

# Predicting damage using sequential deep regression techniques in deep learning methods

**F. m.patastsh<sup>1,\*</sup>, z.beheshti<sup>2</sup>, a.raad<sup>3</sup>**

*1 Department of Computer Engineering, Technical and Engineering Faculty, South Tehran Azad University, Tehran, Iran*

*2 Department of Computer Engineering, Technical and Engineering Faculty, South Tehran Azad University, Tehran, Iran*

*3 Department of Management, University of Management and Accounting, Shahid Beheshti University, Tehran, Iran*

## **Abstract**

**Objective:** One of the important challenges of insurance companies is to determine the optimal rate for property insurance policies such as cars and fire. If the insurance company can detect the possibility of damage in an insurance policy, it will have effective and better decisions in determining the insurance rate, the amount of discount allocated to the insurance policy, or the decision regarding the extension of that insurance policy. Insurance companies and experts in the field of issuing and claims are looking for new methods to assess the risk of customers and insurance policies by predicting the occurrence of possible losses in this field. Traditional methods such as general linear models often fail to identify complex patterns in insurance data. Deep learning, with the ability to identify nonlinear relationships and complex patterns, can overcome these limitations. In this paper, a method to improve the performance of deep learning using sequential deep regression techniques is presented. The proposed approach is a combination of deep learning and sequential models. Long Short Term Memory (LSTM) networks are used to model time series data.

**Methodology:** In this article, the data of the last 7 years of the field of fire insurance issuance and loss of Alborz Insurance Company have been used to examine and predict the loss in this field. In this article, focusing on data pre-processing and extracting the best features. In order to provide the best result and after applying different methods of feature extraction, finally, 20 features were selected from a total of 40 selected features and then trained using deep learning. The proposed approach uses a combination of deep learning and sequential models using networks (LSTM) to model time series data.

**Findings:** In this article, by examining different machine learning methods on the insurance company's issuance and loss data, it was concluded that the ordinal deep regression model performs better than the traditional methods. Improved prediction accuracy, higher reliability and emphasis on the importance of temporal features are key results.

**Result:** In order to predict the occurrence of damage in fire insurance, the 7-year loss and issuance information of Alborz Insurance Company was used with confidentiality, and the combined method of deep learning and sequential models was used, which has more accuracy and results than the previous methods. It was better.

**Keywords:** insurance, fire damage, deep learning, machine learning

# پیش بینی خسارت با استفاده از تکنیک های رگرسیون عمیق ترتیبی در روش های یادگیری عمیق

مونا پرستش<sup>۱\*</sup>، ضیاءالدین بهشتی<sup>۲</sup>، عباس راد<sup>۳</sup>

۱ گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد تهران جنوب، تهران، ایران

۲ گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد تهران جنوب، تهران، ایران

۳ گروه مدیریت، دانشکده ی مدیریت و حسابداری دانشگاه شهید بهشتی، تهران، ایران

## چکیده

هدف: یکی از چالش های مهم شرکت های بیمه، تعیین نرخ بهینه بیمه نامه های اموال مانند اتومبیل و آتش سوزی است. اگر شرکت بیمه بتواند امکان وقوع خسارت را در یک بیمه نامه تشخیص دهد، تصمیمات موثر و بهتری در تعیین نرخ بیمه، میزان تخفیف اختصاص یافته به بیمه نامه و یا تصمیم در مورد تمدید آن بیمه نامه خواهد داشت. شرکت های بیمه و خبرگان رشته صدور و خسارت، به دنبال روش های نوین جهت ارزیابی ریسک مشتریان و بیمه نامه ها از طریق پیش بینی وقوع خسارات احتمالی در این رشته هستند. (Manavi-f & etc, 2020) روش های سنتی مانند مدل های خطی عمومی (GLMs) اغلب در شناسایی الگوهای پیچیده در داده های بیمه ناکام هستند. یادگیری عمیق، با توانایی شناسایی روابط غیرخطی و الگوهای پیچیده، می تواند این محدودیت ها را رفع کند. در این مقاله روشی برای بهبود عملکرد یادگیری عمیق با استفاده از تکنیک های رگرسیون عمیق ترتیبی<sup>۲</sup> ارائه شده است. رویکرد پیشنهادی ترکیبی از یادگیری عمیق و مدل های ترتیبی است. از شبکه های حافظه طولانی کوتاه مدت (LSTM)<sup>۳</sup> برای مدل سازی داده های سری زمانی استفاده می شود.

روش شناسی: در این مقاله از داده های ۷ سال اخیر صدور و خسارت بیمه آتش سوزی شرکت بیمه البرز جهت بررسی و پیش بینی خسارت در این رشته استفاده شده است. در این مقاله با تمرکز روی پیش پردازش داده ها و استخراج ویژگی های برتر جهت ارائه بهترین نتیجه و پس از اعمال روش های مختلف استخراج ویژگی، در نهایت از مجموع ۴۰ ویژگی انتخابی، ۲۰ ویژگی

<sup>1</sup> Generalized Linear Models

<sup>2</sup> Sequential Deep Regression

<sup>3</sup> Long short-term memory

انتخاب و سپس با استفاده یادگیری عمیق آموزش داده شد. رویکرد پیشنهادی، ترکیبی از یادگیری عمیق و مدل‌های ترتیبی با استفاده از شبکه‌های را (LSTM) را برای مدل‌سازی داده‌های سری زمانی استفاده می‌کند.

**یافته‌ها:** در این مقاله و با بررسی روش‌های مختلف یادگیری ماشینی روی داده‌های صدور و خسارت شرکت بیمه، این نتیجه بدست آمد که مدل رگرسیون عمیق ترتیبی نسبت به روش‌های سنتی عملکرد بهتری دارد. بهبود دقت پیش‌بینی، قابلیت اطمینان بالاتر و تاکید بر اهمیت ویژگی‌های زمانی از نتایج کلیدی هستند.

**نتیجه:** جهت پیش‌بینی وقوع خسارت در بیمه‌های آتش‌سوزی، از اطلاعات صدور و خسارت ۷ ساله شرکت بیمه البرز با حفظ محرمانگی استفاده شده است. در این تحقیق از ترکیب روش‌های یادگیری عمیق و مدل‌های ترتیبی استفاده شده که از روش‌های قبلی دارای دقت و نتایج بهتری می‌باشد.

**کلمات کلیدی:** بیمه، خسارت آتش‌سوزی، یادگیری عمیق، یادگیری ماشینی

## مقدمه

امروزه نقش صنعت بیمه در حال تغییر است. به این دلیل که شرکت‌ها از روش‌های تحلیلی جدید برای پیش‌بینی خسارت و ریسک استفاده می‌کنند و این روش‌ها به آن‌ها در بررسی ریسک موجود کمک خواهد کرد. در عصر حاضر مدل‌های کسب و کار سنتی و روش‌های قدیمی همواره از جانب تکنولوژی در معرض تهدید بوده‌اند. شرکت‌های بیمه‌ای جدید از قدرت تکنولوژی‌های نوآورانه استفاده می‌کنند تا رهبران همیشگی بازار بیمه را از بین ببرند. حمایت و حفاظتی که در مقابل ریسک‌ها از بیمه‌گذار می‌شود و راه‌حل‌های پیشنهادی که برای مقابله با ریسک ارائه می‌گردد، از طریق سرویس‌هایی که برای شناسایی ریسک‌های احتمالی طراحی شده بدست می‌آیند و این سرویس‌ها می‌توانند جهت هشدار خطر (در موارد پر ریسک) بکار گرفته شوند؛ در نتیجه این سرویس‌ها مهم‌ترین وجه تمایز این شرکت‌ها و کلید موفقیت آن‌ها در آینده خواهد بود. هوش مصنوعی قوی و تحلیل حجم زیادی از اطلاعات داده‌های حجیم<sup>۱</sup> به بیمه‌گران این قدرت را می‌دهد که به سمت پیش‌بینی خسارت و حوادث حرکت کنند. هر چه میزان اطلاعاتی که شرکت‌های بیمه از بیمه‌گذاران در اختیار دارند بیشتر باشد، آن‌ها قادر خواهند بود از این اطلاعات ارزشمند برای پیش‌بینی رفتار بیمه‌گذاران استفاده کرده و برای هر بیمه‌گذار فایلی از اطلاعات گذشته او تهیه کنند تا به این وسیله حجم خسارات و ریسک را کاهش دهند. می‌توان گفت شرکت‌های بیمه‌ای که بخش عظیمی از تکنولوژی‌های نوآورانه را به خدمت می‌گیرند، فرصت رشد بسیار زیادی در اختیار دارند. اما شرکت‌های بیمه‌ای که برای تعیین حق بیمه به سوالات ساده‌ای مثل سن، جنسیت و شغل بسنده می‌کنند، بعید است در عصر دیجیتال و با پیشرفت اینسورتهک بتوانند به کار خود ادامه دهند. در حقیقت اگر بیمه‌گران «تحلیل‌های بینانه» را به کار نبرند و سیستم سنتی گذشته را اعمال کنند، در مقایسه با شرکت‌های نوآور در پرداخت خسارات دچار تأخیر بیشتری می‌شوند. همین امر باعث می‌شود شرکت‌هایی که این سیستم را در کار خود اعمال کرده‌اند، مشتریان بیشتری جذب نموده و در طولانی مدت

<sup>1</sup> Big Data

طیف وسیعی از بیمه‌گذاران را دربرگیرند. داده‌های بیمه‌ای اغلب شامل روابط غیرخطی و پیچیده‌ای هستند که مدل‌های رگرسیون ساده مانند رگرسیون خطی، درخت تصمیم و .. قادر به درک و مدل‌سازی کامل آن‌ها نیستند. همچنین این شرکت‌ها با حجم وسیع داده مواجه‌اند. در نتیجه به دنبال راهی برای بهبود این روش‌ها با استفاده از روش‌های نوین تر مانند یادگیری عمیق هستیم. زیرا شبکه‌های عصبی عمیق می‌توانند روابط پیچیده بین داده‌های بیمه‌ای را با دقت بیشتری شناسایی کنند، توانایی پردازش و تحلیل بیشتری روی این داده‌های بزرگ دارند و می‌توانند الگوهای مخفی در آن‌ها را کشف کنند.

## مبانی نظری پژوهشی

### ارزیابی ریسک بیمه

صنعت بیمه کشور را میتوان به عنوان یک موسسه بیمه بزرگ فرض کرد که در همه رشته‌های فعالیتهای بیمه‌ای مختلف فعالیت دارد. اگر بخواهیم تجمیع ریسکهای بیمه‌گری را برای یک موسسه بیمه معین انجام دهیم ممکن است آن موسسه بیمه در همه رشته‌های فعالیتهای بیمه‌ای فعالیت نداشته باشد؛ بنابراین در این حالت امکان مدل‌سازی ساختار وابستگی بین ریسکهای بیمه‌گری همه رشته‌های فعالیتهای بیمه‌ای با داده‌های آن موسسه بیمه میسر نخواهد بود. البته مشابه همین تحقیق را میتوان برای هر موسسه بیمه فرضی با داده‌های مربوطه انجام داد و از نتایج آن بهره برد.

منظور از ریسک بیمه‌گری، ریسک‌هایی است که موسسه بیمه به دلیل صدور بیمه‌نامه یا قبول اتکایی با آن مواجه است<sup>۱</sup>. موسسات بیمه با صدور بیمه‌نامه و در قبال دریافت حق بیمه از مشتریان متعهد میشوند که به هنگام وقوع خطرات تحت پوشش بیمه، زیان وارده به مشتریان و بیمه‌گران خود را جبران نمایند و به آنها خسارت پرداخت کنند. این موسسات به منظور اطمینان از توانایی مالی خود در انجام تعهدات و پرداخت خسارت در دوره جاری و دوره‌های آتی، بخشی از درآمد حق بیمه را به صورت ذخایر بیمه‌ای<sup>۲</sup> نگهداری میکنند؛ سپس از محل این ذخایر، دارائیهای سرمایه‌گذاری را می‌خرند. عدم کفایت دارائیهها و وجوه نقدشیرکت در پرداخت خسارت مشتریان، آسیب بزرگی به تداوم فعالیت موسسه بیمه خواهد زد و در ادبیات بیمه به این وضعیت "عدم

توانگری مالی"<sup>۳</sup> گفته میشود

ارزیابی ریسک برای بیمه‌نامه‌ها، باتوجه به اطلاعات خسارت‌های قبلی علاوه بر اطلاعات بیمه‌نامه، بعنوان اقلام اطلاعاتی مؤثر، روشی کلیدی برای شرکت‌های بیمه است. مثلاً در بیمه اتومبیل اگر فقط پرداخت خسارت برای یک بیمه‌نامه را بررسی کنیم، قطعاً برای ارزیابی ریسک نامناسب و کاملاً نادقیق است. درحالیکه اگر این ارزیابی ریسک خسارت بر روی ۱۰۰ هزار بیمه‌نامه مشابه قبلی انجام شود، می‌تواند برای ارزیابی و پیش‌بینی با دقت قابل قبولی استفاده شود (Lentz et al., 2015).

2015)

۱. تقسیم کرده است «ریسک بیمه غیرزندگی» و «ریسک بیمه‌گری را به دو دسته» ریسک بیمه زندگی (IAA) انجمن بین‌المللی اکچوئری

۲ Technical provisions

۳ Insolvency

## پیش بینی خسارت و روش های یادگیری ماشینی

برای پیش بینی خسارت در صنعت بیمه، روش های یادگیری ماشینی مختلفی استفاده می شود که هر کدام ویژگی ها و مزایا خود را دارند. در اینجا چند نمونه از این روش ها را بررسی می کنیم. بصورت کلی می توان این روش ها را بصورت زیر تقسیم بندی کرد:

### ۱. روش های خوشه بندی<sup>۱</sup>:

این روش ها برای تشخیص الگوهای مشابه در داده ها و گروه بندی خطرات مورد استفاده قرار می گیرند. هدف اصلی این است که داده ها درون هر خوشه به طور مشابهی عمل کنند و خوشه ها با یکدیگر متفاوت باشند. خوشه بندی می تواند به شناسایی الگوها و روابط پنهان در داده ها کمک کند که از طریق روش های سنتی مشخص نمی شوند. با استفاده از خوشه بندی می توان ابعاد داده را کاهش داد و به تحلیل و تفسیر آن ها کمک کرد. با تفکیک مشتریان یا پرونده ها بر اساس خطرات مشابه، بیمه گذاران می توانند بهتر مدیریت ریسک کنند، و از مزایای آن امکان شناسایی گروه های خطرات مشابه، کاهش تقلب و مدیریت بهتر ریسک است. جهت انجام خوشه بندی اولین مرحله انتخاب یک الگوریتم خوشه بندی، مانند k-means یا hierarchical clustering است. سپس معمولاً نیاز به تعیین تعداد خوشه ها است که بهترین انتخاب بر اساس معیارهایی مانند ضریب سیلوئت<sup>۲</sup> می باشد. (Sen Hu & etc 2020)

### ۲. روش های آماری پیشرفته<sup>۳</sup>:

این روش ها معمولاً بر پایه تکنیک های آماری پیچیده تری از جمله رگرسیون خطی یا غیرخطی، تحلیل عاملی، تحلیل خوشه ای و غیره می باشند. این روش ها برای تحلیل دقیق داده ها و استخراج اطلاعات کلیدی برای پیش بینی خسارت مورد استفاده قرار می گیرند. از جمله این روش ها، روش های رگرسیون خطی، غیر خطی و با تحلیل های خوشه ای می باشند. از این روش ها جهت کاهش ابعاد و تحلیل ساختاری و همچنین امکان مدیریت بهتر ریسک ها استفاده می شود. این روش ها به دلیل توانایی شان در تحلیل دقیق داده های پیچیده و شناسایی الگوهای پنهان، از اهمیت ویژه ای برخوردارند و در صنعت بیمه بهبود قابل توجهی را در فرآیندهای تصمیم گیری و مدیریت ریسک به ارمغان آورده اند. و در زمینه های مدل سازی و پیش بینی خسارت ها، تحلیل ریسک های مختلف، بهینه سازی قیمت گذاری بیمه و کاهش تقلب و بهبود مدیریت ریسک ها قابل استفاده هستند.

(Jing, L & etc, 2017)

---

<sup>1</sup> Clustering Methods

<sup>2</sup> Silhouette Coefficient

<sup>3</sup> Advanced Statistical Methods

برخی روش های مهم آماری پیشرفته :

- رگرسیون خطی و غیرخطی<sup>۱</sup> : مدل سازی رابطه بین خسارت و متغیرهای تأثیرگذار
- تحلیل عاملی<sup>۲</sup> : کاهش ابعاد داده و استخراج متغیرهای کلیدی
- تحلیل خوشه ای<sup>۳</sup> : تقسیم بندی مشتریان بر اساس ویژگی های مشابه

### ۳. روش های مبتنی بر مدل<sup>۴</sup>

این روش ها شامل الگوریتم هایی هستند که بر اساس داده های آموزشی، یک مدل ساختاریافته برای پیش بینی و تحلیل ریسک های بیمه ای ایجاد می کنند.

- درخت تصمیم (Decision Trees - DTs)

درخت تصمیم یک مدل یادگیری ماشینی است که به صورت یک ساختار درختی تصمیم گیری را از داده های آموزشی یاد می گیرد. این درخت از گره ها و لبه هایی تشکیل شده است که هر گره نماینده یک ویژگی از داده و هر لبه نماینده یک تصمیم یا یک شاخه از گره ها است. در پایان هر شاخه (یعنی برگ درخت)، یک پیش بینی یا یک کلاس برای داده های ورودی قرار می گیرد. و شامل مراحل انتخاب ویژگی، که در آن بر اساس معیارهایی مانند انترپی<sup>۵</sup>، یا بهره اطلاعاتی<sup>۶</sup>، بهترین ویژگی برای جدا کردن داده ها از یکدیگر انتخاب می شود، تقسیم داده که در آن داده ها بر اساس مقدار بهترین ویژگی به دو یا چند زیرمجموعه تقسیم می شوند. و مرحله ساخت درخت است که این فرآیند به صورت بازگشتی ادامه می یابد تا زمانی که یک شرایط پایانی برقرار شود، مانند رسیدن به یک حداقل تعداد نمونه در هر برگ یا عمق معین درخت. این الگوریتم ها به خوبی در تحلیل ریسک و تصمیم گیری در مورد قیمت گذاری بیمه و تخصیص سرمایه مورد استفاده قرار می گیرند. از مزایای آن می توان به قابلیت توضیح پذیری بالا، قابلیت ارزیابی دقیق ریسک ها، و قابلیت استفاده از ویژگی های مختلف داده اشاره کرد (Hanafy, M.& etc 2021)

---

<sup>1</sup> Linear & Nonlinear Regression

<sup>2</sup> Factor Analysis

<sup>3</sup> Cluster Analysis

<sup>4</sup> Model-Based Methods

<sup>5</sup> Entropy

<sup>6</sup> Information gain

## • ماشین بردار پشتیبان<sup>۱</sup> (SVMs)

SVM از مرزهای تصمیم‌گیری<sup>۲</sup> برای تفکیک داده‌ها استفاده می‌کند و برای دسته‌بندی بیمه‌گذاران و تحلیل رفتارهای تقلبی مناسب است

### SVM خطی<sup>۳</sup>:

زمانی که داده‌ها به صورت خطی جداپذیر هستند، SVM یک خط (در دو بعد) یا یک ابرصفحه (در ابعاد بالاتر) را برای تفکیک کلاس‌ها پیدا می‌کند.

### SVM غیر خطی<sup>۴</sup>:

وقتی داده‌ها خطی جداپذیر نیستند، از توابع کرنل<sup>۵</sup> استفاده می‌شود تا داده‌ها را به یک فضای بعد-بالا<sup>۶</sup> نگاشت کند.

### کاربردها در بیمه:

- ✓ کشف تقلب در بیمه‌های سلامت و خودرو
- ✓ دسته‌بندی مشتریان بر اساس ریسک
- ✓ پیش‌بینی نرخ خسارت بر اساس داده‌های تاریخی (Cortes, C & etc 1995)

## ۴. شبکه‌های عصبی مصنوعی<sup>۷</sup> (ANN)

این روش‌ها مدل‌هایی محاسباتی الهام‌گرفته از عملکرد مغز انسان هستند که توانایی یادگیری روابط پیچیده، تحلیل داده‌های غیرخطی، و کشف الگوهای پنهان را دارند. شبکه‌های عصبی در بیمه برای پیش‌بینی خسارت، کشف تقلب، و بهینه‌سازی فرآیندهای بیمه‌ای استفاده می‌شوند.

### انواع مهم شبکه‌های عصبی:

- شبکه‌های عصبی پیش‌خور<sup>۸</sup>: (FNNs) مدل‌سازی ارتباط غیرخطی بین ویژگی‌های بیمه‌ای و خسارت
- شبکه‌های عصبی بازگشتی: (RNNs) مناسب برای تحلیل داده‌های سری زمانی بیمه‌ای

<sup>1</sup> Support Vector Machines

<sup>2</sup> Hyperplanes

<sup>3</sup> Linear SVM

<sup>4</sup> Non-Linear SVM

<sup>5</sup> Kernel Functions

<sup>6</sup> Higher- Dimensional Space

<sup>7</sup> Artificial Neural Networks

<sup>8</sup> Feedforward Neural Networks

- شبکه‌های عصبی کانولوشن<sup>۱</sup>: (CNNs) کاربرد در پردازش تصاویر خسارت بیمه‌ای

(Alexandru Grigore & etc 2022)

## ۵. شبکه‌های عصبی عمیق: (Deep Neural Networks - DNNs)

این مدل‌ها نسخه پیشرفته‌تری از شبکه‌های عصبی هستند که شامل لایه‌های متعدد پردازشی برای استخراج ویژگی‌های پیچیده و یادگیری الگوهای پیچیده‌تر می‌شوند. این مدل‌ها با الهام از ساختار مغز انسان، از شبکه‌های عصبی مصنوعی چندلایه برای یادگیری الگوهای پیچیده در داده‌ها استفاده می‌کند. این روش توانایی بسیار بالایی در پردازش داده‌های حجیم، شناسایی روابط پنهان و انجام پیش‌بینی‌های دقیق دارد. به وسیله این شبکه، یادگیری ویژگی‌ها به صورت خودکار، بدون نیاز به مهندسی ویژگی می‌تواند انجام شود. شبکه‌های عصبی عمیق (DNNs) از لایه‌های متعددی از نورون‌ها تشکیل شده‌اند:

لایه ورودی<sup>۲</sup>: داده‌های خام را دریافت می‌کند (مثلاً تصاویر بیمه‌ای، داده‌های مشتریان)

لایه‌های پنهان<sup>۳</sup>: شامل چندین نورون که وزن‌های ورودی را پردازش می‌کنند و ویژگی‌های پیچیده را استخراج می‌کنند.

لایه خروجی<sup>۴</sup>: نتیجه نهایی را تولید می‌کند (مثلاً پیش‌بینی خسارت بیمه‌ای یا تشخیص تقلب

(He, K & etc, 2022)

این روش‌ها هر کدام با ویژگی‌ها و مزایای خود، در پیش‌بینی خسارت در صنعت بیمه اهمیت دارند و بسته به نیازهای خاص شرکت‌های بیمه و نوع داده‌های موجود، انتخاب می‌شوند.

## پیشینه پژوهش

در سالهای اخیر و مورد توجه قرار گرفتن روش‌های هوش مصنوعی و یادگیری ماشین، تمایل به استفاده از الگوریتم‌های یادگیری ماشین در صنعت بیمه نیز افزایش یافته و در تحقیق‌های متعددی جهت خوشه‌بندی مشتریان، پیش‌بینی خسارت و ارزیابی ریسک، نرخ‌دهی مناسب و .. از این روش‌ها استفاده نموده‌اند. برخی از پژوهش‌های انجام شده در سالهای اخیر در زیر بررسی می‌شود:

ریسی و انایی و همکاران (۱۴۰۲) در پژوهشی برای پیش‌بینی خسارت رشته آتش‌سوزی از روش‌های یادگیری ماشین و همچنین در نهایت از یادگیری عمیق استفاده کردند که در نهایت در قالب برنامه‌ای، ورودی‌هایی از بیمه‌نامه را دریافت و پیش‌بینی احتمال وقوع خسارت را به کاربران بر میگرداند. معنوی و همکاران (۱۴۰۰) در تحقیقی یک روش برای پیش‌بینی امکان رخداد خسارت در بیمه‌نامه‌های شخص ثالث اتومبیل ارائه کردند. در روش پیشنهادی از روش‌های یادگیری ماشین استفاده شده و پس از استخراج ویژگی‌های موثر برای تشخیص خسارت یا عدم خسارت از بیمه‌نامه‌ها، به کمک روش‌های یادگیری ماشین و ویژگی

<sup>1</sup> Convolutional Neural Networks

<sup>2</sup> Input Layer

<sup>3</sup> Hidden Layer

<sup>4</sup> Output Layer



های بدست آمده یک مدل پیش بینی امکان وقوع خسارت، آموزش داده می شود. که در نهایت با استفاده از این مدل می توان در زمان فروش بیمه نامه امکان وقوع خسارت و ریسک فروش بیمه نامه را پیش بینی کرد.

تجددی نودهی و دیگران (۱۴۰۲) از یادگیری جمعی برای ترکیب روش های رگرسیون متعدد، مانند رگرسیون لجستیک، شبکه های عصبی برای پیش بینی هزینه های درمانی بیمه گزاران استفاده کردند .

(Sundarkumar.G & etc 2015) یک روش ترکیبی برای مسائل با داده های غیرمتوازن ارائه کردند، که قادر به کشف خودکار کلاهبرداری ها در شرکت های بیمه می باشد. (Thakur and Sing 2013) مطالعه ای بر روی مشتریان بیمه خودرو انجام داده و از الگوریتم بهبود یافته تری نسبت به روش k-means استفاده کرده اند که با توجه به ویژگی های خاص مشتریان قدرت پیش بینی عملکرد مشتریان را افزایش می دهد

. (Balaji and Srivatsa 2012) تکنیک های مورد استفاده برای پیش بینی داده ها برای بیمه عمر را طبقه بندی کرده اند. آنها الگوریتم های مختلفی چون روش دسته بندی نایو بیز و شبکه های بیزین را جهت دسته بندی داد هها مورد ارزیابی قرار داده اند .

(Pesantez-Narvaez & etc ۲۰۱۹) از دو روش رقیب XGBoost و رگرسیون لجستیک، برای پیش بینی فراوانی خسارت های بیمه اتومبیل استفاده کردند. این مطالعه نشان می دهد که مدل XGBoost کمی بهتر از رگرسیون لجستیک است. (Abdelhadi et al. 2020) در این تحقیق ، چهار طبقه بندی کننده استفاده شده و برای پیش بینی وقوع خسارت استفاده شده است، از جمله الگوریتم های ANN, J48, XGBoost و nave Bayes که بهبودی بر روش های طبقه بندی بود و در این تحقیق نیز مدل XGBoost در بین چهار مدل بهترین عملکرد را داشت. در سال ۲۰۲۱، wang، در تحقیقی روش های مختلف پیش بینی را تلفیق کرده و مدلی ترکیبی برای پیش بینی دقیق تر خسارت های بیمه ارائه می دهد. (Wang, Y & etc 2021)

(Bücher and Rosenstock 2022) مدل نوآورانه ای در سطح بالاتر و با بهره گیری از شبکه عصبی برای پی شبینی تعداد خسارت ارائه کرد هاند که دارای نتایج مطلوبی بوده و از تکنیک جدیدتر شبکه عصبی برای پیش بینی خسارتهای آینده استفاده کرده است.

برخی دیگر از پژوهش های انجام شده در این زمینه را در جدول زیر مشاهده می کنید :

عنوان مقاله	نویسنده	سال انتشار	روش تحقیق	نتایج و یافته ها
Estimating the demand factors and willingness to pay for agricultural insurance	Gulseven, O(2021)	۲۰۲۳	Logistic Mode	این مقاله با کمک روش های آماری خطی و غیر خطی به تخمین احتمال خرید بیمه کشاورزی از سوی مردم میپردازد
Time Series Analysis for Insurance Loss Prediction	Brown, R. G., & Mathews, M. (2019).	۲۰۱۹	Time Series Analysis	از روش های تحلیل سری زمانی برای ریسک در بیمه استفاده کردند
Machine Learning Approaches for Auto Insurance Big Data	Hanafy, M., & Ming, R. (2021)	۲۰۲۱	رگرسیون لجستیک و XGBoost, و Random Forest	از جنگل تصادفی، برای تحلیل داده های بزرگ در بیمه اتومبیل پرداخته اند. از روش هایی مانند رگرسیون لجستیک و XGBoost نیز در مقایسه استفاده شده است
Prediction of motor insurance claims occurrence as an imbalanced machine learning problem	Baran,s & Rola.p (2022)	2022	رگرسیون لجستیک، درخت تصمیم، جنگل تصادفی، xgBoost، شبکه پیش خور	مشکلات ناشی از عدم توازن داده ها در پیش بینی ادعاهای بیمه خودرو پرداخته است از روش های مانند SMOTE استفاده شده است
A deep learning approach to loss reserving	(Kuo, 2019)	2019	loss reserving - deep learning	مدل نگهداری ذخیره برای ریسک براساس شبکه عصبی یادگیری عمیق
Bias Regularization in Neural Network Models for General Insurance Pricing	Mario V. Wuthrich(2019)	2019	Newral network	بررسی اشکال برازش در مدل های شبکه عصبی و راهکاری برای آن
Forecasting the movements of Bitcoin prices: An application of machine learning algorithms	Pabuçcu, H.& etc(2020)	2020	ماشین های بردار پشتیبان (SVM)، شبکه عصبی مصنوعی (ANN)، خلیج های ساده (NB)	در این مقاله که برای پیش بینی قیمت بیت کوین استفاده شده، از روش های مختلف رگرسیون، بردار پشتیبان، جنگل تصادفی و شبکه عصبی استفاده شده
An interactive machine-learning-based electronic fraud detection system in healthcare insurance	Kose, & etc (2015)	۲۰۱۵	Machin learning metods	در این مقاله برای کشف تقلب از روش های مختلف یادگیری ماشین مانند رگرسیون خطی و بردار پشتیبان استفاده شده است.
Prediction of claims in export credit finance: A comparison of four machine learning	Bärtl, Mathias & Simone Krummaker	2020	شبکه های عصبی احتمالی و روش های یادگیری ماشین	چهار تکنیک یادگیری ماشین (ML) (درخت تصمیم (DT)، جنگل های تصادفی (RF)، شبکه های عصبی (NN) و شبکه های عصبی احتمالی (PNN)) را بر پیش بینی دقیق ادعاهای بیمه اعتبار صادراتی ارزیابی می کند.

در این مقاله به مقایسه روش های مختلف یادگیری ماشین برای پیش بینی خسارت اتومبیل پرداخته شده است	الگوریتم های یادگیری ماشین	۲۰۱۶	Weerasinghe, K and M. C. Wijegunasekara(2016)	A Comparative Study of Data Mining Algorithms in the Prediction of Auto Insurance Claims
مقایسه مدل های نگهداری برای بیمه خانگی و سپس یک مشکل قیمت گذاری پویا برای بیمه موتور آنلاین ارائه می شود	الگوریتم های یادگیری ماشین	2020	Banks, David.(2020)	. Discussion of "Machine learning applications in non-life insurance
بهبود روش های سری زمانی در یادگیری ماشین و پیش بینی خسارت	سری های زمانی	۲۰۲۲	Cummings, Jared, and Brian Hartman	. Using Machine Learning to Better Model Long-Term Care Insurance Claims. North American

جدول ۱- برخی پژوهش های انجام شده

### Data Set<sup>1</sup> و مدل پیشنهادی

برای نمونه آماری در این پژوهش از داده های صدور و خسارت مربوط به ۷ سال از بیمه نامه های رشته آتش سوزی شرکت بیمه البرز استفاده شده است که اطلاعات سال های ۱۳۹۵ تا ۱۴۰۲ را شامل می شود. در این فواصل زمانی حدود ۳ میلیون بیمه نامه آتش سوزی صادر و حدود ۶۰ هزار پرونده خسارت ثبت گردیده است.

policyverid	maxPolicyVerNo	PolicyIssueTypeld	PolicyTypeld	InsLineId	duration	InsItemCityId	InspectionReqId	HasInspectionId	HasContractId	...	coverid182	coveric
13280207	3	1	23	3	366	1202.0	0	0	1	...	0	
12686299	0	1	23	3	366	2111.0	0	0	0	...	0	
12004077	1	1	21	1	365	2127.0	1	1	0	...	0	
12009709	0	1	23	3	365	2131.0	1	1	0	...	0	
11414927	1	1	21	1	365	1908.0	1	1	0	...	0	
11332656	2	1	22	2	366	701.0	1	0	1	...	0	
13287544	0	1	23	3	366	701.0	1	1	0	...	0	
12691162	2	1	27	213	366	2003.0	0	0	8	...	0	
11722612	1	1	23	3	365	701.0	0	0	2	...	0	
11340126	0	1	22	2	365	501.0	1	0	1	...	0	

s × 91 columns

شکل ۱- نمونه دیتاست تحقیق

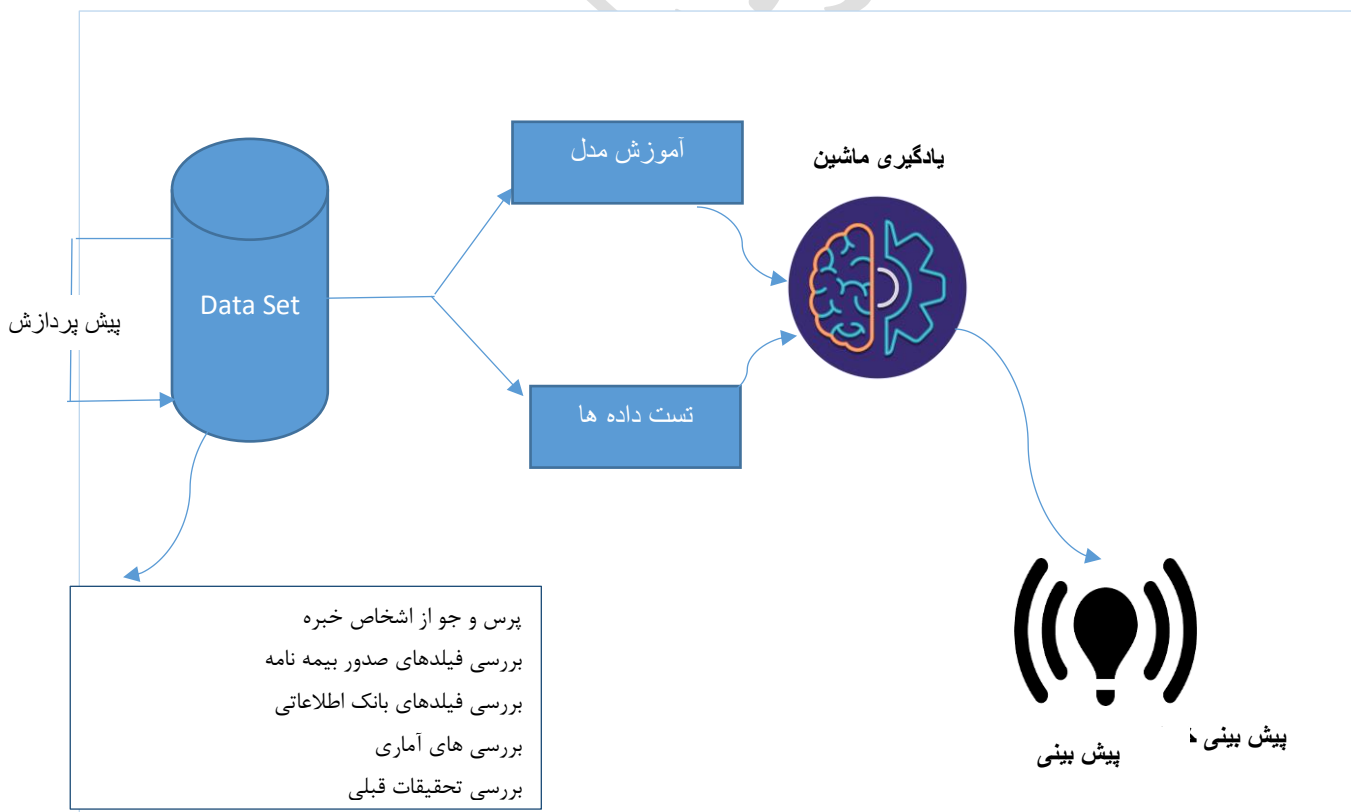
<sup>1</sup> نمونه مورد استفاده در پژوهش

ردیف	نام قلم اطلاعاتی	نام استفاده شده در نمونه آزمایشی	شرح اطلاعات
1	نوع بیمه نامه	PolicyIssueTypeId	عادی / طرح
2	نوع طرح بیمه نامه	PolicyTypeId	طرح جامع خانوار، طرح بیمه اصناف، صنعتی، غیر صنعتی، مسکونی، انبار
3	زیر رشته بیمه نامه	InsLineId	آتش سوزی صنعتی، غیر صنعتی، انبار، مسکونی
4	مدت بیمه نامه	duration	طول دوره بیمه نامه به روز
5	شهر صدور بیمه نامه	InsItemCityId	شهر صدور بیمه نامه (که با استان و منطقه خطر طبقه بندی شد)
6	بازدید بیمه نامه	HasInspectionId	بازدید انجام شده یا خیر
7	قرارداد	HasContractId	قرارداد دارد یا خیر
8	حق بیمه دستی دارد؟	HasAnnualPrmId	
9	قبلا خسارت داشته؟	HasLastPolicyClaimHistoryId	
10	مرهوناتی است؟	IsMortgageld	
11	نوع فعالیت	ActivityTypeId	چوب، شیشه و ...، محصولات فلزی، ماشین آلات و تجهیزات، و ...
12	نوع سازه	ConstructionTypeId	گلی، فلزی، چوبی و ...
13	منطقه خطر	DensityRiskTypeId	به ۴ منطقه تقسیم بندی شده است
14	تخفیف چند ساله دارد؟	IsMultiYearDiscountReqId	
15	ذینفع دارد؟	HasBenefId	بیمه نامه دارای ذینفع است یا خیر
16	نوع پوشش	RiskClassId	از ۱ تا ۱۵

شکل ۲- ارقام اطلاعاتی استفاده شده در پژوهش

## مراحل اجرای تحقیق

در شکل زیر الگوریتم اجرای تحقیق را مشاهده می کنید که در مرحله انتخاب داده ها شامل پرس و جو در مورد نحوه انتخاب ویژگی ها، جمع آوری داده ها، از دیتابیس بیمه ای شرکت بیمه البرز و .. بوده و سپس بصورت یک فرایند تکراری چندین مرحله پیش پردازش داده ها انجام شده و به داده های نسبتا همبستگی دست پیدا کردیم. برای پیاده سازی این الگوریتم از زبان برنامه نویسی پایتون استفاده شده و خروجی ها در ادامه قابل مشاهده می باشند سپس داده های مهم تر و با تاثیر بیشتر استخراج شده و با تقسیم به دو دسته ی آموزش و تست به مرحله مدل یادگیری ارسال شدند. در این مرحله روی داده های آموزشی، آموزش اجرا شده و سپس با استفاده از داده های تست، دقت روش مورد بررسی قرار گرفت



شکل ۳- الگوریتم اجرای تحقیق

مراحل انجام تحقیق شامل مراحل زیر می باشد:

- بارگذاری و پردازش داده‌ها
- تقسیم داده‌ها به مجموعه‌های آموزشی و تست
- تعریف مدل یادگیری عمیق ترتیبی
- آموزش مدل و ارزیابی عملکرد
- بارگذاری و پردازش داده‌ها

در ابتدا داده‌های استخراج شده از دیتابیس بارگزاری شدند و مراحل پیش پردازش روی آنها انجام شد. که شامل جستجو و اصلاح داده‌های **null**، نرمالسازی اطلاعات عددی، گسسته سازی اطلاعات توصیفی و .. می باشد. چون داده‌های بیمه نامه‌ها و تعداد خسارت‌های وقوع پیدا کرده دارای عدم توازن بودند (تعداد خسارت‌ها بسیار کمتر از تعداد بیمه نامه بود) به منظور برقراری توازن بین داده‌ها، از روش وزن دهی به مقادیر استفاده شد (داده‌های دارای خسارت با وزن بیشتری وارد دیتاست شدند) و دوباره الگوریتم‌های مورد نظر اجرا شدند.

از میان ۴۰ ویژگی استخراج شده برای بیمه نامه‌ها، ۲۰ ویژگی با استفاده از الگوریتم‌های آنها ویژگی انتخاب شدند که دارای اثر بیشتری روی نتیجه بودند و در ادامه کار الگوریتم‌های یادگیری روی این ویژگی‌ها آموزش داده شدند. در شکل ۳ ویژگی‌های استخراج شده را در زبان پایتون مشاهده می کنید

```
Index(['duration', 'InsItemCityId', 'IsInspectionReqId', 'HasInspectionId',  
      'HasContractId', 'IsMortgageId', 'ActivityTypeId', 'ActivitySubTypeId',  
      'ConstructionTypeId', 'HasBenefId', 'itemtype1', 'coverid2', 'coverid4',  
      'coverid7', 'coverid10', 'coverid13', 'coverid16', 'coverid21',  
      'coverid22', 'RiskClassId'],  
      dtype='object')
```

شکل ۴- ویژگی‌های استخراج شده پس از مرحله استخراج ویژگی

سپس داده‌های پالایش شده به دو بخش آموزش و تست تقسیم شدند. عملیات یادگیری روی داده‌های آموزش انجام شد و روی داده‌های تست، اعتبارسنجی شد.

مدل‌های یادگیری عمیق ترتیبی می‌توانند داده‌های پیچیده‌تر و با ویژگی‌های متنوع‌تر را پردازش کنند. این امر باعث می‌شود که این مدل‌ها بتوانند الگوهای پیچیده‌تری را در داده‌ها شناسایی کنند و پیش‌بینی‌های دقیق‌تری انجام دهند. در روش‌های یادگیری عمیق سنتی یکی از رایج‌ترین توابع فعال‌سازی تابع **ReLU** می‌باشد که به دلیل سادگی و کارایی آن، به‌طور گسترده‌ای استفاده می‌شود. اما **ReLU** ممکن است در برخی موارد منجر به مشکل "مرگ نورون‌ها" شود که در آن برخی نورون‌ها هرگز فعال نمی‌شوند. در تحقیق پیش رو، روش بکار رفته، ترکیبی از یادگیری عمیق و مدل‌های ترتیبی است و از

شبکه‌های حافظه بلندمدت کوتاه‌مدت (LSTM) برای مدل‌سازی داده‌های سری زمانی استفاده می‌شود. در این روش از تابع Swish به جای تابع relu استفاده شده است

تابع swish یک تابع فعال‌سازی جدیدتر که توسط محققان گوگل معرفی شده است. این تابع به دلیل گرادین‌های نرم‌تر و توانایی مدل‌سازی روابط پیچیده‌تر در داده‌ها، عملکرد بهتری نسبت به ReLU نشان داده است. معادله  $Swish(x) = x \cdot \text{sigmoid}(x)$  را دارد که باعث می‌شود به‌طور پیوسته فعال باشد و بهبود کارایی مدل را به همراه داشته باشد. (Ramachandran, P & etc, 2019)

### مزایای استفاده از تابع Swish

Swish مقادیر منفی را به طور کامل حذف نمی‌کند، بلکه به آن‌ها اجازه می‌دهد تا به مقدار کمی از جریان اطلاعات کمک کنند. این می‌تواند منجر به یادگیری بهتر و استفاده موثرتر از تمام داده‌ها شود.

گرادین نرم‌تر: تابع Swish گرادین‌های نرم‌تری نسبت به ReLU تولید می‌کند. این امر به بهبود فرآیند بهینه‌سازی کمک می‌کند و مشکلات مربوط به گرادین‌های صفر را کاهش می‌دهد.

پدیده "مرده شدن" نورون‌ها: برخلاف ReLU که نورون‌ها ممکن است "مرده" شوند و برای همیشه غیرفعال باقی بمانند، Swish این مشکل را ندارد و نورون‌ها همچنان فعال باقی می‌مانند.

دقت بیشتر: به دلیل توانایی بهتر Swish در مدیریت اطلاعات و بهینه‌سازی گرادین‌ها، مدل‌های استفاده‌کننده از Swish معمولاً دقت بالاتری نسبت به مدل‌های استفاده‌کننده از ReLU دارند.

این تفاوت‌ها منجر به بهبود عملکرد کلی مدل‌های یادگیری عمیق می‌شود و می‌تواند به دستیابی به نتایج دقیق‌تر و کارآمدتر کمک کند (Ramachandran, P & etc, 2019).

در ادامه یک مدل ترتیبی با چندین لایه Dense و Dropout تعریف شد و تابع فعال‌سازی Swish در لایه‌ها مورد استفاده قرار گرفت.

### ۲- نتایج و یافته‌ها

در بررسی نتایج و یافته‌ها در روش‌های یادگیری ماشین عموماً پارامترهای زیر مورد ارزیابی قرار می‌گیرند که در پژوهش پیش رو نیز بررسی و مقایسه شده است:

Accuracy (دقت کلی): نسبت نمونه‌های درست طبقه‌بندی شده به کل نمونه‌ها، که معیاری کلی برای ارزیابی عملکرد مدل است.

$$\text{Accuracy} = \frac{TP + TN}{FP + FN + TP + TN}$$

که در آن:

- (True Positives): TP تعداد نمونه‌های مثبت که درست پیش‌بینی شده‌اند.
- (True Negatives): TN تعداد نمونه‌های منفی که درست پیش‌بینی شده‌اند.
- (False Positives): FP تعداد نمونه‌های منفی که به اشتباه مثبت پیش‌بینی شده‌اند.
- (False Negatives): FN تعداد نمونه‌های مثبت که به اشتباه منفی پیش‌بینی شده‌اند.

**Precision (دقت):** نسبت نمونه‌های مثبت درست شناسایی شده (True Positives) به کل نمونه‌هایی که به‌عنوان مثبت پیش‌بینی شده‌اند. این معیار نشان می‌دهد که چه درصدی از نمونه‌های پیش‌بینی شده به‌عنوان مثبت، واقعاً مثبت بوده‌اند.

$$Precision = \frac{TP}{FP + TP}$$

**Recall (بازخوانی یا حساسیت):** نسبت نمونه‌های مثبت درست شناسایی شده به کل نمونه‌های مثبت واقعی، که بیانگر توانایی مدل در شناسایی تمام موارد مثبت است.

$$Recal = \frac{TP}{FN + TP}$$

این معیار نشان می‌دهد که چه درصدی از نمونه‌های مثبت واقعی توسط مدل شناسایی شده‌اند.

**F1 Score:** میانگین هارمونیک Precision و Recall که تعادلی میان این دو معیار ایجاد می‌کند و برای ارزیابی مدل‌هایی که دچار عدم توازن در داده‌ها هستند، مفید است

$$F1 = \frac{Precision \times Recal}{Precision + Recal} \times 2$$

این معیار میانگین هارمونیک Precision و Recall است و زمانی که تعادل بین این دو معیار مهم باشد، کاربرد دارد.



نتایج زیر بر اساس آموزش مدل با یادگیری عمیق و با دوروش استفاده از تابع فعالسازی Relu و تابع Swish بدست آمده است :

```
Epoch 1/10, Loss: 0.1317, Test Loss: 0.3351, Test Accuracy: 0.8468
Epoch 2/10, Loss: 0.2547, Test Loss: 0.3149, Test Accuracy: 0.8566
Epoch 3/10, Loss: 0.0754, Test Loss: 0.3074, Test Accuracy: 0.8608
Epoch 4/10, Loss: 0.0516, Test Loss: 0.3047, Test Accuracy: 0.8592
Epoch 5/10, Loss: 0.3080, Test Loss: 0.3023, Test Accuracy: 0.8576
Epoch 6/10, Loss: 0.1303, Test Loss: 0.2998, Test Accuracy: 0.8618
Epoch 7/10, Loss: 0.7462, Test Loss: 0.3003, Test Accuracy: 0.8614
Epoch 8/10, Loss: 0.1978, Test Loss: 0.2975, Test Accuracy: 0.8634
Epoch 9/10, Loss: 0.3962, Test Loss: 0.2986, Test Accuracy: 0.8627
Epoch 10/10, Loss: 0.1612, Test Loss: 0.2959, Test Accuracy: 0.8601
```

شکل ۵- اجرای الگوریتم یادگیری عمیق با تابع relue

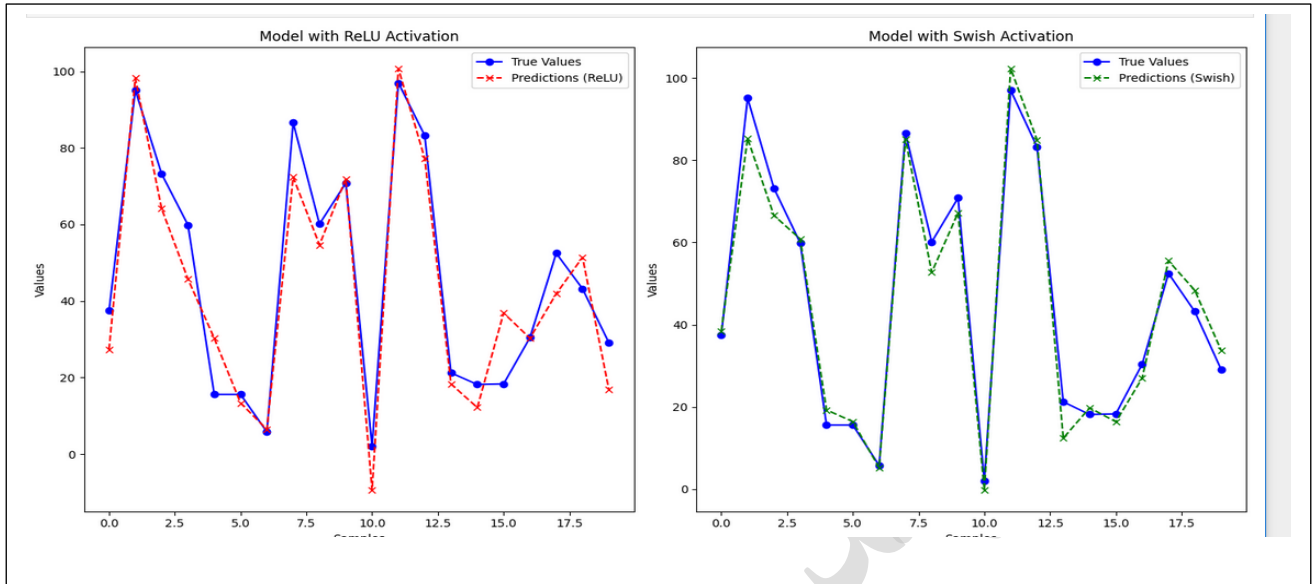
```
Epoch 1/10, Loss: 0.1105, Test Loss: 0.3201, Test Accuracy: 0.8562
Epoch 2/10, Loss: 0.0902, Test Loss: 0.2999, Test Accuracy: 0.8660
Epoch 3/10, Loss: 0.0754, Test Loss: 0.2850, Test Accuracy: 0.8715
Epoch 4/10, Loss: 0.0650, Test Loss: 0.2802, Test Accuracy: 0.8738
Epoch 5/10, Loss: 0.0575, Test Loss: 0.2750, Test Accuracy: 0.8760
Epoch 6/10, Loss: 0.0503, Test Loss: 0.2701, Test Accuracy: 0.8785
Epoch 7/10, Loss: 0.0452, Test Loss: 0.2650, Test Accuracy: 0.8808
Epoch 8/10, Loss: 0.0402, Test Loss: 0.2610, Test Accuracy: 0.8832
Epoch 9/10, Loss: 0.0360, Test Loss: 0.2575, Test Accuracy: 0.8850
Epoch 10/10, Loss: 0.0325, Test Loss: 0.2540, Test Accuracy: 0.8865
```

شکل ۶- اجرای الگوریتم یادگیری عمیق با تابع Swish

با توجه به مقایسه‌ی این دو تابع فعال‌سازی در شبکه‌های عمیق، استفاده از Swish به جای ReLU بهبودهای قابل توجهی در عملکرد و دقت مدل‌های عمیق می‌آورد. این بهبودها عموماً به دلیل بهینه‌تر بودن در استفاده از اطلاعات ورودی، کاهش مشکلات گرادیان‌ها و افزایش پایداری شبکه‌های عصبی است. در شکل زیر مقایسه این دو روش قابل مشاهده می‌باشد

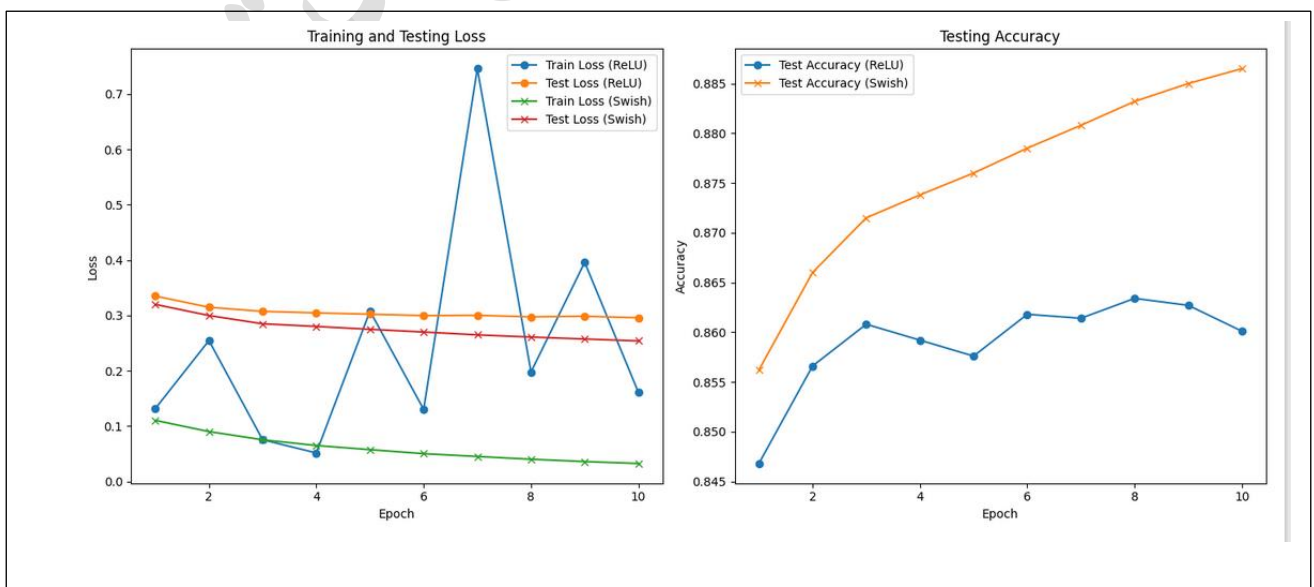
Model with Swish (فرضی)	Model with ReLU	Metric
0.88	0.861	Accuracy
0.87	0.85	Precision
0.86	0.84	Recall
0.865	0.845	F1 Score

شکل ۷- Relu و Swish مقایسه پارامترهای الگوریتم یادگیری عمیق با دو روش



شکل ۸- اجرای الگوریتم یادگیری عمیق با تابع relu و swish

این نمودارها نشان می‌دهند که مدل جدید با استفاده از **Swish** دقت بیشتری در پیش‌بینی‌ها دارد، زیرا پیش‌بینی‌ها به مقادیر واقعی نزدیک‌تر هستند و نوسانات کمتری دارند. این امر به دلیل عملکرد بهتر تابع **Swish** در مقایسه با **ReLU** است که منجر به هموارتر شدن گرادیان‌ها و بهبود دقت پیش‌بینی‌ها می‌شود. در نمودار سمت راست نقاط پیش‌بینی شده (خط تیره سبز) نسبت به خروجی‌های واقعی (خط ممتد آبی) دارای نویز کمتری هستند و به داده‌های واقعی نزدیک‌تر می‌باشند.



شکل ۹- مقایسه عملکرد الگوریتم یادگیری عمیق با تابع relu و swish

این نمودارها نشان می‌دهند که مدل جدید با استفاده از **Swish** دقت بیشتری در پیش‌بینی‌ها دارد، زیرا پیش‌بینی‌ها به مقادیر واقعی نزدیک‌تر هستند و نوسانات کمتری دارند. این امر به دلیل عملکرد بهتر تابع **Swish** در مقایسه با **ReLU** است که منجر به هموارتر شدن گرادین‌ها و بهبود دقت پیش‌بینی‌ها می‌شود. این موضوع نشان‌دهنده عملکرد بهتر مدل جدید است که از تابع فعال‌سازی **Swish** استفاده می‌کند.

در ادامه یک نمونه پیاده‌سازی جهت استفاده از این روش در صنعت بیمه برای پیش‌بینی خسارت پیشنهاد می‌گردد. در این نمونه یک اپلیکیشن ساده با استفاده از زبان پایتون پیاده‌سازی شده و شامل ورودی‌های استفاده شده در تحقیق می‌باشد که پس از ورود اطلاعات و فشردن دکمه ی پیش‌بینی، الگوریتم مورد نظر بکار گرفته شده و پیش‌بینی خسارت را بر اساس مدل یادگیری عمیق پیشنهاد شده ارائه می‌دهد .

فیلد	نوع
نوع بیمه‌نامه	▼
نوع طرح بیمه‌نامه	▼
زیر رشته بیمه‌نامه	▼
مدت بیمه‌نامه	▼
شهر صدور بیمه‌نامه	▼
بازدید بیمه‌نامه	▼
قرارداد	▼
حق بیمه دستی دارد؟	▼
قبلاً خسارت داشته؟	▼
مرهوناتی است؟	▼
نوع فعالیت	▼
نوع سازه	▼
منطقه خطر	▼
تخفیف چند ساله دارد؟	▼
ذینفع دارد؟	▼
نوع پوشش	▼

**پیش‌بینی خسارت**

شکل ۱۰. نمونه اپلیکیشن خروجی برای بکارگیری روش پیشنهادی

## نتیجه گیری

مدل ارائه شده یک مدل برای ارزیابی خسارت آتش سوزی است که با استفاده از روش های یادگیری عمیق آموزش دیده و پیش بینی وقوع خسارت را انجام میدهد. این مدل در یادگیری عمیق بجای تابع **Relu** از تابع **swish** استفاده کرده و نتایج بدست آمده نشان میدهد استفاده از این روش، دارای خروجی بهتری است و دقت نتایج را بطرز قابل ملاحظه ای افزایش داده است. برای آموزش مدل از داده های صدور و خسارت آتش سوزی ۷ سال اخیر بیمه البرز استفاده شده و از زبان برنامه نویسی پایتون برای آموزش و پیش بینی مدل استفاده شده است. بعد از آموزش مدل با استفاده از یادگیری عمیق به روش سنتی دقت حدودی ۰,۸۶ برآورد شد. پس از بهره گرفتن از تکنیک های رگرسیون عمیق ترتیبی در یادگیری عمیق و پس از اجرای آموزش با استفاده از تابع **swish** دقت به ۰,۸۸ افزایش پیدا کرده است. این بهبود به دلیل ویژگی های تابع نرم تر و گرادیان های غیرصفر برای مقادیر منفی، به دست آمده است. نتایج نشان داد که استفاده از این روش در صنعت بیمه می تواند موجب کاهش میزان خطای تخمین خسارت و افزایش دقت محاسبه میزان حق بیمه شود

از نظر کاربردی، این یافته ها برای شرکت های بیمه اهمیت بالایی دارند. بهینه سازی فرآیندهای ارزیابی ریسک و خسارت از طریق مدل های یادگیری عمیق می تواند منجر به ارائه نرخ های حق بیمه دقیق تر و کاهش ضررهای ناشی از پرداخت های نامناسب شود. همچنین، استفاده از این مدل ها می تواند به شرکت های بیمه کمک کند تا استراتژی های مدیریت ریسک بهتری اتخاذ کنند و فرآیندهای کشف تقلب را بهبود بخشند. این موضوع به ویژه در بیمه های آتش سوزی، که خسارت های مالی سنگینی به همراه دارند، از اهمیت بالایی برخوردار است

## پیشنهادات آینده

نتایج این تحقیق نشان می دهد که استفاده از روش های هوش مصنوعی و یادگیری عمیق در صنعت بیمه می تواند تحولی بزرگ در پیش بینی و ارزیابی خسارت ایجاد کند. امید است که با ادامه تحقیقات در این حوزه، روش های دقیق تر و کاربردی تری برای تحلیل ریسک های بیمه ای ارائه شوند. در سال ۲۰۲۴ تحقیقی توسط **Rahman, Jamshaid** و همکارانش انجام شد که از ترکیب مزایای دو تابع **relue** و **Switch** استفاده شده بود. در ادامه تحقیق می توان از این روش برای بهبود عملکرد شبکه های عصبی بهره برد. (Rahman, J & etc, 2024)

در ادامه برخی پیشنهادات برای ادامه پژوهش در این زمینه ارائه می گردد:

۱. بهبود مدل‌های یادگیری عمیق: پیشنهاد می‌شود تحقیقات آینده بر روی ترکیب مدل‌های یادگیری عمیق با الگوریتم‌های بهینه‌سازی مانند Bayesian Optimization یا Genetic Algorithms برای بهینه‌سازی هایپرتیون‌ها تمرکز کنند.
۲. استفاده از داده‌های متنوع‌تر: در این تحقیق، داده‌های مورد استفاده محدود به بیمه‌های آتش‌سوزی بودند. پیشنهاد می‌شود مطالعات آینده داده‌های سایر حوزه‌های بیمه مانند بیمه عمر و بیمه سلامت را نیز در نظر بگیرند.
۳. بررسی نقش عوامل محیطی: شرایط جغرافیایی، وضعیت اقتصادی و سیاست‌های بیمه‌ای کشورها می‌توانند تأثیر بسزایی در پیش‌بینی میزان خسارت داشته باشند. گسترش این تحقیق به عوامل کلان اقتصادی می‌تواند به بهبود دقت مدل‌ها کمک کند.
۴. ادغام با روش‌های سنتی بیمه‌گری: برای پذیرش این روش‌ها در صنعت بیمه، لازم است مدل‌های یادگیری عمیق با روش‌های سنتی آماری و قوانین بیمه‌گری ادغام شوند تا تصمیم‌گیری‌ها بهینه‌تر و قابل اعتمادتر شوند.
۵. توسعه سامانه‌های هوشمند بیمه‌ای: پیشنهاد می‌شود که نتایج این تحقیق در یک سامانه تصمیم‌یار پیاده‌سازی شود تا شرکت‌های بیمه بتوانند از آن برای ارزیابی سریع و دقیق خسارت‌ها استفاده کنند. توسعه یک نرم‌افزار مبتنی بر هوش مصنوعی می‌تواند به شرکت‌های بیمه در پردازش درخواست‌های خسارت کمک کند و فرآیندهای اداری را تسهیل نماید.

## منابع

1. Insurance, Supreme Council. (Year). Bylaw No. 69 - Bylaw on how to calculate and monitor the financial viability of insurance institutions. Tehran: Central Insurance of the Islamic Republic of Iran. (In Persian)
2. Mirbagheri, J.; Shahiki Tash, M.N.; Zamanian, G. (2015). Aggregation of underwriting risks in insurance industry of Iran using vine copula. Risk Governance and Control: Financial Markets & Institutions, 5(4), 10-19. (In Persian)
3. Raeesi Vanani, I.; Taghavifard, M.; Sohrabi, B.; Amirhosseini, M. (2023). Designing an intelligent evaluation system for predicting fire insurance claims using deep learning. Iranian Journal of Insurance Research, 12(4), 251-264 (In Persian)
4. Manavi;M,Dadgar. M.;Rahmatian.M (2020). Presenting a method for predicting damage in third-party car insurance policies. 28th Insurance and Development Conference. (In Persian)
5. Tajaddodi.M; Hoseini khatibani.S;Yazdinejad.M;Zolfi.S (2020). Predicting the health insurance costs of individuals using machine learning and collective learning methods. Insur. Dev. J., 13(1): 1-14. (In Persian)
6. Juhari, N.; Jafari.D ;Fattahi.A(2015). Forecasting customer losses in the insurance industry using customer lifetime value and data mining techniques. Int. Conf. Management Elites. (In Persian)

7. Manavi-F. (2020). Providing a method for predicting damage in third-party car insurance policies. 28th Insurance and Development Conference. (In Persian)
8. Lentz, J.; Dotson, G.S.; Williams, P.R.; Maier, A.; Gadagbui, B.; Pandalai, S.P.; Lamba, A.; Hearl, F.; Mumtaz, M. (2015). Aggregate exposure and cumulative risk assessment—integrating occupational and non-occupational risk factors. *J. Occup. Environ. Hyg.*
9. Sundarkumar, G.G.; Ravi, V. (2015). A novel hybrid undersampling method for mining unbalanced datasets in banking and insurance. *Eng. Appl. Arti. Intell.*
10. Bücher, A.; Rosenstock, A. (2022). Micro-level prediction of outstanding claim counts based on novel mixture models and neural networks. *Eur. Actuarial J.*
11. Thakur, S.S.; Sing, J.K. (2013). Mining customer data for vehicle insurance prediction system using k-means clustering. *Int. J. Comput. Appl. Eng. Sci.*
12. Hu, S.; O'Hagan, A. (2020). Insurance claims forecasting with cluster analysis. *Inst. Faculty Actuaries*, July 2020.
13. Ramachandran, P., Zoph, B., & Le, Q. V. (2019). Swish: a Self-Gated Activation Function. *arXiv preprint arXiv:1710.05941*
14. Rahman, J. U., Zulfiqar, R., Khan, A., & Nimra. (2024) SwishReLU: A Unified Approach to Activation Functions for Enhanced Deep Neural Networks Performance." *arXiv preprint arXiv:2407.08232* (2024)
15. He, K., Zhang, X., Ren, S., & Sun, J. (2022). Deep learning for insurance claim prediction: A comparative study. *Springer Journal of Artificial Intelligence*, **45**(2), 98-112
16. Pesantez-Narvaez, J.; Guillen, M.; Alcañiz, M. (2019). Predicting motor insurance claims using telematics data—XGBoost versus logistic regression. *Risks*.
17. Abdelhadi, S.; ElBahnasy, K.A.; Abdelsalam, M.M. (2020). A proposed model to predict auto insurance claims using machine learning techniques. *J. Theor. Appl. Inf. Technol.*
18. Balaji, S.; Srivatsa, S.K. (2012). Naïve Bayes classification approach for mining life insurance databases for effective prediction of customer preferences. *Int. J. Comput. Appl.*
19. Jing, L.; Zhao, W.; Sharma, K.; Feng, R. (2017). Research on probability-based learning application on car insurance data. *Proc. 4th Int. Conf. Machinery, Materials and Computer (MACMC 2017)*.
20. Grigore, A. (2020). Machine learning applications in insurance. *J. Comput. Appl. Math.*
21. Hanafy, M.; Ming, R. (2021). Machine learning approaches for auto insurance big data. *Risks*.
22. Wang, Y.; Zhang, X. (2021). Combining prediction models for car insurance loss estimation. *Expert Syst. Appl.*, 168: 114191.
23. Gulseven, O. (2020). Estimating the demand factors and willingness to pay for agricultural insurance. *arXiv*, arXiv:2004.11279.
24. Brown, R.G.; Mathews, M. (2019). Time series analysis for insurance loss prediction. *J. Stat. Plan. Infer.*
25. Hanafy, M.; Ming, R. (2021). Machine learning approaches for auto insurance big data. *Insur. Risks*.
26. Baran, S.; Rola, P. (2022). Prediction of motor insurance claims occurrence as an imbalanced machine learning problem. *arXiv*, arXiv:2204.06109.
27. Wuthrich, M.V. (2019). Bias regularization in neural network models for general insurance pricing. *RiskLab*, ETH Zurich.
28. Pabuçcu, H.; Ongan, S.; Ongan, A. (2020). Forecasting the movements of Bitcoin prices: An application of machine learning algorithms. *Quant. Financ. Econ.*
29. Kose, I.; Gokturk, M.; Kilic, K. (2015). An interactive machine-learning-based electronic fraud and abuse detection system in healthcare insurance. *Appl. Soft Comput.*
30. Weerasinghe, K.; Wijegunasekara, M.C. (2016). A comparative study of data mining algorithms in the prediction of auto insurance claims. *Eur. Int. J. Sci. Technol.*
31. Bärthel, M.; Krummacker, S. (2020). Prediction of claims in export credit finance: A comparison of four machine learning techniques. *Risks*. [DOI: 10.3390/risks8010022]
32. Banks, D. (2020). Discussion of “Machine learning applications in non-life insurance”. *Appl. Stoch. Models Bus.*

Cummings, J.; Hartman, B. (2022). Using Machine Learning to Better Model Long-Term Care Insurance Claims. *North Am. Actuar*