



Original Article

Classification and Allocation of Suppliers to Customers in Resilience Supply Chains Using Machine Learning

Mahdi Esmaili*, Laya Olfat**, Maghsoud Amiri***, Iman Raeesi Vanani****

Abstract

Selection and allocation in the resilient supply chain, when disruption threatens the supply chain, has become a strategic decision and the focus of many researches; increase in the applications of machine learning in supply chain studies has led to the emergence of faster and reliable decision-making methods, however, in few studies, machine learning has been used to deal with the problem of selecting and assigning suppliers to customers in resilient mode. The purpose of this research is to take a step towards solving this gap by using machine learning algorithms on real world data from the automotive supply chain in Iran. the performance data of 441 suppliers and 7 customers in 1401 was used. In this research, two clustering algorithms have been used to generate labels based on the concept of resilience capacity; Then, since the interpretability of the results was a priority, based on the labeling of the clusters by the experts, the decision tree was used to classify the suppliers based on their performance. The results showed the K-means tree performs better than the DBSCAN tree and criteria such as on-time delivery, capacity, production line stoppage, quality alert, logistics performance and quality performance are effective on suppliers' resilience.

Keywords: Supply Chain Resilience; Resilient Supplier Selection; Machine Learning; Supplier-to-Customer Allocation; Automotive Supply Chain.

How to Cite: Esmaili, Mahdi; Olfat, Laya; Amiri, Maghsoud; Raeesi Vanani, Iman (2023). Classification and Allocation of Suppliers to Customers in Resilience Supply Chains Using Machine Learning, *Ind. Manag. Persp.*, 13(3), 39-70 (*In Persian*).

Received: Agu. 10, 2023; Revised: Aug. 17, 2023; Accepted: Agu. 26, 2023; Published Online: Aug. 30, 2023.

* Ph.D Student, Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University.

** Professor, Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University.
Corresponding author. Email: olfat@atu.ac.ir

*** Professor, Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University.

**** Associate Professor, Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University.



Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).



طبقه‌بندی و تخصیص تأمین‌کنندگان به مشتری در زنجیره تأمین تاب‌آور با استفاده از یادگیری ماشین

مهدی اسماعیلی*، لعیا الفت**، مقصود امیری***، ایمان رئیسی وانانی****

چکیده

انتخاب و تخصیص در زنجیره تأمین تاب‌آور، زمانی که اختلال زنجیره تأمین را تهدید می‌کند، به‌عنوان یک تصمیم استراتژیک و به‌کانون پژوهش‌های بسیاری تبدیل شده است؛ از سوی دیگر افزایش کاربردهای یادگیری ماشین در سراسر مطالعات زنجیره تأمین به‌ظهور روش‌های تصمیم‌گیری سریع‌تر و مطمئن‌تر منجر شده است، بااین‌حال در مطالعات کمی از یادگیری ماشین برای مقابله با مشکل انتخاب و تخصیص تأمین‌کننده به مشتری در حالت تاب‌آور استفاده شده است. هدف پژوهش حاضر برداشتن گامی در جهت رفع این شکاف با استفاده از الگوریتم‌های یادگیری ماشین بر روی داده‌های دنیای واقعی از زنجیره تأمین خودرو در ایران است. بدین منظور از داده‌های عملکردی ۴۴۱ تأمین‌کننده و ۷ مشتری در سال ۱۴۰۱ استفاده شد. در این پژوهش از دو الگوریتم خوشه‌بندی برای تولید برچسب بر اساس مفهوم ظرفیت تاب‌آوری استفاده شده است؛ سپس از آنجا که تفسیرپذیری نتایج در اولویت قرار داشت، بر اساس لیبل‌گذاری خوشه‌ها توسط خبرگان از درخت تصمیم برای طبقه‌بندی تأمین‌کنندگان بر اساس عملکرد آن‌ها استفاده شد. نتایج نشان داد که درخت K-means عملکرد بهتری نسبت به درخت DBSCAN دارد و معیارهای چون تحویل به‌موقع، درصد تأمین، توقف خط تولید، اختلالات کیفی، عملکرد لجستیکی و عملکرد کیفی بر تاب‌آوری تأمین‌کنندگان مؤثر هستند.

کلیدواژه‌ها: تاب‌آوری زنجیره تأمین؛ انتخاب تأمین‌کننده تاب‌آور؛ یادگیری ماشین؛ تخصیص تأمین‌کننده به مشتری؛ زنجیره تأمین خودرو.

استناددهی: اسماعیلی، مهدی؛ الفت، لعیا؛ امیری، مقصود؛ رئیسی وانانی، ایمان (۱۴۰۲). طبقه‌بندی و تخصیص تأمین‌کنندگان به مشتری در زنجیره تأمین تاب‌آور با استفاده از یادگیری ماشین. *چشم‌انداز مدیریت صنعتی*، ۱۳(۳)، ۳۹-۷۰.

تاریخ دریافت: ۱۴۰۲/۰۵/۱۹، تاریخ بازنگری: ۱۴۰۲/۰۵/۲۶، تاریخ پذیرش: ۱۴۰۲/۰۶/۰۴، تاریخ اولین انتشار: ۱۴۰۲/۰۶/۰۸.

* دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبایی.

** استاد، گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبایی.

Email: olfat@atu.ac.ir نویسنده مسئول

*** استاد، گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبایی.

**** دانشیار، گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبایی.



۱. مقدمه

در زنجیره‌های تأمین جهانی مدرن، جریان مواد از طریق حوادث طبیعی یا انسانی غیرمنتظره می‌تواند مختل شود. با توجه به نقش اعضای زنجیره تأمین و همچنین نوع تسهیلات به‌کاررفته در زنجیره تأمین، وقوع ریسک‌های اختلال، تصمیمات منبع‌یابی، انتخاب تأمین‌کنندگان و تخصیص تقاضا چالش‌برانگیز است.

زنجیره تأمین‌های مدرن دارای پیچیدگی‌های زیادی هستند که این پیچیدگی آن‌ها را در معرض ریسک قرار می‌دهد، اختلال‌های زنجیره تأمین ناشی از عملکرد تأمین‌کنندگان و پیچیدگی‌های زنجیره تأمین است. در بازارهای نامشخص و آشفته امروز، آسیب‌پذیری زنجیره تأمین به یک مسئله تبدیل شده است؛ لذا شرکت‌ها به‌منظور ایجاد مزیت رقابتی به سمت ایجاد زنجیره تأمین تاب‌آور حرکت می‌کنند تا بتوانند علاوه بر مواجهه با اختلال‌ها، ساختار زنجیره تأمین خود را به‌نحوی پیکره‌بندی کنند که به‌عنوان مزیت رقابتی سازمان، در فضای کسب‌وکار کنونی به‌کار گرفته شود و در زمان مناسب پاسخگوی نیازهای مشتری باشد. توجه به ریسک‌های اختلال در استراتژی‌های منبع‌یابی آن‌ها را به سمت خرید و انتخاب تأمین‌کنندگان تاب‌آور (هنگام اختلال حداقل آسیب‌پذیری را داشته و پاسخگوی تقاضای شرکت باشند) سوق می‌دهد. انتخاب و نحوه تخصیص سفارش به تأمین‌کننده، به‌عنوان یک تصمیم استراتژیک برای سازمان‌ها، یک مسئله پیچیده و شامل معیارهای ملموس و نامشهود است [۱۵] در صنعت خودرو به‌دلیل پیچیدگی زنجیره تأمین آن و ضرورت مقابله با ریسک‌ها، تاب‌آوری تأمین‌کنندگان منجر به افزایش تولید خواهد شد [۳۳، ۲۱].

هزینه‌های تحمیل‌شده بر زنجیره تأمین در نتیجه بلایا به‌سختی قابل‌چشم‌پوشی است که باعث می‌شود معیارهای تاب‌آوری بخش مهمی از مشکلات انتخاب تأمین‌کننده باشد. به‌عنوان مثال، طبق گزارش مجمع جهانی اقتصاد، از زمان شیوع ویروس کرونا، معاملات تجاری داخلی و بین‌المللی چین به‌شدت کاهش یافته است [۲۷]. بحران مالی سال ۲۰۰۸، سونامی ژاپن در سال ۲۰۱۱ و انفجار بیروت در سال ۲۰۲۰ موارد دیگری هستند که به‌شدت به زنجیره‌های تأمین در مقیاس‌های مختلف آسیب رسانده‌اند.


انتخاب تأمین‌کننده تاب‌آور از طریق روش‌های مختلفی از جمله برنامه‌ریزی ریاضی، روش‌های تصمیم‌گیری چندمعیاره، روش‌شناسی ترکیبی و اخیراً روش‌های مبتنی بر داده انجام شده است. روش‌های مبتنی بر داده ارائه‌شده توسط هوش مصنوعی، مانند یادگیری ماشینی، در سال‌های اخیر حوزه‌های پژوهشی زیادی را در مدیریت ریسک زنجیره تأمین به خود جلب کرده‌اند. دلایل متعددی پشت رشد اخیر وجود دارد. زمانی که مطالعات زنجیره تأمین از مدل‌سازی ریاضی به سمت چارچوب‌های داده‌محور حرکت می‌کند، یک جنبه یادگیری به کار اضافه می‌شود که به‌وضوح در مدل‌های ریاضی وجود ندارد [۷].

هدف پژوهش حاضر ارائه یک چارچوب تحلیلی برای طبقه‌بندی و تخصیص سفارش به تأمین‌کنندگان بر اساس ظرفیت‌های آن‌ها است. کاربردهای یادگیری ماشین در سراسر زنجیره تأمین اکنون به‌عنوان بخشی از تغییرات انقلاب صنعتی ۴.۰ دیده می‌شود. در این پژوهش ابتدا پژوهش‌های اخیر در مورد تاب‌آوری زنجیره تأمین، انتخاب تأمین‌کننده تاب‌آور و کاربردهای یادگیری ماشین در سراسر مطالعات زنجیره تأمین تشریح شده‌اند؛ سپس داده‌های عملکردی ۴۴۱ تأمین‌کننده در دوره‌های ماهانه سال ۱۴۰۱ در خصوص ۷ مشتری استخراج و پس از پردازش اولیه داده‌های با استفاده از دور الگوریتم DBSCAN و K-means خوشه‌بندی شده است. سپس با نظر خبرگان برچسب‌گذاری صورت گرفته و در مرحله بعد درخت تصمیم بر مبنای خروجی برچسب‌گذاری شده و هر دو الگوریتم به‌منظور طبقه‌بندی و تخصیص تأمین‌کنندگان به مشتریان ارائه شده است. در پایان نتایج به همراه تجزیه و تحلیل آن‌ها آورده است.

در مقاله حاضر در بخش دوم، پژوهش‌های اخیر در مورد انعطاف‌پذیری زنجیره تأمین، انتخاب تأمین‌کننده تاب‌آور و کاربردهای یادگیری ماشین در سراسر مطالعات زنجیره تأمین تشریح شده است. بخش سوم به جزئیات چارچوب تحلیلی مورد استفاده در پژوهش و مطالعه موردی اختصاص دارد. در بخش چهارم نتایج به همراه تجزیه و تحلیل آن‌ها آورده شده است. در نهایت، بخش پنجم شامل نکات پایانی و پیشنهادها است.

۲. مبانی نظری و پیشینه پژوهش

تاب‌آوری. تاب‌آوری یک مفهوم چندبعدی و بین‌رشته‌ای است و پیش از آنکه در حوزه مدیریت زنجیره تأمین سازگاری یابد، ریشه‌هایی در روان‌شناسی و اکوسیستم‌ها داشته است [۲۳]. مطابق چارچوب ارائه‌شده در شکل ۱، تعاریف تاب‌آوری را می‌توان بر اساس چهار مؤلفه اصلی مطرح‌شده در آن‌ها، یعنی انطباق، سرعت، سطح عملکرد و رویداد کانونی دسته‌بندی کرد [۳۴]. عدم توافقی که بین پژوهشگران این حوزه وجود دارد، ناشی از برداشت‌های مختلف آن‌ها از این چهار مؤلفه است.



شکل ۱. محورهای تاب‌آوری ۳۴

تاب‌آوری زنجیره تأمین. افزایش آسیب‌پذیری، ضرورت توجه به انعطاف‌پذیری زنجیره تأمین را بیشتر می‌کند. تاب‌آوری در اوایل دهه ۲۰۰۰ وارد حوزه زنجیره تأمین شد. در این زمان، زنجیره تأمین خود موضوعی نسبتاً جدید بود و سازمان‌ها صرفاً بر موضوعات مرتبط با کارایی متمرکز بودند؛ اگرچه حتی اشکالات جزئی باعث خسارات جدی می‌شد [۳۶].

تاب‌آوری زنجیره تأمین نشان‌دهنده توانایی بازیابی از یک سطح عملکرد نامطلوب به یک سطح عملکرد برنامه‌ریزی‌شده با انجام اقداماتی در جهت بازیابی یا سازگاری است [۲۰].

زنجیره تأمین تاب‌آور. یک دغدغه مهم برای همه مدیران زنجیره تأمین، توانایی زنجیره تأمین آن‌ها در جهت مقاومت در برابر تحولات، اختلالات و رویدادهای پیش‌بینی‌نشده است. زنجیره‌های تأمینی که تحت چنین شرایطی قادر به انجام و ارائه محصولات و خدمات باشد، به‌عنوان تاب‌آور شناخته می‌شوند [۸].

سه شکل از تاب‌آوری شامل مهندسی (بهره‌وری)، محیط‌زیست (تطبیق) و تکامل (رشد و بازیابی) است که با چهار مرحله زنجیره تأمین تاب‌آور شامل آمادگی، پاسخ، بازیابی و رشد و تجدید پیوند می‌خورد [۱].

انتخاب تأمین‌کننده تاب‌آور و تخصیص سفارشی در زنجیره تأمین

مدیریت روابط تأمین. مدیریت روابط تأمین‌کننده کلیه فعالیت‌های مربوط به برنامه‌ریزی استراتژیک و مدیریت کلیه تعاملات بین یک شرکت و تأمین‌کنندگان بوده و شامل موارد زیر است:

- شناسایی تأمین‌کنندگان مناسب؛

- ارزیابی، انتخاب و توسعه تأمین‌کنندگان.

در این فرآیند، چرخه یکپارچه عملکرد تأمین‌کننده باید کنترل شود و با شناسایی یک تأمین‌کننده بالقوه شروع می‌شود. در فرآیند ارزیابی و انتخاب تأمین‌کنندگان بالقوه در خصوص تأمین‌کنندگانی که نمی‌توان رضایت آن‌ها را جلب کرد، نیازها و اهداف باید توسعه یا جایگزین شوند [۱۳].

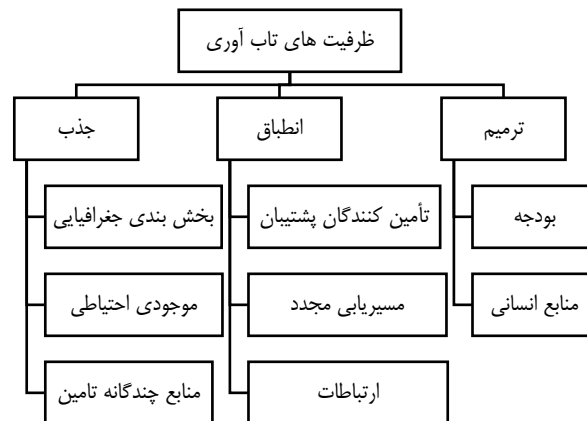
انتخاب تأمین‌کننده. ارزیابی و انتخاب تأمین‌کننده، فرآیند به‌کارگیری تأمین‌کننده توانایی است که محصولاتی باکیفیت بالا، در زمان مناسب و با قیمت مناسب بتواند تأمین کند؛ به‌عبارت‌دیگر انتخاب تأمین‌کننده یک تصمیم چندمعیاره است و دو امر مهم را دربرمی‌گیرد. اولین مورد انتخاب معیارهایی است که باید در نظر گرفته شود و دوم روش‌های مقایسه شایستگی تأمین‌کنندگان است. به‌طورکلی معیارهای سستی انتخاب تأمین‌کننده را می‌توان در دو طبقه کیفی و کمی تقسیم‌بندی کرد. معیارهای کیفی مانند کیفیت محصول، سابقه عملکرد، قابلیت فنی، موقعیت

جغرافیایی، پیشینه روابط کاری، تمایل به تجارت، سیاست‌های گارانتی و معیارهای کمی مانند هزینه‌های حمل‌ونقل، خرید و سفارش، زمان تحویل و نرخ خرابی محصول است [۱۶].

انتخاب تأمین‌کننده تاب‌آور. با افزایش وابستگی به منبع‌یابی جهانی و نیز افزایش احتمال وقوع رویدادهای اختلال در زنجیره تأمین، ایجاد سطح قابل‌اطمینانی از تاب‌آوری پایه تأمین به‌منظور محافظت از خریدار در برابر کمبودها و اختلالات در جریان عرضه، بسیار مهم است [۴۰]. اختلالات در زنجیره تأمین از منابع داخلی و خارجی می‌توانند رخ دهند و جریان مواد را مختل سازند. تأمین‌کنندگان اصلی‌ترین منابع غیرقابل‌اجتناب ریسک‌های خارجی هستند [۳۲].

روبرتو پیرا^۱ و همکاران (۲۰۱۴)، بالادست زنجیره تأمین را به‌عنوان بحرانی‌ترین نقطه در زنجیره‌های تأمینی که در معرض اختلالات قرار می‌گیرد، مشخص کردند [۳۵].

تأمین‌کننده تاب‌آور، تأمین‌کننده‌ای است که عملکرد مطلوبی در هر یک از ظرفیت‌های تاب‌آوری داشته باشد و به تاب‌آوری کل زنجیره تأمین منجر شود. انتخاب تأمین‌کننده بر اساس معیارها و محرک‌های کلیدی تاب‌آوری را «انتخاب تأمین‌کننده تاب‌آور» می‌گویند [۱۷]. این معیارها در شکل ۲، ارائه شده‌اند.

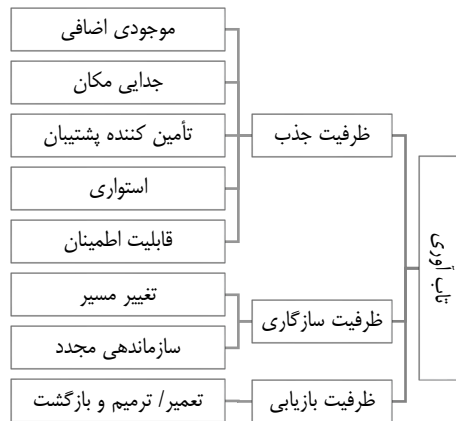


شکل ۲. معیارهای انتخاب تأمین‌کننده تاب‌آور [۱۷]

حسینی و الخالد^۲ (۲۰۱۶)، معیارهای تاب‌آوری برای انتخاب تأمین‌کنندگان را بر اساس ظرفیت تاب‌آوری تأمین‌کننده شناسایی کردند. ظرفیت تاب‌آوری تأمین‌کننده شامل سه جزء

1. Roberta Pereira
2. Al Khaled

ظرفیت جذب^۱، سازگاری^۲ و بازیابی^۳ است. معیارها و زیرمعیارهای تاب‌آوری تأمین‌کنندگان در شکل ۳، مشاهده می‌شود [۱۶].




شکل ۳. معیارها و زیرمعیارهای انتخاب تأمین‌کننده تاب‌آور [۱۶]

یادگیری ماشین. یادگیری ماشین کاربرد الگوریتم‌هایی است که حجم عظیمی از داده را به دانش تبدیل می‌کند. یادگیری ماشین برنامه‌ای طراحی می‌کند که از داده‌ها آموزش ببیند. الگوریتم‌ها این قابلیت را به ماشین می‌دهند تا رفتارشان را بر اساس داده‌ها تغییر دهند. الگوریتم‌های یادگیری ماشین، یک مدل ریاضی را بر اساس داده‌های نمونه برای پیش‌بینی یا تصمیم‌گیری ارائه می‌کنند.

یادگیری ماشین نقش بسیار مهمی در حل مسائل بسیار پیچیده دارد و شامل الگوریتم‌های مدل‌سازی و رایانه‌ای است که می‌تواند بر اساس اطلاعات یادگیری کند و سپس الگوها را بپذیرد [۴].

چرخه یادگیری ماشین. هورویتز و کیرش^۴ (۲۰۱۸)، برای یادگیری ماشین یک چرخه ارائه کرده‌اند که شامل ۱۰ مرحله است. این مراحل در شکل ۴، مشاهده می‌شود.

1. Absorptive capacity
2. Adaptive capacity
3. Restorative capacity
4. Hurwitz & Kirsch



شکل ۴. چرخه یادگیری ماشین [۱۸]

انتخاب تأمین‌کننده با استفاده از یادگیری ماشین. تقسیم‌بندی تأمین‌کننده یکی از فعالیت‌های استراتژیک سازمان‌ها است که به وسیله آن تأمین‌کنندگان را بر اساس شباهت‌هایشان به گروه‌های مختلف دسته‌بندی می‌کنند. قراردادهای مدیریت و رسیدگی به امور تأمین‌کنندگان در هر گروه مشابه یکدیگر است و با تأمین‌کنندگان گروه‌های دیگر متفاوت است. تقسیم‌بندی تأمین‌کننده، به بهبود کارایی و اثربخشی روابط با تأمین‌کنندگان منجر می‌شود و توسعه و بهبود عملکرد سازمان را به همراه دارد [۲۲].

تکنیک‌های تصمیم‌گیری از تصمیم‌گیرندگان در ارزیابی و انتخاب مجموعه‌ای از گزینه‌ها استفاده می‌کند. در برخی موارد، تعداد تأمین‌کنندگان بالقوه و تعداد معیارها به میزان زیادی ضرورت دارد و به کارگیری روش‌های تصمیم‌گیری چندمعیاره در این حالت رضایت‌بخش نیست؛ از سوی دیگر، روش‌های تصمیم‌گیری مانند بسیاری از روش‌های سنتی دیگر به روش‌های توصیفی و ایستا دسته‌بندی می‌شوند؛ در حالی که در بازار رقابتی امروزی، روش‌های تحلیل پیش‌بینی قطعاً مفیدتر از روش‌های توصیفی هستند. در چنین عصری الگوریتم‌های یادگیری عملکرد بهتری دارند. در میان تکنیک‌های یادگیری ماشین، تکنیک درخت تصمیم و ماشین بردار پشتیبان به‌عنوان یک تکنیک یادگیری نظارت شده و تکنیک یادگیری Q به‌عنوان یک تکنیک یادگیری تقویتی توسط پژوهشگران برای حل مشکل انتخاب تأمین‌کننده استفاده شده است [۳۹].

روش‌های سنتی برای انتخاب تأمین‌کننده، هنگامی که به مقیاس‌پذیری و چابکی در محیط‌های روابط با فرکانس بالا می‌رسد، با چالش‌هایی روبه‌رو می‌شوند. به دلیل انفجار داده‌ها در سال‌های اخیر، به کارگیری تکنیک‌های یادگیری ماشین به میزان زیادی افزایش یافته است. روش‌های مختلفی مانند تجزیه و تحلیل پوششی داده‌ها، درخت تصمیم‌گیری، شبکه عصبی مصنوعی و ماشین‌های بردار پشتیبان کاربرد زیادی دارند [۳۸].

والری و کراسون^۱ (۲۰۰۵)، یک تکنیک یادگیری Q اصلاح‌شده برای ارزیابی و انتخاب تأمین‌کنندگان پیشنهاد کردند. یادگیری Q، یک الگوریتم یادگیری تقویتی بدون مدل است که به اقداماتی با نتایج مثبت پاداش می‌دهد و اقداماتی با نتایج منفی را جریمه می‌کند [۴۱].

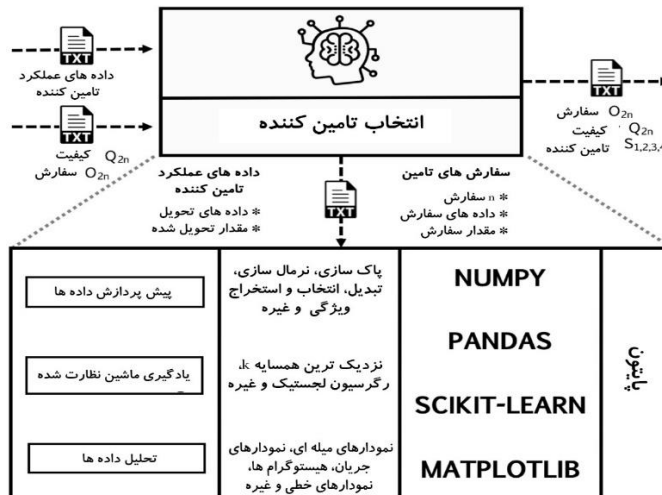
گو^۲ و همکاران (۲۰۰۹)، الگوریتم یادگیری ماشین نظارت‌شده با درخت تصمیم‌گیری را ارائه کردند که مسائل مربوط به انتخاب تأمین‌کننده و به‌طور خاص، انتخاب خصوصیات و طبقه‌بندی چندرده‌ای را بررسی می‌کند [۱۴].

مرکوئی و هاپالا^۳ (۲۰۱۴)، از روش درخت تصمیم‌گیری و ماشین بردار پشتیبان و با ترکیب روش‌های برنامه‌ریزی ریاضی به‌منظور مکمل روش‌های انتخاب تأمین‌کننده جاری در حوزه زنجیره تأمین زیست‌توده به زیست‌سوخت^۴ استفاده کردند [۲۸].

بای^۵ و همکاران (۲۰۱۷)، یک روش ترکیبی تکنیک‌های تصمیم‌گیری چندمعیاره و یادگیری ماشین را برای ارزیابی و بخش‌بندی تأمین‌کنندگان پیشنهاد دادند؛ به‌نحوی که در مرحله نخست، شناسایی مجموعه‌ای از معیارها برای ارزیابی تأمین‌کنندگان صورت گرفت. در مرحله دوم ارزیابی و امتیازدهی تأمین‌کنندگان با توجه به هر یک از معیارهای وزنی با استفاده از روش‌های تصمیم‌گیری چندمعیاره انجام شد. در مرحله سوم تعیین اهمیت/ وزن هر معیار با استفاده از روش تصمیم‌گیری چندمعیاره صورت گرفت و در مرحله چهارم تأمین‌کنندگان بر اساس امتیاز آن‌ها با استفاده از روش یادگیری ماشین نظارت‌شده/ بدون نظارت شامل نزدیک‌ترین همسایه، بردار پشتیبان و درخت تصمیم تقسیم‌بندی شدند [۵].

کاوالکانتی^۶ و همکاران (۲۰۱۹)، اقدام به انتخاب تأمین‌کنندگان تاب‌آور با استفاده از یادگیری ماشین در صنعت دیجیتال کردند و از یادگیری نظارت‌شده و شبیه‌سازی به‌صورت توأمان بهره گرفتند [۹]. مدل مفهومی استفاده‌شده توسط آن‌ها در شکل ۵، ارائه شده است.

-
1. Valluri & Croson
 2. Guo
 3. Mirkouei & Haapala
 4. Biomass-to-Biofuel SC
 5. Bai
 6. Cavalcante



شکل ۵. مدل مفهومی یادگیری ماشین نظارت شده در انتخاب تأمین کننده [۹]

کیران^۱ و همکاران (۲۰۲۰)، انتخاب تأمین کنندگان را بر اساس معیارهای کیفیت و تحویل به‌موقع به‌صورت عددی بر حسب درصد و سایر معیارها شامل پاسخگویی زیست‌محیطی، پاسخگویی اجتماعی، بلوغ صنعت ۴.۰، انعطاف‌پذیری، گارانتی، اعتماد متقابل و ارتباط آسان و شهرت و موقعیت در صنعت را با استفاده از اعداد گسسته بین ۱ تا ۹ و بر اساس مقیاس لیکرت اندازه‌گیری کردند. مجموعه داده‌ها شامل ۱۰۰۰ نمونه بود که به‌طور تصادفی تولید شدند و هر یک ۱۰ ویژگی داشتند. توزیع کلاس در مجموعه داده‌ها به این صورت بود: ۱۴۴ نمونه متعلق به تأمین‌کننده درجه پایین بوده که در کلاس ۱ ارائه شده است؛ ۷۶۴ نمونه متعلق به تأمین‌کننده طبقه متوسط است که در کلاس ۲ مشخص شده‌اند و ۹۲ تأمین‌کننده متعلق به کلاس بالا است که توسط کلاس ۳ نشان داده شده است. آن‌ها سپس اقدام به طبقه‌بندی اطلاعات کردند. آن‌ها در پژوهش خود از چهار روش شبکه‌های عصبی، دسته‌بندی‌کننده بیزی، الگوریتم k -نزدیک‌ترین همسایه و الگوریتم درخت تصمیم J48 استفاده کردند که نتایج نشان داد شبکه‌های عصبی نتایج بهتری نسبت به سایر روش‌ها دارد. آن‌ها نشان دادند که استفاده از الگوریتم‌های J48، NB، ANN و k -NN با ابزار یادگیری ماشینی پایتون می‌تواند از فرآیند تصمیم‌گیری انتخاب تأمین‌کننده پشتیبانی کند و به بهبود تصمیم‌ها و تلاش در جهت کاهش ریسک تأمین‌کنندگان منجر شود [۲۶].

ژاو^۲ و همکاران (۲۰۲۱) در پژوهش خود، روش جدیدی را پیشنهاد کردند که از یادگیری ماشینی برای یادگیری اعتبار داده‌های گذشته استفاده شود. آن‌ها ابتدا از طبقه‌بندی‌کننده ماشین

1. Kuran
2. Zhao

بردار پشتیبان برای طبقه‌بندی داده‌های گذشته کارشناسان ارزیابی تأمین‌کنندگان و محاسبه اعتبار ارزیابی کارشناسان استفاده کردند؛ سپس وزن کارشناسان ارزیابی را تعیین کرده، نتایج ارزیابی را جمع‌بندی کردند و در نهایت ترتیب اولویت‌های انتخاب‌شده را مشخص نمودند. آن‌ها اطلاعات ارزیابی اولیه را تا حداکثر میزان ممکن حفظ کردند و اعتبار نتایج ارزیابی و عادلانه بودن و علمی بودن انتخاب تأمین‌کننده را بهبود بخشیدند. نتایج نشان می‌دهد که طبقه‌بندی داده‌های ارزیابی گذشته کارشناسان ارزیابی توسط مدل طبقه‌بندی بردار پشتیبان امکان‌پذیر است و وزن‌های کارشناسی تعیین‌شده بر اساس اعتبار ارزیابی کارشناسان قابل تنظیم است [۴۲].

ایکا گایدا^۱ و همکاران (۲۰۲۲)، استراتژی بهینه‌سازی را برای فرآیند انتخاب تأمین‌کنندگان پیشنهاد کردند و با به‌کاربردن مجموعه‌ای از متغیرهای رایج برای انتخاب تأمین‌کنندگان و با استفاده از الگوریتم رگرسیون لجستیک، مدلی را برای بهینه‌سازی نیازهای مشتریان بر مبنای داده‌های تأمین‌کننده ارائه دادند. آن‌ها سپس پیش‌بینی‌ها و توصیه‌هایی را برای انتخاب بهترین تأمین‌کنندگان ارائه کردند و با استفاده از رگرسیون لجستیک با پیش‌بینی فهرستی از تأمین‌کنندگان بالقوه که نیازهای واقعی را برآورده می‌کنند، انتخاب را از فهرست پایه تأمین‌کننده آسان‌تر کردند [۱۱].

ایچفاج^۲ و همکاران (۲۰۲۳)، یک چارچوب مبتنی بر دانش توسعه دادند که توسط متخصصان تأیید شده و به‌عنوان هستی‌شناسی^۳ با استفاده از نرم‌افزار پروتج^۴ پیاده‌سازی شده است. هستی‌شناسی پیشنهادی یک پایگاه دانش معیارهای سازگار را فراهم کرده است. هستی‌شناسی پیشنهادی می‌تواند به مدیران در انتخاب معیارهای مناسب یاری رساند [۱۰].

رامجان علی^۵ و همکاران (۲۰۲۳)، اقدام به تأیید و پیشنهاد یک فهرست جامع از معیارهای انتخاب تأمین‌کنندگان با استفاده از جنگل تصادفی کردند و نشان دادند پس از حذف معیارهای غیربحرانی دقت ۳/۸۹ درصد و امتیاز F ۵/۱۷ درصد افزایش یافته است و از میان ۳۰ معیار بالقوه در نظر گرفته‌شده برای انتخاب تأمین‌کننده، ۹ معیار به‌عنوان حیاتی شناسایی شدند. کیفیت، تحویل به‌موقع، قیمت مواد و به‌اشتراک‌گذاری اطلاعات مهم‌ترین معیارها هستند [۲].

خان^۶ و همکاران (۲۰۲۳)، یک مدل یادگیری ماشین را با مدل SCOR برای توسعه یک سیستم مبتنی بر هوش مصنوعی برای انتخاب تأمین‌کننده تاب‌آور و پایدار برای یک شرکت داروسازی ادغام کردند. آن‌ها ابتدا مدل SCOR 4.0 را توسعه دادند؛ سپس معیارها و

1. Eyika Gaida
2. Echefaj
3. Ontology
4. Protégé
5. Ramjan Ali
6. Khan

زیرمعیارهای را با استفاده از روش بهترین - بدترین^۱ وزن دهی کردند و بعد از استانداردسازی وزن‌ها بین ۰ و ۱ با استفاده از الگوریتم تقویت گرادیان^۲ تأمین‌کنندگان را طبقه‌بندی کردند. نتایج نشان داد که الگوریتم تقویت گرادیان، به‌عنوان یک طبقه‌بندی‌کننده، به‌خوبی عمل می‌کند؛ به‌نحوی که تأمین‌کننده با بیشترین امتیاز مقبولیت نشان‌دهنده بهترین تأمین‌کننده و تأمین‌کننده با کمترین نمره مقبولیت نشان‌دهنده بدترین تأمین‌کننده است. در این پژوهش حجم داده‌ها پایین است و رتبه‌بندی صرفاً بر اساس معیارهای SCOR انجام شده است و بیشتر بر کاهش ریسک تمرکز شده است و تاب‌آوری و طبقه‌بندی بر اساس ظرفیت‌های تاب‌آور صورت‌نپذیرفته است [۲۴].

کومار^۳ و همکاران (۲۰۲۳)، یک چارچوب عمومی برای انتخاب تأمین‌کننده تاب‌آور با استفاده از یادگیری ماشین پیشنهاد کردند. آن‌ها نشان دادند که چگونه می‌توان مدل‌های CTGAN را در مواردی که تعداد محدودی نمونه داده وجود دارد، تحت کنترل گرفت. آن‌ها در پژوهش خود از یک مجموعه داده مصنوعی تولیدشده از طریق یک مدل شبیه‌سازی استفاده کردند [۲۵].

اسلام^۴ و همکاران (۲۰۲۴)، یک راه‌حل سه‌مرحله‌ای را برای حل مشکلات انتخاب تأمین‌کننده و برنامه‌ریزی تخصیص سفارش پیشنهاد کردند: در مرحله ۱، با استفاده از یادگیری عمیق تقاضای محصولات را پیش‌بینی می‌شود؛ در مرحله ۲، یک روش جدید تجزیه و تحلیل اجزای اصلی برای تولید وزن تأمین‌کنندگان به‌کار می‌رود و نتایج حاصل از مراحل ۱ و ۲ در مدل بهینه‌سازی چندهدفه استفاده می‌شوند. چارچوب توسعه‌یافته با استفاده از یک مجموعه داده واقعی از صنعت گوشت کانادا بوده و تمرکز در یادگیری ماشین بر پیش‌بینی تقاضا است [۱۹].

در برخی از پژوهش‌های ارائه‌شده از داده‌های واقعی استفاده و طبقه‌بندی بر مبنای ظرفیت‌های تاب‌آوری جذب، انطباق و ترمیم انجام نشده است؛ از طرفی خروجی‌های یادگیری ماشین به‌خوبی تفسیرپذیر نیستند. در پژوهش حاضر علاوه بر استفاده از داده‌های واقعی در حجم زیاد، از داده‌های عملکردی تأمین‌کنندگان در خصوص مشتریان مختلف استفاده شده است. برچسب‌گذاری بر مبنای ظرفیت‌های تاب‌آوری صورت می‌گیرد و از طرفی ترکیب روش‌های یادگیری ماشین نظارت‌شده و بدون نظارت می‌تواند به ایجاد خروجی مناسب و تفسیرپذیر در خصوص تصمیم‌گیری در مورد تأمین‌کنندگان در زنجیره تأمین تاب‌آور منجر شود. از طرفی به‌کارگیری هم‌زمان دو روش خوشه‌بندی و دیدن اثر آن در درخت تصمیم به‌منظور انتخاب روش مناسب می‌تواند به کاربردی‌بودن خروجی پژوهش منجر شود.

-
1. Best worst method (BWM)
 2. Gradient boosting
 3. Kumar
 4. Islam

چارچوب تحلیلی. در این بخش، یک چارچوب تحلیلی مبتنی بر داده با استفاده از یادگیری ماشین ارائه شده و مورد بحث قرار گرفته است. همان‌طور که در بخش بررسی مبانی نظری گفته شد، استقرار الگوریتم‌های یادگیری ماشین اکنون در جامعه پژوهشی به‌خوبی تثبیت شده است. مراحل پژوهش حاضر به شرح زیر است: طبقه‌بندی توسط کارشناسان تأمین و لجستیک به گروه یادگیری ماشین اطلاع داده شده است؛ سپس مجموعه داده مربوطه از انبارهای داده بازیابی شده تا در مدل‌های یادگیری ماشین استفاده شود. پیش‌پردازش گام بعدی برای افزایش کیفیت مجموعه داده است که به‌طور طبیعی به کیفیت بالاتر نتایج یادگیری ماشین منجر می‌شود. گستره وسیعی از الگوریتم‌های خوشه‌بندی برای مرحله بعدی در دسترس است که در آن داده‌ها را خوشه‌بندی می‌شود تا بتوان خوشه‌ها را تجزیه و تحلیل کرد و در نتیجه برچسب‌ها را ساخت. پس از برچسب‌گذاری داده‌ها، تغذیه داده‌ها به مدل‌های یادگیری ماشین که بر اساس الگوریتم‌های نظارت‌شده ساخته شده‌اند، ادامه می‌یابد و نتایج در نهایت برای رسیدن به بینش‌های مدیریتی تفسیر می‌شوند. اگر مدل آنلاین شود، می‌تواند به‌طور مداوم به نظارت بر ظرفیت‌های تاب‌آوری تأمین‌کننده کمک کند. بازخورد کاربران مدل می‌تواند به نقطه شروعی برای تکرار فرآیند تبدیل شود تا این امکان فراهم شود که بارها و بارها برای بهبود نتایج انجام گیرد.



شکل ۶- چارچوب تحلیلی مبتنی بر یادگیری ماشین برای طبقه‌بندی بر اساس ظرفیت‌های تاب‌آوری

مراحل مقدماتی. اثربخشی پیاده‌سازی یک چارچوب داده‌محور برای طبقه‌بندی تأمین‌کنندگان بر اساس ظرفیت‌های تاب‌آوری به یک برنامه از پیش تعیین شده در رابطه با اولویت‌بندی تأمین‌کنندگانی که باید طبقه‌بندی شوند، متکی است. پس برای چنین تأمین‌کنندگانی، مجموعه داده‌ای حاوی سوابق عملکرد آن‌ها باید تهیه شود که پس از پیش‌پردازش به الگوریتم(های) یادگیری ماشین وارد می‌شود. مجموعه داده باید شامل ویژگی‌های مربوطه باشد که اساساً این ظرفیت‌ها را تشکیل می‌دهند یا به میزان زیادی بر آن تأثیر می‌گذارند.

ارائه چنین مجموعه داده‌ای ممکن است به دلیل تعدادی محدودیت، یک کار چالش‌برانگیز باشد. نخست اینکه تأمین‌کنندگان معمولاً تمایلی به ارائه اطلاعات به‌موقع و دقیق مربوط به تأمین‌کنندگان خود ندارند. این وضعیت در مورد تأمین‌کنندگان ردیف ۲ تشدید می‌شود [۳۷]؛ بنابراین اغلب ممکن است با مجموعه داده‌های «به‌هم‌ریخته» مواجه شویم که نیاز مبرمی به پاک‌سازی و پیش‌پردازش داده‌ها دارند. دوم، تهیه مجموعه داده‌هایی که شامل همه یا حتی بیشتر ویژگی‌هایی هستند که جنبه خاصی از یک سیستم انعطاف‌پذیر را به‌خوبی پیش‌بینی می‌کنند، آسان نیست. درنهایت برچسب‌گذاری داده‌های بدون برچسب یک کار دلهره‌آور است که توسط کارشناسان انجام می‌شود که دقت آن می‌تواند بر نتیجه پروژه یادگیری ماشین تأثیر بگذارد.

پیش‌پردازش داده‌ها. کیفیت پیش‌بینی‌های یادگیری ماشین به‌شدت به داده‌های ورودی وابسته است. مجموعه داده‌ای که با نمونه‌های متعدد داده‌های از دست‌رفته، ویژگی‌های نامتعادل، محاسبات نادرست نقطه داده و مقادیر غیرممکن (برای مثال، تعداد منفی محصولاتی که از یک ایستگاه تولید می‌آیند) گرفتار پیش‌بینی‌های قابل‌اعتمادی نیست؛ بنابراین هر کاربرد روش‌های مبتنی بر یادگیری ماشین با پیش‌پردازش داده‌ها شروع می‌شود؛ مگر اینکه داده‌های با کیفیت بالا در دسترس باشند؛ همان‌طور که در مورد دوقلوهای دیجیتال و داده‌های تولیدشده از شبیه‌سازی وجود دارد.

پیش‌پردازش روش‌های متعدد و متنوعی برای پاک‌سازی داده‌ها، تبدیل، پیش‌بینی، عادی‌سازی، گسسته‌سازی و انتساب داده‌ها را تشکیل می‌دهد. این‌ها به مجموعه داده‌هایی اعمال می‌شوند تا ورودی‌های قابل‌خواندن ماشین را با کیفیت بالا برای الگوریتم یادگیری ماشین برای دستیابی به نتایج قابل‌اعتماد ایجاد کنند. این مراحل ممکن است به الگوریتم‌(های) یادگیری ماشین انتخابی وابسته باشند یا نباشند.

برچسب‌گذاری داده‌ها با استفاده از روش‌های خوشه‌بندی. خوشه‌بندی داده‌ها با اهداف دلخواه مورد تجزیه و تحلیل اکتشافی قرار می‌گیرد که یکی از آن‌ها یافتن الگوهایی است که در غیر این صورت برای کاربران مجموعه داده ناشناخته است. خوشه‌ها بر اساس نوعی شباهت بین نقاط داده تشکیل شده‌اند؛ به عبارت دیگر انتظار می‌رود که تنوع کمتری در میان داده‌های درون خوشه‌ها و تنوع بیشتر در میان خود خوشه‌ها وجود داشته باشد.

یکی از موارد استفاده از الگوریتم‌های خوشه‌بندی، کمک به ایجاد برچسب‌هایی برای داده‌ها (کلاس‌ها در مسائل طبقه‌بندی) زمانی است که داده‌های برچسب‌گذاری شده در دسترس نیستند.

این کار با همکاری کارشناسانی که با حوزه خاص تمرین آشنا هستند و کارشناسان یادگیری ماشینی که وظیفه خوشه‌بندی را بر عهده دارند، انجام می‌شود [۳۰].

انتخاب الگوریتم‌ها و معیارها. هنگامی که مجموعه داده آماده شد، یعنی پس از انجام پیش‌پردازش و برچسب‌گذاری، مرحله بعدی انتخاب الگوریتم‌ها خواهد بود. طیف گسترده الگوریتم‌های موجود در قالب رویکردهای جعبه سیاه این امکان را برای پژوهشگران فراهم می‌کند تا آزادانه مناسب‌ترین الگوریتم را برای مسئله‌ای که به دنبال حل آن هستند، انتخاب کنند؛ با این حال زمانی که تفسیر نتایج در اولویت باشد، رویکرد جعبه سفید توصیه می‌شود [۶]. در پژوهش حاضر، الگوریتم‌ها بر اساس اهداف مدیریت زنجیره تأمین تاب‌آور که به پژوهشگر ابلاغ شد، انتخاب می‌شوند؛ ظرفیتی که تأمین‌کنندگان طبقه‌بندی شده نسبت به سایرین بهتر عمل می‌کنند، درحالی‌که تفسیرپذیری را بر عملکرد ترجیح می‌دهند.

انتخاب معیارها برای اندازه‌گیری عملکرد الگوریتم‌ها نیز حیاتی است؛ زیرا راه‌های متعدد و متنوع برای اندازه‌گیری عملکرد الگوریتم‌های یادگیری ماشین خود از نظر بینش مدیریتی قابل تفسیر هستند. برای مثال، استفاده از روش طبقه‌بندی برای پیش‌بینی ظرفیت تاب‌آوری که در آن یک تأمین‌کننده معین نسبت به سایر تأمین‌کنندگان برتری دارد، چهار نتیجه زیر را به دنبال دارد:

- مثبت واقعی (TP): مدل به درستی ظرفیت تاب‌آوری را پیش‌بینی می‌کند که تأمین‌کننده از نظر عملکرد نسبت به دیگران برتری دارد. این امر تصمیم‌گیرندگان زنجیره تأمین را قادر می‌سازد تا یک سبد تأمین‌کننده را ترسیم کنند تا برای تخصیص سفارش‌ها بعدی استفاده شود؛

- منفی واقعی (TN): این مدل به درستی پیش‌بینی می‌کند که یک تأمین‌کننده معین با توجه به ظرفیت انعطاف‌پذیری مطابق انتظار عمل نمی‌کند. این می‌تواند برای تکمیل سبد تأمین‌کننده که از TPها تهیه شده است، مفید باشد؛

- مثبت کاذب (FP): این مدل به اشتباه پیش‌بینی می‌کند که یک تأمین‌کننده معین از نظر ظرفیت تاب‌آوری از بقیه بهتر عمل می‌کند. در صورت بروز خطر اختلال، این امر می‌تواند به اتلاف منابع منجر شود و دوره بهبود را طولانی‌تر کند؛

- منفی کاذب (FN): این مدل به اشتباه پیش‌بینی می‌کند که یک تأمین‌کننده با توجه به ظرفیت تاب‌آوری عملکرد خوبی ندارد؛ بنابراین نسبت به سایرین که با توجه به آن ظرفیت خوب عمل می‌کنند، پایین‌تر است. این احتمالاً نامطلوب‌ترین نتیجه است؛ اگر هدف ترسیم سبد تأمین‌کنندگان از تأمین‌کنندگان تاب‌آور باشد؛ زیرا هدف عملاً محقق نشده است.

معیارها باید مطابق با هدف پیش‌بینی انتخاب شوند. همه چهار نتیجه ذکر شده در بالا به یک اندازه در یک محیط تصمیم‌گیری مهم نیستند. علاوه بر این، معیار اشتباه می‌تواند به نتایج کاملاً

نامطلوب منجر شود؛ زیرا توانایی یادگیری الگوریتم به‌طور مکرر توسط متریک انتخاب‌شده اندازه‌گیری می‌شود و در نتیجه یادگیرنده بیشتر به سمت نتایج ناخواسته سوق داده می‌شود [۶].

آموزش و تفسیر مدل‌های یادگیری ماشین. پس از انتخاب الگوریتم‌ها و معیارها، داده‌ها برای تولید پیش‌بینی به الگوریتم‌ها داده می‌شوند؛ سپس از این پیش‌بینی‌ها برای ترسیم مجموعه‌ای از تأمین‌کنندگان با ملاحظات انعطاف‌پذیری استفاده می‌شود. با در دسترس قرار گرفتن داده‌های جدید، مدل‌ها می‌توانند برای انجام طبقه‌بندی بلادرنگ آنلاین شوند و نظارت دائمی تأمین‌کنندگان را ممکن کنند.

مورد مطالعه. در این بخش، یک آزمایش مبتنی بر یادگیری ماشین بر روی داده‌های دنیای واقعی تولیدشده از فعالیتهای زنجیره تأمین خودرو توضیح داده شده است. تمام وظایف هوش مصنوعی با استفاده از نرم‌افزار پایتون که نرم‌افزار متن‌باز است بر روی یک سیستم Windows® 10 با CPU Intel® Core i7 و ۲۴ گیگابایت حافظه انجام شده است.

مجموعه داده‌ها. در پژوهش حاضر، پس از توافق بر روی هدف استفاده از یادگیری ماشین، یعنی طبقه‌بندی تأمین‌کنندگان بر اساس ظرفیت‌های تاب‌آوری، داده‌های عملکرد ۴۴۱ تأمین‌کننده و ۷ مشتری در قالب یک فایل اکسل شامل ۱۳۳۱۸ رکورد و ۱۰ ستون (ویژگی) در اختیار پژوهشگران قرار گرفت. این داده‌ها شامل اطلاعات مربوط به عملکرد تأمین‌کننده قطعات خودرو در سال ۱۴۰۱ و بر اساس ماه است که تعداد رکوردهای مربوط به تأمین‌کنندگان از ۷۲ رکورد تا ۱ رکورد بر اساس سوابق تأمین تأمین‌کنندگان برای مشتریان است. توضیحات مرتبط با ویژگی‌ها در جدول ۱، ارائه شده است.

جدول ۱. شاخص‌ها و داده‌های موجود در پژوهش

عنوان	شرح	منابع
کُد تأمین‌کننده	مشخصه تأمین‌کننده	
کُد مشتری	سایت تولیدکننده خودرو	
دوره	سال و ماه	
امتیاز تحویل به‌موقع	تأخیر زمانی و حجمی تحویل سفارش	[۲، ۹، ۱۷، ۲۱، ۲۴، ۲۵، ۳۱]
امتیاز درصد تأمین	درصد تأمین قطعه نسبت به تعهد، ظرفیت تأمین	[۲، ۹، ۱۷، ۲۴، ۲۵، ۳۱]
امتیاز توقف خط تولید	امتیاز حاصل زمانی که تأمین‌کننده به کاهش توقف خط تولید منجر شده است.	[۲، ۲۴، ۲۵، ۳۱]
امتیاز عملکرد لجستیکی	امتیاز حاصل از رعایت الزامات بسته‌بندی و حمل‌ونقل توسط تأمین‌کننده	[۲، ۲۱، ۲۴]

عنوان	شرح	منابع
امتیاز اخطار کیفی	امتیاز عملکرد تأمین‌کننده بر مبنای عملکرد کیفی	[۲، ۱۷، ۲۴، ۲۵، ۳۱]
عملکرد کیفی (PPM)	شاخص کیفی تعداد قطعات برگشتی	[۲، ۲۴، ۲۵، ۳۱]
فاصله	مسافت شرکت تأمین‌کننده تا سایت مشتری	[۲، ۲۱، ۲۴]

نمونه‌ای از داده‌های مورد استفاده در پژوهش برگرفته شده از سیستم تأمین ایران خودرو (کانبان) در جدول ۲، ارائه شده است.

جدول ۲. نمونه داده‌های مورد استفاده از پژوهش

کد تأمین‌کننده	کد مشتری	تحويل به موقع	درصد تأمین	توقف خط تولید	عملکرد لجستیکی	اخطار کیفی	عملکرد کیفی	فاصله	دوره
۱۰۰۲	۵۷۸۶	۴	۴	۳	۳	۲	۵	۵	۱۴۰۱/۳
۱۰۰۲	۵۷۸۶	۴	۴	۳	۳	۲	۵	۵	۱۴۰۱/۵
۱۰۰۲	۷۰۱۹	۴	۳	۳	۳	۲	۴	۴	۱۴۰۱/۷
۱۰۰۳	۷۰۱۹	۴	۴	۳	۳	۲	۵	۴	۱۴۰۱/۲
۱۰۰۴	۵۷۸۶	۲	۱	۱	۱	۲	۴	۵	۱۴۰۱/۱۰
۱۰۰۵	۷۰۱۹	۴	۳	۳	۲	۵	۳	۴	۱۴۰۱/۱۲
۱۰۰۶	۷۰۱۹	۴	۱	۳	۱	۳	۳	۴	۱۴۰۱/۱۲
۱۰۰۷	۷۰۱۹	۲	۴	۱	۱	۴	۵	۴	۱۴۰۱/۱۰
۱۰۰۸	۷۵۰۷	۳	۳	۳	۳	۳	۴	۲	۱۴۰۱/۱۰
۱۰۰۹	۵۷۸۶	۲	۴	۳	۳	۴	۱	۵	۱۴۰۱/۹
۱۰۰۹	۷۰۱۹	۲	۴	۳	۳	۳	۱	۴	۱۴۰۱/۱
۱۰۱۰	۷۰۱۹	۴	۴	۳	۳	۲	۴	۴	۱۴۰۱/۸
۱۰۱۱	۵۷۸۶	۳	۳	۳	۳	۲	۴	۱	۱۴۰۱/۳
۱۰۱۱	۵۷۸۶	۲	۱	۳	۳	۲	۴	۱	۱۴۰۱/۸
۱۰۱۲	۷۳۱۰	۳	۲	۳	۳	۳	۲	۵	۱۴۰۱/۱۲
۱۰۱۳	۵۷۸۶	۴	۴	۳	۳	۳	۱	۵	۱۴۰۱/۲
۱۰۱۳	۵۷۸۶	۳	۱	۳	۳	۳	۱	۵	۱۴۰۱/۳

تحلیل‌های آماری انجام شده بر روی داده‌ها با توجه به اینکه اطلاعات در طیف بین ۱ تا ۵ در کلیه ویژگی‌ها گسسته شده است، در جدول ۳، مشاهده می‌شود.

جدول ۳. تحلیل آماری ویژگی‌های پژوهش

ویژگی	توزیع	میانگین	مد	میان	پراکندگی	حداقل	حداکثر	از دست‌رفته
تحويل به موقع		۳/۲۶	۴	۴	۰/۲۵	۱	۴	(%)۰
درصد تأمین		۳/۲۳	۴	۴	۰/۳۵	۱	۴	(%)۰
توقف خط تولید		۲/۸۹	۳	۳	۰/۱۶	۱	۳	(%)۰
عملکرد لجستیکی		۲/۹۸	۳	۳	۰/۰۷	۱	۳	(%)۰
اخطار کیفی		۲/۷۰	۲	۲	۰/۳۴	۲	۵	(%)۰
عملکرد کیفی		۳/۲۴	۴	۴	۰/۴۵	۱	۵	(%)۰
فاصله		۲/۹۸	۳	۱	۰/۵۴	۱	۵	(%)۰

خوشه‌بندی بدون نظارت با استفاده از DBSCAN و K-mean. ابتدا داده‌های بدون برچسب با استفاده از الگوریتم‌های خوشه‌بندی DBSCAN و K-means خوشه‌بندی می‌شود. این گام به پژوهشگر کمک می‌کند تا الگوها و تجمعات مختلف در داده‌ها را شناسایی کند. با استفاده از DBSCAN، تجمعات متنوعی که تعداد اعضای آن‌ها متفاوت است، شناسایی می‌شود. از طرف دیگر با استفاده از K-means، داده‌ها به تعداد مشخصی خوشه تقسیم می‌شوند.

الگوریتم DBSCAN. DBSCAN یک الگوریتم خوشه‌بندی بدون نظارت است که بر اساس یافتن مناطق مختلف تراکم داده‌ها در فضای ویژگی‌ها عمل می‌کند. در این الگوریتم، ابتدا یک نقطه تصادفی انتخاب می‌شود و سپس نقاطی که در محدوده تعیین شده فاصله از این نقطه قرار دارند، به خوشه اضافه می‌شوند؛ سپس برای هر یک از نقاط درون این خوشه، همسایه‌های آن بررسی می‌شوند و اگر تعداد همسایه‌ها به حداقل مقدار تعیین شده برسد، یک خوشه جدید شکل می‌گیرد. این روند برای تمام نقاط ادامه می‌یابد تا خوشه‌های مختلف شناسایی شوند.

مفهوم اصلی در DBSCAN برگرفته از ایده تجمع نقاط نزدیک به هم و وجود تعداد کافی نقاط همسایه در یک فاصله مشخص، به نام همسایگی (E) است. نقاطی که دارای تعداد بیشتری از نقاط همسایه نسبت به آستانه تعیین شده (حداقل تعداد نقاط) هستند، نقاط مرکزی خوشه هستند و در مرکز یک خوشه قرار می‌گیرند. نقاطی که در محدوده‌ی همسایگی نقاط مرکزی قرار دارند، اما شرایط حداقل تعداد نقاط را برآورده نمی‌کنند، نقاط مرزی هستند و نقاطی که دور از هر نقطه مرکزی قرار دارند، نقاط نویزی یا خارج‌ازخوشه به‌شمار می‌روند.

الگوریتم با انتخاب نقطه داده‌ای تصادفی شروع می‌شود و محدوده همسایگی آن را بررسی می‌کند. اگر این نقطه، نقطه مرکزی باشد، الگوریتم با اضافه کردن به صورت بازگشتی نقاط همسایه‌ی آن خوشه را گسترش می‌دهد تا یک گروه مرتبط از نقاط داده‌ای شکل بگیرد. اگر این نقطه، نقطه مرزی باشد، نقطه با خوشه مرتبط می‌شود؛ اما خود خوشه را به بیشتر گسترش نمی‌دهد. این فرآیند تا زمانی ادامه می‌یابد که تمام نقاط قابل دسترسی به خوشه اضافه شده باشند؛ سپس داده‌ای دیگر انتخاب می‌شود و فرآیند تکرار می‌شود تا تمام نقاط داده‌ای یا به یک خوشه اختصاص داده شوند یا به‌عنوان نقاط نویزی مشخص شوند.

قابلیت DBSCAN در تشخیص خوشه‌ها با شکل‌های خودساخته و همچنین کنترل داده‌های نویزی، این الگوریتم را به یک روش پایدار و گسترده‌ای در زمینه‌های مختلف شناسایی الگو، تحلیل تصاویر و سیستم‌های اطلاعات جغرافیایی (GIS) تبدیل کرده است. با این حال برای بهینه‌سازی اجرای DBSCAN نیاز به تنظیم موارد ضروری مانند E و حداقل تعداد نقاط دارد و عملکرد آن در مجموعه‌های داده‌ای با ابعاد بالا به دلیل «تفرین ابعاد» ممکن است کاهش یابد. باوجود این DBSCAN ابزار مؤثری برای کشف الگوها و ساختارهای معنادار در داده‌ها است؛ به‌خصوص در مواقعی که تعداد خوشه‌ها به‌صورت پیش‌فرض مشخص نمی‌شود.

الگوریتم K-means. K-means یک الگوریتم خوشه‌بندی بدون نظارت است که بر اساس محاسبه مرکز خوشه‌ها و تخصیص نقاط به مراکز نزدیک‌تر عمل می‌کند. در این الگوریتم، ابتدا تعداد مشخصی مرکز اولیه به‌صورت تصادفی انتخاب می‌شوند؛ سپس هر نقطه به مرکزی اختصاص داده می‌شود که نزدیک‌ترین به آن باشد؛ سپس مراکز خوشه‌ها بر اساس نقاط جدید محاسبه می‌شوند و این فرآیند تا زمانی که مراکز دیگر تغییر نکنند، ادامه می‌یابد. جدول ۴، مقایسه بین DBSCAN و K-means را نشان می‌دهد.

جدول ۴. مقایسه بین DBSCAN و K-means [۳]

ویژگی	DBSCAN	K-means
نوع الگوریتم	خوشه‌بندی مبتنی بر تراکم	خوشه‌بندی مبتنی بر مرکز
نیاز به تعداد خوشه‌ها	نیاز ندارد	نیاز دارد.
مقاومت به نویز	بله	خیر
شکل خوشه‌ها	نامنظم و متغیر	منظم و متغیر
اندازه خوشه‌ها	متغیر	یکسان
اجرای محاسباتی	پیچیده	ساده

جدول ۲، تنها به مقایسه بین DBSCAN و K-means محدود است و الگوریتم‌های دیگری نیز در خوشه‌بندی بدون نظارت وجود دارند که ممکن است در موارد مختلف بهتر عمل کنند.

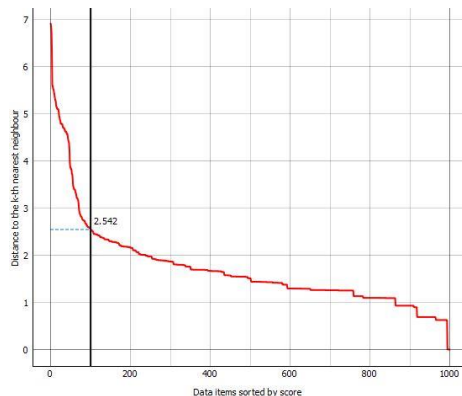
استفاده از دانش تخصصی برای برچسب‌گذاری. با توجه به دانش تخصصی کارشناسان در زمینه تأمین‌کنندگان و صنعت مرتبط، دسته‌های مختلفی که ممکن است در داده‌ها وجود داشته باشند، شناسایی می‌شود. برای هر یک از خوشه‌ها یا دسته‌ها، کارشناسان برچسب‌های مناسبی را تعیین می‌کنند. این گام از دانش تخصصی برای اطمینان از صحت و دقت برچسب‌ها استفاده می‌کند.

استفاده از الگوریتم‌های یادگیری ماشین نظارت‌شده. حالا که داده‌ها برچسب‌گذاری شده‌اند، می‌توان از آن‌ها در الگوریتم‌های یادگیری ماشین نظارت‌شده مانند درخت تصمیم، ماشین بردار پشتیبانی^۱، یا شبکه‌های عصبی استفاده کرد. با استفاده از داده‌های برچسب‌گذاری‌شده، مدل‌های یادگیری ماشین می‌توانند الگوها و ویژگی‌های مهم را یاد بگیرند و برای پیش‌بینی وظایف مختلف مانند تشخیص کیفیت تأمین‌کنندگان یا تخمین زمان تحویل استفاده شوند.

استفاده ترکیبی از خوشه‌بندی بدون نظارت. دانش تخصصی و یادگیری ماشین نظارت‌شده می‌تواند به پژوهشگر در برچسب‌گذاری داده‌های بدون برچسب تأمین‌کنندگان کمک کند و امکان استفاده از آن‌ها در وظایف مختلف یادگیری ماشین را فراهم سازد. این روش به پژوهشگر امکان می‌دهد تا از دانش تخصصی بهره‌برداری نماید و درعین حال از قوت الگوریتم‌های خوشه‌بندی و یادگیری ماشین نظارت‌شده نیز بهره‌برداری کند.

1. Support Vector Machine

خوشه‌بندی و برچسب‌گذاری. در این بخش از پژوهش، جزئیات روش استفاده‌شده برای برچسب‌گذاری داده‌های بدون برچسب تأمین‌کنندگان به‌منظور استفاده در یادگیری ماشین نظارت‌شده تشریح خواهد شد. ابتدا از الگوریتم‌های خوشه‌بندی بدون نظارت DBSCAN و K-means استفاده شده و سپس از دانش تخصصی کارشناسان برای اخذ برچسب‌ها بهره گرفته شد. این بخش ابتدایی از پژوهش، داده‌ها را به دسته‌های مشخص تقسیم می‌کند و اساس اولیه‌ای را برای تعیین برچسب‌های نهایی فراهم می‌سازد. ابتدا داده‌های بدون برچسب با استفاده از الگوریتم DBSCAN به گروه‌های مختلف تقسیم شدند. این الگوریتم بر اساس تراکم داده‌ها در فضای ویژگی‌ها عمل می‌کند و به پژوهشگر امکان شناسایی مناطق مختلفی از داده‌ها را می‌دهد. پارامتر μ برای الگوریتم DBSCAN مطابق با پیش‌فرض کتابخانه Scikit Learn روی عدد ۵ تنظیم شد و نوع فاصله نقاط از یکدیگر نیز به‌صورت اقلیدسی محاسبه شد. برای به‌دست‌آوردن بهترین خوشه‌بندی، حداکثر فاصله اقلیدسی نقاط تا نزدیک‌ترین همسایه k م در خوشه ۲/۵۴۲ به‌دست آمد که در شکل ۷، دیده می‌شود. خروجی این الگوریتم به ایجاد ۲۶ خوشه منجر شد.



شکل ۷. نمودار k الگوریتم DBSCAN

سپس با استفاده از الگوریتم K-means، داده‌ها به گروه‌ها با مراکز مختلف تخصیص داده شدند. خروجی الگوریتم K-means با توجه به اعتبارسنجی سایه‌نما^۱ ارائه‌شده در شکل ۸، شامل ۵ خوشه است. این دو الگوریتم مشترکاً این امکان را فراهم می‌سازند که بتوان ساختار داده‌ها در فضای ویژگی‌ها رصد کرده و گروه‌بندی اولیه را انجام داد. در مرحله بعد، با بهره‌گیری از دانش تخصصی کارشناسان در زمینه تأمین‌کنندگان و صنعت مرتبط، برچسب‌های نهایی برای داده‌ها تعیین شدند. این برچسب‌ها بر اساس پروفایل تاب‌آوری شامل ظرفیت جذب، ظرفیت سازگاری و

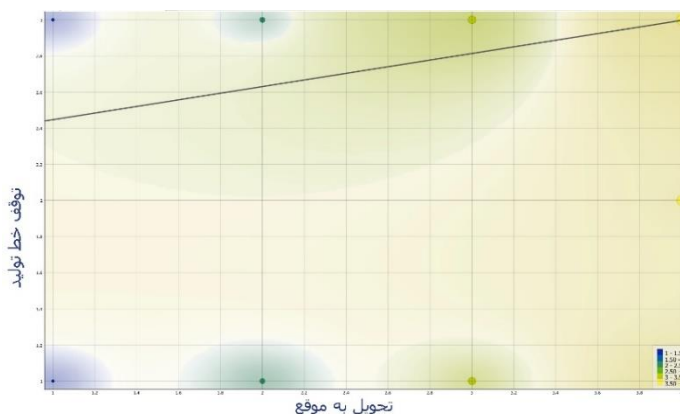
1. Silhouette

ظرفیت بازیابی است. این برچسب‌ها بر اساس اطلاعات دقیق از ویژگی‌های مرتبط با تأمین‌کنندگان و متغیرهای مرتبط با کسب‌وکار انتخاب شدند. این مرحله به پژوهشگر امکان می‌دهد تا داده‌ها را با دقت بیشتری برچسب‌گذاری کرده و اطمینان حاصل کند که تجزیه و تحلیل نهایی توسط تجربیات تخصصی پوشش داده می‌شود؛ سپس با دقت و تمرکز، خوشه‌های حاصل از مرحله خوشه‌بندی ابتدایی بررسی و تحلیل شدند.

2	0.193
3	0.188
4	0.187
5	0.198
6	0.170
7	0.182
8	0.186

شکل ۸. اعتبارسنجی سایه‌نما

این تجزیه و تحلیل دقیق به پژوهشگر امکان می‌دهد تا تمام داده‌ها را به صورت جزئی مرور کرده و مشاهده کند که هر داده به کدام گروه تعلق دارد؛ همچنین این مرحله پژوهشگر را قادر می‌سازد تا داده‌های پرت را که از توزیع نرمال خارج می‌شوند، شناسایی کند و در تجزیه و تحلیل نهایی در نظر بگیرد. نمودار داده‌های پرت در شکل ۹، ارائه شده است. در نهایت تمام این اطلاعات، از جمله خوشه‌بندی‌ها، برچسب‌ها و تجزیه و تحلیل‌ها به هم متصل می‌شوند و به عنوان ورودی به الگوریتم‌های یادگیری ماشین نظارت‌شده قرار می‌گیرند. این مرحله از پژوهش اساسی‌ترین بخش آماده‌سازی داده‌ها را فراهم می‌کند و به پژوهشگر امکان می‌دهد تا از تمام اطلاعات جمع‌آوری شده برای آموزش و ارزیابی مدل‌های یادگیری ماشین نظارت‌شده بهره‌بردار.



شکل ۹. نمودار داده‌های پرت

توزیع برجسب‌ها در خوشه‌ها پس از برجسب زدن

انتخاب معیارها و الگوریتم‌ها. پس از برجسب‌گذاری داده‌ها، الگوریتم یادگیری ماشین نظارت‌شده انتخاب شد تا یک مدل پیش‌بینی ایجاد شود که تصمیم‌گیرندگان زنجیره تأمین را قادر سازد تأمین‌کنندگان را بر اساس ظرفیت انعطاف‌پذیری آن‌ها طبقه‌بندی کند. الگوریتم‌های درخت تصمیم بر اساس دو دلیل اصلی انتخاب شدند: ۱. از آنجاکه «تفسیرپذیری» نتایج برای تصمیم‌گیرندگان در اولویت بود، این دو الگوریتم به‌راحتی از طریق درخت‌های تصمیم‌گیری و نوموگرام‌ها به‌راحتی تفسیر می‌شوند. الگوریتم درخت تصمیم نیز پس از اجرا به‌راحتی در قالب مجموعه‌ای از قوانین IF-THEN تفسیر می‌شود؛ ۲. هر دوی این الگوریتم‌ها ناپارامتریک هستند؛ به این معنی که آن‌ها استقلال را در بین متغیرهای ورودی فرض می‌کنند؛ حتی اگر متغیرها در واقع وابسته باشند. اگر به دلیل کمبود داده‌های کافی یا هزینه‌های محاسباتی، امکان محاسبه وابستگی به روشی دقیق وجود نداشته باشد، ممکن است ایده خوبی باشد که آن‌ها را مستقل فرض کرد [۳۰].

تفسیرپذیری و توجیه‌پذیری دو مفهوم مهم در زمینه یادگیری ماشین هستند که به ویژگی‌ها و رفتار مدل‌های یادگیری ماشین اشاره دارند. تفسیرپذیری به‌معنای توانایی فهم و تفسیر دقیق علت‌ها و عواملی است که مدل به تصمیمات خود می‌رسد؛ به‌عبارت‌دیگر، اگر یک مدل تفسیرپذیر باشد، می‌توان به‌سادگی فهمید که هر ویژگی یا ورودی چگونه بر پیش‌بینی‌ها و نتایج مدل تأثیر می‌گذارد. از این‌نظر، تفسیرپذیری می‌تواند در تبیین عملکرد مدل‌ها و اعتماد به آن‌ها کمک‌کننده باشد. توجیه‌پذیری به‌معنای قدرت توجیه و تبیین تصمیمات و نتایج یک مدل است؛ به‌عبارت‌دیگر توجیه‌پذیری مرتبط با توانایی توضیح‌دادن دلایل پشت تصمیمات مدل به‌طور مفهومی به افراد غیرفنی است. مدلی که توجیه‌پذیر باشد، می‌تواند به‌طور مؤثرتری با متخصصان و کاربران غیرتخصصی ارتباط برقرار کند و به آن‌ها اطمینان دهد که تصمیماتش مبتنی بر منطق و داده‌های واقعی است. عملکرد به‌معنای عملیات و کارایی یک مدل در پیش‌بینی و تصمیم‌گیری است. اندازه‌گیری عملکرد معمولاً با معیارهایی مانند دقت، فراخور و دیگر معیارهای مشابه صورت می‌گیرد. هدف اصلی از یادگیری ماشین بهبود و افزایش عملکرد مدل‌ها در پیش‌بینی و تصمیم‌گیری است. درخت تصمیم یک نوع مدل تفسیرپذیر است. در واقع یک درخت تصمیم با استفاده از تصمیم‌های سلسله‌مراتبی بر اساس ویژگی‌ها، به‌سادگی قابل تفسیر است. هر گره درخت نشان‌دهنده یک تصمیم و یا قاعده‌ای است که بر اساس آن تصمیمات گرفته می‌شود. به‌راحتی می‌توان توضیح داد که چرا و چگونه یک نمونه به یک شاخه خاص از درخت تصمیم هدایت می‌شود و نتایج نهایی چگونه به‌دست می‌آیند. به‌طور کلی درخت‌های تصمیم به‌عنوان مثال‌هایی از مدل‌های تفسیرپذیر می‌توانند در مواردی که نیاز به توجیه و تبیین دقیق دلایل تصمیمات مدل وجود دارد، استفاده شوند؛ زیرا ساختار سلسله‌مراتبی آن‌ها و قوانین قابل‌فهمی که

بر اساس ویژگی‌ها و تقسیم‌بندی‌های ساده ایجاد می‌کنند، امکان تفسیر را فراهم می‌سازد. در مقابل، شبکه‌های عصبی به دلیل ساختار پیچیده و تعداد زیادی لایه و وزن‌های مختلف، معمولاً به دشواری قابل تفسیر و توجیه هستند. به دلیل وجود اتصالات غیرخطی و پارامترهای زیاد، نمی‌توان به سادگی فهمید که ویژگی‌ها چگونه بر تصمیمات نهایی تأثیر می‌گذارند. این امر باعث کاهش توجیه‌پذیری و تفسیرپذیری مدل می‌شود؛ از این رو شبکه‌های عصبی معمولاً توجه بیشتری به عملکرد دارند تا توجیه‌پذیری یا تفسیرپذیری، به همین دلیل، باید توازنی مناسب بین این مفاهیم و مهارت‌های مدل‌سازی برقرار شود تا بهترین نتیجه در هر مسئله خاص به دست آید [۳].

۴. تحلیل داده‌ها و یافته‌های پژوهش

در این بخش، نتایج مدل‌ها بررسی و تحلیل می‌شود که از اعتبارسنجی متقاطع کنار گذاشتن استفاده شده است و شکل شدید اعتبارسنجی متقاطع k-fold به شمار می‌رود. به این معنا که در هر تکرار، یک نقطه داده حذف شده، مدل بر روی تمام نمونه‌های دیگر آموزش داده می‌شود و سپس از یک نقطه داده به عنوان آزمون دقت طبقه‌بندی مدل استفاده می‌شود. این فرآیند برای تمام نقاط داده تکرار می‌شود.

جدول ۵، نمرات پیش‌بینی دو مدل را نشان می‌دهد. همان‌طور که مشخص است، درخت ایجادشده بر مبنای خوشه‌بندی K-means نتایج بهتری را نسبت به درخت ایجادشده توسط DBSCAN نشان می‌دهد.

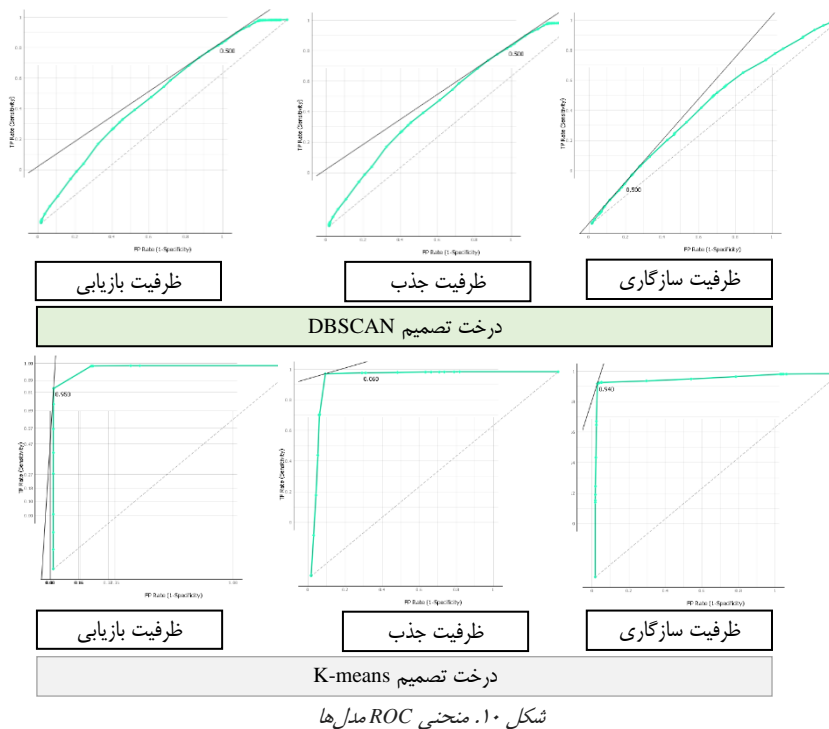
جدول ۵. نمرات پیش‌بینی مدل‌ها

نمرات آزمون					مدل
Recall	Precision	F ₁	CA	AUC	
۰/۹۷۶	۰/۹۷۶	۰/۹۷۶	۰/۹۷۶	۰/۹۷۷	درخت تصمیم K-means
۰/۵۷۹	۰/۵۵۹	۰/۵۲۵	۰/۵۷۹	۰/۶۳۱	درخت تصمیم DBSCAN

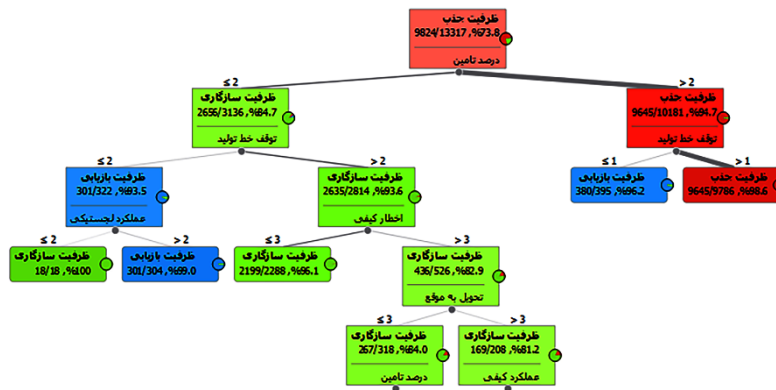
منحنی ROC برای هر یک از مدل‌ها که در شکل ۱۰، ارائه شده است می‌تواند برای اندازه‌گیری دقت پیش‌بینی‌های مدل استفاده شود. سطح زیر نمودار ROC (AUC) معیار خوبی برای دقت پیش‌بینی است و بین صفر و یک متناوب است. این معیار با مقدار ۰/۵ به عنوان عملکرد پیش‌بینی تصادفی در نظر گرفته می‌شود [۹، ۱۲].

با توجه به شکل ۱۰، به دلیل مطلوب بودن طبقه‌بندی صورت‌گرفته در درخت تصمیم K-means نقاط در بالای خط نیمساز قرار گرفته است و نرخ مثبت‌های حقیقی در طبقه‌بندی بر

نرخ مثبت کاذب غلبه دارد که نشان‌دهنده مناسب‌بودن این الگوریتم در حالتی است که در درخت تصمیم DBSCAN طبقه‌بندی به‌درستی انجام نشده و فاصله نقاط تا خط نیمساز کم است.



درخت تصمیم بر اساس هر دو روش خوشه‌بندی DBSCAN و K-means تا ۵ سطح بر اساس خبرگی ایجاد شده و در شکل‌های ۱۱ و ۱۲، ارائه شده است. همان‌طور که مشاهده می‌شود، درخت ایجاد شده بر مبنای خوشه‌بندی K-means عملکرد بهتری نسبت به درخت ایجاد شده توسط DBSCAN دارد.



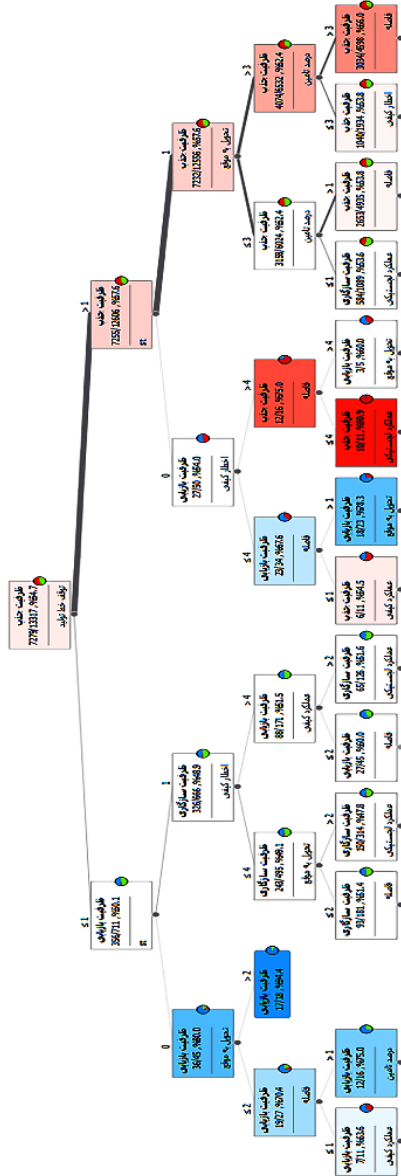
شکل ۱۱. درخت تصمیم بر مبنای خوشه‌بندی K-means

برای مقایسه و تشخیص اینکه کدام یک از دو درخت تصمیم بهتر است، می‌توان به روش‌های زیر توجه کرد:

- دقت پیش‌بینی: اگر یک درخت تصمیم دقت پیش‌بینی بالاتری نسبت به دیگری دارد، احتمالاً بهترین انتخاب است. برای این منظور می‌توان از معیارهایی مانند دقت^۱، دقت متوسط^۲ یا دیگر معیارهای ارزیابی استفاده کرد؛
- شفافیت و قابل‌فهمی: یک درخت تصمیم بهتر، می‌تواند آن باشد که قابلیت تفسیر و فهم بیشتری داشته باشد. اگر یکی از درخت‌ها به صورت ساده‌تر و قابل‌فهم‌تری نمایش داده شود، ممکن است انتخاب مناسبی باشد؛
- جلوگیری از بیش‌برازش^۳: درخت تصمیمی که بیش‌برازش کمتری دارد، معمولاً بهتر عمل می‌کند. اگر یک درخت تصمیم دقت بالایی بر روی داده‌های آموزش داشته، ولی در پیش‌بینی‌های جدید نتایج خوبی نداشته باشد، احتمالاً دچار بیش‌برازش شده است؛
- انطباق با معماری مسئله: درخت تصمیم باید به درستی با معماری مسئله شما انطباق داشته باشد. ممکن است یک درخت تصمیم برای یک مسئله مناسب نباشد؛ اما درخت دیگری بر اساس ساختار داده‌ها و ویژگی‌های مسئله بهتر عمل کند؛
- استفاده از ابزارهای مقایسه: می‌توان از ابزارهای مختلفی برای مقایسه و ارزیابی عملکرد درخت‌های تصمیم استفاده کرد؛ مانند ماتریس‌های درهم‌ریختگی^۴ یا نمودارهای ROC [۳، ۱۲].

1. Accuracy
2. Average Precision
3. Overfitting
4. Confusion Matrices

در نهایت انتخاب درخت تصمیم مناسب به عوامل متعددی بستگی دارد و باید با توجه به مسئله خاص پژوهش و اهداف تحلیل، تصمیم‌گیری شود.



شکل ۱۳. درخت تصمیم بر مبنای خوشه‌بندی DBSCAN

این واقعیت که امتیاز F^1 درخت تصمیم DBSCAN پایین‌تر از درخت تصمیم K-means است، نشان‌دهنده نرخ بالاتر مثبت کاذب و منفی کاذب است [۱۲، ۲۹]. این امر را می‌توان در مقایسه جدول ۶ و جدول ۷، مشاهده کرد که به ترتیب ماتریس‌های سردرگمی مدل درخت تصمیم DBSCAN و مدل درخت تصمیم K-means را نشان می‌دهند.

جدول ۶. ماتریس درهم‌ریختگی مدل درخت تصمیم DBSCAN

	ظرفیت باز یابی	ظرفیت جذب	ظرفیت سازگاری	جمع
واقعی	ظرفیت باز یابی	۲۰۳	۲۱	۲۸۳
	ظرفیت جذب	۱۸	۶۳۶۰	۷۲۷۹
	ظرفیت سازگاری	۱۸۷	۴۳۲۶	۵۶۵۵
	جمع	۴۰۸	۱۰۷۰۷	۱۳۳۱۷

جدول ۷. ماتریس درهم‌ریختگی مدل درخت تصمیم K-means

	ظرفیت باز یابی	ظرفیت جذب	ظرفیت سازگاری	جمع
واقعی	ظرفیت باز یابی	۷۷	-	۶۸۷
	ظرفیت جذب	۵	۹۴	۹۸۲۴
	ظرفیت سازگاری	۱۴	۲۶۶۸	۲۸۰۶
	جمع	۶۲۹	۲۷۶۲	۱۳۳۱۷

۹۹ درصد تأمین‌کنندگانی که عملکرد بهتری با توجه به ظرفیت جذب داشتند، توسط درخت تصمیم K-means به درستی طبقه‌بندی شده‌اند؛ در حالی که ۸۷ درصد از این تأمین‌کنندگان در درخت تصمیم DBSCAN درست طبقه‌بندی شده‌اند. در ظرفیت سازگاری درخت تصمیم DBSCAN ۲۰ درصد درست طبقه‌بندی شده است؛ ولی در درخت تصمیم K-means ۹۵ درصد تأمین‌کنندگان به درستی طبقه‌بندی شده‌اند و در ظرفیت باز یابی ۵۳ درصد تأمین‌کنندگان در درخت تصمیم DBSCAN درست طبقه‌بندی شده‌اند؛ در حالی که در درخت تصمیم K-means صحت طبقه‌بندی ۸۸ درصد است. به طور کلی، CA (دقت طبقه‌بندی) دقت ۹۸ درصد مدل درخت تصمیم K-means و دقت ۵۸ درصد مدل درخت تصمیم DBSCAN را نشان می‌دهد.

همان‌طور که در درخت تصمیم K-means مشخص شده است، شاخص‌هایی چون توقف خط تولید و درصد تأمین (ظرفیت تأمین‌کننده) اهمیت بالایی در طبقه‌بندی دارند. نتایج ارائه‌شده نشان‌دهنده طبقه‌بندی مناسب‌تر درخت تصمیم K-means برای ظرفیت‌های تاب‌آوری و مبنایی برای طبقه‌بندی و تخصیص تأمین‌کننده به مشتریان مختلف بر اساس ظرفیت‌های تاب‌آوری است.

۵. نتیجه‌گیری و پیشنهادها

در دهه‌های اخیر، انتخاب و تخصیص سفارش در زنجیره تأمین به یک تصمیم استراتژیک بسیار حیاتی در مواجهه با اختلالات زنجیره تأمین در دوره‌های بحرانی تبدیل شده است. این تصمیم‌گیری در شرایطی که پایداری زنجیره تأمین با تهدیدهای زیادی مواجه می‌شود، بسیار اهمیت دارد. با افزایش ریسک‌های مختلف اختلالات، به‌ویژه خطرهایی با احتمال وقوع کم و تأثیرات جدی، اهمیت تصمیم‌گیری در زمان‌های بحرانی افزایش یافته است؛ به‌ویژه در محیط زنجیره تأمین جهانی. از دیگر دلایلی که تصمیم‌گیری در زمینه انتخاب و تخصیص سفارش به تأمین‌کننده را با چالش‌های بزرگی مواجه کرده، افزایش کاربردهای یادگیری ماشین در مطالعات زنجیره تأمین است. استفاده از روش‌های یادگیری ماشین این امکان را فراهم می‌سازد تا بتوان تصمیم‌گیری‌های سریع‌تر و دقیق‌تری در مواجهه با ورود حجم بالای داده‌ها به زنجیره تأمین انجام دهیم. این روش‌ها به پژوهشگران امکان می‌دهند تا الگوهای پنهان و پیچیده در داده‌ها را شناسایی کنند و تصمیم‌گیری‌های بهتری در مواجهه با اختلالات و تغییرات سریع زنجیره تأمین داشته باشند.

یکی از چالش‌های موجود در استفاده از یادگیری ماشین، بهبود تفسیرپذیری تصمیم‌های انجام شده است. در صورتی که تصمیم‌گیری‌ها به‌صورت خودکار توسط مدل‌های یادگیری ماشین انجام شوند، ممکن است دشواری در تفسیر دلایل این تصمیم‌ها پیش آید. این مسئله به‌ویژه در زمینه‌های حساس مانند زنجیره تأمین، اهمیت بیشتری دارد. در این پژوهش، تفسیرپذیری تصمیم‌گیری‌ها از طریق استفاده از درخت تصمیم بهبود یافته است. این درخت تصمیم به پژوهشگر امکان می‌دهد تا به‌صورت واضح و شفاف عواملی که تصمیم‌گیری را تحت تأثیر قرار می‌دهند، مشخص کرده و اطمینان حاصل کند که تصمیمات اتخاذشده در مسیر منطقی و قابل تفسیری قرار دارند.

در این پژوهش، دو الگوریتم خوشه‌بندی *DBSCAN* و *K-means* برای تولید برچسب‌ها و پیش‌بینی عملکرد آتی تأمین‌کننده مورد استفاده قرار گرفت؛ سپس خروجی تحلیل نتایج این الگوریتم‌ها به دلیل سهولت تفسیرپذیری در تشکیل درخت تصمیم به کار گرفته شد. نتایج نشان می‌دهد که درخت مبتنی بر خوشه‌بندی *K-means* به بهبود کارایی در پیش‌بینی عملکرد آتی تأمین‌کننده منجر می‌شود. این نتایج نشان می‌دهند که این الگوریتم، توانایی برتری در تجزیه و تحلیل داده‌ها و پیش‌بینی دقیق‌تر آینده دارد؛ در نتیجه پژوهش حاضر نه تنها یک مسیر تازه در پژوهش‌های زنجیره تأمین ارائه می‌دهد؛ بلکه نقش اساسی یادگیری ماشین در بهبود تصمیم‌گیری‌های مهم در زمینه انتخاب و تخصیص سفارش به تأمین‌کننده را نیز برجسته می‌سازد. این پژوهش نشان می‌دهد که ادغام یادگیری ماشین با تصمیم‌گیری در زنجیره تأمین می‌تواند به بهبود عملکرد زنجیره تأمین منجر شود؛ به‌خصوص در حالتی که تعداد سایت‌های

تولید بیش از یک سایت بوده و عملکرد تأمین‌کنندگان در خصوص مشتریان مختلف متفاوت است و در نتیجه تخصیص آن‌ها نیز به هر مشتری بر اساسی ظرفیت‌های تاب‌آوری صورت می‌گیرد؛ به نحوی که تأمین‌کنندگان می‌توانند با توجه به عملکرد خود در خصوص هر مشتری در یکی از ظرفیت‌های جذب، سازگاری و یا بازیابی قرار گیرند و بر مبنای نیاز مشتری و قرارگیری هر تأمین‌کننده بر اساس ظرفیت‌های تاب‌آوری ارائه‌شده در درخت تصمیم به مشتریان تخصیص داده شوند.

تعارض منافع. برای ارائه مطالب و نگارش این مقاله هیچ‌گونه کمک مالی از هیچ فرد، نهاد و سازمانی دریافت نشده است و نتایج و دستاوردهای این مقاله به نفع یا ضرر سازمان یا فردی خاص نخواهد بود. حضور نویسندگان در این پژوهش به عنوان شاهدی بی‌طرف ولی متخصص بوده است و نویسندگان هیچ‌گونه تعارض منافی ندارند.

منابع

1. Adobor, H., & McMullen, R. S. (2018). Supply chain resilience: a dynamic and multidimensional approach. *International Journal of Logistics Management*, 29(4), 1451–1471.
2. Ali, Md. R., Nipu, S. Md. A., & Khan, S. A. (2023). A decision support system for classifying supplier selection criteria using machine learning and random forest approach. *Decision Analytics Journal*, 7, 100238.
3. Alpaydin, E. (2020). *Introduction to machine learning*. MIT press.
4. Atalay, M., & Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamaları-artificial intelligence and machine learning applications in big data analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155–172.
5. Bai, C., Rezaei, J., & Sarkis, J. (2017). Multicriteria green supplier segmentation. *IEEE Transactions on Engineering Management*, 64(4), 515–528.
6. Baryannis, G., Dani, S., & Antoniou, G. (2019). Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993–1004.
7. Baryannis, G., Validi, S., Dani, S., & Antoniou, G. (2019). Supply chain risk management and artificial intelligence: state of the art and future research directions. *International Journal of Production Research*, 57(7), 2179–2202.
8. Brusset, X., & Teller, C. (2017). Supply chain capabilities, risks, and resilience. *International Journal of Production Economics*, 184, 59–68.
9. Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A., & Ivanov, D. (2019). A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49, 86–97.
10. Echefaj, K., Charkaoui, A., Cherrafi, A., Garza-Reyes, J. A., Khan, S. A. R., & Chaouni Benabdellah, A. (2023). Sustainable and resilient supplier selection in the context of circular economy: an ontology-based model. Management of Environmental Quality: *An International Journal*, 34(5), 1461–1489.

11. Eyika Gaida, I. W., Mittal, M., & Yadav, A. S. (2022). Optimal Strategy for Supplier Selection in a Global Supply Chain Using Machine Learning Technique. *International Journal of Decision Support System Technology*, 14(1), 1–13.
12. Geetha, T. V., & Sendhilkumar, S. (2023). *Machine Learning: Concepts, Techniques and Applications*. CRC Press.
13. Glock, C. H., Grosse, E. H., & Ries, J. M. (2017). Reprint of “Decision support models for supplier development: Systematic literature review and research agenda.” *International Journal of Production Economics*, 194, 246–260.
14. Guo, X., Yuan, Z., & Tian, B. (2009). Supplier selection based on hierarchical potential support vector machine. *Expert Systems with Applications*, 36(3), 6978–6985.
15. Ho, W., Xu, X., & Dey, P. K. (2010). Multi-criteria decision making approaches for supplier evaluation and selection: A literature review. *European Journal of Operational Research*, 202(1), 16–24.
16. Hosseini, S., & Khaled, A. Al. (2019). A hybrid ensemble and AHP approach for resilient supplier selection. *Journal of Intelligent Manufacturing*, 30, 207–228.
17. Hosseini, S., Morshedlou, N., Ivanov, D., Sarder, M. D., Barker, K., & Al Khaled, A. (2019). Resilient supplier selection and optimal order allocation under disruption risks. *International Journal of Production Economics*, 213, 124–137.
18. Hurwitz, J., & Kirsch, D. (2018). *Machine learning for dummies*. IBM Limited Edition, 75.
19. Islam, S., Amin, S. H., & Wardley, L. J. (2024). A supplier selection & order allocation planning framework by integrating deep learning, principal component analysis, and optimization techniques. *Expert Systems with Applications*, 235, 121121.
20. Ivanov, D., & Dolgui, A. (2020). Viability of intertwined supply networks: extending the supply chain resilience angles towards survivability. A position paper motivated by COVID-19 outbreak. *International Journal of Production Research*, 58(10), 2904–2915.
21. Jafarnezhad Chaghooshi, A., Kazemi, A., & Arab, A. (2016). Identification and Prioritization of Supplier’s Resiliency Evaluation Criteria Based on BWM. *The Journal of Industrial Management Perspective*, 6(3), 159-186. (In Persian)
22. Jiang, W., & Liu, J. (2018). Inventory financing with overconfident supplier based on supply chain contract. *Mathematical Problems in Engineering*, 2018.
23. Kamalahmadi, M., & Parast, M. M. (2017). An assessment of supply chain disruption mitigation strategies. *International Journal of Production Economics*, 184, 210–230.
24. Khan, M. M., Bashar, I., Minhaj, G. M., Wasi, A. I., & Hossain, N. U. I. (2023). Resilient and sustainable supplier selection: an integration of SCOR 4.0 and machine learning approach. *Sustainable and Resilient Infrastructure*, 8(5), 453–469
25. Kumar, S., Dixit, A. K., & Akarte, M. (2023). Machine Learning Based Decision Support System for Resilient Supplier Selection. In R. Misra, N. Kesswani, M. Rajarajan, B. Veeravalli, I. Brigui, A. Patel, & T. N. Singh (Eds.), *Advances in Data Science and Artificial Intelligence* (pp. 33–43). Springer International Publishing.
26. Kuran, M. S., Eşme, E., Torğul, B., & Paksoy, T. (2020). Supplier Selection with Machine Learning Algorithms. In *Logistics 4.0* (pp. 103–125). CRC Press.
27. Lin, J., & Lanng, C. (2020). Here’s how global supply chains will change after COVID-19. *World Economic Forum* .<https://www.weforum.org/agenda/2020/05/this-is-what-global-supply-chains-will-look-like-after-covid-19/>
28. Mirkouei, A., & Haapala, K. R. (2014). Integration of machine learning and mathematical programming methods into the biomass feedstock supplier selection process.

29. Mueller, J. P., & Massaron, L. (2021). *Machine learning for dummies*. John Wiley & Sons.
30. Pentakalos, O. (2019). *Introduction to machine learning*. Proc. C. Impact
31. Rabieh, M., Azar, A., Modarres Yazdi, M., & Fetanat Fard Haghghi, M. (2011). Designing a Multi-Objective Resource-Based Mathematical Modeling: An Approach to Supply Chain Risk Reduction (Case Study: Iran Khodro Supply Chain). *The Journal of Industrial Management Perspective, 1(1)*, 57-77. (In Persian)
32. Rajesh, R., & Ravi, V. (2015). Supplier selection in resilient supply chains: a grey relational analysis approach. *Journal of Cleaner Production, 86*, 343–359.
33. Ravanestan, K., Aghajani, H., Safaei Ghdikolaei, A., & Yahyazadefar, M. (2017). Determining and Weighting Resilience Strategies in the Iran Khodro Supply Chain. *The Journal of Industrial Management Perspective, 7(1)*, 145-172. (In Persian)
34. Ribeiro, J. P., & Barbosa-Povoa, A. (2018). Supply Chain Resilience: Definitions and quantitative modelling approaches—A literature review. *Computers & Industrial Engineering, 115*, 109–122.
35. Roberta Pereira, C., Christopher, M., & Lago Da Silva, A. (2014). Achieving supply chain resilience: the role of procurement. *Supply Chain Management: An International Journal, 19(5/6)*, 626–642.
36. Shashi, Centobelli, P., Cerchione, R., & Ertz, M. (2020). Managing supply chain resilience to pursue business and environmental strategies. *Business Strategy and the Environment, 29(3)*, 1215–1246.
37. Simchi-Levi, D., Schmidt, W., Wei, Y., Zhang, P. Y., Combs, K., Ge, Y., Gusikhin, O., Sanders, M., & Zhang, D. (2015). Identifying risks and mitigating disruptions in the automotive supply chain. *Interfaces, 45(5)*, 375–390.
38. Tavana, M., Fallahpour, A., Di Caprio, D., & Santos-Arteaga, F. J. (2016). A hybrid intelligent fuzzy predictive model with simulation for supplier evaluation and selection. *Expert Systems with Applications, 61*, 129–144.
39. Tirkolaei, E. B., Sadeghi, S., Mooseloo, F. M., Vandchali, H. R., & Aeini, S. (2021). Application of Machine Learning in Supply Chain Management: A Comprehensive Overview of the Main Areas. *Mathematical Problems in Engineering, 2021*, 1476043.
40. Torabi, S. A., Baghersad, M., & Mansouri, S. A. (2015). Resilient supplier selection and order allocation under operational and disruption risks. *Transportation Research Part E: Logistics and Transportation Review, 79*, 22–48.
41. Valluri, A., & Croson, D. C. (2005). Agent learning in supplier selection models. *Decision Support Systems, 39(2)*, 219–240
42. Zhao, L., Qi, W., & Zhu, M. (2021). A Study of Supplier Selection Method Based on SVM for Weighting Expert Evaluation. *Discrete Dynamics in Nature and Society*.