Archive of SID.ir

Iran. J. Insur. Res., 13(1): Pages: 15-28, Winter 2024, Serial #47

Iranian Journal of Insurance Research
(IJIR)

Homepage: https://ijir.irc.ac.ir/?lang=en

Iranian Insurance Research Center (IIRC)

ORIGINAL RESEARCH PAPER

Providing the concept of risk package instead of risk factor in order to classify the risk of policyholders more accurately

M. Esna-Ashari[1], F. Khamesian[2*], F. Khanizadeh[1]

[1] *Department of property and Casualty Insurance, Iranian Insurance Research Center, Tehran, Iran*

[2] *Department of General Insurance, Iranian Insurance Research Center, Tehran, Iran*

ARTICLE INFO

Article History:
Received 10 June 2023
Revised 30 July 2023
Accepted 01 October 2023

Keywords:
Clustering
Risk package
Third party
Unsupervised algorithm

*Corresponding Author:
Email: *khamesian@irc.ac.ir*
Phone: +9821 22084084
ORCID: 0000-0001-6113-4246

ABSTRACT

BACKGROUND AND OBJECTIVES: The accurate and scientific assessment of the risk to issue an insurance policy is one of the most critical and important stages of risk assessment frameworks. This leads companies to identify high-risk customers and determine the policy rates in accordance with their risks, and as a result, the claims will be covered appropriately through the insurance premiums. In this paper, a new method is presented to define the concept of risk factor in more practical, flexible and accurate way. In this method, which is based on an unsupervised clustering algorithm, initially, every single factor is examined based on different ranges and their corresponding impact on customer loss levels. Then, considering their connection with the ranges of other factors in terms of creating similar levels of customer loss, they are combined to form a package. Thus, different packages are created, each of which is considered a risk factor and comprise the ranges of factors affecting different levels of loss.

METHODS: The k-means clustering method was used to divide insurers into clusters with similar risks, which correspond to the risk packages associated with the customers' risk level. The number of desired clusters should be determined in advance, which is the main challenge of using this algorithm. Two main approaches for validation, namely the silhouette score and the elbow method, were presented.

FINDINGS: Based on the elbow plot and silhouette coefficient, as well as considering the practical and realistic evaluation needed by insurance companies, four clusters were obtained. Cluster 2 and 3 are similar and can be merged to form a cluster of medium risk level. Therefore, three clusters were considered the best outcome for categorizing insurance policyholders.

CONCLUSION: The risk packages can be introduced from the examination of the 3 clusters including People with high, medium and low age (confidence interval) with low price car whose gender is male can be introduced as the highest level of risk; People with medium and high ages (confidence interval) with medium and high car prices can be considered as medium risks, and Middle-aged and older people (confidence interval) with expensive cars were considered the lowest level of risk. From the results of these risk packages, it can be concluded that although a significant population of older policyholders falls into the first package (first cluster), they have the highest level of risk. On the other hand, the older people in the third package (even though their average age is the highest among the clusters) have the lowest level of risk. Another important point is that the risk level decreases as income increases simultaneously with age.

DOI: 10.22056/ijir.2024.01.02

This is an open access article under the CC BY license (http://creativecommons.org/licenses/by/4.0/).

Archive of SID.ir

Archive of SID.ir

نشریه علمی پژوهشنامه بیمه دوره ۱۳، شماره ۱، زمستان ۱۴۰۲، شماره پیاپی ۴۷، ص ۱۵-۲۸

نشریه علمی پژوهشنامه بیمه

سایت نشریه: https://ijir.irc.ac.ir/?lang=fa

مقاله علمی

ارائهٔ مفهوم ریسک‌پکیج به‌جای ریسک‌فاکتور به‌منظور طبقه‌بندی دقیق‌تر ریسک بیمه‌گذاران

مریم اثنی‌عشری[۱]، فرزان خامسیان[۲*]، فربد خانی‌زاده[۱]

[۱] گروه پژوهشی بیمه های اموال و مسئولیت، پژوهشکده بیمه، تهران، ایران

[۲] گروه پژوهشی مطالعات عمومی بیمه، پژوهشکده بیمه، تهران، ایران

اطلاعات مقاله

تاریخ های مقاله:

تاریخ دریافت: ۳۰ خرداد ۱۴۰۲

تاریخ داوری: ۰۸ مرداد ۱۴۰۲

تاریخ پذیرش: ۰۹ مهر ۱۴۰۲

کلمات کلیدی:

الگوریتم بدون نظارت

خوشه‌بندی

ریسک‌پکیج

شخص ثالث

*نویسنده مسئول:

ایمیل: khamesian@irc.ac.ir

تلفن: ۲۲۰۸۴۰۸۴ ۹۸۲۱+

ORCID: 0000-0001-6113-4246

DOI: 10.22056/ijir.2024.01.02

چکیده:

پیشینه و اهداف: ارزیابی صحیح و علمی ریسک صدور بیمه‌نامه یکی از حساس‌ترین و مهم‌ترین مراحل ارزیابی ریسک است و انجام آن باعث شناسایی مشتریان پرریسک و تعیین نرخ بیمه‌نامه، متناسب با ریسک مشتریان و در نتیجه پوشش مناسب خسارت‌های مالی ادعاشده به‌وسیلهٔ حق‌بیمه‌های دریافتی می‌شود. در این پژوهش روشی جدید برای تبیین دقیق‌تر و کاربردی‌تر از ریسک‌فاکتور ارائه شده است. در این روش که مبتنی بر الگوریتم بدون نظارت خوشه‌بندی است، ابتدا بازه‌های مختلف هر عامل مؤثر بر خسارت بررسی و با توجه به میزان تأثیرگذاری بر سطوح خسارت مشتریان به چند ریسک‌فاکتور تقسیم می‌شوند. سپس با توجه به میزان ارتباط آن با بازهٔ دیگر عوامل، از لحاظ ایجاد سطوح خسارت مشابه در مشتریان، با آن‌ها ترکیب می‌شود و پکیجی شامل بازه‌های عوامل تأثیرگذار بر سطوح مختلف خسارت را تشکیل می‌دهد. به‌این‌ترتیب به‌جای یک ریسک‌فاکتور، پکیج‌های مختلفی ایجاد می‌شود که هرکدام از آن‌ها یک عامل ریسک یا همان ریسک‌فاکتور در نظر گرفته می‌شوند.

روش‌شناسی: با استفاده از روش خوشه‌بندی کا-میانگین، بیمه‌گذاران به خوشه‌هایی با ریسک همگن که در واقع ریسک‌پکیج‌های متناظر با میزان پرخطر بودن مشتریان هستند، تقسیم شده‌اند. براساس ساختار الگوریتم کا-میانگین تعداد خوشه‌های مورد نظر باید از پیش تعیین شود. این موضوع چالش اصلی استفاده از الگوریتم مزبور است. در همین راستا دو رویکرد اصلی اعتبارسنجی سایه‌نما (ضریب سیلوئت) و روش آرنج برای حل این مشکل ارائه شده است.

یافته‌ها: با توجه به نمودار آرنج و ضریب سیلوئت و همچنین در نظر گرفتن نیاز شرکت‌های بیمه به ارزیابی کاربردی و منطبق بر واقعیت، ۴ خوشه به دست آمد که با توجه به اینکه خوشهٔ ۲ و ۳ در یک طیف نزدیک به هم و در نتیجه قابل پیوستن به یکدیگر هستند و خوشه با سطح ریسک متوسط را تشکیل می‌دهند، ۳ خوشه به‌عنوان بهترین خروجی دسته‌بندی بیمه‌گذاران لحاظ شد.

نتیجه‌گیری: از بررسی ویژگی‌های به‌دست‌آمده در ۳ خوشهٔ مطرح‌شده می‌توان پکیج‌های ریسک ذیل را معرفی کرد.

- افراد با سنین بالا، متوسط و پایین (چگال در بازهٔ ۳۰ تا ۵۸ سال) با ماشین ارزان‌قیمت و دارای جنسیت مرد را می‌توان به‌عنوان بیمه‌گذاران با بالاترین سطح ریسک معرفی کرد.
- افراد با سنین متوسط و بالا (چگال در بازهٔ ۳۲ تا ۵۳ سال) با ارزش ماشین متوسط و بالا را می‌توان بیمه‌گذاران دارای ریسک‌های متوسط در نظر گرفت.
- افراد با سنین متوسط به بالا (چگال در بازهٔ ۵۱ تا ۶۳ سال) با ماشین گران‌قیمت را می‌توان بیمه‌گذاران با پایین‌ترین سطح ریسک در نظر گرفت.

توجه: مدت‌زمان بحث و انتقاد برای این مقاله تا ۱ آوریل ۲۰۲۴ در وب‌سایت IJIR در «نمایش مقاله» باز است.

Archive of SID.ir

Archive of SID.ir

مقدمه

شرکت‌های بیمه مانند دیگر بنگاه‌های اقتصادی با انواع مختلفی از ریسک‌ها روبه‌رو هستند (Hoy, 1982). در بین ریسک‌هایی که شرکت‌های بیمه و بیمه‌گران با آن مواجه‌اند، ریسک صدور اهمیت ویژه‌ای دارد. در اغلب نظام‌های توانگری مالی، بیش از ۲۲ درصد ریسک‌های شرکت‌های بیمه را ریسک‌های صدور بیمه‌نامه تشکیل می‌دهند (Eling *et al.*, 2007). آنچه در اغلب موارد ممکن است ریسک صدور را افزایش دهد و شرکت بیمه را دچار مشکل کند، ارائهٔ بیمه‌نامه به مشتریان پرریسک و همچنین متناسب نبودن نرخ بیمه‌نامه با ریسک مشتریان و در نتیجه عدم پوشش مناسب خسارت‌های ادعاشده به‌وسیلهٔ حق‌بیمه‌های دریافتی است. با توجه به اهمیت و تأثیر ریسک صدور یا بیمه‌گری بر عملکرد شرکت‌های بیمه، این موارد ممکن است حتی به ورشکستگی یک شرکت بیمه منجر شود. کاهش و کنترل ریسک صدور به‌عنوان یکی از عوامل مهم و مؤثر بر بهبود فرایند بیمه‌گری و در نتیجه عملکرد شرکت‌های بیمه مطرح است و نقش اساسی در تداوم انجام این فرایند و بقای شرکت‌های بیمه دارد. به‌عبارت‌دیگر، می‌توان گفت اگر یک شرکت بیمه در شناسایی و ارزیابی میزان ریسک مشتریان و ارائهٔ پوشش بیمه‌ای متناسب با ریسکشان به آن‌ها دچار مشکل شود، زیان هنگفتی را متوجه خود خواهد کرد. حال آنکه در صورت وجود یک نظام کارا و هوشمند برای شناسایی و ارزیابی سریع میزان ریسک مشتریان، شرکت بیمه می‌تواند تا حد زیادی این مشکل را کاهش دهد و محصولات و پوشش‌های بیمه‌ای خود را به‌صورت کارآمد به مشتریان تخصیص دهد. شرکت‌های بیمه در همهٔ رشته‌ها از جمله بیمهٔ اتومبیل، سعی می‌کنند بیمه‌نامه‌های خود را در طبقات تعرفه‌ای همگن طبقه‌بندی کنند و به بیمه‌گذاران و بیمه‌نامه‌هایی که متعلق به یک طبقهٔ ریسک هستند حق‌بیمهٔ یکسانی را اختصاص دهند تا به این ترتیب از بیمه‌گذاران حق‌بیمهٔ عادلانه دریافت کنند. بنابراین انتخاب مجموعهٔ مناسبی از ریسک‌فاکتورها برای پیش‌بینی صحیح نرخ و همچنین میزان خسارت‌های بیمه‌گذاران، می‌تواند برای یک شرکت بیمه بسیار مهم باشد. هنگامی که از یک مدل ریاضی پیچیده به‌منظور نرخ‌گذاری و تعیین قیمت و یا کشف الگوی خسارات استفاده می‌شود، مطالعهٔ تأثیر یا انجام تحلیل حساسیت ریسک‌فاکتورها در مدل بسیار مهم است (Asmussen and Rubinstein, 1999). در شرایطی که نرخ‌های بیمه‌نامه‌ها را قانون‌گذار تعیین می‌کند (مانند بیمهٔ شخص ثالث در کشور ایران) و شرکت‌های بیمه ناگزیر به پیروی از این نرخ‌ها هستند، باز هم تعیین دقیق ریسک‌فاکتورها و پیش‌بینی سطح خسارت بیمه‌گذاران می‌تواند مفید باشد، زیرا تعیین دقیق عامل‌های ریسک به جلوگیری از انتخاب نامطلوب بیمه‌نامه‌ها کمک می‌کند (Dionne *et al.*, 1999). این عامل‌ها ویژگی‌ها و متغیرهایی هستند که همچنین به شرکت‌های بیمه کمک می‌کنند تا مبلغ خسارات خود را در دورهٔ زمانی معینی (که معمولاً یک‌ساله است)، پیش‌بینی کنند. به‌عبارت‌دیگر، شرکت‌های بیمه میزان خسارات احتمالی خود را براساس این عامل‌ها مدل‌سازی می‌کنند. در بیمه‌های اتومبیل، این عامل‌ها معمولاً متغیرهای قابل مشاهده‌ای در مورد راننده، نوع وسیلهٔ نقلیه و نوع کاربری هستند (Xie, 2021).

مروری بر پیشینهٔ پژوهش

اصلی‌ترین و اثرگذارترین عامل‌های ریسکی که بنا بر مطالعات و پژوهش‌های گوناگون در رشتهٔ شخص ثالث احصا می‌شوند و شرکت‌های بیمه برای پیش‌بینی و ارزیابی ریسک از آن‌ها استفاده می‌کنند، متغیرهایی نظیر سن راننده، جنسیت، سوابق تصادفات یا ادعای خسارت، تاریخ گواهینامه، نوع وسیلهٔ نقلیه، نوع کاربری و محل سکونت هستند (Doerpinghaus*et al.*, 2008; McCartt*et al.*, 2009; Ayuso*et al.*, 2019). این متغیرها با نرخ خسارات همبستگی دارند و در نتیجه می‌توانند برای پیش‌بینی خسارات آینده مفید باشند. البته باید دقت داشت، ریسک‌فاکتورهایی که شناسایی و در نظر گرفته می‌شوند نباید به‌راحتی قابل دستکاری کردن باشند. به‌طور مثال، اگر میزان مسافت پیموده‌شده از طریق کیلومترشمار نصب‌شده بر روی اتومبیل سنجیده شود و اگر این کیلومترشمار قابل دستکاری باشد، این عامل ریسک‌فاکتور مناسبی نیست (Desyllas and Sako, 2013).

یک رویکرد معمول برای انتخاب صحیح عوامل خطر یا همان ریسک‌فاکتورها، مبتنی بر روش‌های آماری چندمتغیره مانند رگرسیون خطی یا GLM است (David, 2015; McCullag, 2019) . اما یکی از مشکلات این روش‌ها در این است که هنوز مقدار زیادی ناهمگونی در کلاس‌های مختلف به‌جا می‌گذارند. منابع مختلفی در این رابطه وجود دارد که از آن جمله می‌توان Arvidsson (2010) را نام برد. درحالی‌که این مدل‌ها ساده و به‌راحتی قابل توضیح‌اند، اما غالباً برای یادگیری و انعکاس اثرات پیچیده بسیار محدودند. رشته‌های بیمهٔ اموال و مسئولیت از جمله بیمهٔ اتومبیل، خطراتی را پوشش می‌دهد که از ترکیب چند منبع (علت) از جمله علل رفتاری ناشی می‌شود و در نتیجه به‌ندرت یک رابطهٔ خطی برای مدل‌سازی رفتارهای پیچیده کافی خواهد بود. به‌عبارتی، در این رشته‌ها تبدیل‌های غیرخطی و تعاملات بین متغیرها می‌توانند واقعیت را با دقت بیشتری منعکس کنند که برای گنجاندن این اثرات در GLM ها، بیم‌سنج باید این ویژگی‌ها را به‌صورت دستی ایجاد کند و در مدل بگنجاند. اما مدل‌های یادگیری ماشین این مشکل را رفع کرده‌اند و تبدیل‌های غیرخطی و روابط بین متغیرها را بدون تعیین دستی آن‌ها یاد می‌گیرند (Spedicato *et al.*, 2018; Burka *et al.*, 2021). این کار معمولاً با مدل‌هایی نظیر شبکهٔ عصبی و مدل‌های مبتنی بر درخت به‌راحتی انجام می‌شود (Hanafy and Ming, 2021). استفاده از این مدل‌ها رویکردی نو و منعطف است و آن‌ها اغلب می‌توانند سطح بالایی از دقت پیش‌بینی را ارائه دهند. محققان زیادی با استفاده از این مدل‌ها به تعیین ریسک‌فاکتورهای انواع رشته‌های بیمه‌ای و طبقه‌بندی مشتریان براساس میزان ریسکشان و همچنین قیمت‌گذاری و تعیین نرخ برای بیمه‌نامه‌ها پرداخته‌اند (Dugas *et al.*, 2003 ; Yeo, 2009). در مسائل قیمت‌گذاری، به‌دلیل پیچیدگی مشخصات مدل و اجرای

Archive of SID.ir

Archive of SID.ir

آن، برای برآورده کردن شفافیت قیمت ارائه‌شده، توضیح مدل از طریق ارزیابی اهمیت متغیرهای مورد استفاده ضروری است. به‌عبارت‌دیگر، همان‌گونه که گفته شد در مسائل قیمت‌گذاری نیز قدم اول شناسایی ریسک‌فاکتورهای اصلی و بررسی تأثیر آن‌ها بر متغیرهای پاسخی نظیر فراوانی یا شدت خسارت است. Xie (2021) در پژوهش خود با استفاده از روش شبکهٔ عصبی مصنوعی به تجزیه‌وتحلیل ریسک‌فاکتورهای اصلی در بیمه‌های اتومبیل پرداخت و اهمیت این متغیرها را با یکدیگر مقایسه کرد.

Cheong *et al.* (2008) با استفاده از مدل‌های GLM به قیمت‌گذاری بیمه‌های اتومبیل در مالزی پرداختند. آن‌ها ابتدا اصلی‌ترین متغیرهای تأثیرگذار بر فراوانی و شدت خسارات را شناسایی و پس از مدل‌سازی فراوانی و شدت خسارات به ارائهٔ حق‌بیمهٔ خالص و ناخالص برای این رشتهٔ بیمه‌ای پرداختند. Segovia-Vargas *et al.* (2015) نیز با استفاده از روش‌های هوش مصنوعی و نظریهٔ راف به تعیین ریسک‌فاکتورها در بیمهٔ اتومبیل پرداختند. به گفتهٔ آن‌ها شواهد تجربی نشان می‌دهد که ریسک‌فاکتورهایی از قبیل سن راننده، جنسیت و ... که به‌صورت معمول ازسوی شرکت‌های بیمه در این رشته در نظر گرفته می‌شود، متغیرهای توضیحی خوبی برای طبقه‌بندی مشتریان این رشته هستند و علاوه‌براین متغیرهای معمول، پاداش_جریمه کمی قدرت توزیع را افزایش می‌دهد. Dugas *et al.* (2003) ریسک‌فاکتورهای اصلی مورد استفاده در نرخ‌گذاری بیمه‌های اتومبیل در منطقهٔ آمریکای شمالی را بررسی کردند. آن‌ها قدرت تمایز و اثرگذاری هریک از این متغیرها را بر روی نرخ بیمه‌نامه تحلیل کردند و عملکرد چندین مدل را در پنج دستهٔ کلی رگرسیون خطی، مدل‌های خطی تعمیم‌یافته، درخت‌های تصمیم، شبکه‌های مصنوعی و ماشین‌های بردار پشتیبان بررسی کردند. مقایسهٔ این مدل‌ها به‌صورت کیفی انجام شد و آن‌ها در نهایت نشان دادند که چگونه شبکه‌های عصبی می‌توانند وابستگی‌های غیرخطی مرتبهٔ بالا را با تعداد کمی از پارامترها که هریک بر روی نسبت بزرگی از داده‌ها تخمین زده می‌شوند، نشان دهند.

حال مسئله اینجاست که با بررسی مشاهدات ریسک‌فاکتورها برای هر نوع بیمه‌نامه‌ای متوجه نوعی تناقض رفتاری ریسک‌فاکتورها می‌شویم. ممکن است یک عامل ریسک در بسیاری از شرایط عامل اصلی پرریسک بودن بیمه‌گذار یا مورد بیمه باشد، ولی در شرایط دیگر همین عامل ریسک اهمیت کمتری در پرریسک بودن بیمه‌گذار دارد و حال چه‌بسا مشاهدات ما از انبوه داده‌ها نشان داده است بسیاری از متغیرها یا ریسک‌فاکتورها در یک وضعیت عامل اصلی پرریسک بودن مشتری و همین ریسک‌فاکتور در وضعیتی دیگر عامل کم‌ریسک بودن مشتری را نشان داده است. در سوابق مطالعاتی و پژوهشی عمدتاً دلیل این امر را در همبستگی ریسک‌ها و ریسک‌فاکتورها می‌بینند و با حذف اثرات همبستگی درصدد تحلیل ریسک‌فاکتورها برمی‌آیند (Barsotti *et al.*, 2016; Meyers *et al.*, 2003). مشکل این دیدگاه در این است که با لحاظ همبستگی بین ریسک‌فاکتورها، اثرات متغیرها به‌طور میانگین محاسبه می‌شوند و اندازهٔ دقیق تأثیرگذاری ریسک‌فاکتورها که چه‌بسا در شرایط مختلف متغیر نیز هست، محاسبه نمی‌شود. ازطرف‌دیگر، این اقدام برای حالتی که ریسک‌فاکتوری در یک شرایط، عامل اصلی پرریسک و در شرایطی دیگر، عامل اصلی کم‌ریسک بودن است، توضیحی ندارد. به‌طور نمونه در مشاهدات پروندهٔ بیمه‌ها مشخص شد در رشتهٔ بیمه‌های شخص ثالث و بدنه (اتومبیل) بسیاری از افراد با سن بالا پرریسک‌اند و در خوشهٔ دیگر افراد با همین میانگین سن، کمترین ریسک را دارند. در نتیجه نمی‌توان در خصوص افزایش سن به‌عنوان یک ریسک‌فاکتور با قاطعیت نظر داد.

با توجه به آنچه گفته شد و سوابق مطالعاتی، در این پژوهش روشی جدید برای بررسی ریسک‌فاکتورها ارائه می‌دهیم تا از طریق آن مبنای دقیق‌تری از ریسک‌فاکتور به دست آید و ایراد مطرح‌شده در روش‌های قبلی را کمی مرتفع سازد. در روش جدید که معرفی می‌شود، ریسک‌فاکتورها با توجه به سطوح مقادیرشان به متغیرهای کوچک‌تر و جدا از هم تقسیم می‌شوند. سپس هرکدام از سطوح مختلف ریسک‌فاکتورهای اصلی که هم‌خوشه هستند، ریسک‌فاکتور جدیدی را تشکیل می‌دهند و به‌این‌ترتیب پکیج‌های مختلفی ایجاد می‌شود که هرکدام از آن‌ها یک عامل ریسک یا همان ریسک‌فاکتور هستند. به‌عبارتی‌دیگر، بازه‌های مقادیر ریسک‌فاکتورهای سابق در ترکیب با یکدیگر ریسک‌فاکتور جدیدی را می‌سازند که باید دوباره ارزیابی شود. ملاک و عملیات جداسازی بازه‌ای مقادیر ریسک‌فاکتورهای اولیه و چگونگی ترکیب آن با بازهٔ مقادیر همدیگر از طریق مدل خوشه‌بندی انجام‌پذیر است. در رابطه با مدل مورد استفاده برای خوشه‌بندی بیمه‌گذاران بیمهٔ شخص ثالث، هدف این پژوهش نوآوری در ارائهٔ مدل یادگیری ماشین نیست، بلکه ارائهٔ دقیق‌ترین برآورد مورد نظر بوده است. در حقیقت با توجه به توانایی خوشه‌بندی، ابزار یادگیری ماشین کاربردی بسیار مهم در طبقه‌بندی ریسک دارند و از همین جهت در مقاله استفاده شده‌اند، زیرا چنانچه به‌جای اینکه همانند ادبیات پژوهش به این نتیجه برسیم که سن یک ریسک‌فاکتور است، با کاربرد یادگیری ماشین به این نتیجه برسیم که بازه‌ای از تغییرات سن به عنوان عامل افزایش ریسک است و بازه‌ای دیگر با توجه به بازه‌ای از عامل ریسک دیگر مانند قیمت خودرو عامل کاهش ریسک است، می‌توانیم مفهوم جدیدی را معرفی کنیم که در ادبیات ریسک‌فاکتورها وجود نداشته است و کاربرد دقیق‌تری از آن است. شایان ذکر است نرم‌افزار مورد استفاده پایتون است. در اکثر مدل‌های یادگیری ماشین در زمان تخمین در پایتون، داده‌ها به دو مجموعهٔ آموزشی (Training Set) و آزمایشی (Testing Set) تقسیم می‌شود و آزمون صحت مدل و برآوردها از طریق راستی‌آزمایی پیش‌بینی‌های مجموعه آزمایشی انجام می‌شود.

سؤالات پژوهش

با توجه به توضیحات ارائه‌شده در بخش قبل، سؤالات پژوهش به شرح ذیل قابل بررسی‌اند:

الف) چه مقادیر و چه ترکیبی از متغیرهای مورد بررسی،

Archive of SID.ir

Archive of SID.ir

پکیج‌های مختلف ریسک (از کم‌ریسک به پرریسک) را تشکیل می‌دهند؟

ب) آیا ریسک‌پکیج به‌عنوان روش اندازه‌گیری جدید در ارزیابی ریسک، نتایج دقیق‌تری نسبت به ریسک‌فاکتور ارائه می‌دهد؟

در ادامهٔ مقاله، روش پژوهش استفاده‌شده برای بررسی و شناسایی پکیج‌های مختلف ریسک معرفی می‌شود. پس از تحلیل هر ریسک‌پکیج که به‌صورت خوشه‌های گوناگون معرفی شده‌اند، پاسخ پرسش‌ها و برتری این رویکرد نسبت به روش کلاسیک که تأثیر ریسک‌فاکتورها را مدنظر قرار می‌دهد نیز مشخص می‌شود.

مبانی نظری و روش‌شناسی پژوهش

خوشه‌بندی فرایند گروه‌بندی مجموعه‌ای از داده‌ها با تقسیم داده‌ها به گروه‌ها یا خوشه‌ها با هدف به حداکثر رساندن شباهت در داخل هر گروه و به حداقل رساندن شباهت بین‌گروهی بوده، به‌طوری که اعضای یک خوشه شباهت زیادی داشته، ولی اعضای خوشه‌های مختلف متفاوت باشند. فرایند خوشه‌بندی اساساً شامل سه مرحلهٔ اصلی است: ۱) تعریف معیار تشابه (Similarity)؛ ۲) تعیین معیاری برای فرایند ساخت خوشه؛ ۳) الگوریتم مناسب برای ساخت خوشه‌ها براساس معیار انتخاب‌شده. بنابراین اولین اقدام، در نظر گرفتن معیاری مناسب برای ارزیابی «فاصله» (عدم تشابه (Dissimilarity)) بین اشیاء است (Han *et al.*, 2012; Likas *et al.*, 2003).

در اصل، معیار تشابه تابع $d : D \times D \to \mathbb{R}_+$ است که بر روی مجموعه‌ای از اشیاء D اعمال می‌شود و ویژگی‌های خاصی دارد. از نظر مفهومی، می‌توان گفت که معیار تشابه معکوس فاصله است. بنابراین، اصطلاح معیار عدم تشابه، به‌عنوان فاصله بین دو شیء نیز در نظر گرفته می‌شود. بنابراین به‌عنوان یک تابع، فاصله معیاری است که ویژگی‌های اساسی یک متریک را دارد (Chen *et al.*, 2009).

۱- غیرمنفی بودن و اصل این‌همانی تمایزناپذیرها (Identity of Indiscernibles)

$$d\left(A,B\right) \geq 0,\ d\left(A,B\right) = 0 \leftrightarrow A = B$$

۲- تقارن

$$d\left(A,B\right) = d\left(B,A\right)$$

۳- نامساوی مثلثی

$$d\left(A,B\right) + d\left(B,C\right) \geq d\left(A,C\right)$$

در ادامه تعدادی از رایج‌ترین توابع فاصله ارائه می‌شود. برای اندازه‌گیری تشابه بین دو شیء/ نمونه، آن‌ها را به‌عنوان بردار در نظر می‌گیریم که به جهت سادگی فرض می‌کنیم که هم‌بعد باشند: $X = \left(x_1, x_2, \ldots, x_n\right)$ و $Y = \left(y_1, y_2, \ldots, y_n\right)$. شایان ذکر است که در برخی موارد، ممکن است (با برخی اصلاحات) بردارهایی با ابعاد مختلف در نظر گرفته شوند.

با در نظر گرفتن بردارهای بالا، فاصلهٔ اقلیدسی را می‌توان به‌سادگی به‌عنوان کوتاه‌ترین فاصله بین ۲ نقطه بدون توجه به ابعاد تعریف کرد. این شیوه رایج‌ترین راه برای یافتن فاصله است. براساس فرمول فاصلهٔ اقلیدسی، فاصلهٔ بین دو نقطه عبارت است از:

$$d_{Euc}\left(X,Y\right) = \left(\sum_{i=1}^{n} \left|x_i - y_i\right|^2\right)^{1/2}$$

فاصلهٔ اقلیدسی را می‌توان با استفاده از نرم مینکوفسکی (Minkowski) که به نرم p نیز معروف است تعمیم داد، که در این صورت برای دو نقطهٔ X, Y خواهیم داشت:

$$d_p\left(\mathrm{X},\mathrm{Y}\right) = \left(\sum_{i=1}^{n} \left|x_i - y_i\right|^p\right)^{\frac{1}{p}},\ P \in \mathbb{N}.$$

همان‌طور که مشاهده می‌شود، برای حالت $p = 2$ فاصلهٔ مینکوفسکی به تابع فاصلهٔ اقلیدسی تبدیل می‌شود. معمولاً مقادیر ۱ و ۲ برای متغیر p استفاده می‌شود. اگر مقدار p را برابر یک قرار دهیم، تابع فاصلهٔ منهتن (Manhattan) به‌دست خواهد آمد:

$$d_{cb}\left(X,Y\right) = \left(\sum_{i=1}^{n} \left|x_i - y_i\right|\right)$$

در حالت‌های حدی نیز فاصلهٔ چبیشف را خواهیم داشت:

$$\lim_{p\to\infty}\left(\sum_{i=1}^{n} \left|x_i - y_i\right|^p\right)^{\frac{1}{p}} = \max\left\{\left|x_i - y_i\right|\right\}$$

$$\lim_{p\to-\infty}\left(\sum_{i=1}^{n} \left|x_i - y_i\right|^p\right)^{\frac{1}{p}} = min\left\{\left|x_i - y_i\right|\right\}$$

الگوریتم کا_میانگین (K-means) یکی از شناخته‌شده‌ترین الگوریتم‌های پرکاربرد خوشه‌بندی‌های غیرسلسله‌مراتبی (Non-hierarchical) در حوزهٔ یادگیری بدون نظارت است. از نظر تاریخی، همچنان کا_میانگین، در میان سایر الگوریتم‌های گروه‌بندی، مناسب‌ترین رویکرد گروه‌بندی داده است. الگوریتم کا_میانگین دارای قابلیت گروه‌بندی تعداد انبوهی از داده‌ها با زمان محاسبات نسبتاً سریع و کارآمد است. از نظر فنی، مراحل الگوریتم به شرح زیر است (MacKay, 2003).

۱- فرض کنید N نقطه داده به شکل $X^l = \left(x_1^l, x_2^l, \ldots, x_n^l\right)$ وجود دارد که $l = 1, 2, \ldots, N$.

۲- مجموعه‌ای از k بردار نماینده (مراکز خوشه) c_j را پیدا کنید ($j = 1, 2, \ldots k$).

۳- نقاط داده را به k زیرمجموعهٔ مجزا S_j حاوی N_j نقطه تقسیم کنید، به‌گونه‌ای که تابع زیر به حداقل برسد:

Archive of SID.ir

Archive of SID.ir

$$J = \sum_{j=1}^{k} \sum_{l \in S_j} X^l - c_j^2$$

که در آن c_j میانگین نقاط مجموعه S_j است که از رابطهٔ زیر به‌دست می‌آید:

$$c_j = \frac{\sum_{l \in S_j} X^l}{N_j}$$

به‌عبارتی‌دیگر، به‌طور مثال در حالتی که با فاصلهٔ اقلیدیسی کار می‌کنیم مقداردهی اولیهٔ مراکز خوشه و سایر محاسبات را آن‌قدر تکرار می‌کنیم که خوشهٔ تازه تشکیل‌شده در نقاط مرکزی تغییر نکند. شکل ۱ مراحل رسیدن از دادهٔ خام به خوشه‌های نهایی را در پنج تکرار نمایش می‌دهد.

همان‌طور که مشاهده کردید، براساس ساختار الگوریتم کا_میانگین تعداد خوشه‌های مورد نظر می‌بایست از پیش تعیین شود. این موضوع چالش اصلی استفاده از الگوریتم مزبور است. برای حل مشکل تعیین بهینهٔ تعداد خوشه‌ها دو رویکرد اصلی سایه‌نما (Silhouette score) و روش آرنج (Elbow method) ارائه شده است (Singh *et al.*, 2013; Pham *et al.*, 2005; Lleti *et al.*, 2004; Kodinariya and Makwana, 2013) برای مطالعهٔ فاصلهٔ جدایی بین خوشه‌های حاصل می‌توان از روش آرنج استفاده کرد. در واقع هر خوشه با محاسبه و مقایسهٔ فواصل نقاط داده در یک خوشه با مرکز آن تشکیل می‌شود. در همین راستا روشی ایده‌آل برای تعیین تعداد مناسب خوشه‌ها، محاسبهٔ مجموع مربعات درون خوشه‌ها (Within-Cluster-Sum-of-Squares (WCSS)) است. مقدار این متغیر مجموع مربعات فواصل هر نقطه داده در همهٔ خوشه‌ها تا مرکز متناظر با آن را ارائه می‌دهد.

$$WCSS = \sum_{C_k}^{C_n} \left(\sum_{p_i in\ C_i}^{p_m} dist(p_i, C_k)^2 \right)$$

در رابطهٔ بالا C مراکز خوشه و i نقاط موجود در خوشه است و هدف به حداقل رساندن مجموع بالاست. فرض کنید n مشاهده در یک مجموعه داده وجود دارد و ما n تعداد خوشه را مشخص کنیم ($K = n$)، سپس WCSS صفر می‌شود، زیرا نقاط داده خودشان به‌عنوان مرکز عمل می‌کنند و فاصلهٔ نقاط تا مرکز صفر خواهد بود که در این حالت به n خوشه خواهیم رسید که طبیعتاً تعدادی بدیهی و غیرمنطقی است. بنابراین یک مقدار آستانه برای K وجود دارد که می‌توانیم آن را با استفاده از نمودار آرنج پیدا کنیم. برای این منظور به‌طور تصادفی الگوریتم کا_میانگین را برای محدوده‌ای از مقادیر K مقداردهی اولیه می‌کنیم و مقدار WCSS را برای هر K رسم می‌کنیم.

برای شکل ۲، مقدار بهینه برای K عدد ۵ خواهد بود. همان‌طور که می‌بینیم با افزایش تعداد خوشه‌ها، مقدار WCSS کاهش می‌یابد. مقدار K براساس میزان کاهش WCSS انتخاب می‌شود. به‌طور مثال، از خوشهٔ ۱ به ۲ و ۳ در نمودار بالا شاهد افت ناگهانی و شدید WCSS هستیم. اما از مقدار ۵ به بعد شاهد افت حداقلی هستیم و ازاین‌رو ۵ به‌عنوان مقدار بهینه برای K انتخاب می‌شود.

برای مطالعهٔ فاصلهٔ جدایی بین خوشه‌های حاصل می‌توان از تحلیل سایه‌نما یا سیلوئت نیز استفاده کرد. نمودار سیلوئت میزان نزدیکی هر نقطه در یک خوشه را نسبت به نقاط موجود در خوشه‌های همسایه نشان می‌دهد و بنابراین راهی برای ارزیابی بصری تعداد خوشه‌ها ارائه می‌دهد. ضرایب سیلوئت از رابطهٔ زیر محاسبه می‌شود:

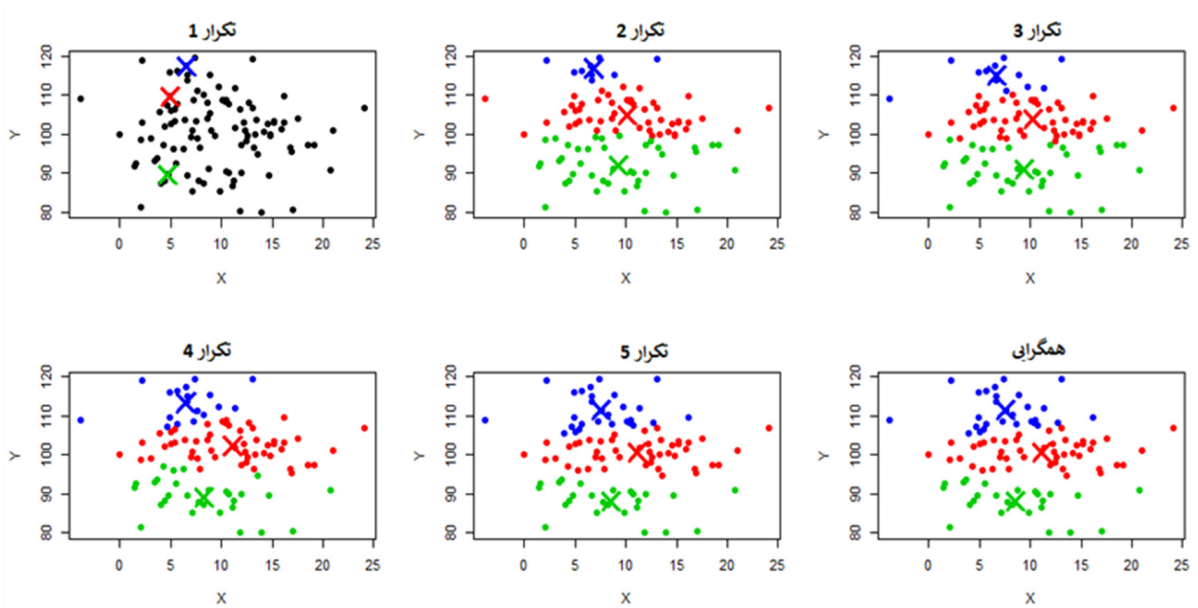

شکل ۱: خوشه‌بندی کا_میانگین (*K=3*)
Fig. 1. K-means clustering (K=3)

Archive of SID.ir

Archive of SID.ir

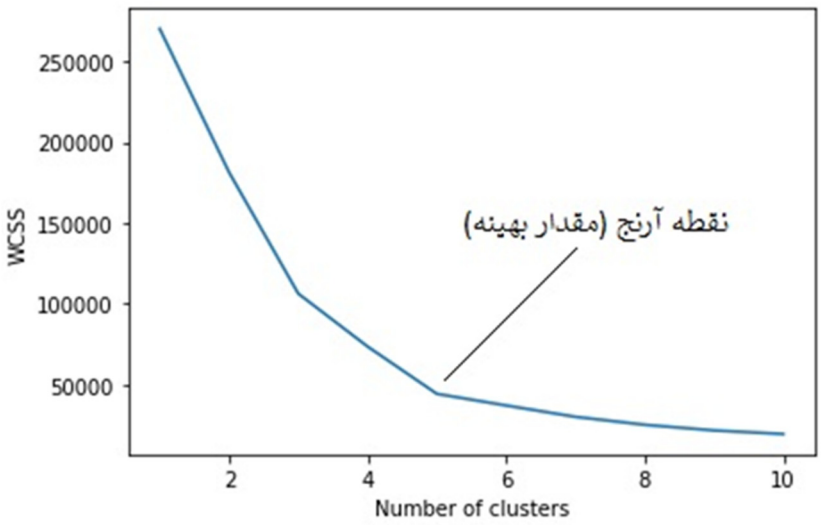

شکل ۲: نمودار *WCSS* در مقابل تعداد خوشه
Fig. 2. Plot of WCSS versus number of clusters

$$s(o)=\frac{b(o)-a(o)}{\max\{a(o),b(o)\}}$$

که در آن:

- $s(o)$ ضریب سیلوئت متناظر با نقطه o،
- $a(o)$ میانگین فاصله بین o و سایر نقاط داده در خوشه‌ای که o به آن تعلق دارد و
- $b(o)$ حداقل میانگین فاصله از o تا خوشه‌هایی هستند که o به آن‌ها تعلق ندارد.

ضرایب در بازهٔ [۱و۱-] تعریف می‌شوند. مقادیر نزدیک به ۱ نشان می‌دهد که نمونهٔ دادهٔ مورد نظر از خوشه‌های همسایه دور است. مقدار صفر بیانگر آن است که نمونه بسیار نزدیک و یا روی مرز تصمیم بین دو خوشه همسایه قرار دارد و مقادیر منفی نشان می‌دهد که آن نمونه‌ها ممکن است به خوشهٔ اشتباهی اختصاص داده شده باشند.

نتایج و بحث

در این مقاله، مطالعه بر روی داده‌های خسارت مالی مربوط به پرونده‌های خسارت بیمهٔ شخص ثالث صورت گرفته است. مجموعه دادهٔ مزبور شامل ۲۰۶۰۶ نمونه و چهار متغیر (ویژگی) با عناوین سن بیمه‌گذار، سطح درآمد بیمه‌گذار (براساس میزان حق‌بیمهٔ پرداختی)، جنسیت بیمه‌گذار و خسارت مالی پرداختی به بیمه‌گذار است. قبل از اعمال مدل بر روی داده‌ها، مراحل پیش‌پردازش داده شامل کشف و جایگزینی مقادیر گم‌شده، کدگذاری متغیرهای اسمی و نرمال‌سازی (تبدیل دامنهٔ تغییرات مشاهدات به بازهٔ صفر و یک) مقادیر متغیرها صورت گرفته است. تمامی تحلیل‌ها با استفاده از نرم‌افزار پایتون انجام شده است.

پس از آماده‌سازی داده‌ها، تعداد خوشه‌های متفاوت برای دسته‌بندی بیمه‌گذاران به گروه‌های مناسب بر روی داده‌ها انجام گرفت و شکل ۳ به‌عنوان خروجی مدل به‌دست آمد:

براساس رویکرد آرنج و با توجه به نمودار بالا، تعداد خوشهٔ بهینه که به بیشترین کاهش در مقدار WCSS منجر می‌شود مقدار آستانهٔ ۴ است. شایان ذکر است مقدار ۳ نیز می‌تواند به‌عنوان یک کاندید برای تعداد بهینهٔ خوشه در نظر گرفته شود. به همین دلیل از نمودارهای سیلوئت برای تصمیم‌گیری مناسب‌تر نیز استفاده می‌شود. در شکل زیر نمودار سیلوئت برای ۳ تا ۶ خوشه‌بندی ترسیم شده است

همان‌طور که در شکل ۴ نیز مشاهده می‌شود بین ضرایب سیلوئت برای تعداد ۳ و ۴ خوشه تفاوت چشمگیری وجود ندارد، اما این ضرایب برای حالتی که مجموعه داده به ۵ یا ۶ خوشه تقسیم می‌شود دچار کاهش زیادی می‌گردد. براساس ضرایب سیلوئت (که بیانگر تعداد بهینهٔ خوشه‌های متمایز است) مقادیر ۳ و ۴ کاندیدهای اصلی برای تعداد بهینهٔ خوشه است. نتایج نشان‌دهندهٔ ۴ خوشه است، اما همان‌طور که در نمودارها مشاهده می‌شود، خوشهٔ دوم و سوم طیفی از طبقهٔ ریسکی متوسط‌اند و برای ارائهٔ مدلی منطبق بر واقعیت و کاربردی‌تر برای شرکت‌های بیمه، بهتر است خوشهٔ دوم و سوم را در یک طبقهٔ ریسک متوسط قرار دهیم. تا در نهایت سه طبقهٔ ریسکی کم‌ریسک، ریسک متوسط و پرریسک را از هم متمایز سازیم. به همین دلیل با وجود اینکه در خروجی نرم‌افزار ۴ خوشه داریم، در نهایت سه طبقهٔ ریسک به‌عنوان نتیجه برآورد و تعداد بهینهٔ خوشه‌بندی انتخاب می‌شود.

پس از پیدا کردن تعداد بهینهٔ خوشه‌های مربوط به بیمه‌گذاران، برای ترسیم آن از تحلیل مؤلفه‌های اصلی استفاده شده و شکل ۵ به‌عنوان خروجی به دست آمده است:

پس از تعیین تعداد بهینهٔ خوشه‌ها، توزیع متغیرهای مختلف در هر خوشه بررسی شد. این امر به تحلیل رفتاری بیمه‌گذاران و توصیف گروه‌بندی‌های مختلف کمک می‌کند. در همین راستا نمودارهای زیر

Archive of SID.ir

Archive of SID.ir

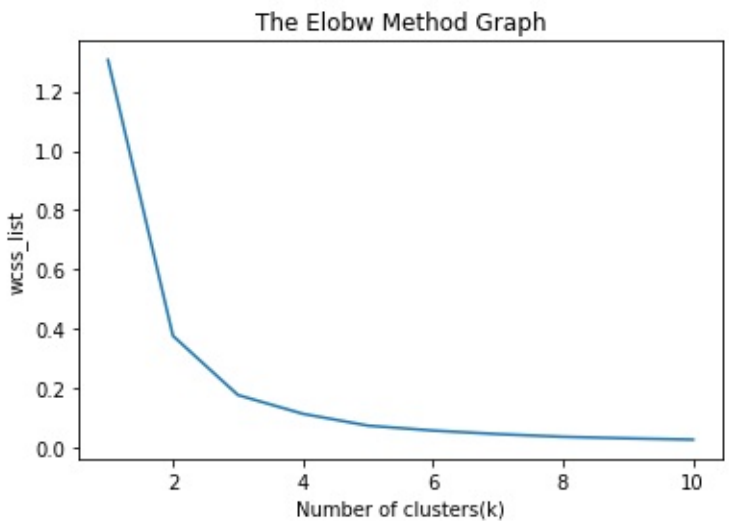

شکل ۳: نمودار آرنج برای ۱۰ خوشه‌بندی روی داده
Fig. 3. Elbow diagram for 10 event clustering

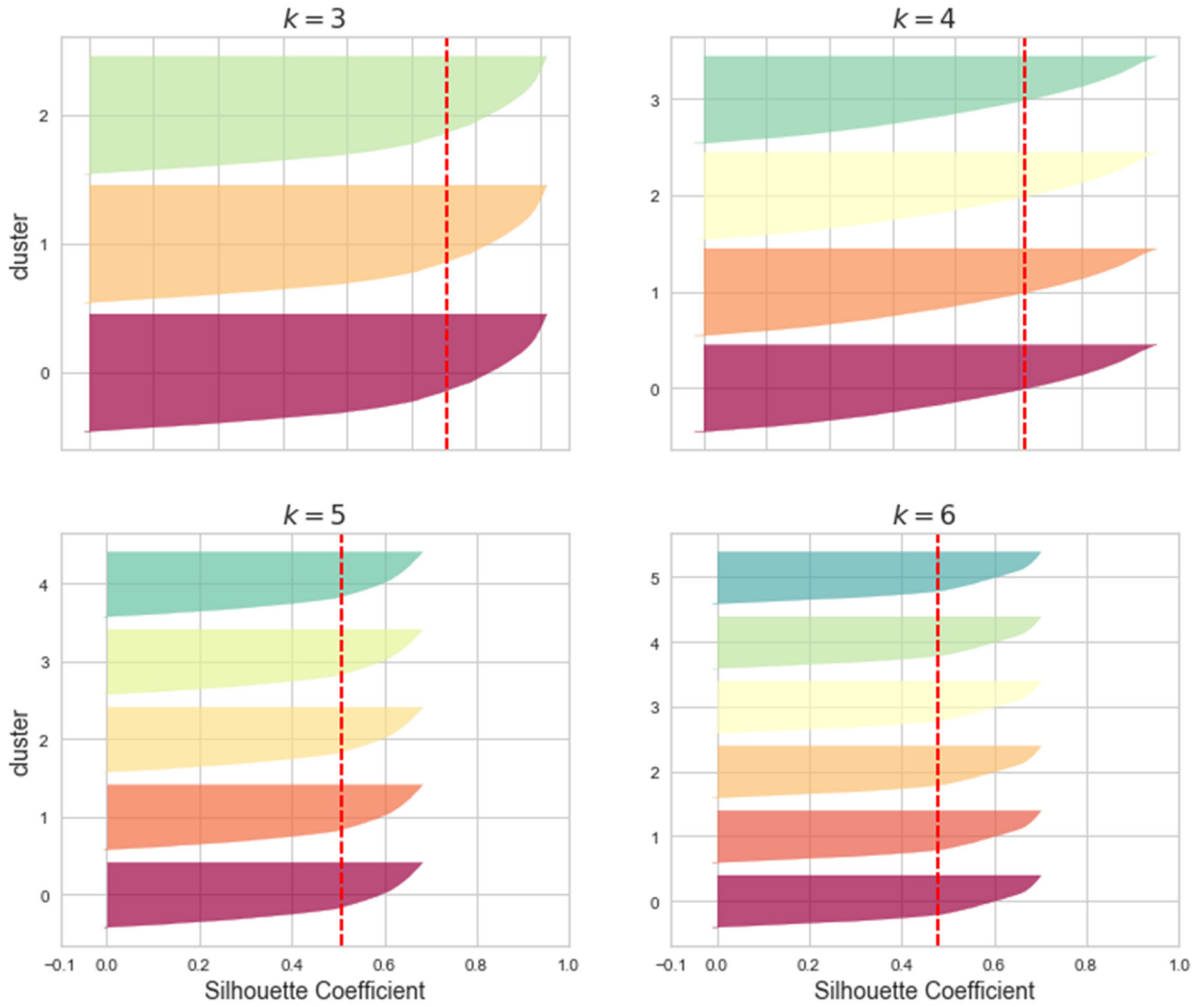

شکل ۴: نمودار سیلوئت برای تعداد ۳، ۴، ۵ و ۶ خوشه
Fig. 4. Silhouette diagram for the number of 3, 4, 5 and 6 clusters

Archive of SID.ir

Archive of SID.ir

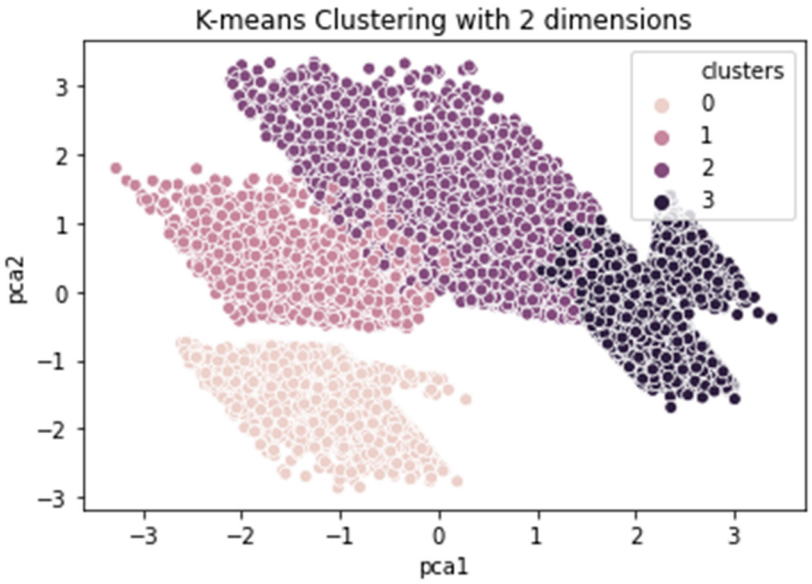

شکل ۵: خوشه‌بندی بهینه از طریق تحلیل مؤلفه‌های اصلی
Fig. 5. Optimal clustering through principal component analysis

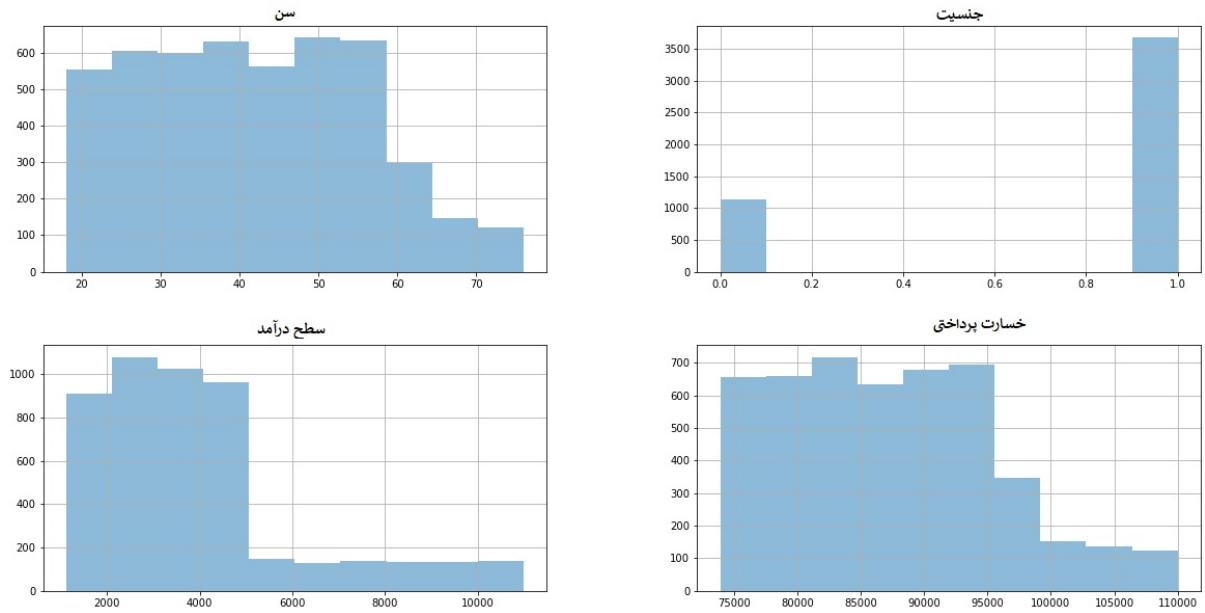

شکل ۶: توزیع متغیرها در خوشهٔ اول
Fig. 6. Distribution of variables in the first cluster

به‌ترتیب شرایط موجود در خوشه‌های ۱ تا ۴ را برای متغیرهای مختلف نشان می‌دهد.

در شکل ۶ تعداد و توزیع چهار متغیر اصلی مورد بررسی در مطالعه در خوشهٔ اول مشاهده می‌شود.

چهار نمودار ترسیم‌شده در شکل ۷، میزان توزیع متغیرهای سن، جنسیت، سطح درآمد و خسارت پرداختی را در خوشهٔ دوم نمایش می‌دهد.

شکل ۸ بیانگر شیوهٔ توزیع متغیرهای مجموعه داده‌های در اختیار در خوشهٔ سوم است.

در نهایت شکل ۹ نمایانگر نمودار توزیع چهار متغیر سن، جنسیت، سطح درآمد و خسارت پرداختی در خوشه و گروه چهارم بیمه‌گذاران است. در همین راستا در بخش بعد با توجه به خروجی‌های به‌دست‌آمده از اعمال مدل و خوشه‌بندی بیمه‌گذاران به تحلیل هر خوشه جداگانه پرداخته می‌شود.

Archive of SID.ir

Archive of SID.ir

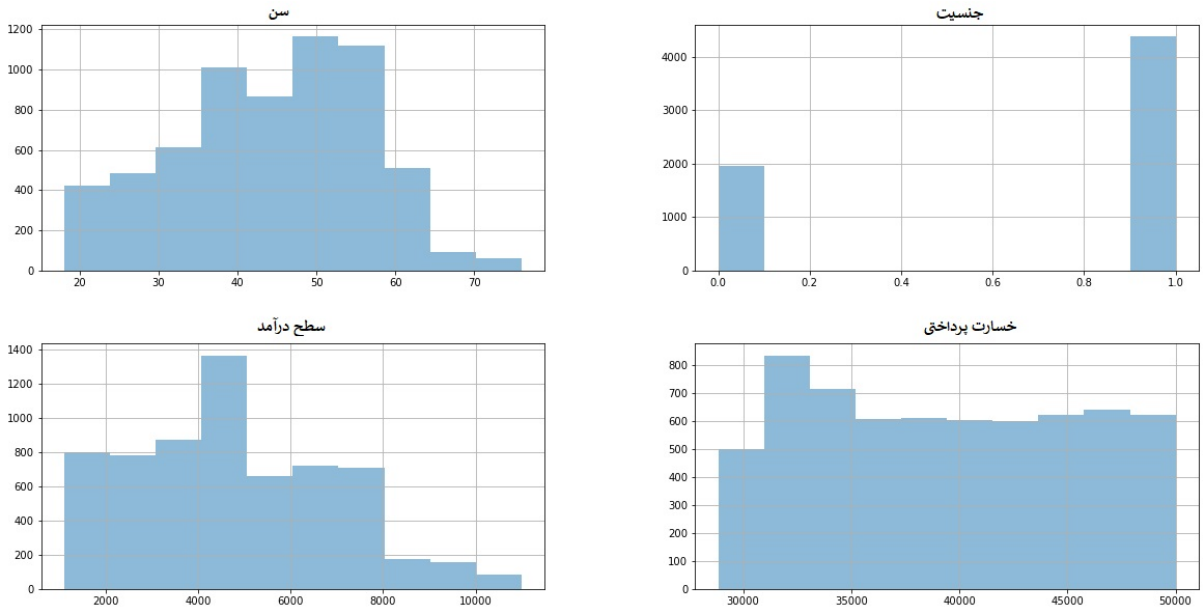

شکل ۷: توزیع متغیرها در خوشهٔ دوم
Fig. 7. Distribution of variables in the second cluster

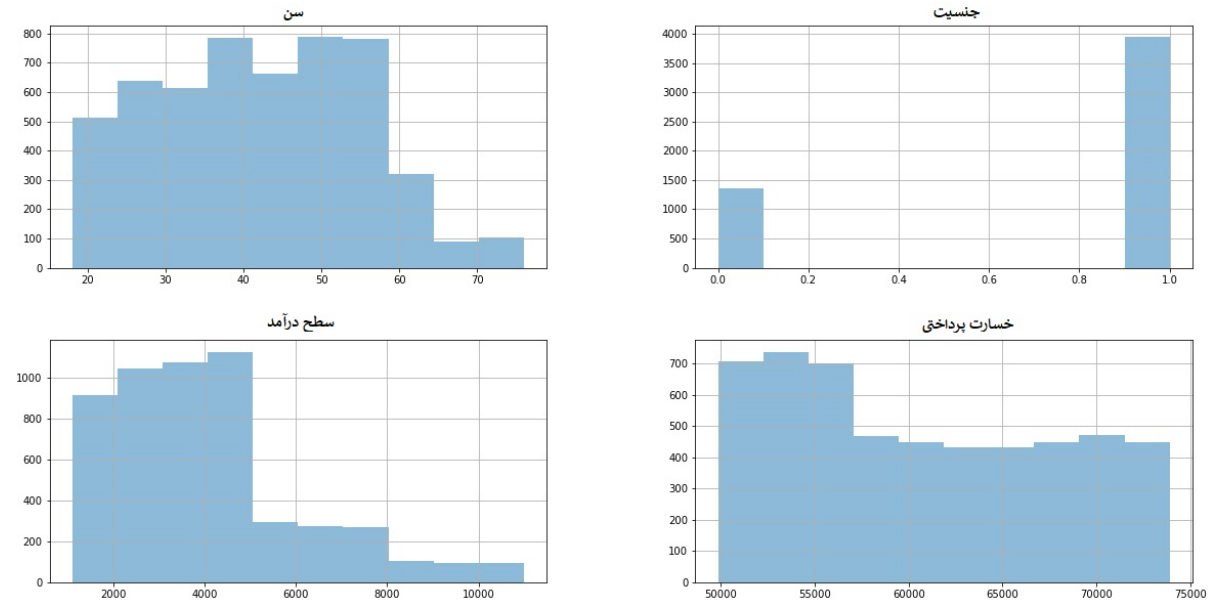

شکل ۸: توزیع متغیرها در خوشهٔ سوم
Fig. 8. Distribution of variables in the third cluster

جمع‌بندی و پیشنهادها

با توجه به تحلیل‌های انجام‌گرفته در بخش ۵، در پاسخ به پرسش اول مبنی بر مقادیر و چگونگی ترکیب متغیرها برای تشکیل ریسک‌پکیج‌های مختلف، خوشه‌های به‌دست‌آمده به شرح ذیل تفسیر می‌شوند.

خوشهٔ اول

آنچه از نتایج برآوردها مشاهده می‌شود، ۴ خوشه بهترین خروجی دسته‌بندی بیمه‌گذاران است. در خوشهٔ اول همان‌طور که در نمودار مشخص است، پهنهٔ سنی بیمه‌گذاران از کم‌سن تا سنین بالا مشاهده می‌شود، اما میانگین سنین ۴۱ سال با انحراف معیار ۱۴ است. مد در این خوشه ۵۰ سال است. البته توزیع داده‌ها مشابه توزیع یکنواخت و شامل همهٔ گروه‌های سنی است. ویژگی دیگر این خوشه، نسبت ۰,۷ مردان به زنان است. از ویژگی‌های مهم دیگر این خوشه این است که معیار سطح درآمد آن در پایین‌ترین

Archive of SID.ir

Archive of SID.ir

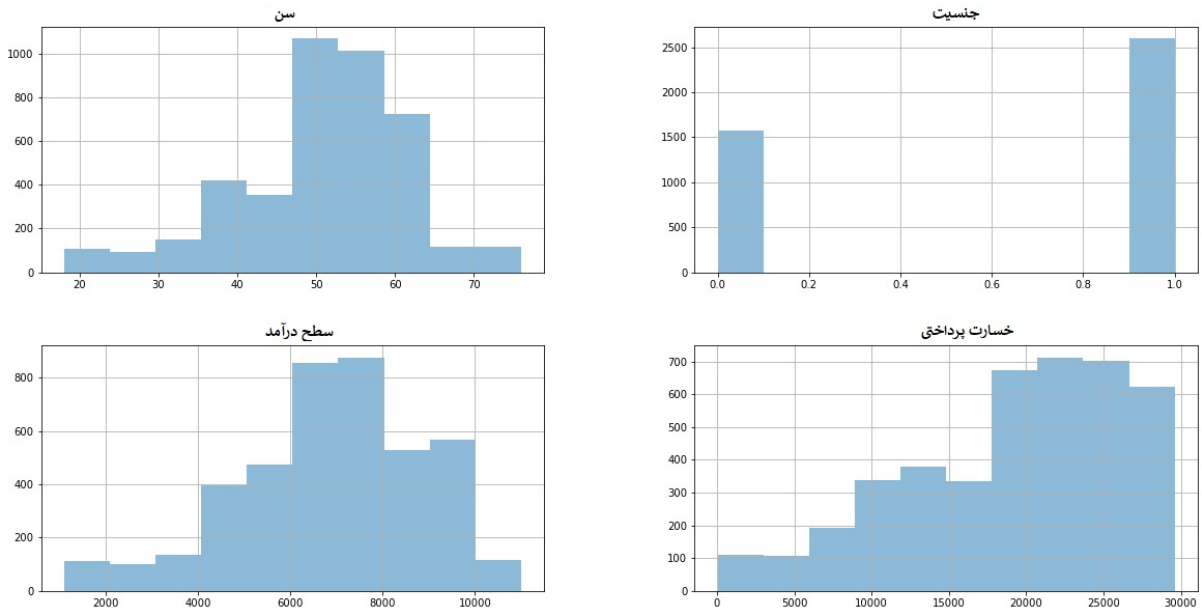

شکل ۹: توزیع متغیرها در خوشهٔ چهارم
Fig. 9. Distribution of variables in the fourth cluster

سطح میان ۴ خوشه ارائه شده است. درعین‌حال بازهٔ ریسک این گروه بیشترین سطح ریسک را نشان می‌دهد. در تفسیر این خوشه می‌توان به گروه‌هایی از بیمه‌گذاران با درآمد کم و بیمه‌گذاران مرد که دارای خودروی ارزان‌قیمت‌تر از متوسط است، اشاره کرد. با توجه به پارامترهای بیان‌شده، شاخصهٔ اصلی پکیج‌سازی از پرریسک‌ترین بیمه‌گذاران مستخرج از خوشهٔ اول، درآمد پایین، ماشین‌های ارزان‌قیمت و نسبت بالای مردان است.

خوشهٔ دوم

در این خوشه، میانگین سنی کمی بیشتر از خوشهٔ اول برابر ۴۴ سال و انحراف معیار ۱۲ است. البته با توجه به چولگی توزیع که در نمودار هم قابل مشاهده است، بیمه‌گذاران این خوشه با سن عموماً متوسط‌اند. معیارهای سطح درآمد نیز در میان ۴ خوشه در حد متوسط است. نسبت مردان به زنان نیز کمترین سطح درمیان خوشه‌هاست. سطح ریسک این گروه در حد متوسط رو به پایین یا طبقهٔ ریسک ۲ قرار دارد. ویژگی‌های مهم این خوشه برای تشکیل پکیج درآمد متوسط با سنین متوسط است.

خوشهٔ سوم

این خوشه با ویژگی‌های میانه‌ای از خوشهٔ اول و دوم است. میانگین سنی ۴۲ سال با انحراف معیار ۱۴ و سطح درآمدی متوسط گروه‌های ۱ و ۲ را داراست. سطح ریسک این خوشه نیز در سطح متوسط خوشه اول و دوم است و در سطح ۳ قرار دارد. این خوشه تأکیدی بر تقابل سه ویژگی سن و سطح درآمد و وجود ریسک بالاتر مردان در گروه‌های سطح درآمدی پایین است و ویژگی دیگری ارائه نمی‌دهد.

خوشهٔ چهارم

این خوشهٔ میانگین سنی متفاوت با سایر خوشه‌ها دارد. میانگین سنی ۵۰ و انحراف معیار ۱۰ نشان‌دهندهٔ بیمه‌گذاران مسن در این خوشه است. همان‌طور که در نمودار نیز مشاهده می‌شود چولگی نیز به سمت راست است. ازطرف‌دیگر معیار سطح درآمد این خوشه نیز بسیار بالاتر از دیگر خوشه‌ها و چوله به راست است. نسبت مردان به زنان در سطح ۰٫۶ است که جزء نسبت پایین در خوشه‌هاست. این خوشه کمترین میزان ریسک (سطح ۱) را در مقابل سایر خوشه‌ها دارد. ویژگی این خوشه افراد با سنین بالا و ماشین‌های گران‌قیمت و سطح درآمدی بالاست.

از بررسی ویژگی‌های به‌دست‌آمده در ۴ خوشهٔ مطرح‌شده می‌توان پکیج‌های ریسک ذیل را معرفی کرد. همان‌گونه که در بخش ۵ ذکر شد، چنانچه بخواهیم تمایز خوشه‌ها را که نشان‌دهندهٔ طبقهٔ ریسکی متفاوت است، شفاف‌تر کنیم و همپوشانی‌های خوشه‌ها را کمتر کنیم، بهتر است خوشهٔ دوم و سوم را در یک طبقهٔ ریسک متوسط قرار دهیم.

– افراد با سنین بالا، متوسط و پایین (چگال در بازهٔ ۳۰ تا ۵۸ سال) با ارزش ماشین ارزان‌قیمت با جنسیت مرد را می‌توان به‌عنوان بالاترین سطح ریسک معرفی کرد.

– افراد با سنین متوسط و بالا (چگال در بازهٔ ۳۲ تا ۵۳ سال) با ارزش ماشین متوسط و بالا را می‌توان به‌عنوان ریسک‌های متوسط در نظر گرفت.

Archive of SID.ir

Archive of SID.ir

– افراد با سنین متوسط به بالا (چگال در بازهٔ ۵۱ تا ۶۳ سال) با ماشین گران‌قیمت را پایین‌ترین سطح ریسک در نظر گرفت.

همان‌طور که در نتایج پکیج‌ها مشاهده می‌شود، با اینکه جمعیت قابل توجهی از بیمه‌گذارانی با سن بالا در پکیج اول (خوشهٔ اول) هستند، بالاترین سطح ریسک را دارند، افرادی با سنین بالا در پکیج سوم (به‌طوری که حتی میانگین سنی این پکیج در بالاترین سطح در خوشه‌هاست) کمترین سطح ریسک را دارند. نکتهٔ درخور توجه دیگر اینکه با افزایش دهک درآمدی و هم‌زمان با افزایش سن (بررسی خوشهٔ ۱ تا ۳) از سطح ریسک کاسته می‌شود. این موضوع بیانگر برتری رویکرد مزبور نسبت به روش کلاسیک ریسک‌فاکتور است که پاسخ به پرسش دوم این پژوهش نیز هست. در خصوص آزمون اینکه ریسک‌پکیج بهتر از ریسک‌فاکتور نشان‌دهندهٔ ریسک افراد است، با توجه به اینکه در نمونهٔ مثلاً افرادی با سنین بالا ولی خسارت کم و بالعکس در سنین پایین و خسارت بالا نیز به میزان چشمگیری (که در نمودارهای انتهای مقاله مشاهده می‌شود) وجود دارند، نشان‌دهندهٔ این است که سن نمایندهٔ دقیقی برای نشان دادن ریسک بیمه‌گذاران نیست، ولی روش جدید با دسته‌بندی ریسک‌پکیج و ترکیب ریسک‌فاکتورها پکیج‌هایی ایجاد شده که توانسته در توضیح‌دهندگی ارتباط پکیج با خسارت‌ها دسته‌های تفکیک‌پذیری ایجاد کند، به‌طوری که تفاوت میانگین و واریانس خسارت‌ها در کلاسترهای بیمه‌گذاران با ریسک‌های قابل تمیز از هم را توانسته توضیح دهد، بدون آنکه هم‌پوشانی حالت ریسک‌فاکتور را داشته باشد.

در نهایت شایان ذکر است که همچنان ترکیب‌هایی از متغیرهای استفاده‌شده در این تحقیق می‌توان تولید کرد که خوشه‌بندی‌های انجام‌شده در این مقاله نمی‌توانند توجیه و دسته‌بندی دقیقی برای آن ارائه دهند. در واقع در این مرحله مبحث رزولوشن به میان می‌آید. به این معنا که اگر بخواهیم تحلیل‌هایی با رزولوشن و دقت بالاتری ارائه دهیم که دربرگیرندهٔ حالت‌های بیشتری باشد به تعداد متغیرهای مستقل بیشتری نیاز داریم. لیکن دسترسی به متغیرهای بیشتر که مقادیر تمیزی در آن‌ها وارد شده باشد امر ساده‌ای نیست. باوجوداین موضوع مزبور توسط تیم نویسندگان این مقاله در دست انجام است و پس از بررسی‌ها و انجام مطالعات، خروجی پژوهش در قالب مقاله‌ای با نتایج مقالهٔ فعلی مقایسه خواهد شد.

مشارکت نویسندگان

مریم اثنی‌عشری: جمع‌آوری مطالعات مرتبط، جمع‌آوری و اخذ داده‌ها، تفسیر داده‌ها، نگارش و ویرایش. فرزان خامسیان: ارائهٔ مدل، تجزیه‌وتحلیل و تفسیر داده‌ها، تجزیه‌وتحلیل و تفسیر داده‌ها و نظارت و سرپرستی. فربد خانی‌زاده: اجرای مدل‌ها، تفسیر نتایج و خروجی‌ها.

تشکر و قدردانی

از پیشنهادهای داوران محترم که به غنای علمی مقاله کمک نمودند، بسیار سپاسگزاریم.

تعارض منافع

نویسندگان اعلام می‌دارند که در خصوص انتشار این مقاله تضاد منافع وجود ندارد. علاوه‌براین، موضوعات اخلاقی شامل سرقت ادبی، رضایت آگاهانه، سوءرفتار، جعل داده‌ها، انتشار و ارسال مجدد و مکرر ازسوی نویسندگان رعایت شده است.

دسترسی آزاد

کپی‌رایت نویسنده(ها) ©2024: این مقاله تحت مجوز بین‌المللی Creative Commons Attribution 4.0 اجازهٔ استفاده، اشتراک‌گذاری، اقتباس، توزیع و تکثیر را در هر رسانه یا قالبی مشروط بر درج نحوهٔ دقیق دسترسی به مجوز CC و منوط به ذکر تغییرات احتمالی در مقاله می‌داند. لذا به استناد مجوز مذکور، درج هرگونه تغییرات در تصاویر، منابع و ارجاعات یا سایر مطالب از اشخاص ثالث در این مقاله باید در این مجوز گنجانده شود، مگر اینکه در راستای اعتبار مقاله به اشکال دیگری مشخص شده باشد. در صورت عدم درج مطالب یادشده و یا استفادهٔ فراتر از مجوز بالا، نویسنده ملزم به دریافت مجوز حق نسخه‌برداری از شخص ثالث است.

به‌منظور مشاهدهٔ مجوز بین‌المللی Creative Commons Attribution 4.0 به نشانی زیر مراجعه شود:

http://creativecommons.org/licenses/by/4.0

یادداشت ناشر

ناشر نشریهٔ پژوهشنامهٔ بیمه با توجه به مرزهای حقوقی در نقشه‌های منتشرشده بی‌طرف باقی می‌ماند.

Archive of SID.ir

Archive of SID.ir

منابع

Arvidsson, S., (2010). Does private information affect the insurance risk?: Evidence from the automobile insurance market. Work. Pap., 1-54 **(54 Pages)**.

Asmussen, S.; Rubinstein, R.Y., (1999). Sensitivity analysis of insurance risk models via simulation. Manage. Sci., 45(8): 1125-1141 **(17 Pages)**.

Ayuso, M.; Guillen, M.; Nielsen, J.P., (2019). Improving automobile insurance ratemaking using telematics: Incorporating mileage and driver behaviour data. Transp., 46: 735-752 **(18 Pages)**.

Barsotti, F.; Milhaud, X.; Salhi, Y., (2016). Lapse risk in life insurance: Correlation and contagion effects among policyholders' behaviors. Insur. Math. Econ., 71: 317-331 **(15 Pages)**.

Burka, D.; Kovács, L.; Szepesváry, L., (2021). Modelling MTPL insurance claim events: Can machine learning methods overperform the traditional GLM approach?. Hung. Stat. Rev., 4(2): 34-69 **(36 Pages)**.

Chen, S.; Ma, B.; Zhang, K., (2009). On the similarity metric and the distance metric. Theor. Comput. Sci., 410(24-25): 2365-2376 **(12 Pages)**.

Cheong, P.; Jemain, A.A.; ISMAIL, N., (2008). Practice and pricing in non-life insurance: The malaysian experience. J. Qual. Meas. Anal. JQMA., 4(1): 11-24 **(14 Pages)**.

David, M., (2015). Auto insurance premium calculation using generalized linear models. Procedia. Econ. Finance., 20: 147-156 **(10 Pages)**.

Desyllas, P.; Sako, M., (2013). Profiting from business model innovation: Evidence from Pay-As-You-Drive auto insurance. Res. Policy., 42(1): 101-116 **(16 Pages)**.

Dionne, G.; Gouriéroux, C.; Vanasse, C., (1999). Evidence of adverse selection in automobile insurance markets. In Automobile Insurance: Road safety, new drivers, risks, insurance fraud and regulation., 20(1).

Doerpinghaus, H.I.; Schmit, J.T.; Yeh, J.J.H., (2008). Age and gender effects on auto liability insurance payouts. J. Risk. Insur., 75(3): 527-550 **(24 Pages)**.

Dugas, C.; Bengio, Y.; Chapados, N.; Vincent, P.; Denoncourt, G.; Fournier, C., (2003). Statistical learning algorithms applied to automobile insurance ratemaking. CAS. Forum., 1(1): 179-214 **(36 Pages)**.

Eling, M.; Schmeiser, H.; Schmit, J.T., (2007). The Solvency II process: Overview and critical analysis. Risk. Manage. Insur. Rev., 10(1): 69-85 **(17 Pages)**.

Han, J.; Kamber, M.; Pei, J., (2012). Data Mining: Concepts and techniques. Elsevier.

Hanafy, M.; Ming, R., (2021). Machine learning approaches for auto insurance big data. Risk., 9(2): 1-42 **(42 Pages)**.

Hoy, M., (1982). Categorizing risks in the insurance industry. Q. J. Econ., 97(2): 321-336 **(16 Pages)**.

Kodinariya, T.M.; Makwana, P.R., (2013). Review on determining number of cluster in K-Means clustering. Int. J., 1(6): 90-95 **(6 Pages)**.

Likas, A.; Vlassis, N.; Verbeek, J.J., (2003). The global k-means clustering algorithm. Pattern. Recognit., 36(2): 451-461 **(11 Pages)**.

Lleti, R.; Ortiz, M.C.; Sarabia, L.A.; Sánchez, M.S., (2004). Selecting variables for k-means cluster analysis by using a genetic algorithm that optimises the silhouettes. Anal. Chim. Acta., 515(1): 87-100 **(14 Pages)**.

MacKay, D., (2003). Information theory, Inference, and learning algorithms. Cambridge university press

McCartt, A.T.; Mayhew, D.R.; Braitman, K.A.; Ferguson, S.A.; Simpson, H.M., (2009). Effects of age and experience on young driver crashes: Review of recent literature. Traffic. Inj. Prev., 10(3): 209-219 **(11 Pages)**.

McCullagh, P., (2019). Generalized linear models. Routledge.

Meyers, G.G.; Klinker, F.L.; Lalonde, D.A., (2003). The Aggregation and Correlation of Reinsurance Exposure. Casualty. Actuarial. Soc. Forum., 69-151 **(82 Pages)**.

Pham, D.T.; Dimov, S.S.; Nguyen, C.D., (2005). Selection of K in K-means clustering. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science., 219(1): 103-119 **(17 Pages)**.

Segovia-Vargas, M.J.; Camacho-Miñano, M.D.M.; Pascual-Ezama, D., (2015). Risk factor selection in automobile insurance policies: A way to improve the bottom line of insurance companies. Rev. brasileira de gestão de negócios., 1228-1245 **(18 Pages)**.

Singh, A.; Yadav, A.; Rana, A., (2013). K-means with Three different distance metrics. Int. J. Comput. Appl., 67(10): 13-17 **(5 Pages)**.

Spedicato, G.A.; Dutang, C.; Petrini, L., (2018). Machine learning methods to perform pricing optimization. A comparison with standard GLMs. Variance., 12(1): 69-89 **(21 Pages)**.

Xie, S., (2021). Improving explainability of major risk factors in artificial neural networks for auto insurance rate regulation. Risk., 9(7).

Yeo, A.C., (2009). Neural networks for automobile insurance pricing. Encycl. Inf. Sci. Technol. Second. Ed., 2794-2799 **(6 Pages)**.

Archive of SID.ir

Archive of SID.ir

معرفی نویسندگان **AUTHOR(S) BIOSKETCHES**

مریم اثنی‌عشری، استادیار گروه پژوهشی بیمه‌های اموال و مسئولیت، پژوهشکده بیمه، تهران، ایران

- Email: *esnaashari@irc.ac.ir*
- ORCID: 0000-0001-5337-9665
- Homepage: https://www.irc.ac.ir/fa-IR/Irc/5020/page

فرزان خامسیان، استادیار گروه پژوهشی عمومی بیمه، پژوهشکده بیمه، تهران، ایران

- Email: *khamesian@irc.ac.ir*
- ORCID: 0000-0001-6113-4246
- Homepage: https://www.irc.ac.ir/fa-IR/Irc/5015/page

فربد خانی زاده، استادیار گروه پژوهشی بیمه‌های اموال و مسئولیت، پژوهشکده بیمه، تهران، ایران

- Email: *kanizadeh@irc.ac.ir*
- ORCID: 0000-0002-0565-2046
- Homepage: https://www.irc.ac.ir/fa-IR/Irc/5019

HOW TO CITE THIS ARTICLE

Esna-Ashari, M.; Khamesian, F.; khanizadeh, F., (2024). Providing the concept of risk package instead of risk factor in order to classify the risk of policyholders more accurately. Iran. J. Insur. Res., 13(1): 15-28.

DOI: 10.22056/ijir.2024.01.02

URL: https://ijir.irc.ac.ir/article_160308.html?lang=en

Archive of SID.ir