



Forecasting Insurance Company Commitments with Long Short-Term Memory Models

Negar Tehraniyazdi 

Ph.D Candidate, Department of Public Administration, Faculty of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran. E-mail: ntehraniy@atu.ac.ir

Reza Vaezi 

Prof., Department of Public Administration, Faculty of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran. E-mail: vaezi@atu.ac.ir

Saeed Setayeshi * 

*Corresponding Author, Prof., Department of Physics and Energy Engineering Nuclear Engineering, Faculty of Physics and Energy Engineering, Amirkabir University of Technology, Tehran, Iran. E-mail: setayesh@aut.ac.ir

Iman Raeesi Vanani 

Associate Prof., Department Industrial Management, Faculty of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran. E-mail: imanraeesi@atu.ac.ir

Abstract

Objective

This study aims to present a novel model for predicting the future commitments of insurance companies that can adequately address the potential challenges of traditional methods. Traditionally, insurance companies use the Chain Ladder approach as a statistical tool to forecast the trend of claims development. This statistical method is favored by regulatory authorities in various countries due to its simplicity in assumptions and clear interpretation. However, certain assumptions, such as the stability of data development and linear relationships between variables, can affect the efficiency of this model when faced with

Citation: Tehraniyazdi, Negar; Vaezi, Reza; Setayeshi, Saeed & Raeesi Vanani, Iman (2024). Forecasting Insurance Company Commitments with Long Short-Term Memory Models. *Financial Research Journal*, 26(4), 876-901. <https://doi.org/10.22059/FRJ.2024.367421.1007532> (in Persian)



internal policies or external factors like the COVID-19 pandemic. Forecasting future commitments close to reality is closely related to the financial stability of insurance companies. The amount that insurance companies allocate to meet their future obligations is identified as reserves. Calculating reserves that are less than the required amounts can pose challenges for insurance companies in fulfilling their commitments while calculating more than necessary amounts can negatively impact the financial statements of insurance companies.

Methods

In this study, a dynamic model based on machine learning algorithms is proposed. The model's output, which combines the number and timing of bodily injury accidents, plays a crucial role in calculating reserves for non-life insurance products. This model is specifically trained to predict the frequency of accidents in Vehicle Third-Party Liability Insurance. It can identify hidden patterns and non-linear, complex relationships within claims data. A Long Short-Term Memory (LSTM) neural network algorithm is employed, recognized for its strong predictive capability in time series data. The model is trained using historical data from Karafarin Insurance Company covering the years 2017 to 2021.

Results

The performance of the model is highly related to the hyperparameters chosen for the model. Two of the most common approaches for tuning the hyperparameters are tested in this study. These Two models are grid and random search. The Root Mean Square Error (RMSE) is used as a performance metric, and it indicates that the grid search has a lower RMSE than the random search for the training data with a slight difference (16.33 versus 17.4). However, the results for the test data in the grid search have a sign of overfitting.

Conclusion

This study recommends using random search for tuning the hyperparameters of the model to predict the frequency of daily incidents. The evaluation of the two approaches for tuning hyperparameters indicates that random search is more suitable for working with unfamiliar data and managing overfitting situations. Overfitting occurs when the model becomes overly influenced by the training data, learning not only the actual patterns but also the noise and minor details of the data. This issue can negatively impact the model's generalization ability.

Keywords: Insurance commitments, Machine learning, Long Short-Term Memory (LSTM), Hyperparameter tuning, Overfitting

پیش‌بینی تعهدات آتی شرکت‌های بیمه با استفاده از مدل حافظه بلندمدت – کوتاه‌مدت

نگار طهرانی‌بزدی

دانشجوی دکتری، گروه مدیریت دولتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران. رایانامه: ntehraniy@atu.ac.ir

رضا واعظی

استاد، گروه مدیریت دولتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران. رایانامه: vaezi@atu.ac.ir

*سعید ستایشی

* نویسنده مسئول، استاد، گروه آموزشی مهندسی هسته‌ای، دانشکده فیزیک و مهندسی انرژی، دانشگاه صنعتی امیرکبیر، تهران، ایران.
رایانامه: setayesh@aut.ac.ir

ایمان رئیسی وانانی

دانشیار، گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران. رایانامه: imanraeesi@atu.ac.ir

چکیده

هدف: این پژوهش به دنبال ارائه مدلی برای محاسبه تعهدات آتی شرکت‌های بیمه است تا به چالش‌های بالقوه موجود در روش سنتی پاسخ مناسبی دهد. به صورت سنتی، شرکت‌های بیمه از روش زنجیره نردنی، به عنوان نوعی ابزار آماری، برای پیش‌بینی روند توسعه خسارت‌ها استفاده می‌کنند. این روش آماری به دلیل سادگی فرضیه‌ها و نفسیر روش، تأیید نهادهای نظارتی در کشورهای مختلف را نیز به همراه دارد. با این حال، وجود فرضیه‌هایی نظیر ایستایی در ساختار توسعه داده‌ها و ارتباط خطی بین متغیرها، ممکن است کارایی مدل را در مواجهه با تغییرات ناشی از عوامل داخل و خارج از سازمان، مانند اعمال سیاستهای داخلی یا عوامل خارجی مانند همه‌گیری کووید-۱۹ متاثر سازد. محاسبه نزدیک به واقعیت تعهدات آتی شرکت‌های بیمه با توانگری مالی آن‌ها ارتباط تنگاتنگی دارد. مبلغی که شرکت‌های بیمه برای پاسخ به تعهدات آتی خود تخصیص می‌دهند، به عنوان ذخیره شناسایی می‌شود. محاسبه ذخایر کمتر از تعهدات آتی، شرکت بیمه را در ایفای تعهداتی دچار مشکل می‌کند و از سویی دیگر، محاسبه بیش از مبلغ مورد نیاز، صورت‌های مالی شرکت‌های بیمه را تحت تأثیر قرار می‌دهد.

روش: مدل ارائه شده در این پژوهش با استفاده از یادگیری ماشین و هوش مصنوعی، تعداد حوادث روزانه با خسارت‌های جانی را در بخش بیمه شخص ثالث پیش‌بینی می‌کند. خروجی این مدل، یعنی ترکیب تعداد و زمان وقوع حوادث، در محاسبه تعهدات آتی و ذخیره خسارت در این بخش بیمه‌ای نقش کلیدی دارد. این مدل با کمک داده‌های تاریخی خسارت بیمه‌گذاران شرکت بیمه کارآفرین، در بخش بیمه شخص ثالث آموزش دیده است. این مدل قادر است لایه‌های پنهان و ارتباطات غیرخطی و پیچیده بین داده‌های خسارتی را شناسایی

استناد: طهرانی‌بزدی، نگار؛ واعظی، رضا؛ ستایشی، سعید و رئیسی وانانی، ایمان (۱۴۰۳). پیش‌بینی تعهدات آتی شرکت‌های بیمه با استفاده از مدل حافظه بلندمدت – کوتاه‌مدت. *تحقیقات مالی*, ۴(۲۶)، ۸۷۶-۹۰۱.

تاریخ دریافت: ۱۴۰۲/۰۸/۱۰

تحقیقات مالی، ۱۴۰۳، دوره ۲۶، شماره ۴، صص. ۹۰۱-۸۷۶

تاریخ ویرایش: ۱۴۰۳/۰۱/۲۵

ناشر: دانشکده مدیریت دانشگاه تهران

تاریخ پذیرش: ۱۴۰۳/۰۲/۱۷

نوع مقاله: علمی پژوهشی

تاریخ انتشار: ۱۴۰۳/۱۰/۱۰

© نویسنده‌گان

doi: <https://doi.org/10.22059/FRJ.2024.367421.1007532>

کند. در این پژوهش، از الگوریتم شبکه عصبی با حافظه بلندمدت - کوتاه‌مدت که در سری‌های زمانی توانایی پیش‌بینی بیشتری دارد، استفاده شده است. داده‌های تاریخی مربوط به خسارت‌های جری بیمه‌گذاران، در بازه زمانی فروردین ۱۳۹۶ تا شهریور ۱۴۰۰ بوده است.

یافته‌ها: کارایی مدل با بهینه‌سازی ابرپارامترها ارتباط نزدیک دارد. برای بهینه‌سازی مدل دو رویکرد، یعنی جستجوی شبکه‌ای و تصادفی برای شناسایی ابرپارامترها با یکدیگر مقایسه شده‌اند. میانگین مربعات خطأ به عنوان شاخص سنجش عملکرد در نظر گرفته شده است. این شاخص برای داده‌های آموزش، در هر دو مدل با فاصله کمی از یکدیگر ($16/33$ در مقابل $17/4$) بترتیب جستجوی شبکه‌ای را نشان می‌دهد؛ اما در این روش، نتیجه داده‌های آزمون از داده‌های آموزش بهتر بود ($15/22$ در برابر $16/33$) که این امر می‌تواند نشانه‌ای از وقوع پیش‌پردازش باشد.

نتیجه‌گیری: این مقاله برای طراحی مدل پیش‌بینی تعداد روزانه حوادث با خسارت‌های جانی، استفاده از روش جستجوی تصادفی را برای تنظیم ابرپارامترهای مدل طراحی شده بر مبنای شبکه عصبی حافظه بلندمدت - کوتاه‌مدت پیشنهاد می‌کند؛ زیرا مدل طراحی شده بر این مبنای، بر مشکل پیش‌پردازش غلبه می‌کند و می‌تواند در کار با داده‌های ناآشنا عملکرد مناسبی داشته باشد. پیش‌پردازش زمانی رخ می‌دهد که مدل بیش از حد از داده‌های آموزشی تأثیر بگیرد و نه تنها الگوهای واقعی را یاد بگیرد، بلکه نویزها و جزئیات جزئی داده‌ها را نیز یاد بگیرد. این ممکن است باعث کاهش جامع‌پذیری مدل شود.

کلیدواژه‌ها: الگوریتم حافظه بلندمدت - کوتاه‌مدت، تنظیم ابرپارامترها، جستجوی تصادفی، جستجوی شبکه‌ای، ذخیره خسارت.

مقدمه

مطالعه و کاربرد هوش مصنوعی و یادگیری ماشین در بخش‌های مختلف مالی، بنگاه‌های خصوصی و حتی دولتی به صورت روزافزونی رو به گسترش است. دولت و بخش خصوصی به صورت روزافزونی از هوش مصنوعی در حوزه‌های متفاوت بهره می‌برند. مقوله‌هایی که برای برنامه‌ریزی موفق مالی، پیش از وقوع حادث به پیش‌بینی نیاز دارند، از جمله حوزه‌هایی هستند که با ورود هوش مصنوعی توانسته‌اند، موقوفیت‌های شایان توجهی را به دست آورند. صنعت بیمه نیز در این بین بهره نبوده و پژوهش‌های متعددی در این زمینه انجام شده است. پیش‌بینی دقیق و تصویر کردن آینده، در موقوفیت شرکت‌های بیمه نقش کلیدی دارد. محاسبه حق بیمه و تعهدات آتی برای یک شرکت بیمه، از جمله مهم‌ترین محاسباتی است که شرکت‌های بیمه به صورت مستمر انجام می‌دهند. در هر دو موضوع فوق، پیش‌بینی نزدیک به واقعیت و توانایی در تصویر کردن آینده، عنصر مشترک در محاسبات است. در این مقاله به دنبال طراحی مدلی جدیدی برای پیش‌بینی تعداد حوادث آتی با استفاده از الگوریتم‌های هوش مصنوعی هستیم. شرکت‌های بیمه برای پوشش تعهداتی آتی خود، موظف به تخصیص منبع مالی هستند. مبلغی که شرکت‌های بیمه برای پاسخ به تعهدات آتی پیش‌بینی می‌کنند، ذخیره خسارت^۱ نام دارد (پوفیناس، گوگاس، پاپادیمیترو و زاگانیدیس^۲، ۲۰۲۳). این مبلغ برای پوشش هزینه‌های چند دسته از بیمه‌نامه‌ها تعریف شده است. دسته ابتدایی که هدف این پژوهش است، خسارت‌هایی هستند که برای بیمه‌گذاران اتفاق افتاده‌اند؛ اما شرکت بیمه از وقوع آن‌ها اطلاعی ندارد. این دسته از خسارت‌ها تحت عنوان خسارت‌های واقع شده ولی گزارش نشده^۳ نام‌گذاری شده است (پوفیناس و همکاران، ۱۹۸۴). دسته دیگر، خسارت‌هایی هستند که شرکت بیمه از وقوع آن‌ها باخبر است؛ اما بهدلایلی از قبیل تأخیر در بررسی و ارزیابی مبلغ خسارت یا انتظار برای حکم دادگاه، مبلغ نهایی خسارت به اطلاع شرکت بیمه نرسیده است. این بخش از ذخیره خسارت عموق، به عنوان خسارت‌های گزارش شده، اما تسویه نشده^۴ نام‌گذاری شده است (هالیول^۵، ۲۰۲۰).

به صورت سنتی، شرکت‌های بیمه برای پیش‌بینی چگونگی توسعه خسارت‌ها، از روش نرdbani^۶ استفاده می‌کنند. روش نرdbani، به دلیل سادگی در فرضیه‌ها و تفسیر روش، مورد تأیید نهادهای نظارتی شرکت‌های بیمه در کشورهای مختلف است و به همین دلیل با وجود ضعف‌هایی که دارد، همچنان به صورت گسترده استفاده می‌شود (تیلور و مک‌گوایر^۷، ۲۰۱۶). از جمله فرضیه‌های مهم این روش، ثبات در ساختار پرتفوی شرکت‌های بیمه و روند توسعه خسارت‌هاست. فرضی که امروزه با توجه به تغییر سیاست‌های درون‌سازمانی یا عوامل برون‌سازمانی به چالش کشیده شده است. از سویی دیگر، در روش نرdbani، ارتباط بین متغیرها به صورت خطی فرض شده است که نمی‌تواند به درستی بیانگر واقعیت باشد (بالونا و ریچمن^۸، ۲۰۲۰).

1. Loss Reserve

2. Poufinas, Gogas, Papadimitriou & Zaganidis

3. Incurred But Not Reported (IBNR)

4. Reported But Not Settled (RBNS)

5. Halliwell

6. Chain-Ladder

7. Taylor & McGuire

8. Balona & Richman

پیش‌بینی تواتر حوادث و شدت خسارت‌های ناشی از وقوع حوادث، دو متغیر اصلی برای محاسبه ذخایر هستند. باید توجه کرد که به جز این دو، متغیر با اهمیت دیگری نیز وجود دارد و آن زمان وقوع حوادث است. پیش‌بینی تواتر سوانح در بازه‌های زمانی متعدد، می‌تواند به مدیریت بهینه مالی و گردش نقدینگی شرکت‌های بیمه کمک شایان توجهی کند. این پژوهش بر ساخت مدل مبتنی بر هوش مصنوعی برای پیش‌بینی تعداد روزانه حوادث مبتنی است. رشتۀ بیمه‌ای مورد بررسی، بیمه شخص ثالث و اطلاعات نیز، متعلق به شرکت بیمه کارآفرین در بازه زمانی ۱۳۹۶ تا ۱۴۰۰ است. در بین الگوریتم‌های هوش مصنوعی با توجه به ساختار داده‌ها، از الگوی حافظه بلندمدت - کوتاه‌مدت استفاده شده است. به منظور تنظیم ابرپارامترها برای معماری مدل پیش‌بینی روزانه خسارت‌ها بر مبنای الگوریتم حافظه بلندمدت - کوتاه‌مدت، از دو روش رایج جستجوی شبکه‌ای و تصادفی برای تنظیم ابرپارامترها استفاده شده است تا با توجه به داده‌های مورد استفاده، مناسب‌ترین ابرپارامترها برای طراحی مدل پیش‌بینی انتخاب شوند.

پیشنهاد پژوهش

ذخیره خسارت

شرکت‌های بیمه بخشنی از اعتبارات مالی خود را برای پوشش خسارت‌های آتی که هنوز گزارش نشده‌اند یا خسارت‌هایی که گزارش شده‌اند، اما هنوز به طور کامل ارزیابی، پردازش یا پرداخت نشده‌اند، اختصاص می‌دهند. این کار با هدف تعریف منابع کافی برای پرداخت تعهداتی شرکت‌های بیمه انجام می‌شود. تخصیص منبع مالی برای پرداخت تعهداتی آینده شرکت بیمه، اقدامی استراتژیک و حیاتی از طرف شرکت‌های بیمه قلمداد می‌شود. این منبع به عنوان ذخیره خسارت شناخته می‌شود.

تعیین ذخیره برای شرکت‌های بیمه، چند هدف کلان را دنبال می‌کند. پایداری مالی از اهم اهداف است. بیمه‌گران اطمینان حاصل می‌کنند که در آینده، توانایی پرداخت خسارت به بیمه‌گذاران را دارند. تعیین ذخیره مناسب و منطبق با واقعیت با انحراف کم، پاسخ به الزامی است که از سوی ناظران فعالیت بیمه‌گران^۱ اعمال شده است. بیمه‌گران در کشورهای مختلف، تحت نظارت نهاد قانون‌گذار و کنترل کننده فعالیت می‌کنند و باید بتوانند الزامات مالی و قانونی برای ادامه فعالیت را احراز کنند. نهاد ناظر با توجه به تطبیق تعهداتی شرکت و مبلغ ذخیره خسارت عموق، مجوز برگزاری مجمع و اعلام رسمی صورت‌های مالی را برای بیمه‌گران صادر می‌کند. این الزامات به منظور رعایت حقوق بیمه‌گذاران تنظیم شده است. شرکت‌های بیمه باید بتوانند گزارش مالی دقیق و شفافی از عملکرد خود برای ذی‌نفعان و همچنین نهادهای نظارتی منتشر کنند. از این رو شناسایی نزدیک به واقعیت خسارت‌ها و تعهداتی آتی، در شفافیت صورت‌های مالی شرکت‌های بیمه امری کلیدی است. شناسایی کمتر از واقعیت این مبلغ، باعث می‌شود که شرکت‌های بیمه توانایی نداشته باشند تا به تعهداتی آتی خود عمل کنند و همچنین تخصیص مبلغی بالاتر از نیاز واقعی شرکت،

صورت‌های مالی شرکت را متأثر می‌کند و باعث شناسایی سود عملیات بیمه‌گری پایین‌تر از واقعیت می‌شود (گابریلی، ریچمن و وتریچ^۱، ۲۰۲۰؛ سهرابی، رئیسی و آنانی و قانونی شیشوان، ۱۳۹۴).

روش نرdbانی برای محاسبه ذخایر

روش نرdbانی زنجیره‌ای یکی از روش‌های محاسبه ذخایر خسارت در صنعت بیمه است که از آن به عنوان یک روش تخمینی برای پیش‌بینی تعهدات مالی آینده استفاده می‌شود. این روش معمولاً در زمینه بیمه‌های غیرزندگی، مانند بیمه شخص ثالث، به کار می‌رود. این روش از داده‌های تاریخی بیمه‌گذاران شرکت بیمه، برای محاسبه تعهداتی مالی آینده استفاده می‌کند (پترسون^۲). این داده‌ها شامل اطلاعاتی مثل تعداد و میزان خسارات گزارش شده در دوره‌های گذشته است. با کمک این اطلاعات، زنجیره‌ای از توسعه خسارات در سال‌های مالی، پس از سال صدور بیمه‌نامه ایجاد می‌شود. در ابتدا، تعداد خسارات گذشته برای هر دوره زمانی محاسبه می‌شود؛ سپس، از نسبت‌های تعداد خسارات بین دوره‌های زمانی مختلف استفاده می‌شود تا تعداد خسارات آینده در هر دوره زمانی پیش‌بینی شود (فرولیچ و ونگ^۳، ۲۰۱۸). با توجه به تعداد خسارات پیش‌بینی شده برای هر دوره زمانی و میزان تعهداتی مالی مرتبط با هر خسارت، می‌توان تعهداتی مالی آینده را محاسبه کرد. این تعهداتی مالی معمولاً شامل مبالغی است که باید برای پوشش خسارت‌های آینده پرداخت شود (هالیول، ۲۰۱۸). این روش به دلیل سادگی در اجرا، شفافیت و قدرت تفسیر بالا، در بین نهادهای نظارتی صنعت بیمه در کشورهای مختلف مورد تأیید است. با وجود کارایی نسبتاً خوب روش نرdbانی، این روش با چندین چالش مواجه است. به طور مثال، این روش فرض می‌کند که الگوهای خسارات در آینده به طور مستمر تغییر نمی‌کنند، در حالی که در عمل این اتفاق نمی‌افتد. همچنین، این روش ارتباط بین متغیرها را به صورت خطی فرض می‌کند که در واقعیت این ارتباط غیرخطی است. این روش به حجم بالای اطلاعات تاریخی نیاز دارد تا بتواند به درستی چگونگی توسعه تعداد خسارت‌ها را استنتاج کند (آوانزی، وانگ و یانگ^۴، ۲۰۱۶). به منظور شناخت بیشتر روش متدائل در صنعت بیمه برای پیش‌بینی تعداد خسارت‌های سال‌های آتی، باید به این نکته توجه کرد که حجم بالایی از خسارت در شرکت‌های بیمه، برای برخی از رشته‌های بیمه‌ای نظیر بیمه شخص ثالث اتومبیل، در سال صدور بیمه‌نامه پرداخت نمی‌شود. بلکه بیشترین سهم از پرداخت خسارت سال دوم و سوم از زمان صدور بیمه‌نامه است. جدول شکل ۱ چگونگی روند پرداخت خسارت در یک شرکت بیمه را نشان می‌دهد. همان طور که مشخص شده است، تنها بخشی از خسارت‌های بیمه‌نامه‌ها در سال صفر، یعنی همان سال صدور بیمه‌نامه پرداخت می‌شود. نمایش سال‌ها به صورت ستونی، نشان‌دهنده سال صدور بیمه‌نامه است. همان طور که در شکل ۱ مشاهده می‌شود، قطر ماتریس، تعداد خسارت‌ها در سال مورد بررسی است و برای سال‌های پس از آن داده‌ای وجود ندارد.

1. Gabrielli, Richman & Wüthrich

2. Peterson

3. Fröhlich & Weng

4. Avanzi, Wong & Yang

Claims occurrence year	Incremental claims loss settlements	Development year						
		0	1	2	3	4	5	6
2005	1232	946	520	722	316	165	48	14
2006	1469	1201	708	845	461	235	56	
2007	1652	1416	959	954	605	287		
2008	1831	1634	1124	1087	725			
2009	2074	1919	1330	1240				
2010	2434	2263	1661					
2011	2810	4108						
2012	3072							

شکل ۱. فراوانی تعداد خسارت‌های پرداخت شده در سال‌های پس از صدور بیمه‌نامه

منبع: وایندروف^۱، ۲۰۱

بر اساس روش نردبانی، با کمک محاسبه میانگین وزن فراوانی خسارت‌ها در دو سال متولی، بخش دوم شکل نیز به کمک رابطه ۱ تکمیل می‌شود.

$$\hat{f}_j = \frac{\sum_{i=1}^{1-j} C_{i,j+1}}{\sum_{i=1}^{1-j} C_{i,j}} = \frac{\sum_{i=1}^{1-j} C_{i,j} \hat{f}_{j,j}}{\sum_{i=1}^{1-j} C_{i,j}} \quad \text{رابطه ۱) محاسبه خسارت‌های آتی}$$

سادگی روند محاسبه و شفافبودن پیش‌بینی تعداد خسارت‌های آتی، یکی از دلایل توفیق این روش در بین شرکت‌های بیمه و نهادها نظارتی است؛ اما توسعه محصول، بهبود فرایندهای ارزیابی و تعیین خسارت، تغییر فرایند دادرسی و قوانین، وجود مبالغ خسارت پرت (بسیار بالا یا بسیار پایین) کارآمد بودن این روش سنتی را به چالش می‌کشد.

کاربرد هوش مصنوعی در محاسبه ذخایر

پژوهش‌های متعددی در زمینه کاربرد هوش مصنوعی در بخش‌های مختلف صنعت بیمه انجام شده است و در این بین الگوریتم‌های متعددی آزمون شده‌اند. الگوریتم‌های یادگیری ماشین، توانایی‌های محاسباتی توسعه‌یافته‌ای دارند که به پیش‌بینی‌های دقیق‌تر از ذخایر کمک می‌کنند. هوش مصنوعی می‌تواند به شرکت‌های بیمه در تدوین مدل‌های شخصی‌سازی شده برای پیش‌بینی مبلغ خسارت‌های آتی نیز بسیار مؤثر باشد؛ زیرا با توجه به قابلیت‌های هوش مصنوعی علاوه‌بر پردازش داده‌های ساختار یافته، امکان پردازش نیمه‌ساختار یافته یا بدون ساختار را فراهم کرده است (بلیرونگ، کاست، لامونتاجن و مارسو^۲، ۲۰۲۰). تحقیقات اخیر نشان می‌دهد که یادگیری ماشین می‌تواند علاوه‌بر پیش‌بینی تعداد خسارت‌ها در پیش‌بینی مبلغ هر خسارت نیز مؤثر باشد (ووتريش^۳، ۲۰۱۸). شبکه‌های عصبی قادرند با توجه به توانایی بالای پردازش اطلاعات را به صورت خرد پردازش و الگوهای پیچیده را استنتاج کنند. از دیگر پژوهش‌های انجام شده در این زمینه، می‌توان به استفاده از یادگیری ماشین برای پیش‌بینی ضرایب توسعه خسارت‌های واقع شده، ولی گزارش

1. Weindorfer

2. Blier-Wong, Cossette, Lamontagne & Marceau

3. Wüthrich

نشده اشاره کرد (دفلیس و موریکونی^۱، تایه^۲، ۲۰۲۳). درخت تصمیم‌گیری، مانند درختان بی‌نهایت تصمیم‌گیری^۳ یا تقویت گرادیان شدید^۴، از جمله الگوریتم‌های پُرکاربرد در این زمینه است (ووتريش، ۲۰۱۹). درخت‌های تصمیم‌گیری، از جمله گونه طبقه‌بندی و رگرسیون، به دلیل توانایی در درک ارتباطات پیچیده و همچنین قدرت تفسیرپذیری بالا، بیش از سایر روش‌ها در این زمینه استفاده شده‌اند. در ادامه اطلاعات برخی از پژوهش‌هایی که در این زمینه انجام شده‌اند، بیان شده است.

جدول ۱. خلاصه پژوهش‌های انجام شده در زمینه موضوع پژوهش حاضر

عنوان	نویسنده و سال انتشار	خلاصه
رزرو ادعاهای فردی: استفاده از یادگیری ماشین	دینگ و کین ^۵ (۲۰۱۹)	این مطالعه به بررسی استفاده از تکنیک‌های یادگیری ماشین، مانند شبکه‌های عصبی و جنگل تصادفی ^۶ برای پیش‌بینی ذخایر خسارت می‌پردازد و عملکرد آن‌ها را با روش‌های سنتی مانند روش زنجیره نزدبانی و روش پواسون پیش‌پراکنده مقایسه می‌کند. روش‌های سنتی تاریخی از داده‌های تجمیعی به فرم مثلثی استفاده می‌کرده‌اند.
مدل سازی تعداد رویدادهای پنهان در معرض تأخیر مشاهده	کروکور، آتونیو و وربلن ^۷ (۲۰۱۹)	این مطالعه به پیش‌بینی رویدادهای گذشته‌ای می‌پردازد که به دلیل تأخیر در مشاهده، بر زینه‌هایی مانند تخمین هزینه‌های گارانتی، تعیین قیمت قراردادهای نگهداری و ارزیابی خسارت‌های بیمه‌ای تأثیرهایی گذاشته است. نایدیده گرفتن این رویدادهای دیده‌نشدنی، ممکن است به تخمین کمتر از واقعیت تعداد حوادث منجر شود. این مطالعه بر تدوین مدلی برای شناسایی مدت زمان بین وقوع حادثه و مشاهده آن تمرکز دارد که به نام تأخیر مشاهده معروف است.
درختان افزایش گرادیان برای مدل سازی و پیش‌بینی هزینه خسارت بیمه خودرو	کولمن ^۸ (۲۰۲۰)	در این مقاله، به کارگیری روش تقویت گرادیان برای پیش‌بینی خسارت‌های بیمه ارائه شده است که نشان می‌دهد روش افزایش گرادیان، دقت پیش‌بینی را از روش سنتی مدل خطی عمومی فراتر می‌برد و بستر قوی‌ای برای ایجاد مدل‌های قیمت‌گذاری بیمه فراهم می‌کند و نتایج قابل تفسیری تولید می‌کند که به ویژه در بیمه‌های بازرگانی مفید است.
وابستگی فراوانی و شدت در مدل ریسک جمعی: رویکردی بر اساس توزیع سارمانوف	بولانسه و ورنیک ^۹ (۲۰۲۰)	هدف این مطالعه تطابق تعداد خسارت‌ها و شدت هر خسارت با استفاده از توزیع سارمانوف ^{۱۰} است. توزیع‌های بواضون و بینومیال منفی برای تعداد ادعاهای استفاده می‌شوند، در حالی که توزیع‌های گاما و لاغنرمال برای هزینه‌های ادعا مورد استفاده قرار می‌گیرند. توزیع سارمانوف از طریق تخمین بیشینه درستنمایی محاسبه می‌شود. داده‌های واقعی از پرتفوی بیمه اسپانیایی برای تحلیل عددی استفاده می‌شوند.

1. De Felice & Moriconi

2. Muhammad M. Taye

3. ExtraTrees

4. Extra Gradiant Boosting-XGBoost

5. Ding & Qin

6. Random Forest

7. Crevecoeur, Antonio & Verbelen

8. Guelman

9. Bolancé & Vernic

10. Sarmano

مدل‌های یادگیری ماشین می‌توانند از داده‌های جدید یاد بگیرند و خودآموز شوند که به بیمه‌گران امکان می‌دهد که محاسبات ذخیره خود را به صورت مداوم بهبود ببخشند (کروکور و همکاران، ۲۰۱۹)، این قابلیت بهویژه در پاسخ به تغییرات در شرایط بازار، مقررات و رویدادهای غیرمنتظره مانند فاجعه‌های طبیعی یا رکود اقتصادی بسیار ارزشمند است. علاوه‌بر قابلیت‌های ذکر شده، الگوریتم‌های یادگیری ماشین می‌توانند بیمه‌گذاران و خسارت‌ها را بر اساس ویژگی‌های مختلفی تقسیم کنند که این امکان را به بیمه‌گران می‌دهد تا خطرها را با دقت بیشتری ارزیابی کنند. این تقسیم‌بندی می‌تواند به تخمین‌های دقیق‌تری از ذخایر برای گروه‌های مشتری مختلف، محصولات یا مناطق جغرافیایی مختلف منجر شود (آروجو، پاتنام، پوپسکو، ولنسیا و یادو^۱، ۲۰۲۴) علاوه‌براین، برخی از الگوریتم‌های یادگیری ماشین امکان نظارت به صورت زمان واقعی بر الگوهای خسارت و کفایت ذخایر را فراهم می‌کنند. بیمه‌گران می‌توانند از این اطلاعات برای تنظیم پیش‌بینی خود به صورت فعل استفاده کنند و خطر ذخیره‌گیری کمتر یا بیشتر از نیاز را به حداقل برسانند (آروجو و همکاران، ۲۰۲۴).

هرچند یادگیری ماشین در محاسبات ذخایر بیمه مزایای چشمگیری دارد با چالش‌ها و نقاط ضعف‌هایی نیز همراه است. برای مثال، الگوریتم‌های یادگیری ماشین، بهویژه مدل‌های یادگیری عمیق، اغلب به حجم زیادی از داده با کیفیت بالا نیاز دارند تا عملکرد خوبی داشته باشند. شناخت صحیح از اطلاعات و پاک‌سازی آن‌ها، ممکن است شرکت‌های بیمه را با چالش مواجه کند. علاوه‌براین، بسیاری از مدل‌های یادگیری ماشین، بهویژه مدل‌های پیچیده، در فرایند تصمیم‌گیری خود، همانند جعبه سیاه هستند و تفسیرپذیری بالایی ندارند. همین امر باعث شده است که از مدل‌هایی مانند درخت تصمیم‌گیری که در بین الگوریتم‌های یادگیری ماشین از بازدهی متوسطی برخوردارند؛ اما قدرت تفسیرپذیری بالایی دارد، بیش از الگوریتم‌های پرقدرت در پیش‌بینی استفاده شود (امبرخت، مائو، ونگ و ونگ^۲، ۲۰۲۱). از سویی دیگر، الگوهای سنتی مورد تأیید نهادهای ناظر، ممکن است قدرت اعتبار سنجی مدل‌های مبتنی بر هوش مصنوعی را نداشته باشد و این امر شرکت‌های بیمه را با چالش مواجه کند.

با توجه به مطالعاتی که در این زمینه انجام شده است، می‌توان مزایا و معایب استفاده از هوش مصنوعی در پیش‌بینی ذخایر و محاسبات شرکت‌های بیمه را بدین گونه خلاصه کرد که استفاده از هوش مصنوعی، دقت محاسبات و قدرت پیش‌بینی را افزایش داده و امکان استفاده بهینه از داده‌ها را برای شرکت‌های بیمه فراهم کرده است.

روش‌های مبتنی بر هوش مصنوعی و یادگیری ماشین، امکان ارزیابی مؤثرتری برای خطرات نسبت به روش‌های سنتی دارند و امکان استنتاج الگوی نهفته در داده‌ها و تحلیل آن‌ها را دارند. علاوه‌براین، قابلیت استفاده از انواع مختلف داده‌های ساختاریافته، نیمه‌ساختاریافته و غیرساختاریافته را برای شرکت فراهم می‌کنند (زیادی، صلواتی و لطفی هروی، ۱۴۰۲). بنابراین شرکت‌های بیمه می‌توانند طیف گسترده‌ای از داده‌ها، شامل داده‌های بیمه‌گذاران، خسارت‌های تاریخی، متغیرهای اقتصادی - اجتماعی یا حتی داده‌های غیرساختاریافته مانند گزارش‌های خسارت را تحلیل و ارتباطات پیچیده و غیرخطی بین متغیرهای مختلف را بررسی کنند. علاوه‌بر امتیازهای محاسباتی که بیان شد، شرکت‌های بیمه می‌توانند با

1. Araujo, Patnam, Popescu, Valencia & Yao

2. Embrechts, Mao, Wang & Wang

استفاده از الگوریتم‌های مناسب، داده‌سازی در خسارت‌ها و تقلب سازمان یافته را تشخیص دهنده است. این امر می‌تواند به محاسبه نزدیک به واقعیت ذخایر شرکت‌های بیمه کمک شایان توجهی کند (حاجی لوه و کاظمی بوکانی، ۱۴۰۱). اما همان گونه که در مجموعه تحقیقات جولیان آرجو و همکاران بیان شده است، استفاده از الگوریتم‌های یادگیری ماشین خالی از ایراد نیست. مدل‌های مبتنی بر یادگیری ماشین، به استفاده از حجم بالای داده نیازمندند. کیفیت داده‌ها و پاک‌سازی آن‌ها، بر عملکرد مدل‌های طراحی شده تأثیر مستقیمی دارد (شریفی، سربخشیان و رسیدی، ۱۳۹۷). برخی از الگوریتم‌های یادگیری ماشین با قابلیت بالای پیش‌بینی، مانند یادگیری عمیق، قابلیت تفسیرسازی ضعیفی دارند که این امر می‌تواند در حوزه‌هایی که تأیید نهاد ناظر برای محاسبات ضروری است با اهمیت باشد. علاوه بر موارد فوق، درجه به بالای حساسیت عملکرد مدل به ابرپارامترها نیز موضوع با اهمیت دیگری است که باید به آن توجه داشت. با توجه به موارد ذکر شده می‌توان چنین جمع‌بندی کرد که استفاده از الگوریتم‌های هوش مصنوعی در کنار تمام مزیت‌هایی فنی و محاسباتی که دارد با چالش‌هایی نیز مواجه است. برای حل چالش‌ها، می‌توان از ترکیب روش‌های آماری و مدل‌های مبتنی بر هوش مصنوعی استفاده کرد. همچنین استفاده از الگوریتم‌هایی که درجه تفسیرپذیری بالاتری دارند، می‌توانند در کنار الگوریتم‌هایی با قدرت محاسباتی بالاتر استفاده شوند.

روش‌ها و متداول‌ترین

مدل مبتنی بر حافظه بلندمدت – کوتاه‌مدت

در بین روش‌های مبتنی بر هوش مصنوعی، شبکه‌های عصبی بازگشتی^۱ برای پردازش سری‌های زمانی و دنباله‌ها استفاده می‌شود. تشخیص الگوی زمانی در داده‌ها، از جمله توانایی‌های با اهمیت این گروه از الگوریتم‌های هوش مصنوعی است (باغبانی و اسکندری، ۱۳۹۶). این شبکه‌ها اجزای مختلفی دارند، از قبیل تعداد لایه‌های ورودی، لایه‌های مخفی و لایه‌های خروجی که با استفاده از این لایه‌ها می‌توانند سری‌های زمانی را تحلیل و در بازه‌های زمانی متعدد پیش‌بینی کنند (چنگ و همکاران، ۲۰۱۷). در بین مجموعه الگوریتم‌های برگشتی، شبکه عصبی حافظه بلندمدت – کوتاه‌مدت از ویژگی با اهمیت حافظه سلولی^۲ برخوردار است و می‌تواند اطلاعات را به مدت طولانی‌تری حفظ کند (هوچرایتر، ۱۹۹۷؛ برونلی، ۲۰۱۸). این ویژگی امکان پردازش اطلاعات سری زمانی با پیچیدگی و یا حجم اطلاعات بالا را برای مدل فراهم می‌کند و مدل‌های طراحی شده با شبکه عصبی حافظه بلندمدت – کوتاه‌مدت می‌توانند بر مشکل وابستگی‌های زمانی بلندمدت فائق آیند (زیادی و همکاران، ۱۴۰۲).

در طراحی شبکه عصبی حافظه بلندمدت – کوتاه‌مدت از مفهوم یادگیری عمیق^۳ به‌طور گسترده استفاده می‌شود.

1. Recurrent Neural Network (RNN)

2. Cheng et al., 2017

3. Cell Memory

4. Hochreiter

5. Brownlee

6. Deep Learning

این معماری می‌تواند در بهترین شکل ممکن وابستگی‌های بلندمدت در داده‌ها را در ک کند، بنابراین برای پیش‌بینی دنباله‌ها بسیار مناسب است (برونلی، ۲۰۱۷).

برخلاف شبکه‌های عصبی سنتی، شبکه عصبی حافظه بلندمدت - کوتاه‌مدت اتصالات بازخورد را در خود دارد که به آن امکان می‌دهد تا به جای بررسی نقطه‌ای داده‌ها در سری‌های زمانی، داده‌ها را به صورت کلی نیز مورد بررسی قرار دهد (چنگ، ۲۰۱۷) این ویژگی باعث می‌شود که شبکه عصبی حافظه بلندمدت - کوتاه‌مدت در درک و پیش‌بینی الگوهای در داده‌های توالی مانند سری‌های زمانی، متن و گفتار بسیار مؤثر باشد (دینگ و کین، ۲۰۲۰).

منطق تحلیل داده‌های مبتنی بر الگوریتم حافظه بلندمدت – کوتاه‌مدت

همان گونه که در معرفی شبکه عصبی حافظه بلندمدت - کوتاه‌مدت مطرح شد، این شبکه گونه از شبکه‌های بازگشته است که توانسته بر نقطه ضعف محو شدگی گرادیان^۱ غلبه کند. شبکه عصبی حافظه بلندمدت - کوتاه‌مدت از سه بخش کلی درست شده است. بخش اول تصمیم می‌گیرد که آیا اطلاعات قبلی که وارد شبکه شده‌اند باید حفظ شود یا بی‌اهمیت هستند و مدل می‌تواند آن‌ها را فراموش کند (یلماز و بویوکتاhtaکیم^۲، ۲۰۲۳). در بخش دوم، سلول سعی می‌کند اطلاعات جدید را از ورودی به این سلول یاد بگیرد (بلک، سالاج، سابرامونی، لگنشتاین و ماس^۳، ۲۰۱۸). در نهایت، در بخش سوم، سلول اطلاعات بهروز شده را از زمان فعلی مورد بررسی به زمان بعدی در داده‌های سری زمانی منتقل می‌کند. این یک چرخه حافظه بلندمدت - کوتاه‌مدت به عنوان یک مرحله زمانی تلقی می‌شود (برونلی، ۲۰۱۷).

این سه بخش از یک واحد از الگوریتم حافظه بلندمدت - کوتاه‌مدت به عنوان دروازه‌ها^۴ شناخته می‌شوند. آن‌ها جریان اطلاعات به ورودی و خروجی از سلول حافظه یا سلول حافظه بلندمدت - کوتاه‌مدت را کنترل می‌کنند. دروازه اول به نام دروازه فراموشی، دروازه دوم به عنوان دروازه ورودی و آخرین دروازه به عنوان دروازه خروجی نام گذاری شده‌اند (چن^۵، ۲۰۱۸؛ هوچرایتر، ۱۹۹۷).

ابرپارامترها

در مدل شبکه عصبی حافظه بلندمدت - کوتاه‌مدت و دیگر مدل‌های یادگیری ماشین، ابرپارامترها پارامترهایی هستند که قبل از آموزش مدل، توسط پژوهشگر پیشنهاد و تنظیم می‌شوند و تأثیر مستقیمی بر عملکرد نهایی مدل دارند (برونلی، ۲۰۱۷). از ابرپارامترها به در مدل حافظه بلندمدت - کوتاه‌مدت، می‌توان به تعداد واحدها^۶ اشاره کرد. تعداد واحدها بیانگر تعداد نورون‌ها در هر لایه از شبکه است که بر کیفیت و قدرت مدل تأثیر مستقیم دارد. دو میان ابرپارامتر کلیدی، تعداد لایه‌های است. افزایش تعداد لایه‌ها می‌تواند معماری مدل را پیچیده‌تر کند (هازان و یانگ یوان^۷، ۲۰۱۸). تعداد واحدهای

1. vanishing gradient

2. Yilmaz & Büyüctahtakın

3. Bellec, Salaj, Subramoney, Legenstein & Maass

4. Gate

5. Chen

6. LSTM Units

7. Hazan & Yang Yuan

خروجی، ابرپارامتر بعدی است که تعیین می‌کند مدل به چه تعداد مقادیر خروجی را پیش‌بینی می‌کند. این تعداد باید با ویژگی‌های مسئله مطابقت داشته باشد. از دیگر ابرپارامترهای با اهمیت، نرخ یادگیری است. این عامل بیانگر این است که به چه سرعت مدل وزن‌ها را به روز کند. نرخ یادگیری باید با دقت تنظیم شود تا مدل به سرعت به یک مقدار بهینه برسد. همچنین - تعداد دوره‌های آموزش^۱ مشخص می‌کند که مدل چند بار باید با داده‌ها آموزش بینند (عباسیان، ابراهیمی و فرزانگان، ۱۳۹۴). این تعداد باید به گونه‌ای تنظیم شود که مدل به طور کافی آموزش بینند؛ اما از پیش‌آموزش جلوگیری شود (برانلی، ۲۰۱۸). در نهایت تابع هزینه - تابع هزینه مشخص می‌کند که چگونه عملکرد مدل با داده‌های واقعی مقایسه شود. انتخاب تابع هزینه مناسب برای مسئله بسیار حیاتی است (خالید و جاوید، ۲۰۲۰). روش‌های متعددی برای شناسایی ابرپارامترها در شبکه‌های عصبی وجود دارد که می‌توان به جست‌وجوی شبکه‌ای، تصادفی بیزین و الگوریتم‌های ژنتیک اشاره کرد (زوکر، کیسکار و مریتی، ۲۰۱۷). در این پژوهش عملکرد دو مدل از پُرکاربردترین روش‌ها، یعنی جست‌وجوی شبکه‌ای و تصادفی با یکدیگر مقایسه می‌شوند. با وجود روش‌های پیشرفته‌تر بهینه‌سازی از قبیل بیزین (عباسیان و همکاران، ۱۳۹۴)، همچنان دو روش فوق از کاربری بالایی در ساخت مدل‌های مبتنی بر هوش مصنوعی برخوردارند. این دو روش برای پیاده‌سازی و درک، آسان هستند که این امر امکان دسترسی و پیاده‌سازی بالا با سطوح مختلف دانش از یادگیری ماشین را فراهم می‌آورد. پیاده‌سازی این دو روش نیازمند الگوریتم‌های پیچیده‌ای نیست و به منابع محاسباتی مجازی نیاز ندارد. علاوه بر این، هر دو روش بدون بررسی دلایل نهفته در انتخاب ابرپارامترها از پیچیدگی غیر ضروری جلوگیری می‌کنند. از سویی دیگر، دو روش جست‌وجوی تصادفی و شبکه‌ای این قابلیت را دارند که به عنوان مبانی ارزشمندی برای مقایسه با روش‌های پیشرفته‌تر در تحقیقات آتی عمل کنند و به محققان کمک کنند تا مناسب‌ترین الگوریتم و عملی‌ترین تکنیک را انتخاب کنند (فیورر و هاتر، ۲۰۱۹).

جست‌وجوی شبکه‌ای

جست‌وجوی شبکه‌ای یک رویکرد سیستماتیک است که شامل مشخص کردن مقادیری از ارزش‌های ممکن برای هر ابرپارامتر است. سپس یک شبکه از تمام ترکیب‌های ممکن از ابرپارامترها ساخته و مدل را با هر ترکیب آموزش داده و ارزیابی می‌کند. جست‌وجوی شبکه‌ای به طور جامع فضای جست‌وجو را بررسی می‌کند. این روش به سادگی اجرا می‌شود و برای شناسایی تعداد محدودی از ابرپارامترها مناسب است. با این حال، ممکن است محاسبات پُرهازینه و زمان بر باشد. همچنین ممکن است روابط متفاوت بین ابرپارامترها را نادیده بگیرد. نقطه ضعف مهم دیگر در جست‌وجوی شبکه‌ای، این است که فرض می‌کند بهترین ترکیب ابرپارامترها در داخل شبکه از پیش تعیین شده وجود دارد (کارتیسری و ایمانی^۲، ۲۰۱۸). اگر ابرپارامترهای بهینه واقعی در دامنه جست‌وجوی تعیین شده نباشند، جست‌وجوی شبکه‌ای ممکن است نتواند

1. Epoch

2. Khalid & Javaid

3. Merity, Keskar & Socher

4. Feurer & Hutter

5. Kartikasari & Imani

آن‌ها را پیدا کند. به علاوه، با افزایش تعداد ابرپارامترها و مقادیر آن‌ها، فضای جستوجوی شبکه‌ای به صورت نمایی افزایش می‌یابد. این ممکن است به انجرار ترکیبی منجر شود و جستوجوی جامع را غیرعملی کند (کارتیسری و ایمانی، ۲۰۱۸؛ فریز، دریگ و مایرز^۱، ۲۰۱۹).

جستوجوی تصادفی

جستوجوی تصادفی از دیگر روش‌های پُرکاربرد در تنظیم ابرپارامترها است که به صورت گسترده در یادگیری‌های عمیق استفاده می‌شود. هدف اصلی جستوجوی تصادفی، پیمایش مسیری سیستماتیک در یک طیف از پیش‌تعیین‌شده برای ابرپارامترهای مدل مبتنی بر یادگیری ماشین است تا در نهایت، مطلوب‌ترین ترکیب بر اساس عملکرد شاخص ارزیابی که از پیش‌تعیین شده است، شناسایی شود (برگستا و بنیگو^۲، ۲۰۱۳). در اجرای این روش نیز همانند جستوجوی شبکه‌ای، در ابتدا باید مجموعه‌های آزمون و اعتبارسنجی داده‌های تعریف شوند (برگستا و بنیگو^۳، ۲۰۱۳). تصادفی بودن این روش، آن را به روشی کارآمد برای جستجو و جلوگیری از ارزیابی کامل همه ترکیب‌های ممکن بدل کرده است. برای هر ترکیب، در این روش از اعتبارسنجی متقطع^۴ استفاده می‌شود. این روند شامل تقسیم مجموعه داده به k زیرمجموعه متمایز است. مدل با استفاده از $1 - k$ زیرمجموعه آموزش می‌بیند و با آخرین زیرمجموعه ارزیابی می‌شود. این روند k بار تکرار می‌شود و هر مجموعه یکبار در نقش مجموعه اعتبارسنج قرار می‌گیرد (چن، ۲۰۱۸). پس از ارزیابی تعداد مشخصی از تنظیمات ابرپارامترهای تصادفی، مجموعه‌ای از ابرپارامترها که بهترین معیار عملکرد، شناسایی می‌شوند. این روش از نظر زمانی کارآمدتر است و می‌تواند به ترکیبات بسیار مطلوبی هم دست یابد (لیندمان، مولر، ویتز، جازدی و ویریچ^۵، ۲۰۲۱؛ فریز و همکاران، ۲۰۱۸).

دو روش جستوجوی شبکه‌ای و تصادفی در الگوریتم حافظه بلندمدت – کوتاه‌مدت با تواتر بالایی برای شناسایی ابرپارامترها استفاده می‌شوند. از جمله مزیت‌های با اهمیت روش یادگیری شبکه‌ای می‌توان به امکان جستوجوی مناسب‌ترین ابرپارامتر در بین تمامی ترکیب‌های تعریف شده در شبکه جستجو اشاره کرد. این امر می‌تواند برای طراح شبکه این اطمینان را ایجاد کند که ترکیبی نادیده گرفته نشده است. از سویی دیگر درجه بالای تفسیرپذیری^۶ نیز از جمله مزایای با اهمیت روش جستوجوی شبکه‌ای است. دلیل تفسیرپذیری در امکان جستجو برای تمامی ترکیب‌های ممکن از ابرپارامترها تعریف شده است. در کنار مزیت‌های با اهمیت این روش، هزینه بالای محاسبات و انعطاف‌ناپذیری از جمله معایبی است که در مقالات متعدد به آن اشاره شده است (زیادی و همکاران، ۱۴۰۲). به‌منظور امکان ارزیابی عملکرد در این تحقیق، علاوه‌بر جستوجوی شبکه‌ای، جستوجوی تصادفی نیز آزمون شده است. از جمله با اهمیت‌ترین مزایای این روش، کارایی بالا و هزینه پایین محاسبات است. همچنین با توجه به قابلیت توسعه‌پذیری بالایی که دارد،

1. Frees, Derrig & Meyers

2. Bergstra & Bengio

3. k-fold

4. Lindemann, Müller, Vietz, Jazdi & Weyrich

5. Interpretability

برای جست‌وجوی ابرپارامترها بر خلاف روش شبکه‌ای، به تقسیم فضای پارامترها نیازی ندارد و می‌تواند روش مناسبی برای شبکه‌های عصبی با پارامترهایی با ابعاد بالا یا پیوسته باشد و سازگاری بالاتری در قیاس با جست‌وجوی شبکه‌ای از خود نشان دهد (برگسترا و بنیگو، ۲۰۱۲). این روش نیز همانند روش جست‌وجویی تصادفی، چالش‌هایی دارد. از جمله مهم‌ترین چالش‌ها، می‌توان به احتمال نادیده گرفتن ترکیب بهینه اشاره کرد؛ زیرا در این روش کلیه ترکیب‌های ممکن مورد ارزیابی قرار نمی‌گیرند. علاوه بر این درجه تفسیرپذیری این روش در مقابل جست‌وجوی شبکه‌ای پایین‌تر است. به طور خلاصه جست‌وجوی شبکه‌ای برای کاوش جامع در یک مجموعه از پیش تعیین شده ابرپارامترها که با هزینه بالاتر همراه است، کاربری چشمگیری دارد. در مقام قیاس، جست‌وجویی تصادفی کارآمدتر و توسعه‌پذیرتر است و می‌تواند برای موضوع‌هایی با گسترهٔ پیچیدگی بالا کاربرد داشته باشد. با توجه به نقاط قوت و ضعف دو روش، استفاده از هر دو تکنیک، می‌تواند به عنوان مکمل عمل کند.

شاخص ارزیابی عملکرد مدل

ارزیابی عملکرد نقش مهمی در بررسی کیفی تحقیقات ایفا می‌کند و اهمیت آن بهویژه در حوزهٔ پیش‌بینی سری زمانی بسیار پُررنگ است. یک روش پُرکاربرد برای این منظور، خطای جذر میانگین مربعات^۱ است که میزان اختلاف میان مقادیر مورد انتظار و واقعی را اندازه‌گیری می‌کند (خالید و جاوید، ۲۰۲۰) و به طور مختصر دقت کلی مدل را با یک عدد توصیف می‌کند. کاهش خطای جذر میانگین مربعات، بهبود عملکرد را نشان می‌دهد و حساسیت این معیار بر خطاهای نادر نیز تأکید می‌کند (چای و درکسلر، ۲۰۱۴). باید توجه داشت که در تحلیل عملکرد مدل‌های مبتنی بر الگوریتم حافظه بلندمدت - کوتاه‌مدت، تنها نمی‌تواند به مقدار داده اکتفا کرد. تفسیر آن به در نظر گرفتن عوامل دیگری نیاز دارد. برای نمونه، چنانچه در مدل طراحی شده، عدد خطای جذر میانگین مربعات برای دسته داده‌های آزمون کمتر از آموزش باشد، بیانگر این واقعیت است که رویداد پیش‌بازش رخ داده است. بنابراین به منظور انتخاب مطلوب‌ترین مدل، علاوه بر مقدار مطلق خطای جذر میانگین مربعات، باید به مقدار حاصل شده برای داده‌های آموزش و آزمون نیز توجه شود (چن، ۲۰۱۸).

زبان برنامه‌نویسی و اجرای مدل

شبکه عصبی مورد بحث برای پیش‌بینی تعداد روزانه حوادث با خسارت‌های فیزیکی، در بیمه شخص ثالث با زبان پایتون ساخته شده است. پایتون، یک زبان برنامه‌نویسی اساسی در زمینه‌های یادگیری ماشین و تحلیل داده، به عنوان یک انتخاب ایدئال برای پیاده‌سازی مدل‌های حافظه بلندمدت - کوتاه‌مدت با هدف پیش‌بینی سری‌های زمانی است (السورت و گوتل^۳، ۲۰۲۰). طراحی شفاف آن و مجموعه‌ای از کتابخانه‌های یادگیری ماشین مانند کراس^۴، ایجاد و آموزش

1. Root Mean Square Error (RMSE)

2. Chai & Draxler

3. Elsworth & Güttel

4. Keras

مدل‌های مبتنی بر حافظه بلندمدت - کوتاه‌مدت را آسان می‌کند. توانمندی پایتون در پردازش داده با کتابخانه‌های مانند پandas^۱ و نامپای^۲ تقویت می‌شود که به طور کارآمد با داده‌های سری زمانی برخورد و آن‌ها را پیش‌بینی می‌کنند. برای تصویرسازی، ابزارهایی مانند متپلات‌لیب^۳ و سی‌برن^۴ تحلیل الگوهای سری زمانی را غنی می‌کنند. برای پیاده‌سازی الگوریتم‌های حافظه بلندمدت - کوتاه‌مدت و تنظیم ابرپارامترها، از کتابخانه‌های کراس و اسکیتی‌لرن^۵ بهره گرفته شده است. کراس برای ساخت و آموزش مدل‌های یادگیری عمیق به کار می‌رود، در حالی که اسکیتی‌لرن مجموعه گسترده‌ای از الگوریتم‌های یادگیری ماشین و ابزارهای تحلیل و استخراج داده را شامل می‌شود. هر دو کتابخانه به علت سادگی، کارایی و سازگاری با سایر مؤلفه‌های پایتون، برای طراحی حافظه بلندمدت - کوتاه‌مدت عملکرد بسیار موفقی داشته‌اند (پیکسربیو^۶، ۲۰۲۲). برای ساخت مدل از محیط ابری گوگل کلب^۷ به عنوان یک محیط دستوری برای برنامه‌نویسی پایتون استفاده شده است. دسترسی رایگان به آن، سهولت استفاده از امکانات ابر، منابع محاسباتی قوی، یکپارچگی با کتابخانه‌های پایتون از مزیت‌های اصلی این فضا است.

نتایج

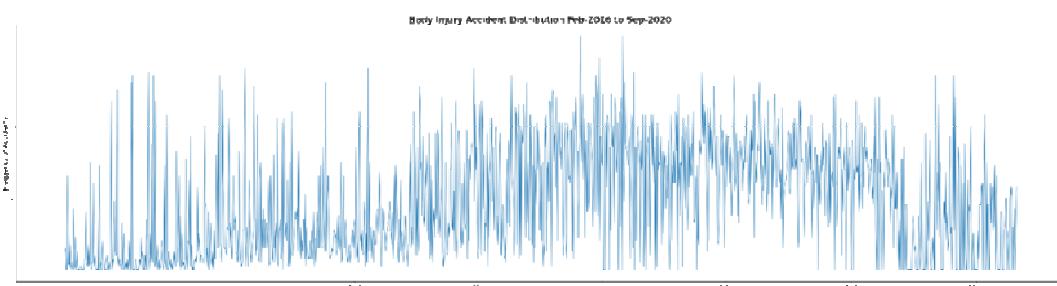
هدف اصلی انجام این پژوهش، ساخت مدلی مبتنی بر الگوریتم حافظه بلندمدت - کوتاه‌مدت برای پیش‌بینی تعداد تصادف‌ها، به منظور محاسبه تعداد خسارت‌های واقع شده، ولی گزارش نشده در شرکت‌های بیمه است. به این منظور، از داده‌های تاریخی یک شرکت بیمه استفاده شد تا با بررسی داده‌ها، الگوهای پنهان موجود در آن شناسایی شود. این مطالعه، به طور خاص، بر پیش‌بینی فراوانی حوادث با خسارت‌های جرح و فوت بیمه مسئولیت شخص ثالث وسائل نقلیه متمرکز است. مجموعه داده‌ای مورد استفاده در این پژوهش، متعلق به یک شرکت بیمه خصوصی فعل در صنعت بیمه ایران است. تعداد داده‌ها ۱۴۰۰ روز از سال ۱۳۹۶ تا ۱۴۰۰ با میانگین ۱۸/۶۲ حادثه در روز است. حداقل تعداد حوادث با آسیب جسمی، برابر با صفر و حداکثر آن، ۶۵ حادثه در روز است. با هدف شناسایی ابرپارامترها در معماری این مدل، عملکرد دو روش جستجوی تصادفی و شبکه‌ای با یکدیگر مقایسه شده است. شاخص ارزیابی عملکرد نیز خطای جذر میانگین مربعات معروف شده است.

آماده سازی داده‌ها^۸

آماده سازی دیتا در استفاده از الگوریتم‌های یادگیری ماشین، اهمیت بسیار زیادی دارد. این مرحله از فرایند تحلیل داده و مدل‌سازی، مرحله حیاتی‌ای است که بر کیفیت و دقت نتایج نهایی بسیار تأثیرگذار است. در ابتدا کار با داده‌های خام آغاز

-
1. Pandas
 2. NumPy
 3. Matplotlib
 4. Seaborn
 5. scikit-learn
 6. Peixeiro
 7. Google Colaboratory (Colab)
 8. Data Cleaning

می‌شود. تصادف‌های یکتایی که در بازه زمانی مدنظر واقع شده‌اند، از کل داده‌ها استخراج می‌شوند. بر اساس اطلاعات موجود در زمان حادثه، سری زمانی با فاصله یک روز ایجاد شد. در مجموع، سری زمانی ۱۴۰۰ روزه از فروردین سال ۱۳۹۶ تا شهریور ۱۴۰۰ ساخته شد. فراوانی داده‌ها در شکل ۲ مشاهده می‌شود.



شکل ۲. سری زمانی تصادف‌های منجر به خسارت جانی

با توجه به گستره تنوع داده‌ها، ابتدایی‌ترین اقدام برای طراحی مدل مبتنی بر حافظه بلندمدت – کوتاه‌مدت، تعیین مقیاس^۱ داده‌هاست. داده‌ها باید به یک مقیاس مشخص و قابل مدیریت تبدیل شوند. در معماری مدل در دست بررسی پیش از تغییر مقیاس، داده‌ها بر مبنای لگاریتمی تغییر داده شدند، تبدیل داده‌ها به مقیاس لگاریتمی معمولاً در مواردی که داده‌ها توزیع‌های پویا و وسیعی دارند و تفاوت‌های بزرگی بین مقادیر داده‌ها وجود دارد، استفاده می‌شود. این تبدیل به اندازه‌گیری نسبت‌ها و تفاوت‌ها بین مقادیر کمتر حساسیت کمتری دارد. علاوه‌بر این، تبدیل به مقیاس لگاریتمی، ممکن است به تقریب توزیع داده‌ها به توزیع نرمال کمک کند که یکی از فرضیه‌های مهم بسیاری از الگوریتم‌های یادگیری ماشین است.

در مدل‌های مبتنی بر حافظه بلندمدت – کوتاه‌مدت که از توابعی مانند تانزانیت هیپربولیکی^۲ استفاده می‌کنند، مقیاس داده بهبود معناداری در عملکرد مدل دارد. در پایتون، می‌توان با استفاده از کتابخانه اسکالرن^۳ و به صورت مشخص، میان مکس اسکالر^۴ دامنه داده‌ها را تعریف کرد. بنابراین پس از تبدیل به مقیاس لگاریتمی، مقادیر داده‌ها در بازه ۰ و ۱ تعریف شد (پیکسریو، ۲۰۲۲). این کار باعث می‌شود که تمام ویژگی‌ها در یک مقیاس یکسان باشد و مقایسه آن‌ها آسان‌تر شود. این مقیاس داده معمولاً به مدل‌ها کمک می‌کند تا سریع‌تر و بهتر آموزش داده شوند و همچنین ممکن است از مشکلات مربوط به بزرگی یا کوچکی مقادیر داده‌ها جلوگیری کند (یداوا و شاران^۵). داده‌های مورد بررسی شامل زمان و تعداد تصادف در هر روز است. به منظور ارتقای کیفیت نتیجه، داده‌ها بررسی می‌شوند تا چنانچه برای روزهایی تعداد

1. Data Scaling

2. Tanh

3. Sklearn

4. MinMaxScaler

5. Yadava & Sharan

تصادف‌ها بیان نشده با یک منطق داده‌ها به درستی پر شوند^۱ روش‌هایی مانند میانگین‌گیری یا پیش‌بینی مقادیر از پرکاربردترین سیاست‌ها در این زمینه هستند. این اقدام می‌تواند از اشتباهات در تحلیل و پیش‌بینی جلوگیری کند.

مرحلهٔ بعدی برای ساخت مدل حافظهٔ بلندمدت – کوتاه‌مدت تقسیم داده‌ها^۲ به دو مجموعه آموزش و آزمون است. در این مدل ۸۰ درصد از داده‌ها به آموزش اختصاص پیدا کرده و مابقی برای آزمون عملکرد یادگیری استفاده می‌شوند. مرحلهٔ بعدی، تعیین و ایجاد تولید کنندهٔ دنباله‌های زمانی^۳ است. بر این اساس، دنباله‌های مصنوعی با بازهٔ زمانی برای n روزه تولید می‌شود تا داده روز $+1$ را پیش‌بینی کند.

انتخاب ابرپارامترها

همان طور که پیش‌تر، در رابطه با نحوه انتخاب ابرپارامترها توضیح داده شد، در این مقاله، از دو روش جست‌وجوی تصادفی و شبکه‌ای برای شناخت ابرپارامترها استفاده کرده‌ایم. کتابخانه‌های اسکیت‌لرن^۴ و کراس تاسور فلو^۵ در پایتون برای ایجاد این دو مدل استفاده شده‌اند.

عملکرد مدل بر مبنای جست‌وجوی شبکه‌ای

در روش انتخاب ابرپارامترها به صورت شبکه‌ای، یک شبکه از مقادیر یا دامنه‌های ممکن برای هر ابرپارامتر ساخته می‌شود. این شبکه به روشنی ترکیب‌های تنظیمات ابرپارامتر را که در طول جست‌وجو برای آن‌ها کاوش می‌شود، تعریف می‌کند. مجموعه داده به زیرمجموعه‌های آموزش و اعتبارسنجی تقسیم می‌شود. از طریق تکنیک معتبر اعتبارسنجی متقاطع^۶، عملکرد هر ابرپارامتر نسبت به مقادیر دیگری که در شبکه ممکن تعیین شده است، مقایسه می‌شود.

دامنه تعریف شده برای ابرپارامترها به شرح زیر است:

- واحدهای حافظهٔ بلندمدت – کوتاه‌مدت: [۲۵۶، ۱۲۸، ۶۴]
- تراکم لایه‌ها^۷: [۳۲، ۶۴، ۱۲۸]
- نرخ کاهش تصادفی^۸: [۰.۱، ۰.۳، ۰.۵]
- دوره‌ها^۹: [۱۵۰، ۱۰۰، ۵۰]

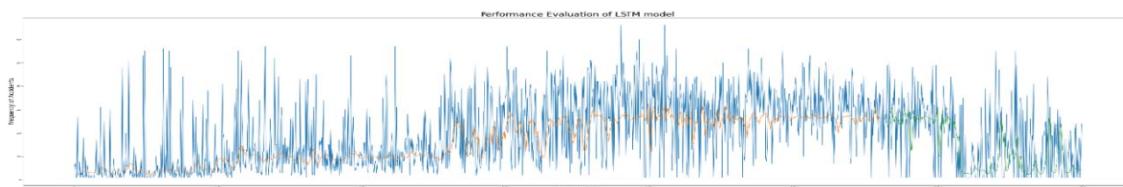
نتایج اجرای این رویکرد برای شناسایی مدل پیش‌بینی تعداد حوادث روزانه با خسارت جرحی در جدول بیان شده است.

-
1. Handling Missing Data
 2. Data Splitting
 3. Time Series Generator
 4. scikit-learn
 5. Keras/TensorFlow
 6. Cross Validation
 7. Dense Units
 8. Drop out
 9. Epochs

جدول ۲. نتایج جست‌وجوی شبکه‌ای

ابرپارامتر	تعداد واحداًها	تراکم لایه‌ها	نرخ کاهش تصادفی	دوره‌ها
عدد انتخاب شده	۱۲۸	۶۴	.۰/۲	۵۰

میزان خطای جذر میانگین مربعات برای مجموعه آموزش و مجموعه آزمون، به ترتیب $16/33$ و $15/12$ است. اگرچه از تکنیک کاهش تصادفی استفاده شده است؛ اما همچنان عدد خطای جذر میانگین مربعات این مدل در مجموعه آزمون پایین‌تر است که مشکل بیش‌برازش را نشان می‌دهد. موقع چنین حالتی گویای این موضوع است که در مدل، یادگیری از داده‌های آموزشی، بیش از میزانی که قابلیت عمومی‌سازی داشته باشد، رخ داده است. به عبارت دیگر، این مدل در مقابل داده‌هایی که قبلاً به کمک آن‌ها آموزش دیده است (داده‌های آموزشی) عملکرد عالی دارد؛ اما چهار مشکل در عمومی‌سازی به داده‌های جدید و ناآشنا (داده‌های آزمون) می‌شود. عملکرد پیش‌بینی مدل حافظه کوتاه‌مدت – بلندمدت در شکل ۳ به تصویر کشیده شده است:



شکل ۳. عملکرد آموزش و پیش‌بینی مدل پیش‌بینی تعداد روزانه حوادث بر اساس جست‌وجوی شبکه‌ای

عملکرد مدل بر مبنای جست‌وجوی تصادفی

تنظیم ابرپارامترها با استفاده از جست‌وجوی تصادفی به طور مکرر در مدل‌های حافظه بلندمدت – کوتاه‌مدت برای پیش‌بینی سری‌های زمانی استفاده می‌شود. رویکرد تصادفی برخلاف رویکرد شبکه‌ای که به صورت منظم و جامع ترکیب ابرپارامترها را بررسی می‌کند، در جست‌وجوی تصادفی انتخاب ترکیب ابرپارامترها با رویکردی تصادفی پیش می‌رود. این روش به طور تصادفی مقادیر ابرپارامترها را در محدوده‌های تعیین‌شده نمونه‌برداری شده و این امکان را فراهم است که به طریق مؤثری تنظیمات بهینه کشف شوند (زنگ، جی، یو و لیو، ۲۰۲۳).

در این پیمایش، به جای تعیین مقادیر ابرپارامترها، محدوده‌ای معادل با کمترین و بیشترین مقدار برای هر ابرپارامتر در تنظیمات جست‌وجوی شبکه‌ای تعریف می‌شود. محدوده جست‌وجو برای شناخت ابرپارامترهای مدل پیش‌بینی تعداد روزانه تصادفها به شرح زیر است:

- واحدهای حافظه بلندمدت – کوتاه‌مدت (۶۴، ۲۵۶)
- تراکم لایه‌ها: (۱۲۸، ۳۲)
- نرخ کاهش تصادفی: (۰.۱، ۰.۵)
- دوره‌ها: (۵۰، ۱۵۰)

پس از اجرای کد، نتایج حاصل، به شرح جدول ۳ به دست آمد.

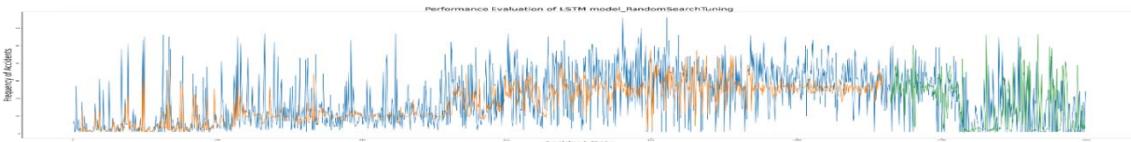
جدول ۳. نتایج جستوجوی تصادفی

دوره‌ها	نرخ کاهش تصادفی	تعداد لایه‌ها	تعداد واحداًها	ابرپارامتر
۱۳۵	۰/۱۴۰۴۰	۶۹	۲۴۹	عدد انتخاب شده

پس از اجرای مدل، برای ارزیابی عملکرد آن، نتیجهٔ خطای جذر میانگین مربعات محاسبه شده است برای داده‌های آموزش و آزمون، به ترتیب $17/49$ و $19/58$ گزارش شده است.

اعمال تکنیک کاهش تصادفی و استفاده از رویکرد جستوجوی تصادفی کاهش تأثیر بیش‌برازش کمک کرد. به عبارت دیگر، در این روش مقدار خطای جذر میانگین مربعات در مجموعه داده آزمون مقداری کمی بالاتر از مجموعه داده آموزش دارد. این اختلاف در ارزش خطای جذر میانگین مربعات نشان‌دهنده توانایی مدل در عمومی‌سازی و اثر موققیت‌آمیز تنظیم نرخ کاهش تصادفی داده‌های است؛ زیرا این تکنیک به‌طور مؤثری تمایل به بیش‌برازشی در مدل را کاهش داده و در عین حال عملکرد پیش‌بینی قابل قبولی را حفظ کرده است.

عملکرد مدل حافظه بلندمدت – کوتاه‌مدت طراحی شده با تنظیمات تصادفی ابرپارامترها در شکل ۴ تصویر شده است:



شکل ۴. عملکرد آموزش و پیش‌بینی مدل پیش‌بینی تعداد روزانه حوادث بر اساس جستوجوی تصادفی

یافته‌های پژوهش

در این پژوهش تمرکز بر توسعه مدل پیش‌بینی روزانه تصادف‌ها در رشتۀ بیمه شخص ثالث با خسارت‌های جانی است. برای این منظور از مدل حافظه بلندمدت – کوتاه‌مدت استفاده شده است. خروجی این مدل، به عنوان مکمل برای مدل سنتی نرdbانی در محاسبه و پیش‌بینی تعداد خسارت‌های واقع شده، اما گزارش نشده در صنعت بیمه کارایی دارد؛ زیرا علاوه‌بر قدرت پیش‌بینی بالا، متغیر زمان را نیز در پیش‌بینی وارد کرده است تا شرکت‌های بیمه بتوانند دید مناسبی از تعداد تصادف‌های روزانه داشته باشند و همچنین، منابع مالی خود را در بخش ذخایر به درستی مدیریت کنند.

برای معناری مدل، به شناخت پارامترها و ابرپارامترها نیاز بوده است. در بخش اول آموزش از طریق داده‌ها حاصل می‌شود. پس از آماده‌سازی داده‌ها، آن‌ها به دو بخش آموزش و آزمون دسته‌بندی شده و برای شناخت ابرپارامترها عملکرد دو روش جستوجوی شبکه‌ای و تصادفی با یکدیگر مقایسه شدند.

نتایج این کاوش نمایانگر توفیق روش جستوجوی تصادفی در مورد عملکرد مدل حافظه بلندمدت – کوتاه‌مدت در عمومی‌سازی و عملکرد روی داده‌های ناآشنا است. در نتیجه طراحی شبکه عصبی بر مبنای جستوجوی تصادفی، در

پیش‌بینی داده‌های ناآشنا قدرت بیشتری دارد و مدل مقاومتری طراحی شده است. این در حالی است که در مدل جست‌وجوی شبکه‌ای، چالش پیش‌بازش به وجود آمده بود.

چالش پیش‌بازش با استفاده از مشاهده خطای جذر میانگین مربعات در مجموعه داده‌های آزمون نسبت به مجموعه داده‌های آموزش نمایان شد ($15/12$ در مقابل $16/33$). کمتر بودن خطای جذر میانگین مربعات در مجموعه داده‌های آزمون نسبت به آموزش، بیانگر این مطلب است که مدل توانسته است الگوهای داده‌های آموزشی را حفظ کند، ولی در تطبیق با تغییرات در شرایط واقعی دچار مشکل است. این عدد برای جست‌وجوی تصادفی $19/8$ به دست‌آمده که بیشتر از مجموعه آموزشی، یعنی $17/4$ است. اختلاف مشاهده شده در عملکرد بین جست‌وجوی تصادفی و جست‌وجوی شبکه‌ای، اهمیت تکنیک‌های تنظیم ابرپارامتر در دستیابی به مدلی با عملکرد بالا و همچنین جامع پذیری را نشان می‌دهد.

نتیجه‌گیری و پیشنهادها

مفهوم بیمه و بیمه‌گری با مقوله پیش‌بینی و تصویر کردن آینده ارتباط مستقیم دارد. افزایش دقت و کاهش در انحراف پیش‌بینی‌ها، توفیق شرکت‌های بیمه را به همراه خواهد داشت. ذخایر از جمله مهم‌ترین شاخص‌های ارزیابی توانگری مالی شرکت‌های بیمه، نزد نهاد ناظر هستند. بنابراین ارتقای کیفی پیش‌بینی، می‌تواند نگاه قرین به واقعیتی از توانگری مالی شرکت بیمه برای نهاد ناظری ایجاد کند.

استفاده از مدل حافظه کوتاه‌مدت – بلندمدت، برای پیش‌بینی حوادث و محاسبه ذخایر لازم برای خسارت‌های واقع شده و گزارش نشده در شرکت‌های بیمه، می‌تواند با توجه به قدرت پیش‌بینی بالای این مدل، چشم‌انداز امیدوارکننده‌ای برای شرکت‌های بیمه ایجاد کند.

چالش با اهمیتی که سعی شد در این پژوهش به صورت متمرکز به آن پرداخته شود، طراحی و معماری مدل حافظه کوتاه‌مدت – بلندمدت، برای پیش‌بینی تعداد خسارت‌های واقع شده و گزارش نشده به شرکت‌های بیمه بود. برای طراحی مدل از دو روش متداول جست‌وجوی شبکه‌ای و تصادفی، برای بهینه‌کردن ابرپارامترها استفاده شده است. مقایسه عملکرد این دو روش با یکدیگر، می‌تواند به افزایش تفسیرپذیری مدل کمک کند و در شیوه طراحی شفافیت بیشتری به دنبال داشته باشد. یکی از ضعف‌های مهم در طراحی این مدل، چالش پیش‌بازش است. شناسایی ابرپارامترهای بهینه، سبب شد تا در نهایت مدلی طراحی شود که بتواند با داده‌های ناآشنا نیز عملکرد مناسبی داشته باشد. به‌منظور ارتقای مدل و بهینگی آن، می‌توان در پژوهش‌های آتی سایر روش‌های شناسایی ابرپارامترها را نیز آزمون کرد. الگوریتم ژنتیک و بیزین (باغبانی و اسکندری، ۱۳۹۶) از جمله این موارد هستند.

گام بعدی در مسیر توسعه مدل طراحی شده، افزایش پیچیدگی‌ها و استفاده از سری‌های زمانی چند متغیره است. در برخی از مقاله‌ها با هدف پیش‌بینی متغیرهای کلان اقتصادی یا سایر متغیرهای مالی که بر مبنای داده‌های سری زمانی

است، از الگوریتم حافظه کوتاه‌مدت - بلندمدت تودرتو^۱ (زيادی و همکاران، ۱۴۰۲) تبدیلی^۲ (احمدی و نبی‌زاده، ۱۴۰۲) استفاده شده است. علاوه‌بر توسعه مدل، می‌توان از داده‌های چندمتغیره نیز استفاده کرد. برای اعتبارسنجی، علاوه‌بر خطای جذر میانگین مربعات، از روش میانگین مطلق درصد خطای^۳ نیز استفاده شده است، نتایج حاصل از دقت بسیار خوب پیش‌بینی حکایت می‌کند. با توجه به خروجی مدل‌های طراحی شده، می‌توان مدل پیش‌بینی را علاوه‌بر تعداد حوادث، به مبلغ حوادث نیز توسعه داد تا شرکت‌های بیمه بتواند، از تعهداتی آتی خود نگاه نزدیک به واقعیتی داشته باشد. توسعه مدل می‌تواند توانایی شناخت الگوهای غیرعادی موجود در داده‌ها را نیز به همراه داشته باشد.

در توسعه مدل توجه به این نکته حائز اهمیت است که اگرچه شبکه عصبی حافظه بلندمدت - کوتاه‌مدت، به طور ذاتی وابستگی‌های زمانی را ضبط می‌کند، تطبیق یافته‌های آن با الگوهای فصلی پیچیده و روندهای طولانی‌مدت، می‌تواند برای شرکت‌های بیمه چالش برانگیز باشد. یکی از روش‌های توسعه مدل، بررسی مدل‌های ترکیبی حافظه کوتاه‌مدت بلندمدت با روش‌های دیگر سری زمانی، مانند مدل تجزیه و تحلیل متغیرهای هم‌دوره‌ای خودگرسیون متحرک^۴ یا الگوریتم پیش‌بین^۵ است (کارتیسری و ایمانی، ۲۰۱۸). یکی دیگر از موضوع‌های قابل بررسی در تحقیقات آتی، ترکیب شبکه عصبی و حافظه بلندمدت - کوتاه‌مدت با روش‌های یاد شده است؛ به گونه‌ای که بتوان از مزایای آن‌ها نیز بهره‌مند شد و قابلیت تفسیرپذیری مدل را ارتقا داد.

استفاده از مدل طراحی شده برای صنعت بیمه، می‌تواند کارکردهای دیگری در سایر حوزه‌ها داشته باشد که کیفیت عملکرد آن‌ها به پیش‌بینی حوادث وابسته است. برای نمونه، می‌توان به پیش‌بینی حوادث پُرتکرار طبیعی که چرخه تکرار آن‌ها به صورت موسمی است، اشاره کرد. دولت به عنوان متولی مدیریت بلایا و حوادث فاجعه‌آمیز، باید برای احراز مسئولیت‌های خود در این زمینه، پیش از وقوع حوادث برای منابع مالی مورد نیاز خود ارزیابی داشته باشد و این امر بدون داشتن نگاه مناسب به تواتر و شدت حوادثی از قبیل سیالابها یا آتش سوزی موسمی منابع طبیعی ممکن نخواهد بود. با این نگاه مدل پیشنهادی پیش‌رو، شباهت‌های ماهوی بسیاری با نیاز دولت در زمینه پیش‌بینی زمان وقوع حوادث پُرتکرار دارد تا بتواند منابع مالی مناسب (ذخایر) را به درستی شناسایی و هزینه کند. بنابراین می‌توان این مفهوم را با اطلاعات مربوط به میزان بارندگی که سیالاب‌های فصلی را به دنبال دارند یا شدت گرمای هوا که به آتش‌سوزی موسمی منجر می‌شوند، توسعه داد.

منابع

حاجی‌لو، ریحانه و کاظمی بوکانی، سید اسماعیل (۱۴۰۱). نقش هوش مصنوعی و سیستم‌های خبره در توسعه صنعت بیمه با رویکرد مرور ادبیات پژوهش. دهمین کنفرانس بین‌المللی پژوهش‌های نوین حسابداری، مدیریت و علوم انسانی در هزاره سوم، تهران.

- 1. stacked LSTM
- 2. Conventional LSTM
- 3. Mean Absolute Percentage Error
- 4. Seasonal Autoregressive Integrated Moving Average_SARIMA
- 5. Prophet

شریفی، مهدی؛ سربخشیان، احمد و رشیدی، آیدین (۱۳۹۷). کاربرد الگوریتم‌های یادگیری ماشینی در پیش‌بینی ریسک بیمه‌های زندگی. *بیست و پنجمین همایش ملی بیمه و توسعه*. تهران، ایران.

احمدی، سیما و نبی‌زاده، علی (۱۴۰۲). استفاده از مدل حافظه طولانی کوتاه‌مدت پیچشی برای پیش‌بینی سیلاپ در استان گلستان، ایران. *نشریه علمی پژوهشی سنجش از دور و اطلاعات مکانی*، ۱(۲)، ۲۳۹-۲۴۶.

شهرابی، بابک، رئیسی وانانی، ایمان و قانونی شیشوان، وحیده (۱۳۹۴). ارزیابی عملکرد شرکت‌ها و تحلیل روندهای مالیاتی با استفاده از الگوریتم داده‌کاوی. *تحقیقات مالی*، ۱۷(۲)، ۲۱۹-۲۳۸.

عباسیان، عزت‌الله؛ ابراهیمی، محسن و فرزانگان، الهام (۱۳۹۴). طراحی بهینه اوراق بهادارسازی در رابطه کارفرما-کارگزار براساس رویکرد استنباط بیزین از مخاطره اخلاقی. *تحقیقات مالی*، ۱۷(۱)، ۱۲۳-۱۴۰.

باغبانی، غزاله و اسکندری، فرزاد (۱۳۹۶). برآورد وجه نقد ورودی و خروجی شعب بانک تجارت برای محاسبه وجه نقد مورد نیاز شعبه با استفاده از تحلیل چندمتغیره خوشبندی بیزین و پیاده‌سازی آن در شبکه‌های عصبی. *تحقیقات مالی*، ۱۹(۱)، ۴۱-۵۷.

زیادی، حسین؛ صلواتی، عرفان و لطفی هروی، محمد‌مهدی (۱۴۰۲). پیش‌بینی قیمت مسکن با استفاده از الگوریتم هوش مصنوعی LSTM. *تحقیقات مالی*، ۲۵(۴)، ۵۵۷-۵۷۶.

References

- Abbasian, E., Ebrahimi, M. & Farzanegan, E. (2015). Optimal design of securitization in a principal-agent relationship based on Bayesian inference for moral hazard. *Financial Research Journal*, 17(1), 123-140. doi: 10.22059/jfr.2015.50708 (in Persian)
- Ahmadi, S., & Nabizadeh, A. (2023). Using Convolutional Long Short-Term Memory Model for Flood Prediction in Golestan Province, Iran. *Journal of Remote Sensing and Geoinformation Research*, 1(2), 239-246. doi: 10.22061/jrsgr.2023.2021 (in Persian)
- Araujo, J., Patnam, M., Popescu, A., Valencia, F., & Yao, W. (2024). Effects of macroprudential policy: Evidence from over 6000 estimates. *Journal of Banking & Finance*, 169, 107273.
- Avanzi, B., Wong, B. & Yang, X. (2016). A micro-level claim count model with overdispersion and reporting delays. *Insurance: Mathematics and Economics*, 71, 1-14.
- Baghbabi, G. & Eskandari, F. (2017). Estimation of Input & Output Cash of Tejarat Branches in order to Calculate Branches' Required Cash Via Multivariate Bayesian Clustering Analysis and the Implementation in Neural Network. *Financial Research Journal*, 19(1), 41-60. doi: 10.22059/jfr.2017.60152 (in Persian)
- Balona, C., & Richman, R. (2020). The actuary and IBNR techniques: A machine learning approach. Available at SSRN 3697256.

- Bellec, G., Salaj, D., Subramoney, A., Legenstein, R., & Maass, W. (2018). Long short-term memory and learning-to-learn in networks of spiking neurons. *Advances in neural information processing systems*, 31.
- Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13(2).
- Blier-Wong, C., Cossette, H., Lamontagne, L., & Marceau, E. (2020). Machine learning in P&C insurance: A review for pricing and reserving. *Risks*, 9(1), 4.
- Bolancé, C. & Vernic, R. (2020). Frequency and severity dependence in the collective risk model: an approach based on Sarmanov distribution. *Mathematics*, 8(9), 1400.
- Brownlee, J. (2018). How to develop LSTM models for time series forecasting. *Machine learning mastery*, 14.
- Brownlee, J. (2019). How to Prepare Univariate Time Series Data for Long Short-Term Memory Networks. *Deep Learning for Time Series*.
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? *Model Development Discussion*, 7(3), 1247-1250.
- Chen, G. (2018). *A Gentle Tutorial of Recurrent Neural Network with Error Backpropagation*. arXiv:1801.01078, 1-10.
- Cheng, G., Peddinti, V., Povey, D., Manohar, V., Khudanpur, S., & Yan, Y. (2017, August). An Exploration of Dropout with LSTMs. In *Interspeech* (pp. 1586-1590).
- Crevecoeur, J., Antonio, K. & Verbelen, R. (2019). Modeling the number of hidden events subject to observation delay. *European Journal of Operational Research*, 277(3), 930-944.
- De Felice, M., & Moriconi, F. (2019). Claim watching and individual claims reserving using classification and regression trees. *Risks*, 7(4), 102.
- Ding, G. & Qin, L. (2020). Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 11(6), 1307-1317.
- Elsworth, S., & Güttel, S. (2020). Time series forecasting using LSTM networks: A symbolic approach. *arXiv preprint arXiv:2003.05672*.
- Embrechts, P., Mao, T., Wang, Q., & Wang, R. (2021). Bayes risk, elicibility, and the Expected Shortfall. *Mathematical Finance*, 31(4), 1190-1217.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *Automated machine learning: Methods, systems, challenges*, 3-33.
- Frees, E. W., Derrig, R. A., & Meyers, G. (Eds.). (2014). *Predictive modeling applications in actuarial science* (Vol. 1). Cambridge University Press.
- Fröhlich, A., & Weng, A. (2018). Parameter uncertainty and reserve risk under Solvency II. *Insurance: Mathematics and Economics*, 81, 130-141.

- Gabrielli, A., Richman, R., & Wüthrich, M. V. (2020). Neural network embedding of the over-dispersed Poisson reserving model. *Scandinavian Actuarial Journal*, 2020(1), 1-29.
- Gelman, L. (2012). Gradient boosting trees for auto insurance loss cost modeling and prediction. *Expert Systems with Applications*, 39(3), 3659-3667.
- Hajilo, R. & Kazemi Boukani, S.E. (2021). The role of artificial intelligence and expert systems in the development of the insurance industry with a literature review approach. *The 10th International Conference on Modern Research in Accounting, Management and Humanities in the Third Millennium*. Tehran. (in Persian)
- Halliwell, L. (2020). Chain Ladder Bias: Its Reason and Meaning. *Casualty Actuarial Society*, 1(2), 214-248.
- Hazan, E. & Yang Yuan, K. (2018). Hyperparameter Optimization. *ICLR*, 1-18.
- Hochreiter, J. (1997). Long short-term memory. *Neural Computation*, MIT Ress.
- Kartikasari, M. D., & Imani, N. (2018). Time Series Analysis of Claims Reserve in General Insurance Industry. *The 8th Annual Basic Science International Conference* (pp. 227-233). Maglang, Indonesia: ISSN.
- Khalid, R., & Javaid, N. (2020). A survey on hyperparameters optimization algorithms of forecasting models in smart grid. *Sustainable Cities and Society*, 61, 102275.
- Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia Cirp*, 99, 650-655.
- Merity, S., Keskar, N. S., & Socher, R. (2017). *Regularizing and optimizing LSTM language models*. arXiv preprint arXiv:1708.02182.
- Peixeiro, M. (2022). *Time Series Forecasting in Python*. NY: Manning.
- Peterson, T. (1984). Loss Reserving. Property/Casualty Insurance. *The Journal of Risk and Insurance*, 114-121.
- Poufinas, T., Gogas, P., Papadimitriou, T., & Zaganidis, E. (2023). Machine learning in forecasting motor insurance claims. *Risks*, 11(9), 164.
- Sharifi, M., Sarbakhshian, A. & Rashidi, A. (2018). Application of machine learning algorithms in life insurance risk prediction. *25th National Conference on Insurance and Development*. Tehran, Iran. (in Persian)
- Sohrabi, B., Raeisi Vanani, I. & Ghanooni Shishone, V. (2015). Evaluating the Corporate Tax Performance and Analyzing the Tax Trends through the Utilization of Data Mining Algorithms. *Financial Research Journal*, 17(2), 219-238. doi: 10.22059/jfr.2015.57311 (in Persian)
- Taye, M. M. (2023). Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*, 12(5), 91.
- Taylor, G. & McGuire, G. (2016). Stochastic loss reserving using generalized linear models. CAS Monograph, 3, 1-112.
- Weindorfer, B. (2012). *A Practical guide to the use of the Chain Ladder Method for*

- Determining technical provisions for outstanding claims in non life insurance.* University of Applied Sciences of Vienna.
- Wüthrich, M. (2018). Neural networks applied to chain-ladder reserving. *European Actuar Journal*, 8, 407–436.
- Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100.
- Yilmaz, D., & Büyüktakın, İ. E. (2023, June). Learning optimal solutions via an LSTM-optimization framework. In *Operations Research Forum* (Vol. 4, No. 2, p. 48). Cham: Springer International Publishing.
- Zhang, L., Ji, T., Yu, S., & Liu, G. (2023). Accurate prediction approach of SOH for lithium-ion batteries based on LSTM method. *Batteries*, 9(3), 177.
- Ziyadi, H. , Salavati, E. , & Lotfi Heravi, M. M. (2023). Housing Price Forecasting Using AI (LSTM). *Financial Research Journal*, 25(4), 557-576. doi: 10.22059/frj.2023.349924.1007398 (in Persian)