	19.8	18.1	16	11	24.4	37.5
2004/2003	الحقيقية	8.1	12.6	20.2	15	15.9	31.3	23.8	23
	المتوقعة	8.3	12.6	19.8	15.2	15.9	31.5	23.4	22.8
2005/2004	الحقيقية	7.8	13.3	18.9	15.8	18.6	21.3	20.4	24.2
	المتوقعة	8	13.3	18.8	16	18.5	21.1	20.3	23.8
2006/2005	الحقيقية	7.6	12.8	15.4	13.2	12.9	22.9	17.9	23.1
	المتوقعة	7.8	12.9	15.2	13,٤	12.9	22.4	١٧,٨	٢٢,٧
2007/2006	الحقيقية	7.4	12.3	12.1	9.9	10.7	20	14	25.4
	المتوقعة	7.6	12.4	12	10.2	10.9	19.6	14	23.8
2008/2007	الحقيقية	12.3	7.4	7.4	7.9	7.6	16.9	9.1	12.9
	المتوقعة	12.2	7.5	7.4	7.9	7.8	16.5	9.1	12.7
2009/2008	الحقيقية	8.4	9.1	6.2	6.4	8	8.9	9	15.4
	المتوقعة	8.5	9.1	6.3	6.6	8.1	8.9	9	15.1
2010/2009	الحقيقية	10.9	7.1	7.7	8.8	10.5	8.5	8.8	6
	المتوقعة	10.7	7.1	7.8	8.7	10.4	8.6	8.8	6.1
2011/2010	الحقيقية	13.3	9	9.2	9.9	11.6	5.8	9.1	13.5
	المتوقعة	13.3	9	9.3	10	11.6	6.1	9.2	13.3
2012/2011	الحقيقية	12.4	12.1	9.8	10.3	10.8	5.3	10.1	15.4
	المتوقعة	12.4	12.1	9.9	١٠,٤	10.9	٥,٦	١٠,٢	١٥,١
2013/2012	الحقيقية	17.3	18.1	9.3	9.7	12.2	5.2	12.5	14.7
	المتوقعة	17.4	18.1	9.4	9.9	12.3	5.5	12.5	14.5
2014/2013	الحقيقية	18.2	16.3	10.9	10.4	15.4	6.2	13.4	15.3
	المتوقعة	18.2	16.3	11.1	10.7	15.3	6.6	13.4	15.2
2015/2014	الحقيقية	17.7	17.7	13.5	10	17	5.9	17.7	15.3
	المتوقعة	17.6	17.7	13.5	10.3	16.8	6.3	17.5	15.3
2016/2015	الحقيقية	18.6	15.8	14	9.5	15.8	6.1	19.7	21.5
	المتوقعة	18.5	15.8	14	9.9	15.8	6.5	19.5	21.3
2017/2016	الحقيقية	14	14.3	10.6	9.9	15.3	8.3	13.4	20.8
	المتوقعة	14.1	14.3	10.8	10.2	15.3	8.7	13.5	20.3
2018/2017	الحقيقية	16.4	14.5	10.7	9.7	14.2	6.1	8.9	24.8
	المتوقعة	16.5	14.5	10.9	10	14.4	6.5	9.3	24.3
2019/2018	الحقيقية	14.4	17	11.8	10.9	12.3	5.4	8.8	18.1
	المتوقعة	14.6	16.9	11.8	11.1	12.4	5.8	9.1	17.8
2020/2019	الحقيقية	16.7	17.6	11.8	10.6	9.9	5.4	14.3	18.5
	المتوقعة	16.8	17.6	11.7	10.7	10.1	5.7	14.3	18.3
2021/2020	الحقيقية	14.1	17.8	10.6	10.8	8.4	6.9	13.7	16.5
	المتوقعة	14.2	17.8	10.5	10.8	8.7	7.2	13.6	16.3
2022/2021	الحقيقية	12.7	20.3	8.2	10.2	9.2	5.9	12	11.1
	المتوقعة	12.7	20.2	8.2	10.2	9.2	6.1	11.9	10.9
2023/2022	الحقيقية	10.2	19.1	7.3	9.1	10.6	11.2	10.5	12.3
	المتوقعة	10.3	19	7.4	9.1	10.6	11.2	10.4	12

المصدر من اعداد الباحثة بناء على مخرجات برنامج MATLAB

د. سماح سيد بيومي خليل

- تم استخدام نموذج LSTM ذاته المستخدم في التنبؤ بمعدل الاحتفاظ لتوقع معدل المصروفات العمومية والإدارية، وقد حقق النموذج أداءً تنبؤياً عالي الدقة حيث أظهرت النتائج ان قيمة (RMSE) بلغت ٠,٢٣٣١، وسجل معامل التحديد ( $R^2$ ) قيمة مرتفعة بلغت ٠,٩٩٨٠، وبلغت قيمة (MAPE) حوالي ١,٥٦٪، وهي نسبة مقبولة جداً وتعكس دقة تنبؤية قوية للنموذج.

أظهر النموذج أداءً ثابتاً عبر السنوات، مع تقارب كبير بين القيم الفعلية والمتوقعة، ففي السنوات الأولى من الجدول (مثل ٢٠٠٢/٢٠٠٣)، كانت القيم المتوقعة قريبة جداً من القيم الحقيقية، مما يشير إلى قدرة النموذج على التعامل بشكل جيد مع البيانات التاريخية. بينما في السنوات الأحدث (مثل ٢٠٢٢/٢٠٢١ و ٢٠٢٣/٢٠٢٢)، كانت هناك بعض الاختلافات الطفيفة بين القيم الحقيقية والمتوقعة، وهو ما يعكس الصعوبة المتزايدة في التنبؤ بالقيم عندما تزداد التغيرات في البيئة الاقتصادية أو في سياسات الشركات. وبالنسبة للاتجاه العام،

- بعض الشركات الكبرى مثل مصر للتأمين وقناة السويس للتأمين أظهرت نتائج متوقعة قريبة جداً من النتائج الفعلية على مر السنوات، مما يعكس استقراراً نسبياً في المصروفات العمومية والإدارية. بالمقابل، كانت شركة البيت المصري السعودي وشركة رويال للتأمين قد أظهرت بعض التقلبات الأكبر في البيانات المتوقعة مقارنة بالحقيقية، ما قد يعكس تحديات أكبر في التنبؤ بهذه الشركات التي تتأثر بشكل أكبر بالتغيرات في السوق أو استراتيجيات الإدارة. وهذا يثبت قدرة النموذج على التنبؤ بالاتجاهات العامة لمعدل المصروفات العمومية والإدارية لشركات التأمين على المدى الطويل.

وبناءً على هذه النتائج، تم التنبؤ بمعدل المصروفات العمومية والإدارية لمدة ثلاثة سنوات قادمة وكانت النتائج كالآتي:

جدول رقم (١٠) يعرض القيم المتوقعة (المستقبلية) لمعدل المصروفات العمومية والإدارية على مدار ٣ سنوات

السنوات	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2024/2023	10.3	18	7.1	9.2	11	11.3	10.9	12.4
2022/2024	12.5	20.6	7.9	10.1	9.1	9.8	12.1	12.1
2026/2025	13.8	19.4	10.2	10.3	8.3	10.7	13.3	15.7

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

- يعرض الجدول السابق (١٠) قيم التنبؤ المستقبلي لمعدل المصروفات العمومية والإدارية للشركات محل الدراسة خلال الفترة (٢٠٢٤/٢٠٢٣ إلى ٢٠٢٦/٢٠٢٥)، وتُظهر النتائج تبايناً في الاتجاهات المستقبلية بين الشركات. حيث تُظهر شركة مصر للتأمين اتجاهاً تصاعدياً تدريجياً في معدل المصروفات العمومية والإدارية المتوقع، حيث يرتفع من ١٠,٣٪ في ٢٠٢٣/٢٠٢٤ إلى ١٣,٨٪ في ٢٠٢٥/٢٠٢٦. وبالمثل، من المتوقع أن تشهد شركة اليانز للتأمين وشركة رويال للتأمين زيادة ملحوظة في هذه المصروفات خلال فترة التنبؤ. في المقابل، من المتوقع أن تحافظ شركة قناة السويس للتأمين على معدل مصروفات عمومية وإدارية مرتفع نسبياً ولكنه مستقر حول نطاق ١٨٪ إلى ٢٠,٦٪. بينما تُظهر شركة المهندس للتأمين معدلات أقل نسبياً مع اتجاه تصاعدي ملحوظ. أما شركة المجموعة العربية المصرية GIG وشركة الدلتا للتأمين تتراوح اتجاهاتها بين استقرار وزيادة طفيفة، مع بعض التذبذب. يعكس هذا التباين في التنبؤات المستقبلية لمعدلات المصروفات العمومية والإدارية استراتيجيات تشغيلية مختلفة بين الشركات، أو توقعات مختلفة لنمو الأعمال والاستثمارات الإدارية.

د. سماح سيد بيومي خليل

- وتشير مؤشرات أداء النموذج المستخدم إلى قدرة نموذج LSTM على التقاط الاتجاهات طويلة الأجل لمعدلات المصروفات العمومية والإدارية بدقة عالية حيث بلغت قيم كلا من (RMSE) قيمة ٠,٢٥٧٥، و (MAPE) قيمة 1.08% و (R<sup>2</sup>) بلغت ٠,٩٧٤٥ وبالتالي يعكس هذا التنبؤ قدرة نموذج LSTM على التقاط الاتجاهات طويلة المدى، وهذه النتائج تُمكن شركات التأمين من العمل على تحسين موازنات المصروفات بناءً على تنبؤات دقيقة وتعزيز كفاءة إدارة التكاليف عبر توقع التقلبات المستقبلية

**ثالثاً: معدل العمولات وتكاليف الإنتاج**

يعرض الجدول الآتي مقارنة تفصيلية بين القيم الحقيقية والمتوقعة لمعدل العمولات وتكاليف الإنتاج خلال الفترة من ٢٠٠٣/٢٠٠٢ حتى ٢٠٢٣/٢٠٢٢ لعدد ثمانية شركات تأمين مصرية محل الدراسة، باستخدام نفس نموذج LSTM المطور

جدول رقم (١١) يوضح الفارق بين القيم الفعلية التاريخية والقيم التي تنبأ بها النموذج لنفس الفترة لمعدل العمولات وتكاليف الإنتاج

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	البايزر للتأمين	شركة رويال للتأمين
2003/2002	الحقيقية: 32.1 المتوقعة: 32.2	32.1	32.3	35.1	27.1	31.6	28.0	45.0	11.3
		32.2	32.4	35	27.3	31.7	28.2	44.4	11.9
2004/2003	الحقيقية: 37 المتوقعة: 36.7	37	33.1	39	24.8	33	28.4	33.5	14.8
		36.7	33	38.6	25	32.8	28.5	33.3	15.2
2005/2004	الحقيقية: 34.2 المتوقعة: 34	34.2	32.4	36.6	31.9	33.3	25.2	27.9	17.6
		34	32.2	36.3	31.8	33.1	25.4	27.9	17.9
2006/2005	الحقيقية: 33.5 المتوقعة: 33.3	33.5	32.5	34.8	23.9	34.8	25.3	33.6	15.9
		33.3	32.4	34.6	24.1	34.6	25.5	33.4	16.3
2007/2006	الحقيقية: 32.2 المتوقعة: 31.9	32.2	29.7	31.3	27.2	26	24.9	32.6	8.3
		31.9	29.7	31.1	27.2	26	25	32.3	8.8
2008/2007	الحقيقية: 30.1 المتوقعة: 29.8	30.1	29.1	29.2	22	25.9	22.5	30	11.6
		29.8	29	29	22.1	25.9	22.6	29.8	12
2009/2008	الحقيقية: 27.7 المتوقعة: 27.6	27.7	28.7	29.8	19.8	25.2	23.5	28.7	18
		27.6	28.6	29.6	20	25.2	23.6	28.5	18.2
2010/2009	الحقيقية: 31.7 المتوقعة: 31.3	31.7	30.5	31	24.4	25	24.8	24.8	19
		31.3	30.3	30.7	24.4	25	24.8	24.8	19.2
2011/2010	الحقيقية: 26.1 المتوقعة: 26.2	26.1	29.7	26.8	22.6	25.3	25.8	32	18.8
		26.2	29.7	26.8	22.8	25.4	25.9	31.8	19
2012/2011	الحقيقية: 31.4 المتوقعة: 31	31.4	21.8	31.2	23.8	24.2	27.9	24.4	20.5
		31	21.9	30.9	23.8	24.2	27.7	24.4	20.6
2013/2012	الحقيقية: 32.9 المتوقعة: 32.5	32.9	22.6	30.4	23.4	24.2	29.9	26.2	26.7
		32.5	22.7	30.2	23.5	24.3	29.7	26.2	26.6
2014/2013	الحقيقية: 31.9 المتوقعة: 31.6	31.9	23.1	34	18.8	24.1	32.5	23.9	23.4
		31.6	23.1	33.5	19	24.2	31.1	24	23.4
2015/2014	الحقيقية: 32.7 المتوقعة: 32.2	32.7	28.6	30	19.6	24.8	34.8	20.1	22.8
		32.2	28.3	29.7	19.8	24.7	34.3	20.3	22.8
2016/2015	الحقيقية: 31.7 المتوقعة: 31.3	31.7	26.9	30.4	19.6	25.1	27.8	23	20.5
		31.3	26.7	30.1	19.8	25	27.6	23	20.5

د. سماح سيد بيومي خليل

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2017/2016	الحقيقية المتوقعة	28.5 ٢٨,٤	27.7 ٢٧,٥	34.1 ٣٣,٦	19.1 ١٩,٣	25.9 ٢٥,٨	28 ٢٧,٨	21.5 ٢١,٦	25.1 ٢٥
2018/2017	الحقيقية المتوقعة	30.9 ٣٠,٧	27.2 ٢٧	36.8 ٣٦,١	18.7 ١٨,٩	25.2 ٢٥,٢	39.1 ٣٩,٣	20.7 ٢١	27.1 ٢٧
2019/2018	الحقيقية المتوقعة	30.7 30.7	28.4 ٢٨,٥	33.4 ٣٣,١	20.3 ٢٠,٦	25.7 ٢٥,٨	38.1 ٣٧,٦	29.9 ٢٩,٩	23.8 ٢٣,٩
2020/2019	الحقيقية المتوقعة	31.6 ٣١,٥	30.1 ٣٠,١	30.2 ٣٠,١	20.6 ٢٠,٩	30.9 ٣٠,٨	37.5 ٣٧,١	30.1 ٣٠,١	26.3 ٢٦,٤
2021/2020	الحقيقية المتوقعة	34.2 ٣٣,٩	23.7 ٢٣,٩	29.9 ٢٩,٩	22.2 ٢٢,٥	34.8 ٣٤,٦	37.9 ٣٧,٥	29.9 ٢٩,٩	32.2 ٣٢,١
2022/2021	الحقيقية المتوقعة	26.3 ٢٦,٥	24.2 ٢٤,٥	31 ٣٠,٩	22.6 ٢٢,٩	35.6 ٣٥,٣	35.2 ٣٤,٩	30.2 ٣٠,٢	30.3 ٣٠,٣
2023/2022	الحقيقية المتوقعة	26.2 ٢٦,٥	26.3 ٢٦,٥	28.5 ٢٨,٦	23.6 ٢٣,٩	36.3 ٣٦	31.4 ٣١,٤	31.4 ٣١,٤	30.6 ٣٠,٦

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

تم استخدام نفس نموذج الشبكة العصبية LSTM الذي تم تطويره للتنبؤ بالقيم التاريخية لمعدل العمولات وتكاليف الإنتاج رغم اختلاف أنماط البيانات بين الشركات من حيث التذبذب أو الاتجاه العام، أظهر النموذج ثباتاً ملحوظاً في الأداء، حيث حقق  $RMSE = 0.2352$ ، و  $R^2 = 0.9983$ ، مع نسبة خطأ مطلق (MAPE) منخفضة جداً بلغت ٠,٧٢%، مما يدل على دقة تنبؤية عالية. ومن خلال تحليل النتائج، نجد أن النموذج تعامل بكفاءة مع الشركات ذات الاتجاهات الثابتة نسبياً مثل مصر للتأمين والدلتا للتأمين، وكذلك مع الشركات ذات التغيرات المفاجئة مثل بيت التأمين المصري السعودي وشركة رويال للتأمين. فعلى سبيل المثال، رغم التذبذب الواضح في قيم "رويال للتأمين" في السنوات الأخيرة، ظل الفارق بين القيم الحقيقية والمتوقعة في معظم الأحيان أقل من نصف نقطة. كما أن شركات مثل اليانز للتأمين و GIG التي أظهرت نمواً تدريجياً عبر السنوات، استطاع النموذج التنبؤ بقيمها بدقة دون انحرافات واضحة، ما يبرز قدرة النموذج على التكيف مع أنماط مختلفة باستخدام نفس المعمارية والمعاملات دون الحاجة إلى تخصيص منفصل لكل شركة. تدل هذه النتائج على قوة النموذج وعموميته في التعامل مع بيانات متعددة المصادر والشركات، وهو ما يدعم إمكانية استخدامه كأداة تحليلية موحدة في قطاع التأمين لدعم قرارات التخطيط والموازنة.

وبناءً على هذه النتائج، تم التنبؤ بمعدل العمولات وتكاليف الإنتاج لمدة ثلاثة سنوات قادمة وكانت النتائج كالآتي

جدول رقم (١٢) يعرض القيم المتوقعة (المستقبلية) لمعدل العمولات وتكاليف الإنتاج على مدار ٣ سنوات

السنوات	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2024/2023	30.6	26	28.7	23.9	37.1	30.1	32.8	31.2
2022/2024	26.3	24.9	30.4	21.6	35.9	35.3	30.4	29.8
2026/2025	29.8	25.5	29.6	22	36.2	36.8	30.1	30.2

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

د. سماح سيد بيومي خليل

- يعرض الجدول السابق (١٢) التنبؤ المستقبلي لمعدل العمولات وتكاليف الإنتاج للشركات محل الدراسة خلال الفترة (٢٠٢٣/٢٠٢٤ إلى ٢٠٢٥/٢٠٢٦)، حيث نلاحظ تنوعاً ملحوظاً في مستويات هذه التكاليف والتغيرات المتوقعة بين الشركات. حيث تُظهر شركة الدلتا للتأمين أعلى معدلات متوقعة للعمولات وتكاليف الإنتاج، حيث تتراوح حول ٣٦٪ إلى ٣٧٪ خلال فترة التنبؤ مع استقرار نسبي. وبالمثل، تُظهر شركة بيت التأمين المصري السعودي معدلات مرتفعة نسبياً مع اتجاه تصاعدي ملحوظ. في المقابل، تُظهر شركة المجموعة العربية المصرية GIG أدنى معدلات متوقعة للعمولات وتكاليف الإنتاج، حيث تتراوح حول ٢٢٪ إلى ٢٣،٩٪ مع استقرار نسبي. كما تُظهر قناة السويس للتأمين معدلات أقل نسبياً مقارنة بالمتوسط العام. أما شركة مصر للتأمين وشركة اليانز للتأمين وشركة رويال للتأمين فتُظهر معدلات متوسطة تتراوح بين ٢٦٪ و ٣٣٪ مع بعض التقلبات الطفيفة خلال فترة التنبؤ. أظهرت تغيراً طفيفاً مع ارتفاع في ٢٠٢٤/٢٠٢٥ يتبعه انخفاض طفيف.

- وتشير مؤشرات أداء النموذج المستخدم في هذا التنبؤ إلى دقة عالية جداً. حيث بلغ قيم كلاً من (RMSE) قيمة ١٣٧٥،٠ و (MAPE) بلغت ٠،٦٥٪ و (R<sup>2</sup>) بلغت ٠،٩٨١٩، وبالتالي فإن هذه النتائج توضح فاعلية نموذج LSTM المستخدم، وقدرته على تقديم رؤى دقيقة حول سلوك تكاليف الإنتاج والعمولات عبر الشركات المختلفة. ويساعد هذا التباين الشركات على تقييم كفاءة الهياكل التسويقية والإنتاجية الخاصة بها مقارنة بالمنافسين، وتحديد فرص التحسين لتعزيز الكفاءة والربحية على المدى الطويل.

رابعاً: معدل الخسائر

يعرض الجدول الآتي مقارنة تفصيلية بين القيم الحقيقية والمتوقعة لمعدل الخسارة خلال الفترة من ٢٠٠٢/٢٠٠٣ حتى ٢٠٢٢/٢٠٢٣ لعدد ثماني شركات تأمين مصرية محل الدراسة، باستخدام نفس نموذج LSTM المعتمد

جدول رقم (١٣) يوضح الفارق بين القيم الفعلية التاريخية والقيم التي تنبأ بها النموذج لنفس الفترة لمعدل الخسائر

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2003/2002	الحقيقية	66.3	62.2	46	53.5	60.4	59.9	68.7	75.3
	المتوقعة	٦٦،٤	٦٢،٣	٤٦،٢	٥٣،٦	٦٠،٦	٦٠	٦٨،٧	٧٥،٣
2004/2003	الحقيقية	88.5	62.6	47.5	59.8	62.7	48.9	40	68
	المتوقعة	٨٨،٣	٦٢،٤	٤٧،٦	٥٩،٨	٦٢،٥	٤٨،٩	٤٠،٣	٦٧،٨
2005/2004	الحقيقية	79.5	56.8	34.6	58.6	57.3	64	61.5	63.9
	المتوقعة	٧٩،٣	٥٦،٩	٣٤،٩	٥٨،٦	٥٧،٣	٦٤	٦١،٦	٦٤
2006/2005	الحقيقية	72.9	74.9	48.1	64.4	45.3	71.8	63.2	86.7
	المتوقعة	٧٣،١	٧٤،٨	٤٨،٤	٦٤،٥	٤٥،٩	٧١،٩	٦٣،٣	٦٨،٩
2007/2006	الحقيقية	94.2	74.1	60.8	84.1	74.1	81.8	67	68.8
	المتوقعة	٩٣،٩	٧٤	٦٠،٩	٨٤	٧٣،٩	٨١،٧	٦٧،٢	٦٨،٨
2008/2007	الحقيقية	84.2	70.9	70.9	92.2	89.2	73.4	80.7	70.7
	المتوقعة	٨٤	٧١،١	٧١	٩٢	٨٨،٩	٧٣،٤	٨٠،٧	٧٠،٩
2009/2008	الحقيقية	67.3	73.9	73.2	70.5	72.4	64.9	82.5	68.7
	المتوقعة	٦٧،٣	٧٣،٩	٧٣،٢	٧٠،٥	٧٢،٤	٦٥،١	٨٢،٣	٦٨،٩
2010/2009	الحقيقية	73.1	71.8	71.6	74.8	65	59	75.6	72.3
	المتوقعة	٧٣،١	٧١،٨	٧١،٦	٧٤،٨	٦٥،١	٥٩،٢	٧٥،٥	٧٢،٤

د. سماح سيد بيومي خليل

السنوات	القيمة الحقيقية والمتوقعة	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2011/2010	الحقيقية	56.5	74.6	69.7	69.2	65.6	50.1	60.8	63.8
	المتوقعة	٥٦,٦	٧٤,٤	٦٩,٦	٦٩,٢	٦٥,٦	٥٠,٣	٦٠,٨	٦٣,٨
2012/2011	الحقيقية	73.4	64.8	64.3	70.9	69.2	51.8	65.3	77.6
	المتوقعة	٧٣,٥	٦٤,٨	٦٤,٣	٧٠,٩	٦٩,٢	٥١,٩	٦٥,٣	٧٧,٥
2013/2012	الحقيقية	69.3	62.3	66	67.1	61.6	55.5	58.2	66.7
	المتوقعة	٦٩,٣	٦٢,٢	٦٥,٩	٦٧,١	٦١,٦	٥٥,٥	٥٨,٢	٦٦,٧
2014/2013	الحقيقية	48.4	67.9	36.1	76.7	60.2	54.9	60	58.4
	المتوقعة	٤٨,٥	٦٧,٨	٣٦,٤	٧٦,٦	٦٠,٢	٥٤,٩	٦٠,١	٥٨,٥
2015/2014	الحقيقية	56.6	59.7	59.6	64.1	56.2	51.9	66.3	56.4
	المتوقعة	٥٦,٦	٥٩,٨	٥٩,٦	٦٤	٥٦,٢	٥٢	٦٦,٢	٥٦,٦
2016/2015	الحقيقية	54	57.3	49.1	69.1	57.7	57.4	60.7	54.5
	المتوقعة	٥٣,٩	٥٧,٣	٤٩,٢	٦٩	٥٧,٦	٥٧,٤	٦٠,٧	٥٤,٦
2017/2016	الحقيقية	55.9	57.7	47.3	68.8	54.5	50.8	48.9	62.2
	المتوقعة	٥٦	٥٧,٦	٤٧,٤	٦٨,٧	٥٤,٦	٥٠,٨	٤٩	٦٢
2018/2017	الحقيقية	62.4	73	34.3	68.7	57.2	49.9	54.3	58
	المتوقعة	٦٢,٣	٧٢,٨	٣٤,٦	٦٨,٦	٥٧,٢	٥٠,١	٥٤,٤	٥٨,١
2019/2018	الحقيقية	56.8	50.8	34.7	66.7	55.9	51.8	55.8	59.5
	المتوقعة	٥٦,٨	٥٠,٩	٣٤,٩	٦٦,٦	٥٥,٩	٥١,٨	٥٥,٩	٥٩,٥
2020/2019	الحقيقية	59.1	48.6	44.5	65.5	51	52.1	51	49.4
	المتوقعة	٥٩	٤٨,٦	٤٤,٦	٦٥,٤	٥٠,٩	٥٢,١	٥١	٤٩,٥
2021/2020	الحقيقية	57.3	48.4	38.8	66	57.7	53.1	49.8	52.6
	المتوقعة	٥٧,٢	٤٨,٤	٣٩	٦٥,٩	٥٧,٦	٥٣,١	٤٩,٩	٥٢,٦
2022/2021	الحقيقية	67.1	45.1	50.3	67.8	64.1	64.3	54.4	63.1
	المتوقعة	٦٧	٤٥,٣	٥٠,٤	٦٧,٧	٦٤	٦٤,٢	٥٤,٦	٦٣
2023/2022	الحقيقية	60.3	44.3	51.3	55.3	46	41.5	44	54.3
	المتوقعة	٦٠,٢	٤٤,٣	٥١,٢	٥٥,٣	٤٦	٤١,٥	٤٤	٥٤,٢

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

- تم استخدام نفس نموذج الشبكة العصبية LSTM وقد أظهرت النتائج أداءً دقيقاً للنموذج. حيث بلغت مؤشرات الأداء الكلية للنموذج على كامل البيانات  $RMSE = 0.5377$ ،  $R^2 = 0.9978$ ، و  $MAPE = 0.71\%$ ، ما يعكس دقة عالية وقدرة تنبؤية قوية للنموذج. تُظهر النتائج أن النموذج حافظ على مستوى عالٍ من الدقة في جميع الشركات على الرغم من التفاوت الكبير في نمط البيانات بين شركة وأخرى، سواء من حيث الاستقرار أو التذبذب أو الاتجاهات الصاعدة والهابطة. فعلى سبيل المثال، استطاع النموذج أن يتابع التحولات السريعة لشركات مثل بيت التأمين المصري السعودي ورويال للتأمين، حيث بقي الفارق بين القيم الحقيقية والمتوقعة محدوداً حتى في السنوات التي شهدت تغيرات

د. سماح سيد بيومي خليل

حادة. كما حافظ على تطابق شبه تام للقيم في شركات ذات اتجاهات أكثر استقرارًا مثل مصر للتأمين وشركة GIG ومن اللافت أيضًا أن أداء النموذج لم يتأثر بوجود قيم مرتفعة جدًا أو منخفضة جدًا في بعض السنوات، بل استمر في إنتاج تنبؤات دقيقة لجميع الشركات بدون الحاجة إلى تعديل البنية أو المعلمات، وبناءً على هذه النتائج، تم التنبؤ بمعدل الخسائر لمدة ثلاثة سنوات قادمة وكانت النتائج كالآتي

جدول رقم (١٤) يعرض القيم المتوقعة (المستقبلية) لمعدل الخسائر على مدار ٣ سنوات

السنوات	مصر للتأمين	قناة السويس للتأمين	المهندس للتأمين	المجموعة العربية المصرية GIG	الدلتا للتأمين	بيت التأمين المصري السعودي	اليانز للتأمين	شركة رويال للتأمين
2024/2023	٥٩,٣	٥٠,٢	٥٢,٩	٦٥,٩	٥٩,٦	٥٥,١	٥١,٣	٥٤,٥
2022/2024	٦١,٧	٥٢	٥١,٨	٦٨	٦٠,١	٥٤,٨	٥٤,٨	٥٧,٧
2026/2025	٦٣,٥	٥١,٩	٥٢,٤	٦٧,٧	٥٩,٨	٥٥,٢	٥٣,١	٥٨,٢

المصدر: من اعداد الباحثة بناء على مخرجات برنامج MATLAB

- من الجدول السابق (١٤) والخاص بالتنبؤ المستقبلي لمعدل الخسائر للشركات محل الدراسة خلال الفترة (٢٠٢٤/٢٠٢٣ إلى ٢٠٢٦/٢٠٢٥)، نلاحظ تقاربًا نسبيًا في معدلات الخسائر المتوقعة بين معظم الشركات، مع بعض الاستثناءات الملحوظة. تُظهر شركة المجموعة العربية المصرية GIG أعلى معدلات خسائر متوقعة بشكل ملحوظ، حيث تتراوح بين ٦٥,٩٪ و ٦٨٪ خلال فترة التنبؤ مع اتجاه تصاعدي طفيف. في المقابل، تُظهر شركة قناة السويس للتأمين وشركة اليانز للتأمين أدنى معدلات خسائر متوقعة نسبيًا، حيث تتراوح في الغالب حول ٥٠٪ إلى ٥٤٪ مع بعض التقلبات الطفيفة. أما شركة مصر للتأمين وشركة الدلتا للتأمين فتُظهران معدلات خسائر متوسطة تتراوح حول ٥٩٪ إلى ٦٣,٥٪ و ٥٩,٦٪ إلى ٦٠,١٪ على التوالي، مع اتجاه تصاعدي طفيف لكليهما. وتُظهر شركة المهندس للتأمين وشركة بيت التأمين المصري السعودي وشركة رويال للتأمين معدلات خسائر متقاربة نسبيًا تتراوح في نطاق ٥١٪ إلى ٥٨٪ خلال فترة التنبؤ.

- وتشير مؤشرات أداء النموذج المستخدم في هذا التنبؤ إلى دقة استثنائية. حيث يبلغ قيمة كلا من (RMSE) قيمة ٠,٠٥٧، و (MAPE) قيمة ٠,٨٣٪، و (R<sup>2</sup>) قيمة ٠,٩٨٥٥، إن التقارب النسبي في معدلات الخسائر المتوقعة يعكس استراتيجيات اكتتاب وإدارة مخاطر مشابهة بين الشركات، إن الدقة العالية للنموذج توفر للشركات رؤية موثوقة لتحسين استراتيجيات إدارة الخسائر والتخطيط الاستراتيجي.

### نتائج الدراسة

- أظهرت نتائج الدراسة كفاءة النموذج المقترح باستخدام الشبكة العصبية من نوع LSTM في التنبؤ بكل من معدل الاحتفاظ ومعدل العمولات وتكاليف الإنتاج ومعدل الخسارة لشركات التأمين محل الدراسة. حيث تم بناء النموذج باستخدام نفس البنية والمعلمات لكافة الشركات، مع تطبيق تطبيق Z-Score، واعتماد أسلوب التنبؤ التكراري مع إعادة التدريب في كل خطوة، ما يعكس قابلية النموذج للتعميم على بيانات متنوعة.
- أظهر نموذج الشبكات العصبية طويلة الذاكرة (LSTM) أداءً متميزًا في توقع القيم التاريخية لمعدل الاحتفاظ، حيث بلغت قيمة جذر متوسط الخطأ التربيعي (RMSE) حوالي ٠,٤٥٩٥، مما يعكس دقة عالية وتقاربًا واضحًا بين القيم الفعلية والمتوقعة. كما بلغ متوسط الخطأ النسبي المطلق (MAPE) نسبة ٠,٣٨٪، وهي نسبة منخفضة تشير إلى فعالية النموذج في تقليل نسب الخطأ في التوقع. بالإضافة إلى ذلك، سجل النموذج معامل التحديد (R<sup>2</sup>) بقيمة ٠,٩٨٨٣، مما يدل على قدرة النموذج على تفسير ٩٩,٨٣٪ من التباين في البيانات، ويؤكد كفاءته في تمثيل الأنماط التاريخية بدقة. كما لوحظ انخفاض طفيف في دقة التنبؤ المستقبلي لمعدل الاحتفاظ مقارنة بالأداء المتميز في توقع القيم التاريخية. تساعد هذه الدقة العالية لشركات التأمين تطوير خطط مخصصة لتعزيز معدلات الاحتفاظ.

د. سماح سيد بيومي خليل

- بالنسبة لتوقعات معدل الاحتفاظ المستقبلية باستخدام نموذج LSTM، أظهرت مؤشرات الأداء دقة عالية في توقع القيم المستقبلية. حيث بلغت قيمة جذر متوسط الخطأ التربيعي (RMSE) قيمة ٠,٦٢٧٢، مما يدل على أن التباين بين القيم المستقبلية والفعلية في البيانات التاريخية التي تم تدريب النموذج عليها كان صغيراً، مما يعكس دقة محتملة للتوقعات المستقبلية. كما أظهر متوسط الخطأ النسبي المطلق (MAPE) قيمة ٠,٩٢٪، مما يعكس دقة النموذج العالية في توقع القيم المستقبلية مقارنة بالقيم التاريخية التي تدرب عليها. إضافةً إلى ذلك، بلغ معامل التحديد  $R^2$  قيمة (0.9766)، مما يشير إلى أن النموذج يفسر حوالي ٩٧,٦٦٪ من التباين في البيانات، وبالتالي يحقق أداءً ممتازاً في توقع معدل الاحتفاظ في المستقبل. وعلى الرغم من ذلك، يظل الأداء في التنبؤ المستقبلي جيداً ولكنه أقل دقة بشكل طفيف من توقع القيم التاريخية، وتمكن هذه التوقعات الدقيقة شركات التأمين من التخطيط للموارد وتوقع الإيرادات المستقبلية بشكل أفضل.
- بالنسبة لتوقع القيم التاريخية لمعدل المصروفات العمومية والإدارية باستخدام نموذج LSTM، أظهرت مؤشرات الأداء دقة عالية في توقع القيم الفعلية. حيث بلغت قيمة جذر متوسط الخطأ التربيعي (RMSE) حوالي ٠,٢٣٣١، مما يشير إلى أن الفروقات بين القيم المتوقعة والقيم الفعلية كانت ضئيلة للغاية، مما يعكس دقة التوقعات. كما أظهر النموذج قدرة تفسيرية ممتازة، حيث سجل معامل التحديد ( $R^2$ ) قيمة مرتفعة بلغت ٠,٩٩٨٠، مما يؤكد أن النموذج يفسر غالبية التباين في البيانات بشكل دقيق. أما بالنسبة لمتوسط الخطأ النسبي المطلق (MAPE)، فقد بلغت قيمته حوالي ١,٥٦٪، مما يعكس أن الخطأ بين القيم المتوقعة والفعلية كان منخفضاً بنسبة ضئيلة، مما يعكس فعالية النموذج في توقع معدل المصروفات العمومية والإدارية. وبشكل عام، أظهر النموذج دقة عالية في توقع القيم التاريخية، ويتوقع الحفاظ على مستوى مماثل من الدقة في التنبؤات المستقبلية، وتساعد هذه الدقة في فهم هيكل التكاليف وإمكانية تحسين الكفاءة التشغيلية.
- أما بالنسبة لمؤشرات توقع معدل المصروفات العمومية والإدارية المستقبلية، فقد أظهرت مؤشرات أداء النموذج دقة عالية أيضاً. حيث بلغت قيمة جذر متوسط الخطأ التربيعي (RMSE) 0.2575، مما يشير إلى أن النموذج يتمتع بدقة جيدة في تقدير القيم المتوقعة. كما يعكس متوسط نسبة الخطأ المطلق (MAPE) الذي بلغ ١,٠٨٪ دقة مقبولة للتوقعات من حيث النسبة المئوية للخطأ المتوقع. بالإضافة إلى ذلك، فإن معامل التحديد ( $R^2$ ) الذي بلغ ٠,٩٧٤٥، يشير إلى أن النموذج يفسر جزءاً كبيراً من التباين في قيم معدل المصروفات العمومية والإدارية، مما يعكس فاعليته في توقع القيم المستقبلية. ولقد أظهر النموذج دقة عالية جداً في توقع القيم التاريخية، وهو ما ينعكس إيجاباً على دقة التنبؤات المستقبلية، وتساعد هذه الدقة في تقييم فعالية قنوات التوزيع وإدارة تكاليف العمليات.
- بالنسبة لتوقع القيم التاريخية لمعدل العمولات وتكاليف الإنتاج باستخدام نموذج LSTM، أظهرت مؤشرات الأداء دقة عالية في توقع القيم الفعلية. حيث بلغت قيمة جذر متوسط الخطأ التربيعي (RMSE) حوالي ٠,٢٣٥٢، مما يشير إلى أن الفروقات بين القيم المتوقعة والقيم الفعلية كانت ضئيلة للغاية، مما يعكس دقة التوقعات. كما أظهر النموذج قدرة تفسيرية ممتازة، حيث سجل معامل التحديد ( $R^2$ ) قيمة مرتفعة بلغت ٠,٩٩٨٣، مما يؤكد أن النموذج يفسر غالبية التباين في البيانات بشكل دقيق. أما بالنسبة لمتوسط الخطأ النسبي المطلق (MAPE)، فقد بلغت قيمته حوالي ٠,٧٢٪، مما يعكس أن الخطأ بين القيم المتوقعة والفعلية كان منخفضاً بنسبة ضئيلة، مما يعكس قدرة النموذج على تقديم توقعات دقيقة للغاية بالنسبة للمستقبل. يُعتبر أداء النموذج في توقع القيم المستقبلية لمعدل العمولات وتكاليف الإنتاج ممتازاً ويقارب مستوى الدقة العالية الذي أظهره في توقع القيم التاريخية، وتتيح هذه التوقعات الدقيقة لشركات التأمين التخطيط لسياسات التسعير وإدارة العلاقات مع الوسطاء بشكل فعال.
- بالنسبة للمؤشرات الخاصة بتوقع القيم المستقبلية لمعدل العمولات وتكاليف الإنتاج باستخدام نموذج LSTM، كانت كالتالي: حيث بلغ جذر متوسط الخطأ التربيعي (RMSE) قيمة ٠,١٣٧٥، مما يعكس دقة ممتازة للنموذج في تقدير القيم المستقبلية. كما أن متوسط نسبة الخطأ المطلقة (MAPE) البالغ ٠,٦٥٪ يدل على مستوى عالٍ جداً من الدقة في التوقعات كنسبة مئوية للخطأ المتوقع. بالإضافة إلى ذلك، فإن معامل التحديد ( $R^2$ ) البالغ ٠,٩٨١٩، يشير إلى أن النموذج يفسر جزءاً كبيراً جداً من التباين في بيانات معدل العمولات وتكاليف الإنتاج التاريخية والمنتبأ بها، مما يعكس فعالية النموذج في توقع معدل الخسائر. أظهر

د. سماح سيد بيومي خليل

- النموذج دقة جيدة في توقع القيم التاريخية، وتشير المؤشرات إلى دقة أعلى في التنبؤ بالقيم المستقبلية، وتساعد هذه الدقة في تقييم كفاءة عمليات الاكتتاب وإدارة المخاطر.
- بالنسبة لتوقع القيم التاريخية لمعدل الخسائر باستخدام نموذج LSTM، أظهرت مؤشرات الأداء دقة عالية في توقع القيم الفعلية. حيث بلغ جذر متوسط الخطأ التربيعي (RMSE) قيمة ٠,٥٣٧٧، مما يشير إلى أن الفروقات بين القيم المتوقعة والقيم الفعلية كانت ضمن حدود معقولة، مما يعكس دقة التوقعات. كما أظهر النموذج قدرة تفسيرية جيدة، حيث سجل معامل التحديد ( $R^2$ ) قيمة مرتفعة بلغت ٠,٩٩٧٨، مما يؤكد أن النموذج يفسر غالبية التباين في البيانات بدقة. أما بالنسبة لمعدل الخطأ النسبي المطلق (MAPE)، فقد بلغت قيمته حوالي ٠,٧١٪، مما يعكس أن الخطأ بين القيم المتوقعة والفعلية كان منخفضاً، مما يعكس فعالية النموذج في توقع معدل الخسائر.
- بالنسبة لمؤشرات الأداء الخاصة بتوقع القيم المستقبلية لمعدل الخسائر باستخدام نموذج LSTM، بلغ جذر متوسط الخطأ التربيعي (RMSE) قيمة ٠,٠٥٧، وهو رقم صغير جداً يدل على دقة عالية جداً في تقدير القيم. كما أن متوسط نسبة الخطأ المطلقة (MAPE) البالغ ٠,٨٣٪ يشير إلى دقة مثالية للنموذج في توقع القيم المستقبلية. هذه القيمة تعكس أن النموذج يحقق تقريباً توقعات دقيقة دون أي خطأ نسبي يُذكر. بالإضافة إلى ذلك، فإن معامل التحديد ( $R^2$ ) البالغ ٠,٩٨٥٥ يشير إلى أن النموذج يفسر جزءاً كبيراً جداً من التباين في بيانات معدل الخسائر التاريخية والمتنبأ بها، مما يعكس فعالية كبيرة في توقع القيم المستقبلية بشكل دقيق. يُظهر النموذج دقة استثنائية في توقع معدل الخسارة المستقبلي، تفوق بشكل ملحوظ مستوى الدقة الجيد الذي أظهره في توقع القيم التاريخية، وتوفر هذه التوقعات الدقيقة رؤى قيمة لشركات التأمين في تحديد المخصصات المالية وإعادة تقييم استراتيجيات الاكتتاب وإدارة المطالبات.

التوصيات:

- بناءً على نتائج الدراسة التي تم عرضها والتي تتضمن مؤشرات الأداء للنماذج التنبؤية لمعدل الاحتفاظ، معدل المصروفات العمومية والإدارية، العمولات وتكاليف الإنتاج، ومعدل الخسائر، يمكن تقديم بعض التوصيات التالية:
- بالنظر إلى دقة النماذج المستخدمة، خصوصاً نموذج LSTM في التنبؤ بالقيم المستقبلية، يمكن الاستفادة من هذه النماذج كأداة أساسية في عمليات التنبؤ المستقبلية وتحليل الأداء لشركات التأمين بوجه عام.
- يظهر النموذج قدرة ممتازة في التنبؤ بالقيم المستقبلية، وهو ما يمكن استخدامه لتحسين استراتيجيات التسعير وإدارة المخاطر في شركات التأمين. من خلال الاعتماد على التنبؤات الدقيقة للمستقبل، يمكن للشركات اتخاذ قرارات أفضل بشأن تسعير المنتجات التأمينية وتحسين خطط التعويضات.
- تؤكد نتائج التنبؤات المستقبلية دقة تقديرات النموذج، مما يتيح لشركات التأمين إعادة تقييم سياسات إعادة التأمين الخاصة بها. يمكن اتخاذ قرارات أكثر استراتيجية بشأن حجم التغطية وإعادة التأمين بناءً على التنبؤات الدقيقة لمعدلات الخسارة والاحتفاظ.
- دمج النموذج في أنظمة صنع القرار: يجب دمج نتائج وتوقعات نموذج LSTM في أنظمة صنع القرار الاستراتيجي والتخطيط المالي والتسويقي في الشركات. يمكن أن يساعد ذلك في اتخاذ قرارات أكثر استنارة بناءً على رؤى مستقبلية موثوقة.
- ما أن النماذج أظهرت قدرة على تقليل الأخطاء في البيانات التاريخية، فإن استخدامها في العمليات التشغيلية اليومية يمكن أن يساهم في تحسين كفاءة الإدارة والتشغيل، وبالتالي تقليل التكاليف التشغيلية وتحسين أداء الشركات التأمينية.
- قياس الأداء الفعلي ومقارنته بالتنبؤات: مع مرور الوقت، يجب على الشركات قياس أدائها الفعلي ومقارنته بالتنبؤات التي قدمها النموذج. سيساعد ذلك في تقييم دقة النموذج بشكل مستمر وتحديد أي تحسينات ضرورية.
- تحليل أسباب التباينات في نتائج المعدلات بين الشركات المختلفة وإجراء تحليل معمق لفهم الأسباب الكامنة وراء هذه الاختلافات وتقييم كفاءة استراتيجياتها التشغيلية والتسويقية مقارنة بالمنافسين.
- التحديث والصيانة الدورية للنموذج: يجب التأكد من تحديث النموذج بشكل دوري ببيانات جديدة وإجراء الصيانة اللازمة لضمان استمرار دقته وفعاليته بمرور الوقت وتكيفه مع أي تغييرات في ديناميكيات السوق.

## المراجع

### المراجع العربية

- ١- البلقيني، محمد توفيق إسماعيل. (٢٠٠١)، "استخدام نظرية الفئات الفازية في تقدير حجم المطالبات في التأمين التكميلي على السيارات"، المجلة المصرية للدراسات التجارية، كلية التجارة جامعة المنصورة، مج ٢٥، ع ٢، ١ - ٢٥، مسترجع من <https://search.mandumah.com/Record/60179>
- ٢- حافظ، محمد محمد السيد، (٢٠١٨)، "التحليل الكمي للمعدلات الفنية في شركات التأمين في السوق المصري بالتطبيق على فرع التأمين الطبي". مجلة الدراسات المالية والتجارية - كلية التجارة جامعة بني سويف، ٣٤، ١٧٢ - ٢١٨.
- ٣- حسين، محمد وحيد عبدالباري. (١٩٩٤)، "نموذج مقترح لحساب مخصص التقلبات في معدلات الخسارة في التأمينات العامة: بالتطبيق على تأمين السيارات التكميلي"، المجلة المصرية للدراسات التجارية كلية التجارة جامعة المنصورة، مج ١٨، ع ٤، ٥٣٥ - ٥٧٢. مسترجع من <http://search.mandumah.com/Record/60869>
- ٤- الحصري، محمد حسن سيد، وإبراهيم، محمد غازي صابر، (٢٠١٧)، "استخدام النماذج الخطية المعممة في تسعير تأمين السيارات التكميلي"، مجلة البحوث الإدارية أكاديمية السادات للعلوم الإدارية، مج ٣٥، ٢٤، ٥٣ - ١٠٥.
- ٥- صلاح الدين جمعة حسن، زهرة، عبد المنعم جودة خُزين، محمد، & محمد سعد حسين، أسماء. (٢٠٢٣)، "تقدير عدد مطالبات تأمين السيارات التكميلي باستخدام النماذج التجميعية المعممة Generalized Additive Models وأساليب التسوية LASSO Regularization بالتطبيق على إحدى شركات التأمين العاملة في سوق التأمين المصري". المجلة المصرية للدراسات التجارية كلية التجارة جامعة المنصورة، مج ٤٧، ٤٤، ١٠٦٤ - ١٠٨٧.
- ٦- طعيمة، علاء، (٢٠٢٢). كتاب التعلم العميق: من الاساسيات حتى بناء شبكة عصبية عميقة بلغة البايثون.
- ٧- عبد الحميد، هبة سلطان محمد. (٢٠١٤)، "استخدام التوزيعات الاحتمالية في تحديد حد الاحتفاظ الأمثل لشركات التأمين: دراسة تطبيقية". مجلة البحوث المالية والتجارية كلية التجارة جامعة بور سعيد، ٤٤، ٣٦٣ - ٣٨٩.
- ٨- علي، إيمان عماد عبد العليم. (٢٠١٦). تأمين السيارات التكميلي المشاكل والتحديات: دراسة تحليلية. مجلة البحوث التجارية، مج ٣٨، ٢٤، ٤٣ - ٧٧. مسترجع من <http://search.mandumah.com/Record/771704>
- ٩- محمد مسعد المعداوى محمد (٢٠١٠)، استخدام التحليل متعدد المتغيرات في تسعير تأمين السيارات التكميلي، رسالة ماجستير، كلية التجارة - جامعة المنصورة.
- ١٠- المعداوي، جيهان مسعد، وعبد الله، مصطفى يوسف، (٢٠١٧)، "استخدام الشبكات العصبية في التنبؤ بمطالبات تأمين السيارات التكميلي"، المجلة المصرية للدراسات التجارية كلية التجارة جامعة المنصورة، مج ٤١، ٤٤، ١٢٩ - ١٥٢.
- ١١- نور الحميدي، حساني حسين، (٢٠١٥)، "استخدام معدل الاحتفاظ ونسبة الطاقة الاستيعابية المستغلة في تحليل أخطار المحفظة التأمينية"، مجلة الاقتصاد والمالية، كلية العلوم الاقتصادية والتجارية وعلوم التيسير، جامعة حسبية بن بو علي، مج ١، ١٤، ١١٩ - ١٣١.
- ١٢- الهاشمي، "ليث حليم مالك"، (٢٠٢٢)، 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، ٤٦٩ - ٥٠٤.

المراجع الأجنبية

- 1- Abdulkadir, U.I., Fernando, A. (2024), A deep learning model for insurance claims predictions, *Journal on Artificial Intelligence*, 6(1), 71–83.
- 2- De Mauro, A. (2021). *Data analytics made easy* (1st ed.). Packt Publishing Ltd.
- 3- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
- 4- Montavon, Grégoire & Samek, Wojciech & Müller, Klaus-Robert. (2018). *Methods for Interpreting and Understanding Deep Neural Networks*. *Digital Signal Processing*. 73. 1-15.
- 5- Saputro, A. R., & Murfi, H. (2019), Analysis of deep neural networks for automobile insurance claim prediction. *Journal of Big Data*, 6(1), 1-15.
- 6- Sepp Hochreiter and Jürgen Schmidhuber. 1997. Long Short-Term Memory. *Neural Comput.* 9, 8 (November 15, 1997), 1735–1780 .
- 7- Shungube, P., Bokaba, T., & Others. (2024). A deep learning approach for healthcare insurance fraud detection. *Journal of Artificial Intelligence in Finance*, 12(3), 45-60. <https://doi.org/10.21203/rs.3.rs-5453482/v1>
- 8- Somaratne, Lahiru H, (202٢), Ultimate loss reserve forecasting using bidirectional LSTMs. *CAS E-Forum*, 45(2), 123-145. Retrieved from <https://eforum.casact.org/article/37953-ultimate-loss-reserve-forecasting-using-bidirectional-lstms>
- 9- Sze, V., Chen, Y., Yang, T., & Emer, J.S. (2017). Efficient Processing of Deep Neural Networks: A Tutorial and Survey. *Proceedings of the IEEE*, 105, 2295-2329.
- 10- Tehraniyazdi, N., Vaezi, R., Setayeshi, S., & Raesi Vanani, I. (2024). Forecasting insurance company commitments with long short-term memory models, *Financial Research Journal*, 26(4), 854-879.
- 11- Xia, H., Zhou, Y., & Zhang, Z. (2022). Auto insurance fraud identification based on a CNN-LSTM fusion deep learning model. *International Journal of Ad Hoc and Ubiquitous Computing*, 39(1-2), 37–45.

الملحق (أ)

الأكواد المستخدمة في تحديد أفضل تكوين للشبكة

الأكواد المستخدمة في برنامج (MATLAB) بعد تحديد أفضل شبكة

clc; clear; close all;

rng(300); % تعيين البذرة العشوائية لضمان ثبات النتائج %

% Excel تحميل البيانات من ملف %

```
dataFile = 'C:\deep\data.xlsx'; % المسار إلى الملف
dataRetention = readmatrix(dataFile); % قراءة البيانات من الملف
% تقسيم البيانات إلى تدريب واختبار
trainRatio = 0.8;
numTrain = round(trainRatio * size(dataRetention, 1));
trainDataRetention = dataRetention(1:numTrain, :);
testDataRetention = dataRetention(numTrain+1:end, :);
%% Z-Score Normalization
muRetention = mean(trainDataRetention(:));
sigmaRetention = std(trainDataRetention(:));
trainDataRetentionNorm = (trainDataRetention - muRetention) / sigmaRetention;
testDataRetentionNorm = (testDataRetention - muRetention) / sigmaRetention;
%% تجهيز البيانات للشبكة العصبية
XTrain = cellfun(@(x) x', num2cell(trainDataRetentionNorm, 2), 'UniformOutput',
false);
YTrain = cellfun(@(x) x', num2cell(trainDataRetentionNorm, 2), 'UniformOutput',
false);
XTest = cellfun(@(x) x', num2cell(testDataRetentionNorm, 2), 'UniformOutput',
false);
YTest = cellfun(@(x) x', num2cell(testDataRetentionNorm, 2), 'UniformOutput',
false);
%% بناء النموذج LSTM
layers = [
    sequenceInputLayer(size(dataRetention, 2))
    bilstmLayer(70, 'OutputMode', 'sequence')
    dropoutLayer(0.05)
    bilstmLayer(70, 'OutputMode', 'sequence')
    dropoutLayer(0.05)
```

```
fullyConnectedLayer(size(dataRetention, 2))
regressionLayer
];
%% إعدادات التدريب
options = trainingOptions('adam', ...
'MaxEpochs', 400, ...
'MiniBatchSize', 1, ...
'InitialLearnRate', 0.2, ...
'LearnRateSchedule', 'piecewise', ...
'LearnRateDropFactor', 0.5, ...
'LearnRateDropPeriod', 50, ...
'GradientThreshold', 1, ...
'ValidationFrequency', 20, ...
'Verbose', 0, ...
'ValidationPatience', 20);
%% تدريب النموذج
net = trainNetwork(XTrain, YTrain, layers, options);
% التنبؤ باستخدام مجموعة الاختبار
YPredTest = predict(net, XTest);
YPredTest = cell2mat(YPredTest);
YTestOriginal = cell2mat(YTest);
% Z-Score Normalization عكس
YPredTestOriginal = (YPredTest * sigmaRetention) + muRetention;
YTestOriginal = (YTestOriginal * sigmaRetention) + muRetention;
% مؤشرات الأداء
rmseTest = sqrt(mean((YTestOriginal - YPredTestOriginal).^2));
SStotTest = sum((YTestOriginal - mean(YTestOriginal)).^2);
```

---

---

```
SSresTest = sum((YTestOriginal - YPredTestOriginal).^2);
R2Test = 1 - (SSresTest / SStotTest);
MAPETest = mean(abs((YTestOriginal - YPredTestOriginal) ./ YTestOriginal)) *
100;
fprintf('Test RMSE: %.4f\n', rmseTest);
fprintf('Test R2: %.4f\n', R2Test);
fprintf('Test MAPE: %.2f%%\n', MAPETest);
%% إعادة التدريب على جميع البيانات
XAll = [XTrain; XTest];
YAll = [YTrain; YTest];
netAll = trainNetwork(XAll, YAll, layers, options);
YPredAll = predict(netAll, XAll);
YPredAll = cell2mat(YPredAll);
YAllOriginal = cell2mat(YAll);
% Z-Score Normalization عكس
YPredAllOriginal = (YPredAll * sigmaRetention) + muRetention;
YAllOriginal = (YAllOriginal * sigmaRetention) + muRetention;
% مؤشرات الأداء
rmseAll = sqrt(mean((YAllOriginal - YPredAllOriginal).^2));
SStotAll = sum((YAllOriginal - mean(YAllOriginal)).^2);
SSresAll = sum((YAllOriginal - YPredAllOriginal).^2);
R2All = 1 - (SSresAll / SStotAll);
MAPEAll = mean(abs((YAllOriginal - YPredAllOriginal) ./ YAllOriginal)) * 100;
fprintf('All Data RMSE: %.4f\n', rmseAll);
fprintf('All Data R2: %.4f\n', R2All);
fprintf('All Data MAPE: %.2f%%\n', MAPEAll);
```

```
عرض القيم %
fprintf('\n:القيم الحقيقية والمنتبأ بها لجميع البيانات');
disp('القيم الحقيقية    القيم المنتبأ بها');
disp([YAllOriginal, YPredAllOriginal]);
%% === الإعدادات الأساسية ===
rng(300); % لتكرار النتائج
futureYears = 3;
numCompanies = size(dataRetention, 1);
originalLength = size(dataRetention, 2);
windowSize = 21;
noiseLevel = 0.001;
futurePredictions = zeros(numCompanies, futureYears);
%% === ضوضاء + إعادة تدريب + Sliding Window التنبؤ التكراري مع ===
for company = 1:numCompanies
    % تطبيع بيانات الشركة %
    companyData = (dataRetention(company, :) - muRetention) / sigmaRetention;
    for year = 1:futureYears
        % إنشاء تسلسل بإضافة الضوضاء %
        noisyInput = companyData + noiseLevel * randn(size(companyData));
        inputSeq = noisyInput(end-windowSize+1:end);
        predValue = predict(netAll, {inputSeq});
        predValue = predValue{1}(end);
        % عكس التطبيع %
        predValueOriginal = predValue * sigmaRetention + muRetention;
        futurePredictions(company, year) = predValueOriginal;
    % تحديث البيانات %
    companyData = [companyData, predValue];
end
```

```
if length(companyData) > originalLength
    companyData = companyData(end-originalLength+1:end);
end
%% === إعادة التدريب باستخدام Sliding Window لجميع الشركات ===
XTrain = {};
YTrain = {};
for c = 1:numCompanies
    if c == company
        fullSeq = companyData;
    else
        fullSeq = (dataRetention(c, :) - muRetention) / sigmaRetention;
    end
    % تطبيق sliding window
    for i = 1:(length(fullSeq) - windowSize + 1)
        window = fullSeq(i:i+windowSize-1)';
        XTrain{end+1} = window;
        YTrain{end+1} = window; % هنا الهدف هو نفسه الإدخال لأننا نتنبأ بالقيمة التالية
    end
end
end
% إعادة تدريب الشبكة
netAll = trainNetwork(XTrain, YTrain, layers, options);
end
end
%% === تقييم النموذج ===
disp('!تنبؤات المستقبل لجميع الشركات');
disp(futurePredictions);
actualFuture = dataRetention(:, end-2:end);
```

---

---

```
rmseFuture = sqrt(mean((actualFuture(:) - futurePredictions(:)).^2));
mapeFuture = mean(abs((actualFuture(:) - futurePredictions(:)) ./ actualFuture(:))) *
100;
SS_res = sum((actualFuture(:) - futurePredictions(:)).^2);
SS_tot = sum((actualFuture(:) - mean(actualFuture(:))).^2);
r2Future = 1 - (SS_res / SS_tot);
fprintf('\n  مؤشرات الأداء للتنبؤات المستقبلية\n');
fprintf('RMSE: %.4f\n', rmseFuture);
fprintf('MAPE: %.2f%%\n', mapeFuture);
fprintf('R²: %.4f\n', r2Future);
```

---

---

## Predicting Technical Performance Indicators in Auto Supplementary Insurance Using Deep Neural Networks (LSTM): An Applied Study

### Abstract:

This study aimed to develop a predictive model using Long Short-Term Memory (LSTM) neural networks to forecast key technical indicators—retention ratio, commission and acquisition expense ratio, general and administrative expense ratio, and loss ratio—for the supplementary motor insurance branch of eight property and liability insurance companies operating in the Egyptian insurance sector. The LSTM model was built with the same architecture and parameters for all companies. Based on historical data (time series), the model demonstrated high accuracy in simulating and predicting future values over a three-year horizon. Performance metrics showed low RMSE values (e.g., 0.6272 for retention ratio, 0.2575 for general and administrative expense ratio, 0.1375 for commission and acquisition expenses, and 0.0057 for loss ratio), low MAPE values (e.g., 0.92% for retention ratio, 1.08% for general and administrative expenses, 0.65% for commission and acquisition expenses, and 0.83% for loss ratio), and high R<sup>2</sup> values (e.g., 0.9766 for retention ratio, 0.9745 for general and administrative expenses, 0.9819 for commission and acquisition expenses, and 0.9855 for loss ratio). The study recommends adopting LSTM models to support strategic decision-making and improve the estimation of future costs in the Egyptian insurance sector.

**Keywords:** Comprehensive Motor Insurance, Long Short-Term Memory (LSTM) Deep Networks, Technical Ratios