

Predicting the Lead Time of Auto Parts Orders in the Supply Chain Using Machine Learning

Faezeh Zamani 

Ph.D. Student of Industrial Management Group,
Department of Economics and Management,
Science and Research Branch, Islamic Azad
University, Tehran, Iran

Ahmad Ebrahimi*



Assistant Professor of Industrial Management &
Technology Group, Department of Economics and
Management, Science and Research Branch, Islamic
Azad University, Tehran, Iran

Roya Soltani 

Assistant Professor of Industrial Engineering Group,
Department of Engineering, Khatam University,
Tehran, Iran

**Babak Farhang
Moghaddam** 

Associate Professor, Institute Management and
Planning Studies, Tehran, Iran

Abstract

This research aims to investigate the effective factors in predicting lead time (LT) and create a predictive model of LT to improve sustainability and resilience for Kanban orders in the lean supply chain (LSC). The study follows the data mining (DM) method, and the dataset includes 103023 observations from the Kanban system, which were extracted in compliance with the requirements of the dataset quality indicators in the period 1402/6 to 1402/11. First, indicators affecting the LT of orders were extracted. Process mining was used to identify influential variables in high-variance processes to improve performance and accuracy. A stepwise analysis approach was used to select features for the model fitting stage. Also, tuning the parameters of non-parametric approaches was used. The predictive model uses Multiple Linear Regression, Multiple with curvature, Lasso, Elastic Net, Boosted Decision Tree, Bootstrap Random Forest, K-Nearest Neighbor, and

* Corresponding Author: Ahmad.Ebrahimi@srbiau.ac.ir

How to Cite: xxxxxxxx

Boosted Multi-Layer Perceptron. The performance of the fitted regression models has been confirmed using R^2 , RASE, and validation of the results and model. The results showed that the logistical features are effective in LT, and the Boosted Multi-Layer Perceptron is the best for predicting orders' LT with an accuracy of 96% and an error of 5.84. Using the model's predictive capability for new data in the Kanban system, the results obtained within four months have been used. The improvements from using DM capabilities in the Kanban system all express the significant impact of combining lean and machine learning (ML) tools to empower and resilient Lean Supply Chain Management (LSCM).

1. Introduction

The main problem in this research is identifying the factors that effectively predict the LT of orders in the LSC, choosing the best ML algorithm for predicting the exact LT, and how process mining can effectively identify the most repeatable variables in the main variants and investigate how DM can reduce waste in LSC.

Despite classification studies on risk, disruption, and delay prediction in the literature, to our knowledge, fewer articles were found regarding the use of DM to predict the accurate LT of orders in the LSC with logistical features. Also, according to researchers, DM is considered a tool to overcome the limitations of lean tools and strengthen their performance. However, the studies corresponding to the executive case did not observe the results and improvements from the ML application in predicting the LT of orders.

Therefore, in this research, in terms of innovation, 1) machine learning has been used to accurately predict the LT of Kanban orders, considering logistical factors, 2) Process mining has been used in the identification stage of influential variables, 3) The results and improvements obtained from predicting the LT of orders regarding risk reduction and sustainability improvement have been examined and compared.

Research Question(s)

The main questions in this research are specified as follows:

1. What factors affect LT's prediction in the lean supply chain?

3. How do we predict the LT in the lean supply chain?
4. How can DM effectively reduce waste in the lean supply chain?

2. Literature Review

Regarding the issue's importance and urgency, transparency and accurate prediction of the LT have reduced risk and improved sustainability and resilience in the LSC. These effects are significant in both theoretical and operational dimensions, such as reducing logistic costs, safety stock, working capital, stoppage, level of inventories, storage cost, energy consumption, and risk. After reviewing the literature, the most relevant articles in the field of ML are listed in Table2.

3. Methodology

This research is practical from the objective point of view, and from the data point of view, it is quantitative. This study includes four main processes: 1) reviewing the literature and data collection, 2) research method and pre-processing, 3) model construction, and 4) model evaluation and results (Jayanti, 2022 & Wasesa). First, influential variables were extracted by reviewing the literature. Then, the dataset was extracted from the Kanban system in compliance with the requirements of the data set quality indicators from 6/1402 to 11/1402. Then, process mining was used to identify the features with the most repeatability in the main variants, and finally, influential variables were extracted through brainstorming. An integrated stepwise analysis approach has been used to select features. The predictive model uses MLR, curvature, Lasso, Elastic Net, Boosted DT, Bootstrap RF, KNN, and Boosted Multi-Layer Perceptron. The parameters of non-parametric approaches are tuned to improve forecasting performance and accuracy. In this research, evaluation and validation are the main criteria for evaluating the model's predictive power, and error and accuracy indices have been used together. Therefore, the performance of the fitted regression models using R^2 and RASE evaluation indices and validation of the results and the model are confirmed.

4. Results

After fitting the regression models, for each row of test data, predict the LT and compare it with the actual values of the LT; then, to identify the best model, R^2 , RASE, and model comparison approaches are used.

The results show that the Boosted Multi-Layer Perceptron, with one hidden layer, five activation functions, and a learning rate of 0.1, has the highest accuracy at 96% and the lowest root average square error at 5.84, compared to other fitted models.

5. Discussion and Conclusion

The obtained results show that the identified independent variables are related to customer factors (safety stock), manufacturer factors (inspection status, quality point), logistic factors (vehicle, distance), part factors (name, part-expert), and order factors (number of holidays, Kanban issue date) are effective on the LT. As the selected model in this research, the regression model of the Boosted Multi-Layer Perceptron has the highest R^2 and the lowest RASE criteria. Process mining is practical and helpful in identifying the main variants. By using the model's predictive capability for new data in the Kanban order issuing system within four months, the improvements all express the significant impact of combining lean tools and ML to empower LSCM. The practical implications of this research can guide managers in implementing practices with lean tools, improving sustainability, eliminating waste, and being more competitive in the current challenging business environment. Academics can benefit from the present study because it provides ML practices that can be further tested and validated.

This research generalizes and develops the use of DM as a decision-making support tool in predicting the LT to overcome the limitations of lean tools, and it can improve the efficiency and stability of the LSC and reduce the risk. While this research provides valuable insights, it also has limitations, including the lack of data on influential variables identified in the literature. In implementing this research, there are suggestions for future research that examine factors such as production capacity, weather, and location conditions and deep learning to fit more reliable and accurate results and investigate prescriptive analyses to


پیش‌بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۵

optimize the LT of orders based on the fitted regression models, the design of the experiment and using the profiler's capabilities.


Keywords: Machine Learning, Regression, Lean Supply Chain Management, Kanban, Lead Time.

پیش بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیری ماشین


دانشجوی دکتری رشته مدیریت صنعتی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

فائزه زمانی 


استادیار گروه مدیریت صنعتی و تکنولوژی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

احمد ابراهیمی *

استادیار گروه مهندسی صنایع، دانشگاه خاتم، تهران، ایران

رویا سلطانی 

دانشیار موسسه مطالعات برنامه ریزی و مدیریت، تهران، ایران

بابک فرهنگ مقدم 

چکیده

هدف این پژوهش بررسی عوامل موثر در پیش بینی زمان انتظار و ایجاد مدل پیش بینانه زمان انتظار سفارشات کابنان به جهت بهبود پایداری و تاب آوری در زنجیره تامین ناب می باشد. برای دستیابی به این هدف، مطالعه از روش داده کاوی پیروی می کند، مجموعه داده ها شامل ۱۰۳۰۲۳ مشاهده، از سیستم کابنان واکسترانت زنجیره تامین با رعایت الزامات شاخص های کیفیت دیتاست در بازه ۱۴۰۲/۶ تا ۱۴۰۲/۱۱ استخراج شده است. ابتدا شاخص های موثر بر زمان انتظار سفارشات استخراج شده است و به جهت بهبود عملکرد و دقت پیش بینی، از فرآیند کاوی جهت شناسایی متغیرهای پرتکرار و تاثیرگذار در واریانت های اصلی و سپس در مرحله برازش مدل، از رویکرد تحلیل گام به گام تلفیقی جهت انتخاب ویژگی ها و از تنظیم پارامتر رویکردهای رگرسیونی ناپارامتریک استفاده شده است. مدل پیش بینانه با استفاده از مدل های رگرسیونی خطی چندمتغیره، چندمتغیره دارای انحنا، لاسو، الاستیک نت، درخت تصمیم تقویتی، جنگل تصادفی بوت استرپ، k- نزدیک ترین همسایه، شبکه عصبی تقویتی برازش داده شده است. عملکرد مدل های رگرسیونی برازش شده با استفاده از شاخص های ارزیابی R^2 ، RASE و اعتبارسنجی نتایج و مدل تایید شده است. نتایج نشان داد که عوامل لجستیکی در زمان انتظار سفارشات موثر بوده و الگوریتم شبکه عصبی تقویت شده بهترین مدل در پیش بینی زمان انتظار سفارشات با دقت ۹۶ درصد و با خطا ۵/۸۴ است. سپس قابلیت

مقاله حاضر برگرفته از رساله دکتری مدیریت صنعتی دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران است.

* نویسنده مسئول: Ahmad.Ebrahimi@srbiau.ac.ir

پیش‌بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۷

پیش‌بینی مدل برای دیتاهای جدید در سیستم صدور سفارشات کانبان به کار گرفته شده است، نتایج و بهبودهای حاصل از بهره‌گیری قابلیت‌های داده‌کاوی در سیستم کانبان همگی بیان‌گر تاثیر معنی‌دار ترکیب ابزار ناب و یادگیری ماشین به جهت توانمندسازی و تاب‌آوری زنجیره تامین ناب می‌باشد.

کلیدواژه‌ها: یادگیری ماشین، رگرسیون، مدیریت زنجیره تامین ناب، کانبان، زمان انتظار

مقدمه

شفافیت و پیش‌بینی دقیق زمان انتظار سفارشات کانبان در زنجیره تامین ناب منجر به تاب‌آوری، کاهش هزینه‌های عملیاتی و ارتقا سطح پایداری می‌شود (Alsadi *et al.*, 2022; Schneckenreither *et al.*, 2021) و عدم قطعیت در برآورد زمان تحویل تامین‌کنندگان منجر به ابطال سفارشات صادره کانبان، تاخیر در تامین سفارشات و افزایش ریسک توقف خطوط تولید می‌گردد و جریمه‌های گزافی را به شرکت‌های تامین‌کننده تحمیل می‌نماید (Gabellini *et al.*, 2024; Singh and Soni, 2019). لذا برای پرکردن این خلاء، سازمان‌ها با استفاده از یادگیری ماشین به شناسایی فاکتورهای پرمخاطره و موقعیت‌های پرریسک می‌پردازند، به این معنا که در زمان مواجهه زنجیره تامین با چالش‌های زمان، هزینه و محدودیت‌های منابع، یادگیری ماشین به عنوان یک رویکرد برتر به مدیریت ریسک‌ها می‌پردازد (Baryannis *et al.*, 2019; Pozzi *et al.*, 2022; Yang *et al.*, 2023). با استناد به پیوند قوی و هم‌افزایی بین تولید ناب و صنعتی^۱، می‌توان با بهره‌گیری از داده‌کاوی جهت پیش‌بینی هر چه دقیق‌تر زمان انتظار و تلفیق آن با رویکرد تولید ناب، به جهت کاهش یا حذف اتلاف‌ها در سطح زنجیره تامین ناب اقدام نمود (Dillinger *et al.*, 2022; Pozzi *et al.*, 2022) و هر چه بیشتر به اهداف اقتصادی، اجتماعی، محیطی (پایداری) در مدیریت زنجیره تامین ناب دست یافت (Maware and Parsley, 2023). از آنجایی که سازمان‌ها به دنبال کاهش زمان انتظار به منظور کاهش هزینه‌های تولید خود هستند، زمان انتظار کوتاه‌تر به عنوان یک منبع اصلی دستیابی به مزیت رقابتی بالقوه، می‌تواند به بهینه‌سازی در زنجیره تامین داخلی و پایداری بیشتر نیز کمک کند (Ivanov and Jaff, 2017). امروزه اکوسیستم زنجیره تامین دیجیتالی از پیامدهای تحول و پویایی ناشی از دیجیتالی شدن بهره‌مند گردیده است و برای کلیه ذینفعان در این حوزه، این یک پیشرفت چشمگیر است و یادگیری ماشین

^۱ انقلاب صنعتی چهارم، یا Industry 4.0، نسل چهارم انقلاب صنعتی است که بر پایه استفاده گسترده از فناوری‌های نوین و پیشرفته در تولید و زنجیره‌های تامین بنا شده است.

در هسته این تحول بزرگ قرار دارد (Mohamed-Iliasse *et al.*, 2022). لذا هدف این پژوهش شناسایی و غربال کردن عوامل موثر، تعیین رابطه بین متغیرهای تاثیرگذار و ایجاد مدل پیش‌بینی زمان انتظار سفارشات به منظور بهبود پایداری و تاب‌آوری در زنجیره تامین ناب می‌باشد.

ضرورت پیش‌بینی زمان انتظار در زنجیره تامین ناب از دو بعد نظری (ادبیات موضوع) و بعد عملیاتی (مصاحبه با متخصصین صنعت) مطرح است که در جدول شماره ۱ خلاصه شده است.

جدول شماره ۱: جمع‌بندی اثرات پیش‌بینی زمان انتظار از بعد نظری و عملیاتی

بعد	ذینفعان	کاهش هزینه لجستیکی	کاهش سطح موجودی‌ها	کاهش هزینه انبارش	کاهش ذخیره احتیاطی	کاهش سرمایه در گردش	کاهش مصرف انرژی	کاهش آلودگی	کاهش هزینه مدیریت ریسک	پایداری	افزایش بهره‌وری	کاهش توقف خط	منابع
نظری	تامین کننده	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	(Alnahhal <i>et al.</i> , 2021; Bassiouni <i>et al.</i> , 2024; Gabellini <i>et al.</i> , 2024; Singh and Soni, 2019)
	زنجیره تامین	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	(Alnahhal <i>et al.</i> , 2021; Bassiouni <i>et al.</i> , 2024; Gabellini <i>et al.</i> , 2024; Ivanov and Jaff, 2017; Rokoss <i>et al.</i> , 2024)
	مشتری	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	(Burggräf <i>et al.</i> , 2021; Ivanov and Jaff, 2017; Rokoss <i>et al.</i> , 2024)
	جامعه						✓	✓					(Alnahhal <i>et al.</i> , 2021; ER and MOSAWI, 2022)
	محیط						✓	✓					(Alnahhal <i>et al.</i> , 2021; ER and MOSAWI, 2022)
عملیاتی	تامین کننده	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	مصاحبه با متخصصین صنعت خودرو
	زنجیره تامین	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	
	مشتری	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	
	جامعه						✓	✓				✓	
	محیط						✓	✓		✓			

با مطالعه پیشینه پژوهش (جدول شماره ۲)، مشاهده گردید که علیرغم پژوهش‌های کلاسه‌بندی^۱ در خصوص تعیین ریسک، پیش‌بینی اختلال در زنجیره تامین و ریسک تاخیر، مطالعات کمتری به بهره‌گیری از یادگیری ماشین جهت پیش‌بینی دقیق زمان انتظار سفارشات

¹ Classification

کانبان در زنجیره تامین ناب با لحاظ عوامل جغرافیایی پرداخته‌اند. همچنین در پیشینه پژوهش کمتر از فرآیند کاوی به جهت شناسایی متغیرهای تاثیرگذار در فرآیندهای با واریانس بالا استفاده شده است. لذا در این پژوهش به لحاظ نوآوری (۱) به بهره‌گیری از یادگیری ماشین جهت پیش‌بینی دقیق زمان انتظار سفارشات کانبان با لحاظ عوامل لجستیکی پرداخته شده است. (۲) از فرآیند کاوی در مرحله شناسایی متغیرهای تاثیرگذار با بیشترین تکرار در واریانتهای اصلی علاوه بر سایر رویکردهای کیفی استفاده شده است. (۳) نتایج و بهبودهای حاصل از پیش‌بینی زمان انتظار سفارشات در خصوص کاهش ریسک و بهبود پایداری در یک سیستم ناب مورد بررسی و مقایسه قرار گرفته است.

لذا این پژوهش با ارائه یک چارچوب عملی جهت پر کردن این شکاف پژوهشی در زنجیره تامین ناب قابل تعمیم و ضروری است.

با توجه به ضرورت بیان شده، سوالات پژوهش به شرح ذیل تعریف می‌شود:

- (۱) عوامل موثر بر محاسبه زمان انتظار سفارشات در زنجیره تامین ناب چیست؟
- (۲) زمان انتظار سفارشات در زنجیره تامین ناب را چگونه می‌توان پیش‌بینی کرد؟
- (۳) داده کاوی چگونه در جهت کاهش اتلاف‌ها در زنجیره تامین ناب موثر واقع می‌شود؟

پیشینه پژوهش

مبانی نظری پژوهش

تولید ناب اصلتا از شرکت تویوتا و در پایان جنگ جهانی دوم-که با کمبود منابع روبرو شدند- با هدف افزایش بهره‌وری (یا کاهش مصرف منابعی که منجر به ایجاد ارزش افزوده نمی‌شوند) و کاهش هزینه تولید به واسطه حذف هر گونه اتلاف، و با استقرار سیستم تولید تویوتا^۱ پدید آمده است (Maware and Parsley, 2023; Qureshi *et al.*, 2023).

زنجیره تامین یک تغییر پارادایم را در نتیجه صنعتی ۴,۰ و ادغام تکنولوژی‌های جدید از قبیل اینترنت اشیاء، رایانش ابری، ناب ۴,۰، هوش مصنوعی، تجزیه و تحلیل پیش‌بینانه در سیستم‌های تولیدی تجربه نموده است. صنعتی ۴,۰ اجرای ناب ۴,۰ را ممکن ساخته تا منجر به کاهش زمان انتظار، مواد و منابع به جهت کاهش اتلاف‌ها گردد. ناب ۴,۰ و صنعتی ۴,۰ هر دو به دنبال تقویت بهره‌وری و انعطاف‌پذیری فرآیندهای تولیدی و خدماتی هستند. ابزار ناب در زنجیره تامین به منظور بهینه‌سازی فعالیت‌ها به کار گرفته شده و منجر به کاهش

¹ Toyota Production System

اتلاف‌ها، بهبود کیفیت، کاهش هزینه‌ها، افزایش انعطاف‌پذیری و پایداری در سطح زنجیره می‌گردد (Garcia-Buendia et al., 2021; Qureshi et al., 2023).

زمان انتظار^۱ از دیدگاه تولیدکننده، زمان سپری شده بین ثبت سفارش و زمان تحویل واقعی آن است. زمان انتظار در میان مهم‌ترین شاخص‌های عملکرد شرکت‌ها قرار دارد که سازمان‌های در پی به حداقل رساندن آن و کاهش سطح موجودی خود هستند تا بتوانند محصول درست را در کم‌ترین زمان ممکن به دست مشتریان خود رسانده و انتظارات مشتریان را با لحاظ نوسانات تقاضا برآورده سازند. غالب رویکردهای برنامه‌ریزی و زمانبندی تولید بر پایه زمان انتظار است، بدین ترتیب کارآیی این رویکردها به شدت تحت تاثیر صحت در پیش‌بینی زمان انتظار می‌باشد و انعطاف‌پذیری زمان انتظار امری مهم تلقی می‌شود (Burggräf et al., 2021; de Oliveira et al., 2021).

یادگیری ماشین زیرشاخه‌ای از هوش مصنوعی و علوم کامپیوتر است که بر مبنای یادگیری آماری به جهت استخراج دانش، روندها، الگوهای پنهان در مجموعه داده‌هاست، در حالت کلی به دو دسته تکنیک یادگیری با نظارت و بدون نظارت تقسیم می‌شود. یادگیری با نظارت به دنبال پیش‌بینی پارامترهای خروجی بر پایه متغیرهای ورودی و دیتاست آموزشی است، که یکی از بنیادی‌ترین رویکردهای آن مدل‌های رگرسیون است (Bassiouni et al., 2024; Gong et al., 2023).

مرور مطالعات گذشته

با مرور پیشینه پژوهش، روش‌های بکارگرفته شده در خصوص پیش‌بینی زمان انتظار در حوزه‌های تحلیل آماری و شبیه‌سازی و یادگیری ماشین دسته‌بندی گردیده است. که مرتبط‌ترین مقالات حوزه یادگیری ماشین در جدول شماره ۲ آمده است:

جدول ۲. خلاصه مطالعات گذشته

منابع	هدف	ویژگی	انتخاب ویژگی ^۲	الگوریتم	دستاورد/ نتایج
(Öztürk et al., 2006)	تخمین زمان انتظار تولیدات سفارشی	۲۶	مبتنی بر درخت	Tree	مقایسه عملکرد با ۴ رویکرد در ادبیات

^۱ Lead Time

^۲ Feature Selection

منابع	هدف	ویژگی	انتخاب ویژگی ^۲	الگوریتم	دستاورد/ نتایج
(Alenezi et al., 2008)	پیش بینی زمان از طریق زمان چرخه سفارش	۲	-	SVR ANN	مقایسه عملکرد ماشین بردار پشتیبان نسبت به شبکه عصبی
(Pfeiffer et al., 2016)	تخمین زمان انتظار تولید	۱۲	-	Tree	مقایسه عملکرد درخت نسبت به الگوریتم‌های خطی
(Gyulai et al., 2018)	پیش بینی زمان انتظار در محیط فروشگاهی بر اساس ویژگی‌هایی از محصول	۷	مبتنی بر درخت	Regression Tree SVR	مقایسه عملکرد جنگل تصادفی نسبت به سایر الگوریتم‌ها
(Lingitz et al., 2018)	پیش بینی زمان انتظار با استفاده از الگوریتم‌های یادگیری ماشین	۴۱	-	LM-Ridge RT-RF- SVM- KNN- ANN	مقایسه عملکرد الگوریتم‌های مختلف یادگیری ماشین
(Baryanis et al., 2019)	پیش بینی ریسک‌های زنجیره تامین	۱۵	آزمون واریانس، درخت	SVM DT-RDT	پیش بینی ریسک
(Brintrup et al., 2020)	پیش بینی سفارشات دیر هنگام در زنجیره تامین	۱۹	طوفان فکری	RF-SVM- Logistic	پیش بینی اختلال در زنجیره
(Schnec kenreith er et al., 2021)	پیش بینی زمان انتظار سفارش	۴۰	آزمون همبستگی	ANN	پیش بینی زمان انتظار داینامیک سفارش
(de Oliveira et al., 2021)	پیش بینی زمان انتظار خرید در زنجیره تامین داروسازی	۸	-	LR SVM-RF KNN-MLP	مقایسه عملکرد ۵ الگوریتم، لحاظ شاخص جغرافیایی
(Welsing et al., 2021b)	ترکیب فرآیند کاوی و یادگیری ماشین در فرآیندهای با واریانس بالا		فرآیند کاوی	DT SVM Naïve Bayes	بالا بردن صحت پیش بینی در فرآیندهای با واریانس بالا
(Steinberg et al., 2023)	پیش بینی تحویل دیر هنگام تامین کننده	۱۲	آزمون همبستگی	LR-SVR- DT RF-AB- GB MLP	پیش بینی تاخیر تحویل
(Bassioni et al., 2024)	تعیین وضعیت سفارشات در زنجیره تامین	۵۲	شبکه عصبی	RT-RF KNN- ANN SVM	تعیین اولویت ریسک، لحاظ شاخص‌های جغرافیایی

دستاورد/ نتایج	الگوریتم	انتخاب ویژگی ^۲	ویژگی	هدف	منابع
برآورد دقیق میزان تاخیر، لحاظ شاخص های اقتصادی	Deep Learning	شبکه عصبی	۲۰	پیش بینی ریسک تاخیر تحویل در زنجیره تامین	(Gabellini <i>et al.</i> , 2024)
پیش بینی تاریخ تحویل	XGB-ANN SVM-RF DT-LR	SHAP ^۱	۴۶	تعیین زمان تحویل سفارش	(Rokoss <i>et al.</i> , 2024)

بررسی ادبیات نشان داد که در برخی از مطالعات از جمله النزی و همکاران (۲۰۰۸)، پفیفیر و همکاران (۲۰۱۶)، لینگیتز و همکاران (۲۰۱۸) و دالیوریا و دیگران (۲۰۲۱) صرفاً به مقایسه عملکرد الگوریتم‌ها بدون انتخاب ویژگی پرداخته شده است. در مطالعات اوزترک و دیگران (۲۰۰۶) و گیولی و دیگران (۲۰۱۸) با لحاظ انتخاب ویژگی‌ها، عملکرد الگوریتم‌های مختلف مقایسه شده است. در پژوهش‌های باریانس و دیگران (۲۰۱۹)، برینترپ و دیگران (۲۰۲۰) و باسیون و دیگران (۲۰۲۴) از طریق الگوریتم‌های کلاسه‌بندی به پیش‌بینی اختلال و ریسک در زنجیره تامین پرداخته شده است. اما فقط در مطالعات دالیوریا و دیگران (۲۰۲۱) و باسیون و دیگران (۲۰۲۴) متغیرهای جغرافیایی در فرآیند لجستیک لحاظ شده‌اند. و صرفاً در پژوهش گابلینی و دیگران (۲۰۲۴) به پیش‌بینی دقیق میزان تاخیر در زنجیره تامین با رویکرد یادگیری عمیق و بر مبنای شاخص‌های اقتصادی پرداخته شده است. همچنین ولسینگ و دیگران (۲۰۲۱) عنوان نموده‌اند که ترکیب فرآیند کاوی و یادگیری ماشین در فرآیندهای با واریانس بالا به بالابردن صحت پیش‌بینی مدل منجر می‌گردد.

روش

این پژوهش از منظر هدف، کاربردی و از منظر نحوه گردآوری داده‌ها، توصیفی بوده که نتایج آن به جهت بهره‌برداری و تعمیم در اختیار متخصصین قرار می‌گیرد و از منظر داده، کمی است. برای دستیابی به این هدف، در مرحله نخست به مرور ادبیات در خصوص متدهای پیش‌بینی زمان انتظار و استخراج متغیرهای مستقل، پرداخته شده و در این راستا منابع کتابخانه‌ای، مقالات معتبر لاتین موجود و نشریات الکترونیک در بازه (۱۹۹۰-۲۰۲۴) مورد

^۱ Shapley Additive Explanation (SHAP) value

پیش‌بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۱۳

مطالعه و بررسی قرار گرفته (جدول شماره ۲) و متغیرهای پرتکرار موثر بر پیش‌بینی زمان انتظار به شرح جدول شماره ۳ شناسایی گردید.

جدول شماره ۳. شناسایی متغیرهای موثر

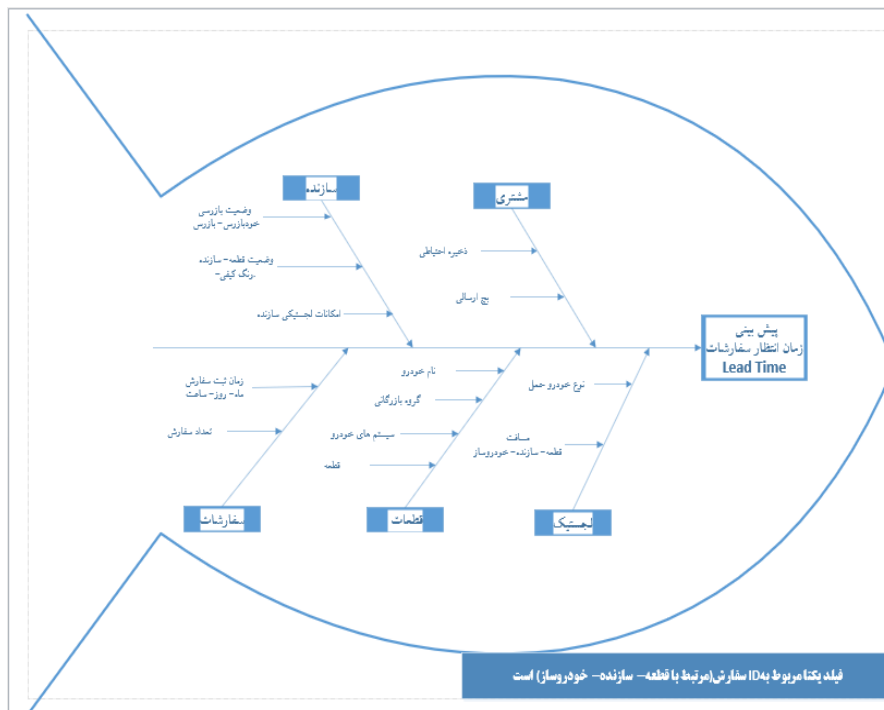
متغیر	گابینی و دیگران (۲۰۲۴)	برگراف و دیگران (۲۰۲۱)	روکوس و دیگران (۲۰۲۴)	پنشینر و دیگران (۲۰۱۶)	التری و دیگران (۲۰۰۸)	ولسیگ و دیگران (۲۰۲۱)	بریترب و دیگران (۲۰۲۰)	باسیونی و دیگران (۲۰۲۴)	لیگیتز و دیگران (۲۰۱۸)	ایوانو و جف (۲۰۱۷)	اوزترک و دیگران (۲۰۰۶)	استینبرگ و دیگران (۲۰۲۳)	دالیوریا و دیگران (۲۰۲۱)	اسچنکرتر و دیگران (۲۰۲۱)	باریانس و دیگران (۲۰۱۹)
تعداد سفارش	✓							✓	✓	✓	✓	✓	✓	✓	✓
شناسه سفارش			✓			✓					✓	✓	✓	✓	✓
قیمت/ سود							✓								
مشتری	✓				✓	✓	✓	✓	✓				✓		
سازنده	✓			✓		✓	✓	✓	✓	✓	✓	✓	✓		✓
موقعیت جغرافیایی								✓					✓		
ظرفیت سازنده				✓	✓				✓	✓	✓			✓	✓
محصول نهایی				✓		✓	✓					✓	✓	✓	
قطعه	✓		✓			✓	✓				✓	✓	✓	✓	✓
گروه تامین						✓	✓						✓		
گروه تکنولوژی	✓										✓			✓	
اپراتور															
وضعیت کیفی			✓		✓							✓			✓
نوع حمل							✓				✓				
زمان سفارش				✓		✓	✓	✓			✓	✓	✓		✓
بج سایز			✓			✓					✓	✓			
ذخیره احتیاطی															
متغیرهای اقتصادی	✓														
زمان انتظار درخواستی			✓			✓						✓			✓

در مرحله بعدی، با استخراج جدول رویداد^۱ و از طریق فرآیند کاوی، واریانت‌های پرتکرار شناسایی گردیده و سپس از طریق برگزاری ۸ جلسه مصاحبه با متخصصین صنعت، برگزاری جلسات طوفان فکری و تحلیل علل اصلی، ۱۸ متغیر تاثیرگذار شناسایی و نمودار استخوان ماهی جهت نمایش نقشه ذهنی (شکل شماره ۱) ترسیم گردیده است. چارچوب این پژوهش

¹ Event Log

بر اساس ساخت مدل‌های پیش‌بینانه مبتنی بر دیتاست جمع‌آوری شده در سطح زنجیره تامین گروه خودروسازی سایپا پیاده‌سازی شده و نتایج آن جهت بررسی عوامل موثر و پیش‌بینی زمان انتظار سفارشات در زنجیره تامین ناب قابل استفاده و تعمیم می‌باشد.

شکل ۱: نمودار استخوان‌ماهی عوامل



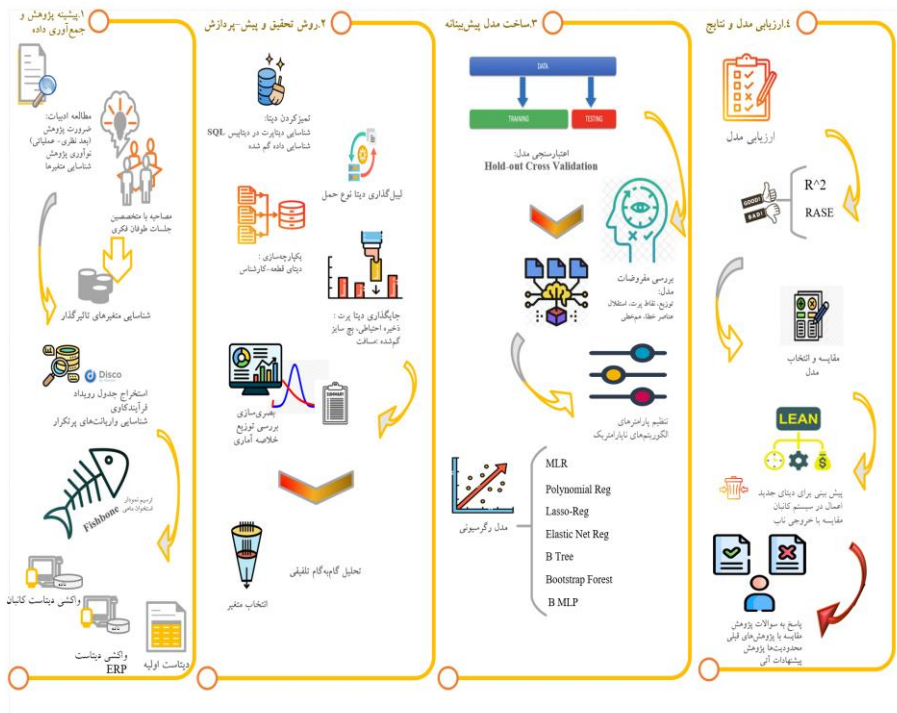
گروه خودروسازی سایپا با ۵ سایت تولیدی و ظرفیت تولید سالانه ۹۵۰ هزار خودرو در حال فعالیت می‌باشد و گستره کاملی از دسته‌بندی محصولات از سواری تا تجاری را پوشش می‌دهد. زنجیره تامین گروه سایپا در چندین لایه تعریف شده است و مدیریت زنجیره تامین توسط شرکت سازه گستر سایپا صورت می‌پذیرد که با بیش از ۱۰۰۰ تامین کننده در کشور در سطوح مختلف همکاری می‌نماید. شرکت سازه گستر سایپا از ابزار کانبان جهت کنترل موجودی و مدیریت زنجیره تامین ناب در سطح گروه بهره گرفته است.

مراحل اجرای پژوهش (شکل شماره ۲) شامل ۴ فرآیند اصلی (۱) بررسی پیشینه پژوهش و جمع‌آوری دیتا (۲) روش تحقیق و پیش پردازش (۳) ساخت مدل پیش‌بینانه (۴) ارزیابی مدل

پیش بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۱۵

و نتایج می باشد (Jayanti and Wasesa, 2022). جهت اجرای این پژوهش و جمع آوری داده از اطلاعات موجود در پایگاه داده سیستم های ERP، کاتبان و اکسترانت زنجیره تامین گروه خودروسازی سایپا با رعایت الزامات شاخص های کیفیت دیتاست (تمامیت، خودسازگاری، بموقع بودن، محرمانگی، صحت، استانداردسازی، بی طرفی، سهولت) استفاده گردیده است (Gong et al., 2023).

شکل ۲: مراحل اجرای پژوهش



جامعه آماری این تحقیق شامل سفارشات ثبت شده در سیستم کاتبان (به تفکیک شماره فنی- سازنده- خودروساز) برای سازندگان دارای صفات مشترک (نظیر وجود قراردادفعال، درصد تخصیص) است. بر همین اساس نمونه آماری شامل دیتای مرتبط به سفارشات ثبت شده کاتبان در بازه ۱۴۰۲/۰۶ لغایت ۱۴۰۲/۱۱ در زنجیره تامین گروه خودروسازی سایپا می باشد. پیش از اقدام به برآزش دیتا، پیش پردازش داده ها به جهت اطمینان از این که دیتای

خام سازگار، تمیز و مفید باشد ضروری است، لذا از تکنیک‌های مختلفی از جمله تمیز کردن داده‌ها (شناسایی داده پرت، داده گم‌شده)، بصری‌سازی، انتخاب متغیرها استفاده شده است. انتخاب ویژگی را می‌توان به عنوان فرآیند شناسایی ویژگی‌های مرتبط و حذف ویژگی‌های غیرمرتبط و تکراری با هدف مشاهده زیرمجموعه‌ای از ویژگی‌ها که مساله را به خوبی و با حداقل کاهش درجه کارآیی تشریح می‌کنند تعریف کرد (Gong et al., 2023). لذا به جهت شناسایی و صحنه‌گذاری متغیرهای موثر علاوه بر بررسی ادبیات موضوع (جدول شماره ۳)، از فرآیند کاوی در نرم‌افزار DISCO و برگزاری جلسات مصاحبه و طوفان فکری، استفاده شده و سپس در مرحله برازش مدل نیز از تحلیل گام به گام تلفیقی^۱ برای انتخاب متغیرهای تاثیرگذار در پیش‌بینی زمان انتظار بهره گرفته شده است. در این پژوهش، به جهت ساخت مدل پیش‌بینانه از رگرسیون استفاده شده است؛ رگرسیون شامل الگوریتم‌هایی از یادگیری با نظارت ماشین می‌شود که مقادیر متغیر وابسته را بر اساس مقادیر متغیرهای مستقل پیش‌بینی می‌کند. اساساً یک معادله ریاضی که متغیر وابسته را به عنوان تابعی از متغیرهای مستقل تعریف می‌نماید (Ifraz et al., 2023; Kumar and Singh, 2022). به منظور پیش‌بینی متغیر پیوسته زمان انتظار سفارشات از الگوریتم‌های رگرسیونی مندرج در جدول ۴ با استفاده از ابزار JMP استفاده شده است.

جدول ۴. مدل رگرسیونی به کارگرفته شده و خصوصیات آن‌ها

نام روش	parametric	Non-Parametric	خطی	غیرخطی
Multiple Linear Regression	✓		✓	
Polynomial Regression	✓			✓
Lasso-Regression	✓		✓	
Elastic Net Regression		✓	✓	
Boosted Tree		✓		✓
Bootstrap Forest		✓		✓
K-Nearest Neighborhood		✓		✓
Boosted Multi-Layer Perceptron		✓		✓

معمول‌ترین شیوه رگرسیون، متد رگرسیون حداقل مربعات چندمتغیره کلاسیک^۱ است. مدل رگرسیون خطی چندگانه به شکل زیر می‌باشد:

¹ Mixed Selection

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_k x_{ki} + \varepsilon_i \quad \text{معادله ۱}$$

به طوری که $y_i \in R$ متغیر وابسته، $x_{11}, \dots, x_{ki} \in R$ مجموعه متغیرهای مستقل، $\beta_0, \beta_1, \dots, \beta_k \in R$ مجموعه پارامترها و $\varepsilon_i \sim N(0, \sigma^2)$ باقیمانده^۱ یا خطا باشد. β_0 عرض از مبدا و β_1 برابر میانگین y وقتی که متغیر X به اندازه یک واحد افزایش داشته باشد، است. با فرض مدل خطی، پارامترهای رگرسیون با استفاده از متد حداقل مربعات برای می‌نیم نمودن خطا به دست می‌آیند (Rahman et al., 2023).

در صورتی که در مدل خطی چندگانه، الگویی غیر معمول و غیر تصادفی در باقیمانده‌ها دیده شود، نسبت به برازش مدل رگرسیونی چندگانه دارای انحنا اقدام خواهیم نمود. در مدل رگرسیون چندگانه دارای انحنا رابطه بین متغیر پیش‌بینی کننده و متغیر هدف به صورت چند جمله‌ای از درجه n (برای متغیرهای X) مدل شده است، اما پارامترهای معادله رگرسیونی همچنان درجه یک می‌باشند. رگرسیون لاسو یک مدل از نوع رگرسیون خطی بر پایه عمل گر انتخاب و انقباض کم‌ترین قدر مطلق است که در آن ضرایب به صورت تنگ تخمین زده می‌شود. این روش بدین دلیل مفید است که تمایل به تعداد محدودتری از متغیرهای مستقل و تخمین مقادیر کوچک‌تر برای ضرائب دارد (Rahman et al., 2023; Tao, 2023). رگرسیون الاستیک‌نت دو مدل رگرسیونی (لاسو و ریج) را با هم ترکیب کرده و معایب آن‌ها را حذف نموده و جایگزین مطمئنی برای آن‌هاست.

درخت تصمیم تقویت گرادیان یک مدل یادگیری اثر کلی بر پایه درخت تصمیم است. گرادیان تقویتی با یک حدس از پاسخ شروع می‌شود سپس گرادیان محاسبه شده و یک مدل برازش می‌شود که در آن تابع هزینه می‌نیم گردد. مدل جاری بر پایه یک پارامتر نرخ یادگیری^۱ به مدل قبلی اضافه خواهد شد. جنگل تصادفی یک تکنیک اثر کلی است که چندین درخت تصمیم را شامل می‌شود، انتخاب تصادفی هر معیار به عنوان گره منجر به دستیابی به تنوع در ساخت مدل می‌شود و متغیرها به صورت تصادفی انتخاب خواهند شد نه بر اساس سودمندترین متغیر. این روش از یک استراتژی به عنوان کیسه‌بندی^۲ استفاده کرده که درخت‌های زیاد و عمیقی به یکدیگر متصل خواهند شد. جنگل تصادفی متد درخت تصادفی را m بار از طریق بردار مقادیر ورودی تکرار و سپس میانگین مقادیر نتایج به عنوان مقدار پیش‌بینی شده در نظر گرفته می‌شود. مشخصه و مزیت اصلی این رویکرد استفاده از

¹ Residual

² Bagging

شاخص جینی^۱ به عنوان معیار انتخاب ویژگی و اعتبارسنجی داخلی است که شامل رتبه‌بندی متغیرهای مستقل می‌گردد (Kumar and Singh, 2022; Tao, 2023).

الگوریتم k-نزدیک‌ترین همسایه به دلیل معیارهای ساده و قابلیت پیش‌بینی آن برای الگوهای پیچیده غیرخطی بکار گرفته می‌شود. این پیش‌بینی به واسطه تعیین نقاط مشابه بین نقاط داده در فضای ویژه ارائه می‌گردد. در این روش از تابع فاصله اقلیدسی^۲ و تنظیم کردن^۳ پارامتر (K) استفاده می‌شود (Shapi et al., 2021; Singh and Soni, 2019).

شبکه‌های عصبی، ساختارهای شبکه‌ای بسیار سازمان‌یافته هستند که لایه‌های آن برطبق سیستم عصبی در مغز انسان قرار گرفته‌اند. شبکه عصبی شامل ۳ لایه ورودی، پنهان و خروجی می‌شود. نرون‌های ورودی ابتدا اطلاعات و ویژگی‌های ورودی را دریافت و سپس به نرون‌های لایه پنهان ارسال می‌نمایند، لایه پنهان این داده‌ها را با توابع فعال‌سازی پردازش کرده و نتایج را به لایه پنهان بعدی ارسال می‌کند و این مراحل ادامه می‌یابد تا داده‌ها به نرون‌های لایه خروجی برسند. شبکه به وسیله تنظیم وزن و بایاس بین لایه‌ها آموزش داده شده و خطا تنظیم گردیده و خروجی‌های مرتبط با ورودی‌ها تولید می‌شود، مجموعه این فرآیند پیش‌انتشار^۴ نامیده می‌شود. مهم‌ترین ویژگی شبکه عصبی قابلیت آن در ساخت مدل غیرخطی، توانایی در یادگیری و تعمیم‌دهی و تاب‌آوری خطا است (Ifraz et al., 2023).

در مرحله ارزیابی مدل، یافتن مدلی با بهترین ویژگی‌ها که قابلیت تعمیم اطلاعات را داشته باشند، مسئله‌ای مهم است و کار چالش‌برانگیز که بتواند دقت پیش‌بینی رضایت‌بخشی را ایجاد کند. در این پژوهش ارزیابی و اعتبارسنجی^۵، معیارهای اصلی برای ارزیابی توان پیش‌بینی مدل محسوب می‌شوند. هدف از انتخاب مدل، تعیین سطح مناسبی از بایاس و واریانس^۶ برای دستیابی به دقت بالاتر و جلوگیری از بیش‌برازش یا کم‌برازش^۷ است. دقت یک معیار بسیار مهم است، اما برای ارزیابی مدل کافی نیست؛ بنابراین هنگام ارزیابی مدل از شاخص‌های خطا و دقت به صورت توأم استفاده شده است. پس از برازش هر مدل به جهت ارزیابی، مقدار پیش‌بینی شده توسط الگوریتم با مقدار واقعی آن در مجموعه دیتای

¹ Gini Index

² Euclidean distance function

³ tune

⁴ forward propagation

⁵ Evaluation & Validation

⁶ Bias & Variance

⁷ Overfitting & Underfitting

پیش‌بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۱۹

تست مورد مقایسه قرار گرفته (اعتبارسنجی نتایج) و خطای آن با معیارهای مرتبط مقایسه شده است.

لذا در این پژوهش از معیارهای R^2 ، RASE برای ارزیابی مدل استفاده شده است.

R^2 : ضریب تعیین یا همان مربع ضریب همبستگی است.

$$R^2 = \frac{SS_{\text{model}}}{SS_{\text{Total}}} = 1 - \frac{SS_{\text{Error}}}{SS_{\text{Total}}} \quad \text{معادله ۲}$$

در تشریح رابطه مذکور، تغییرپذیری کل در متغیر پاسخ (SS_{Total}) به دو بخش تقسیم می‌شود: SS_{model} تغییرپذیری که توسط مدل رگرسیونی توضیح داده شده و SS_{Error} تغییرپذیری که توسط مدل توضیح داده نشده است. در حالت کلی هر چه مقدار ضریب R^2 به یک نزدیک‌تر باشد، تغییرپذیری که مدل تشریح نموده است بیشتر خواهد بود. RASE: ریشه میانگین مربعات خطاست.

$$\text{RASE} = \sqrt{\frac{\text{SSE}}{n}} \quad \text{معادله ۳}$$

در خصوص چند مدل با ضرایب تعیین و ضرایب تعیین اصلاح شده تقریباً یکسان، مدلی انتخاب خواهد شد که RASE کوچک‌تری داشته باشد.

برای اعتبارسنجی مدل نیز از رویکرد hold-out Cross-validation و تقسیم دیتا به دو بخش آموزش (۷۵٪) و تست (۲۵٪) بهره گرفته شده است.

یافته‌ها

دیتاست اولیه به شرح جدول شماره ۵ می‌باشد. پس از مرحله حذف وضعیت‌های ابطال و منقضی، تمیز کردن داده‌ها، بررسی نقاط پرت، اصلاح دیتاهای گم‌شده و نادرست، اصلاح فرمت داده، لیبلینگ، تعداد ۱۰۳۰۲۳ رکورد سفارشات احصاء گردیده است که نمایش بصری دیتا در شکل شماره ۳ نمایش داده شده است.

جدول شماره ۵: دیتاست اولیه

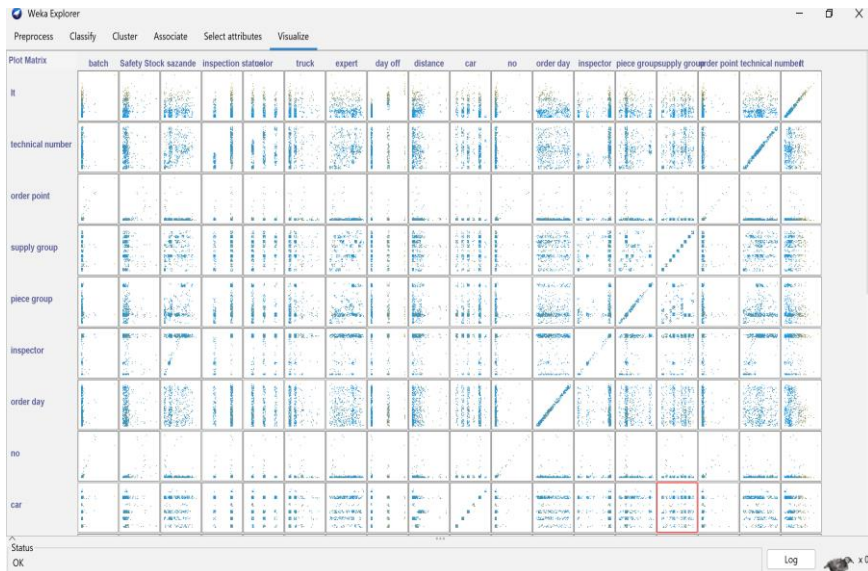
زنجیره تامین گروه خودروسازی سایپا		
بازه جمع آوری دیتا: ۱۴۰۲/۶ لغایت ۱۴۰۲/۱۱	تعداد رکورد: ۱۰۸۴۹۵	
مشتری	۵ کلاس	شامل ۵ خودروساز
تامین‌کننده	۳۳۱ کلاس	تامین‌کننده قطعه

¹ Coefficient of Determination

² Root Average Squared Error

زنجیره تامین گروه خودروسازی سایپا		
تعداد رکورد: ۱۰۸۴۹۵	بازه جمع آوری دیتا: ۱۴۰۲/۶ لغایت ۱۴۰۲/۱۱	
خودروی تولیدی	۶ کلاس	خودرو
شماره فنی قطعه	۲۷۰۲ کلاس	قطعه
دسته‌بندی گروه‌های تامین	۹ کلاس	گروه تامین
تکنولوژی ساخت	۵۶ کلاس	گروه تکنولوژی
تخصیص شماره فنی به کارشناس	۱۲۹ کلاس	قطعه- کارشناس
خودبازرس- بازرس مقیم	۲ کلاس	وضعیت بازرسی
بازرس همکار	۱۶۸ بازرس	بازرس
وضعیت کیفی سازنده	۳ کلاس	رنگ کیفی
نوع خودرو حمل	۱۲ کلاس	نوع حمل
زمان پذیرش سفارش (ماه- روز)	۱۳۹ کلاس	تاریخ صدور کانبان
به تفکیک قطعه-سازنده- محل تحویل		مسافت
تعداد چیدمان در هر پالت		بیج سایز
ذخیره احتیاطی به ساعت		ذخیره احتیاطی
روز تعطیل در بازه سفارش تا رسیدمحموله		تعداد روز تعطیل
تعداد رسید شده		تعداد رسید شده
		زمان انتظار
		متغیر هدف

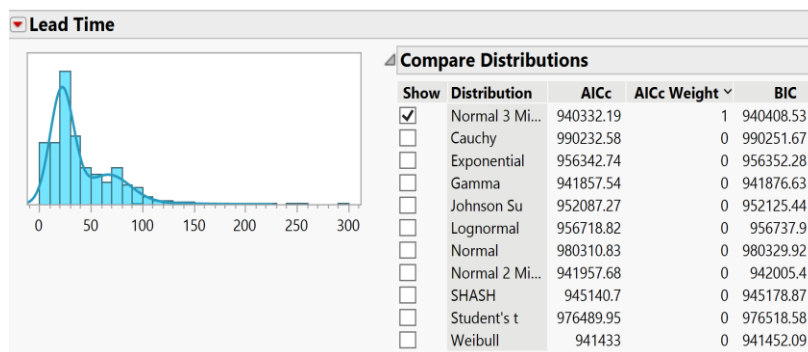
شکل ۳: بصری سازی



پیش بینی زمان انتظار سفارشات قطعات خودرو در زنجیره تامین با استفاده از یادگیر...؛ زمانی و همکاران | ۲۱

سپس در پژوهش به بررسی توزیع و خلاصه آماری متغیر هدف، پرداخته شده است (شکل شماره ۳ و ۴). همان طور که نمایش داده شده، متغیر هدف دارای توزیع نرمال ۳ متغیره بوده و چولگی به سمت راست دارد.

شکل ۴: نمایش توزیع متغیر هدف



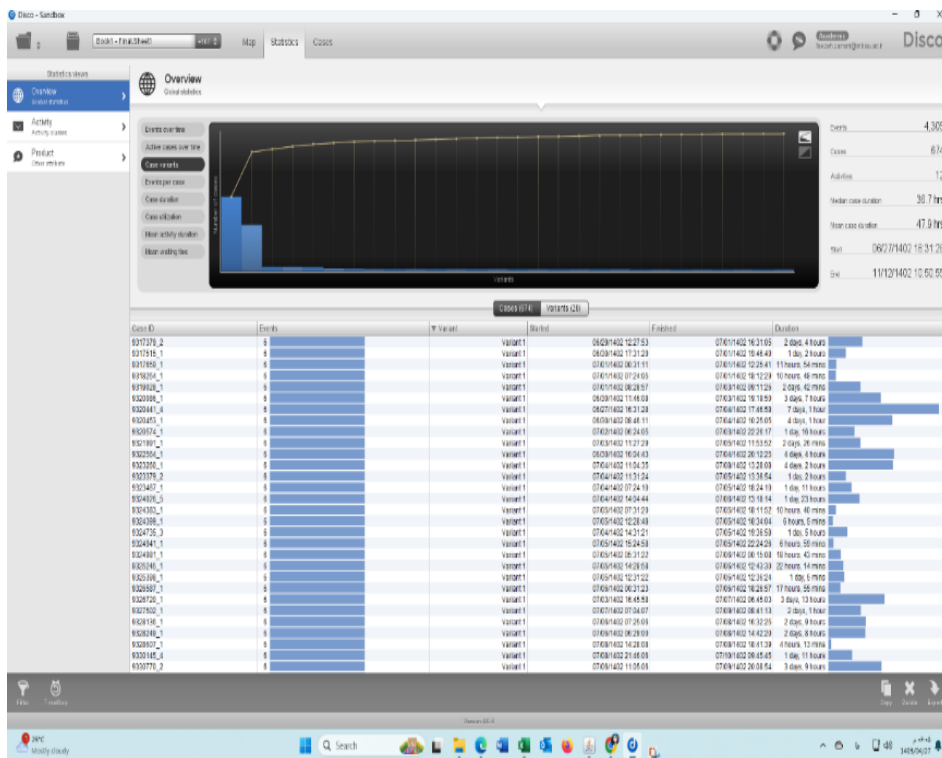
شکل ۵: خلاصه آماری

Quantiles			Summary Statistics	
100.0%	maximum	297	Mean	38.144987
99.5%		135	Std Dev	28.184578
97.5%		103	Std Err Mean	0.0878101
90.0%		80	Upper 95% Mean	38.317094
75.0%	quartile	53	Lower 95% Mean	37.97288
50.0%	median	29	N	103023
25.0%	quartile	20	N Missing	0
10.0%		8		
2.5%		3		
0.5%		2		
0.0%	minimum	1		

در ادامه جهت شناسایی و صحه گذاری متغیرهای موثر علاوه بر بررسی سوابق پژوهش (جدول شماره ۳) و برگزاری جلسات طوفان فکری با متخصصین صنعت، از فرآیند کاوی با استفاده از فیلترهای مبتنی بر فعالیت و مسیرها در نرم افزار DISCO استفاده شده است و واریانت های دارای بیشترین تکرار استخراج که در شکل شماره ۶ نمایش داده شده است. در مرحله بعد، در فاز برازش مدل رگرسیونی از طریق تحلیل گام به گام تلفیقی که به صورت همزمان از رویکردهای روبه جلو و روبه عقب بهره می گیرد برای شناسایی متغیرهایی که

دارای بالاترین سطح تاثیر گذاری در متغیر هدف می باشند بهره گرفته شده است. سپس متغیرها بر اساس معیارهای ارزش^۱ و (P-Value<0.05) رتبه بندی شده اند (شکل ۷ شماره).

شکل ۶: فرآیندکاوای جهت شناسایی فرآیندهای دارای واریانت بالا



شکل ۷: تحلیل گام به گام تلفیقی جهت انتخاب متغیر

Source	Logworth	PValue
تعداد روز تعطیل	38661.08	0.00000
تاریخ صدور کابینان	16455.54	0.00000
نام سازنده	7486.315	0.00000
کارشناس قطعه	3862.779	0.00000
نام خودرو	1500.609	0.00000
مسافت	416.142	0.00000
Safety Stock	310.485	0.00000
خودروی حمل	181.922	0.00000
وضعیت بازرسی	30.251	0.00000
رنگ کیفی	20.060	0.00000

¹ Logworth

سپس، برازش مدل‌های رگرسیونی مطابق با متدهای مذکور (جدول شماره ۴) صورت پذیرفته است. لازم به ذکر است جهت برازش مدل رگرسیونی خطی چند متغیره و مدل رگرسیونی دارای انحنا ابتدا مفروضات مرتبط با مدل رگرسیونی شامل: (۱) فرض مناسب و واقعی بودن رابطه خطی، (۲) فرض برابری واریانس خطا، (۳) فرض نرمال بودن عناصر خطا از طریق آزمون اندرسون-دارلینگ^۱، (۴) فرض وجود استقلال یا عدم همبستگی عناصر خطا از طریق آزمون دوربین-واتسون^۲، (۵) فرض وجود نقاط پرت و نقاط پرت بالقوه از طریق آماره Cook's D و (۶) فرض هم خطی^۳ یا همبستگی متغیرهای مستقل از طریق فاکتور تورم واریانس^۴ به تفکیک مورد بررسی و تحلیل قرار گرفته است. در ادامه از رویکردهای رگرسیونی لاسو، الاستیک نت (بر پایه جریمه) در محاسبه ضرایب مدل‌های رگرسیونی چندگانه برای حل مسائل هم خطی استفاده شده است. همچنین به جهت بهینه‌سازی مقادیر عددی پارامترها در رویکردهای رگرسیونی ناپارامتریک از مقادیر و روش‌های بهینه‌سازی مندرج در جدول شماره ۶ استفاده شده است.

جدول شماره ۶: بهینه‌سازی پارامترهای الگوریتم رگرسیون

الگوریتم	پارامتر	بهینه‌سازی
Lasso-Regression	Response Distribution= Normal Number of Grid points=150 Min Penalty Fraction=0.0001 Grid Scale=Square Root Initial Displayed Solution=Best Fit	Solution Path Chart Lambda Penalty=0.66
Elastic Net Regression	Response Distribution= Normal Elastic Net Alpha=0.99 Number of Grid points=150 Min Penalty Fraction=0.0001 Grid Scale=Square Root Initial Displayed Solution=Best Fit	Solution Path Chart Lambda Penalty=0.67
Boosted Tree	Number of Layers= 1000 Splits per Tree=19 Learning Rate=0.255 Min Size Split=10 Random Seed=1234	Cumulative Validation Chart (RSquare Validation-Number of Layers) Number of Layers= 1000
Bootstrap Forest	Number of Trees in the Forest=1000 Number of Terms Sampled per Split=7 Bootstrap Sample Rate=1 Min Splits per Tree=10 Max Splits per Tree=2000	Cumulative Validation Chart (RSquare Validation-Number of Layers)

¹ Anderson-Darling

² Durbin-Watson

³ Multicollinearity

⁴ Variance Inflation Factor (VIF)

الگوریتم	پارامتر	بهینه‌سازی
	Min size Split=103 Random Seed=1234	
K-Nearest Neighbor	$1 \leq K \leq K_{\max} = 320$ $K_{\max} = \sqrt{N} = 320$ Random Seed=1234	Model Selection Chart (RASE-K) K=5
Boosted Multi-Layer Perceptron	Hidden Layers=1 First (TanH=3, Linear=1, Guassian=1) Number of Models=60 Learning Rate=0.1	Try and Error

پس از برازش مدل‌های رگرسیونی با استفاده از داده‌های آموزشی نسبت به پیش‌بینی زمان انتظار سفارشات برای هر ردیف سفارشات در بخش داده‌های تست و مقایسه آن با مقادیر واقعی زمان انتظار بهره گرفته شده، سپس برای شناسایی بهترین مدل از شاخص‌های R^2 ، RASE و رویکرد مقایسه مدل^۱ (جدول شماره ۷ و شکل ۸) استفاده شده است.

جدول ۷. مقایسه شاخص‌های مدل رگرسیونی دیتای تست

نام روش	R^2	RASE
Multiple Linear Regression	۰/۹۵	۶/۲۱
Multiple Linear Regression (with Interaction)	۰/۹۵	۶/۲۱
Lasso-Regression	۰/۹۵	۶/۳۰
Elastic Net Regression	۰/۹۵	۷/۰۰
Boosted Tree	۰/۹۵	۶/۱۲
Bootstrap Forest	۰/۹۵	۶/۳۴
K-Nearest Neighborhood	۰/۸۸	۹/۶۶
Boosted Multi-Layer Perceptron	۰/۹۶	۵/۸۴

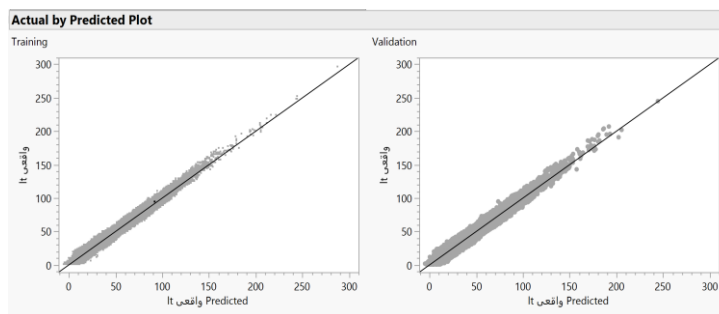
¹ Model Comparison

شکل ۸. رویکرد مقایسه مدل در بخش دیتای تست از نرم افزار JMP

Model Comparison Validation=1									
Predictors									
Target	Predictors								
واقعی It	Pred Formula It	واقعی (LS-total)	Fit Least Squares						
	Pred Formula It	واقعی (LS.Cross-total)	Fit Least Squares						
	It	واقعی Prediction Formula(Lasso-total)	Fit Generalized Lasso						
	It	واقعی Prediction Formula(Elastic-total)	Fit Generalized Elastic Net						
	It	واقعی Predictor(BTree-total)	Boosted Tree						
	It	واقعی Predicted(BF-total)	Bootstrap Forest						
	Predicted It 5	واقعی (KNN=5-total)	K Nearest Neighbors						
	Predicted It	واقعی (Boosting-MLP-total)	Neural						
Measures of Fit for It واقعی									
Predictor	Creator	.2	.4	.6	.8	RSquare	RASE	AAE	Freq
Predicted It واقعی (Boosting-MLP-total)	Neural					0.9559	5.8448	4.8934	25518
It واقعی Predictor(BTree-total)	Boosted Tree					0.9517	6.1163	4.7521	25518
Pred Formula It واقعی (LS.Cross-total)	Fit Least Squares					0.9503	6.2068	5.2858	25518
Pred Formula It واقعی (LS-total)	Fit Least Squares					0.9502	6.2097	5.3015	25518
It واقعی Prediction Formula(Lasso-total)	Fit Generalized Lasso					0.9487	6.3018	5.3540	25518
It واقعی Predicted(BF-total)	Bootstrap Forest					0.9480	6.3432	5.0195	25518
It واقعی Prediction Formula(Elastic-total)	Fit Generalized Elastic Net					0.9366	7.0046	5.8107	25518
Predicted It 5 واقعی (KNN=5-total)	K Nearest Neighbors					0.8794	9.6643	6.9730	25518

نتایج مقایسه‌ای جدول ۷ و شکل شماره ۸ نشان می‌دهد که الگوریتم رگرسیونی شبکه عصبی تقویتی با یک لایه پنهان و پنج تابع فعال‌سازی (مندرج در جدول شماره ۶) و نرخ یادگیری (۰/۱) دارای ۶۰ تکرار، بالاترین دقت پیش‌بینی را با ۹۶٪ و کم‌ترین ریشه میانگین مربعات خطا را با ۵/۸۴ نسبت به سایر مدل‌های برآزش شده داراست؛ بنابراین مدل رگرسیونی برآزش شده در شکل شماره ۹، به عنوان مدل منتخب در این پژوهش می‌باشد که علاوه بر دقت بالاتر نسبت به مدل‌های دیگر، از نظر معیار خطا جایگاه بالاتری نسبت به سایر مدل‌ها دارد. لازم به ذکر است که پارامترهای این مدل پیش‌بینانه از طریق سعی و خطا بهینه‌سازی گردیده است.

شکل ۹. مدل رگرسیونی برآزش شده از طریق شبکه عصبی تقویتی



سپس از طریق به کارگیری قابلیت پیش‌بینی مدل برای صدور سفارشات جدید، نتایج به دست آمده توسعه یافته و بدین ترتیب عملکرد روش پیشنهادی در بازه چهار ماهه مورد ارزیابی

قرار گرفته است. بهبودهای حاصل (جدول شماره ۸)، همگی بیان گر تاثیر معنی دار ترکیب رویکرد ناب و ابزار یادگیری ماشین به جهت توانمندسازی زنجیره تامین ناب در سطح گروه خودرو سازی می باشد.

جدول ۸: کاهش اتلاف ها ناشی از ترکیب به کار گیری ناب و داده کاوی

اتلاف	شرح دستاورد	درصد بهبود	ارزش ریالی (میلیارد ریال)
زمان	کاهش میانگین LT	۳۵	-
	کاهش توقفات خط	۱۹	-
سرمایه در گردش	کاهش ارزش موجودی قطعات	۴۹	۱۸۱
	فضای اشغال شده در انبارها	۳۹	۸
هزینه لجستیک	تعداد پالت در گردش	۶۱	۳
	هزینه ساخت پالت جدید	۱۰۰	۲۵
هزینه موجودی	کاهش سطح ذخیره احتیاطی	۲۸	۴۱۰
	کاهش ابطال	۱۴/۱	-
ریسک تامین	کاهش انقضاء	۱۳/۲۶	-

بحث و نتیجه گیری

هدف این پژوهش شناسایی و غربال کردن عوامل موثر، تعیین رابطه بین متغیرهای تاثیر گذار و ایجاد مدل پیش بینانه زمان انتظار سفارشات کابنان به منظور بهبود پایداری و تاب آوری در زنجیره تامین ناب می باشد. در خصوص پاسخگویی به سوال اول پژوهش، نتایج به دست آمده نشان می دهد که متغیرهای مستقل شناسایی شده مرتبط با عوامل مشتری (ذخیره احتیاطی)، عوامل سازنده (وضعیت بازرسی، رنگ کیفیت)، عوامل لجستیکی (خودروی حمل، مسافت)، عوامل قطعه (نام خودرو، کارشناس قطعه) و عوامل سفارش (تعداد روز تعطیل، تاریخ صدور کابنان) بر زمان انتظار سفارشات موثر می باشند. در پاسخ به سوال دوم، پس از بررسی مفروضات، انتخاب متغیرهای تاثیر گذار، بهینه سازی پارامترهای مدل، برازش مدل های رگرسیونی، نتایج مدل برازش شده به تفصیل مورد بررسی قرار گرفته و مدل رگرسیونی شبکه عصبی تقویتی به عنوان مدل منتخب در این پژوهش بالاترین میزان دقت پیش بینی ۹۶٪ و کم ترین ریشه میانگین مربعات خطا ۵/۸۴ را دارا می باشد. در پاسخ به سوال سوم، بهبودهای حاصل از به کار گیری قابلیت پیش بینی مدل برای صدور سفارشات جدید کابنان (جدول شماره ۸)، همگی بیان گر تاثیر معنی دار ترکیب رویکرد ناب و ابزار یادگیری ماشین

به جهت توانمندسازی زنجیره تامین ناب در سطح گروه خودروسازی می‌باشد. این مسئله همچنین تایید کننده یافته‌های سایر مقالات پژوهشی در خصوص رابطه معنی‌دار بین تکنولوژی صنعتی ۴,۰ (ساخت مدل‌های پیش‌بینانه) و تکنیک‌های تولید ناب برای انجام محاسبات کانبان به منظور کاهش اتلاف‌ها می‌باشد (Alsadi *et al.*, 2022; Dillinger *et al.*, 2022; Elafri *et al.*, 2022; Garcia-Buendia *et al.*, 2021; Maware and Parsley, 2023; Pozzi *et al.*, 2022)

بنابر یافته‌های این پژوهش، ادعای ولسینگ و همکاران (۲۰۲۱) در خصوص قابلیت فرآیند کاوی در شناسایی متغیرهای پرتکرار واریانت‌های اصلی به منظور بالابردن صحت پیش‌بینی داده کاوی، مورد تایید قرار گرفته است (Welsing *et al.*, 2021). همچنین استفاده از مدل‌های یادگیری ماشین به عنوان یک ابزار پشتیبان تصمیم‌سازی، برای غلبه بر محدودیت‌های تولید ناب و تقویت عملکرد زنجیره تامین ناب قابل تعمیم و توسعه می‌باشد و مدیران ارشد این امکان را دارند که تاب‌آوری و پایداری زنجیره تامین ناب را بهبود بخشیده و ریسک تامین را به حداقل رسانند. همچنین دانشگاهیان می‌توانند با بهره‌گیری از یکپارچگی فرآیند کاوی و داده کاوی و ترکیب ابزارهای ناب با یادگیری ماشین، تعمیم‌پذیری این مدل پیش‌بینانه را مورد آزمایش و اعتبارسنجی قرار دهند. در حالی که این پژوهش بینش‌های ارزشمندی در زنجیره تامین ناب ارائه می‌کند، با محدودیت‌هایی نیز مواجه بوده است از جمله: نبود دیتا در خصوص برخی متغیرهای تاثیرگذار شناسایی شده در بخش ادبیات، موانع در جمع‌آوری اطلاعات در سطح زنجیره تامین، وجود داده‌های پرت، دیتاهای گم‌شده و احتیاط در تعمیم یافته‌ها از جمله محدودیت‌های این پژوهش می‌باشد. در اجرای این روش تحقیق، پیشنهاداتی برای تحقیقات آتی وجود دارد که عبارتند از: اول، با جمع‌آوری و بررسی سایر عوامل از جمله ظرفیت تولید و تعداد شیفت سازنده، شرایط جوی و مکانی منطبق بر طول و عرض جغرافیایی و با گسترش مدل‌های یادگیری ماشین از جمله یادگیری عمیق می‌توان به نتایج مطمئن‌تر و دقیق‌تری دست یافت. دوم، براساس سطوح مشخص شده عوامل، روابط بین متغیرهای تاثیرگذار مستقل و متغیر هدف و مدل‌های رگرسیونی برازش شده، از طریق طراحی آزمایش^۱ و با استفاده از قابلیت‌های پروفایلر^۲ نسبت به تحلیل‌های تجویزی^۳ در حوزه بهینه‌سازی زمان انتظار

¹ Design of Experiment

² Profiler

³ Prescriptive Analysis

سفارشات اقدام گردد. سوم، به منظور شناسایی بهترین مدل پیش‌بینانه از مقایسه مدل برازش شده با رویکرد فرآیند کاوی با سایر رویکردهای متداول انتخاب متغیر استفاده گردد.




تعارض منافع

این پژوهش فاقد تعارض منافع است.

سپاسگزاری

مقاله حاضر مستخرج از پایان‌نامه دکتری مدیریت صنعتی بوده و در این جا فرصت را مغتنم شمرده تا از داوران محترم دانشکده و همچنین داوران گرامی مجله مطالعات مدیریت کسب و کار هوشمند که با بیان نظرات ارزشمند خود به هر چه بهتر شدن این پژوهش کمک شایانی نمودند، تشکر و قدردانی گردد.

ORCID

Faezeh Zamani		https://orcid.org/0009-0003-7422-0823
Ahmad Ebrahimi		https://orcid.org/0000-0002-5373-7466
Roya Soltani		https://orcid.org/0000-0002-1473-5337
Babak Farhang Moghadam		https://orcid.org/0000-0002-5120-9037

References

- Alenezi, A., Moses, S.A. and Trafalis, T.B. (2008), "Real-time prediction of order flowtimes using support vector regression", *Computers & Operations Research*, Vol. 35 No. 11, pp. 3489–3503, <https://doi.org/10.1016/j.cor.2007.01.026>
- Alnahhal, M., Ahrens, D. and Salah, B. (2021), "Dynamic Lead-Time Forecasting Using Machine Learning in a Make-to-Order Supply Chain", *Applied Sciences*, Vol. 11 No. 21, <https://doi.org/10.3390/app112110105>
- Alsadi, J., Antony, J., Mezher, T., Jayaraman, R. and Maalouf, M. (2022), "Lean and Industry 4.0: A Bibliometric Analysis, Opportunities for Future Research Directions", *Quality Management Journal*, Taylor and Francis Ltd., <https://doi.org/10.1080/10686967.2022.2144785>
- Baryannis, G., Dani, S. and Antoniou, G. (2019), "Predicting supply chain risks using machine learning: The trade-off between performance and interpretability", *Future Generation Computer Systems*, Vol. 101, pp. 993–1004, <https://doi.org/10.1016/j.future.2019.07.059>
- Bassiouni, M.M., Chakraborty, R.K., Sallam, K.M. and Hussain, O.K. (2024), "Deep learning approaches to identify order status in a complex supply chain", *Expert Systems with Applications*, Vol. 250, p. 123947 <https://doi.org/10.1016/j.eswa.2024.123947>
- Brintrup, A., Pak, J., Ratiney, D., Pearce, T., Wichmann, P., Woodall, P. and McFarlane, D. (2020), "Supply chain data analytics for predicting supplier disruptions: a case study in complex asset manufacturing", *International Journal of Production Research*, Taylor & Francis, Vol. 58 No. 11, pp. 3330–3341, <https://doi.org/10.1080/00207543.2019.1685705>
- Burggräf, P., Wagner, J., Heinbach, B. and Steinberg, F. (2021), "Machine Learning-Based Prediction of Missing Components for Assembly – a Case Study at an Engineer-to-Order Manufacturer", *IEEE Access*, Vol. 9, pp. 105926–105938, DOI:10.1109/ACCESS.2021.3075620
- Dillinger, F., Bergermeier, J. and Reinhart, G. (2022), "Implications of Lean 4.0 Methods on Relevant Target Dimensions: Time, Cost, Quality, Employee Involvement, and Flexibility", *Procedia CIRP*, Vol. 107, Elsevier B.V., pp. 202–208, <https://doi.org/10.1016/j.procir.2022.04.034>

- Elafri, N., Tappert, J., Rose, B. and Yassine, M. (2022), "Lean 4.0: Synergies between Lean Management tools and Industry 4.0 technologies", *IFAC-PapersOnLine*, Vol. 55, Elsevier B.V., pp. 2060–2066, <https://doi.org/10.1016/j.ifacol.2022.10.011>
- ER, C.H. and MOSAWI, T. Al. (2022), "Effects of Big Data Analytics on Sustainable Manufacturing: A Comparative Study Analysis", *Chinese Journal of Urban and Environmental Studies*, World Scientific Publishing Co., Vol. 10 No. 04, p. 2250022, <https://doi.org/10.1142/S2345748122500221>
- Gabellini, M., Civolani, L., Calabrese, F. and Bortolini, M. (2024), "A Deep Learning Approach to Predict Supply Chain Delivery Delay Risk Based on Macroeconomic Indicators: A Case Study in the Automotive Sector", *Applied Sciences (Switzerland)*, Multidisciplinary Digital Publishing Institute (MDPI), Vol. 14 No. 11, <https://doi.org/10.3390/app14114688>
- Garcia-Buendia, N., Moyano-Fuentes, J., Maqueira-Marín, J.M. and Cobo, M.J. (2021), "22 Years of Lean Supply Chain Management: a science mapping-based bibliometric analysis", *International Journal of Production Research*, Taylor and Francis Ltd., <https://doi.org/10.1080/00207543.2020.1794076>
- Gong, Y., Liu, G., Xue, Y., Li, R. and Meng, L. (2023), "A survey on dataset quality in machine learning", *Information and Software Technology*, Vol. 162, p. 107268, doi: <https://doi.org/10.1016/j.infsof.2023.107268>
- Gyulai, D., Pfeiffer, A., Nick, G., Gallina, V., Sihm, W. and Monostori, L. (2018), "Lead time prediction in a flow-shop environment with analytical and machine learning approaches", *IFAC-PapersOnLine*, Vol. 51 No. 11, pp. 1029–1034, doi: <https://doi.org/10.1016/j.ifacol.2018.08.472>
- İfraz, M., Aktepe, A., Ersöz, S. and Çetinyokuş, T. (2023), "Demand forecasting of spare parts with regression and machine learning methods: Application in a bus fleet", *Journal of Engineering Research*, Vol. 11 No. 2, p. 100057, doi: <https://doi.org/10.1016/j.jer.2023.100057>
- Ivanov, A. and Jaff, T. (2017), "Manufacturing Lead Time Reduction and Its Effect on Internal Supply Chain", in Campana, G., Howlett, R.J., Setchi, R. and Cimatti, B. (Eds.), *Sustainable Design and Manufacturing 2017*, Springer International Publishing, Cham, pp. 398–407, DOI:10.1007/978-3-319-57078-5_38
- Jayanti, L.P.S.D. and Wasesa, M. (2022), "Application of Predictive Analytics To Improve The Hiring Process In A Telecommunications Company", *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer Dan Teknologi Informasi*, Universitas Islam Negeri Sultan Syarif Kasim Riau, Vol. 8 No. 1, DOI: <http://dx.doi.org/10.24014/coreit.v8i1.16915>
- Kumar, C. and Singh, B. (2022), "A Comparative Study of Machine Learning Regression Approach on Dental Caries Detection", *Procedia Computer Science*, Vol. 215, pp. 519–528, <https://doi.org/10.1016/j.procs.2022.12.054>

- Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer, A., Sihn, W. and Monostori, L. (2018), "Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer", *Procedia CIRP*, Vol. 72, pp. 1051–1056, <https://doi.org/10.1016/j.procir.2018.03.148>
- Maware, C. and Parsley, D.M. (2023), "Can Industry 4.0 Assist Lean Manufacturing in Attaining Sustainability over Time? Evidence from the US Organizations", *Sustainability (Switzerland)*, MDPI, Vol. 15 No. 3, <https://doi.org/10.3390/su15031962>
- Mohamed-Iliasse, M., Loubna, B. and Abdelaziz, B. (2022), "Machine Learning in Supply Chain Management: A Systematic Literature Review", *International Journal of Supply and Operations Management*, Kharazmi University, Vol. 9 No. 4, pp. 398–416, DOI:10.22034/ijssom.2021.109189.2279
- de Oliveira, M.B., Zucchi, G., Lippi, M., Cordeiro, D.F., da Silva, N.R. and Iori, M. (2021), "Lead Time Forecasting with Machine Learning Techniques for a Pharmaceutical Supply Chain", *International Conference on Enterprise Information Systems, ICEIS - Proceedings*, Vol. 1, Science and Technology Publications, Lda, pp. 634–641, DOI:10.5220/0010434406340641
- Öztürk, A., Kayalığıl, S. and Özdemirel, N.E. (2006), "Manufacturing lead time estimation using data mining", *European Journal of Operational Research*, Vol. 173 No. 2, pp. 683–700, <https://doi.org/10.1016/j.ejor.2005.03.015>
- Pfeiffer, A., Gyulai, D., Kádár, B. and Monostori, L. (2016), "Manufacturing Lead Time Estimation with the Combination of Simulation and Statistical Learning Methods", *Procedia CIRP*, Vol. 41, pp. 75–80, doi: <https://doi.org/10.1016/j.procir.2015.12.018>
- Pozzi, R., Cannas, V.G. and Ciano, M.P. (2022), "Linking data science to lean production: a model to support lean practices", *International Journal of Production Research*, Taylor and Francis Ltd., Vol. 60 No. 22, pp. 6866–6887, <https://doi.org/10.1080/00207543.2021.1946192>
- Qureshi, K.M., Mewada, B.G., Kaur, S. and Qureshi, M.R.N.M. (2023), "Assessing Lean 4.0 for Industry 4.0 Readiness Using PLS-SEM towards Sustainable Manufacturing Supply Chain", *Sustainability (Switzerland)*, MDPI, Vol. 15 No. 5, <https://doi.org/10.3390/su15053950>
- Rahman, Md.S., Ghosh, T., Aurna, N.F., Kaiser, M.S., Anannya, M. and Hosen, A.S.M.S. (2023), "Machine learning and internet of things in industry 4.0: A review", *Measurement: Sensors*, Vol. 28, p. 100822, doi: <https://doi.org/10.1016/j.measen.2023.100822>
- Rokoss, A., Syberg, M., Tomidei, L., Hülsing, C., Deuse, J. and Schmidt, M. (2024), "Case study on delivery time determination using a machine learning approach in small batch production companies", *Journal of Intelligent Manufacturing*, <https://doi.org/10.1007/s10845-023-02290-2>
- Schneckenreither, M., Haeussler, S. and Gerhold, C. (2021), "Order release planning with predictive lead times: a machine learning approach",

- International Journal of Production Research*, Taylor & Francis, Vol. 59 No. 11, pp. 3285–3303, <https://doi.org/10.1080/00207543.2020.1859634>
- Shapi, M.K.M., Ramli, N.A. and Awal, L.J. (2021), "Energy consumption prediction by using machine learning for smart building: Case study in Malaysia", *Developments in the Built Environment*, Vol. 5, p. 100037, <https://doi.org/10.1016/j.dibe.2020.100037>
- Singh, S. and Soni, U. (2019), "Predicting Order Lead Time for Just in Time production system using various Machine Learning Algorithms: A Case Study", *2019 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, pp. 422–425, DOI: [10.1109/CONFLUENCE.2019.8776892](https://doi.org/10.1109/CONFLUENCE.2019.8776892)
- Steinberg, F., Burggräf, P., Wagner, J., Heinbach, B., Saßmannshausen, T. and Brintrup, A. (2023), "A novel machine learning model for predicting late supplier deliveries of low-volume-high-variety products with application in a German machinery industry", *Supply Chain Analytics*, Vol. 1, p. 100003, <https://doi.org/10.1016/j.sca.2023.100003>
- Tao, S. (2023), Predicting BMW Stock Price Based on Linear Regression, LSTM, and Random Forest Regression, *BCP Business & Management EMFRM*, Vol. 2022, DOI: <https://doi.org/10.54691/bcpbm.v38i.3712>
- Welsing, M., Maetschke, J., Thomas, K., Gützlaff, A., Schuh, G. and Meusert, S. (2021), "Combining Process Mining and Machine Learning for Lead Time Prediction in High Variance Processes", in Behrens, B.-A., Brosius, A., Hintze, W., Ihlenfeldt, S. and Wulfsberg, J.P. (Eds.), *Production at the Leading Edge of Technology*, Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 528–537
- Yang, M., Lim, M.K., Qu, Y., Ni, D. and Xiao, Z. (2023), "Supply chain risk management with machine learning technology: A literature review and future research directions", *Computers & Industrial Engineering*, Vol. 175, p. 108859, <https://doi.org/10.1016/j.cie.2022.108859>