



Original Article

Prediction and Monitoring of Ton-Kilometers and Waybill for Detecting Abnormal Behavior

Amirali Eghtesad^{*ID}, Abbas Saghaei^{**ID}, Amir Azizi^{***}

Abstract

The objective of this research is to predict and monitor the ton-kilometers and waybill on the Iran's roads to find abnormal Behavior. In this study, data was collected from monthly observations over a period of 6 years (1395 to 1400) by the Iran Road Maintenance and Transportation Organization, categorized by province. Different machine learning techniques, deep learning, and time series methods were employed to predict ton-kilometers, and the results were monitored for abnormal behavior following an increase in interest rates and taxes. For model implementation, a dataset of 72 records of ton-kilometers and 72 records of issued waybill, collected from 32 provinces over six years of road transportation, was utilized. Initially, four different prediction methods, including random forest, LSTM neural network, ARIMA, and ETS, were extensively examined. The empirical results indicate that the random forest outperforms the other models. this study employs the statistical quality control tool, the z-score, to detect outliers and abnormal behavior in the data. The empirical findings reveal that out of the 32 provinces, three provinces exhibit abnormal behavior, and one of them is attributed to factors other than an increase in interest rates and transportation taxes.

Keywords: Prediction; Statistical Quality Control; Waybill; Ton-Kilometer; Machine Learning; Deep Learning; Monitoring.

How to Cite: Eghtesad, Amirali; Saghaei, Abbas; Azizi, Amir (2023). Prediction and Monitoring of Ton-Kilometers and Waybill for Detecting Abnormal Behavior, *Ind. Manag. Persp.*, 13(4), 249-273 (In Persian).

Received: Sep. 04, 2023; Revised: Oct. 04, 2023; Accepted: Oct. 21, 2023; Published Online: Nov. 15, 2023.

* Master's degree, Department of Industrial Engineering, Technical and Engineering Faculty, Research Science Unit, Islamic Azad University, Tehran, Iran.

** Professor, Department of Industrial Engineering, Technical and Engineering Faculty, Research Science Unit, Islamic Azad University, Tehran, Iran.

Corresponding author. Email: a.saghaei@srbiau.ac.ir

*** Assistant Professor, Department of Industrial Engineering, Technical and Engineering Faculty, Research Science Unit, Islamic Azad University, Tehran, Iran



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/>).



پیش‌بینی و پایش میزان تن - کیلومتر و برنامه حمل‌شده جاده‌ای کشور به‌منظور تشخیص رفتار غیرعادی

امیرعلی اقتصاد*^{1b}، عباس سقایی**^{1d}، امیر عزیزی***

چکیده

جابه‌جایی کالا جزء ضروری و لاینفک فرآیند برنامه‌ریزی توسعه ملی است؛ هدف پژوهش حاضر، پیش‌بینی و پایش میزان تن - کیلومتر و برنامه حمل‌شده کشور به منظور تشخیص رفتار غیرعادی است. در این پژوهش برای گردآوری داده‌ها از مشاهده ماهانه به‌دست‌آمده طی ۶ سال (۱۳۹۵ تا ۱۴۰۰) که توسط «سازمان راهداری و حمل‌ونقل جاده‌ای ایران» به تفکیک هر استان جمع‌آوری شده، استفاده شده است. در این پژوهش تن - کیلومتر با روش‌های مختلف تن - کیلومتر و برنامه پیش‌بینی شده و نتیجه برای یافتن رفتار غیرعادی پس از افزایش نرخ بهره و مالیات کنترل می‌شود. برای پیاده‌سازی مدل، از ۷۲ داده تن - کیلومتر حمل‌شده و ۷۲ برنامه صادرشده که از ۳۲ استان طی شش سال حمل‌ونقل جاده‌ای جمع‌آوری شده است، استفاده شد. چهار روش مختلف پیش‌بینی، یعنی جنگل تصادفی، شبکه عصبی LSTM، ARIMA و ETS به تفصیل بررسی شدند. نتایج تجربی نشان می‌دهد که جنگل تصادفی از سایر مدل‌ها بهتر عمل می‌کند. در این پژوهش از ابزار کنترل کیفیت آماری امتیاز Z برای تشخیص داده‌های پرت و رفتار غیرعادی استفاده شد. نتایج تجربی حاکی از آن است که از ۳۲ استان، ۳ استان دارای رفتار غیرعادی هستند که یکی از آن‌ها به دلیلی غیر از افزایش نرخ بهره و مالیات حمل‌ونقل جاده‌ای است.

کلیدواژه‌ها: پیش‌بینی؛ کنترل کیفیت آماری؛ برنامه جاده‌ای؛ تن - کیلومتر؛ یادگیری ماشین؛ یادگیری عمیق؛ پایش.

استناددهی: اقتصاد، امیرعلی؛ سقایی، عباس؛ عزیزی، امیر (۱۴۰۲). پیش‌بینی و پایش میزان تن - کیلومتر و برنامه حمل‌شده جاده‌ای کشور به‌منظور تشخیص رفتار غیرعادی. *چشم‌انداز مدیریت صنعتی*، ۱۳(۴)، ۲۴۹-۲۷۳.

تاریخ دریافت: ۱۴۰۲/۰۶/۱۳، تاریخ بازنگری: ۱۴۰۲/۰۷/۱۲، تاریخ پذیرش: ۱۴۰۲/۰۷/۲۹، تاریخ اولین انتشار: ۱۴۰۲/۰۸/۲۴.

* کارشناس ارشد، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

** استاد، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

نویسنده مسئول Email: a.saghaei@srbiau.ac.ir

*** استادیار، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.



۱. مقدمه

در جهان امروز، بخش حمل‌ونقل از جمله بخش‌های زیربنایی هر جامعه است که علاوه بر تحت تأثیر قراردادادن فرآیند توسعه اقتصادی، در جریان توسعه دچار تغییر و تحول می‌شود. حمل‌ونقل به معنای جامع آن شامل مدیریت زیربنا، روبنا (ناوگان) از نیازهای اساسی جوامع امروزی است؛ به طوری که در هر کشوری برای اعتلای توان اقتصادی، فرهنگی و امنیتی و سیاسی، داشتن شبکه حمل‌ونقل گسترده و قابل اطمینان از نیازهای اولیه محسوب می‌شود. حتی برخی معتقدند که حمل‌ونقل از ابزارهای ابتدایی توسعه است.

در مناطقی که زیرساخت‌های حمل‌ونقل مناسب‌تر و کارآمدتری در مواجهه با نیازهای جابه‌جایی دسترسی به بازارها و منابع دارند، فرصت‌های اجتماعی و اقتصادی بیشتر به وجود می‌آید؛ بنابراین توسعه حمل‌ونقل منطقه‌ای، ملی و بین‌المللی به شهرنشینی، یکپارچگی اقتصادی و جهانی‌سازی کمک می‌کند. از سوی دیگر سیستم حمل‌ونقل جاده‌ای امروزه سهم زیادی از حمل‌ونقل کالاها در بیشتر کشورهای جهان را به خود اختصاص داده که نشان‌دهنده اهمیت بالای حمل‌ونقل جاده‌ای است [۵].

از دیدگاه اقتصادی، حمل‌ونقل نقش مهمی در توسعه اقتصادی کشورها دارد [۱۴]. با سرمایه‌گذاری در زیرساخت‌های حمل‌ونقل شهری و خدمات عمومی حمل‌ونقل، الگوی مکان‌یابی واحدهای تولیدی و الگوهای تراکم شهری تغییر می‌کند و در نتیجه کارایی و بازدهی نیروی کار افزایش خواهد یافت؛ بنابراین بهبود و تسهیل خدمات حمل‌ونقل به کاهش هزینه‌های جابه‌جایی، افزایش تقسیم‌کار جغرافیایی و بالا رفتن حجم مبادلات بین مناطق می‌انجامد [۱۵].

در حال حاضر، روش‌های متعددی برای محاسبه هزینه حمل در شیوه‌های مختلف حمل‌ونقل (جاده‌ای، ریلی، دریایی، هوایی و چندوجهی) وجود دارد. قابلیت دسترسی به اطلاعات حمل بار در شیوه‌های مختلف (به‌عنوان داده موردنیاز پژوهش) متفاوت است که به تفاوت در تعداد پژوهش‌ها در شیوه‌های مختلف حمل منجر شده است. برای مثال، دسترسی به اطلاعات حمل بار دریایی و ریلی نسبت به جاده‌ای با سهولت بیشتری همراه بوده که به تعداد بیشتر مطالعات در حوزه حمل دریایی و ریلی نسبت به جاده‌ای منجر شده است. پیش‌بینی هزینه حمل جاده‌ای به‌عنوان حوزه مطالعاتی این پژوهش، متأثر از عوام متعددی است که بررسی هر یک از این عوامل و تعیین نحوه اثرگذاری آن‌ها بر هزینه حمل موجب رفع ابهامات و حرکت به سوی بهینگی پیش‌بینی هزینه حمل خواهد شد.

کشور ایران به دلیل موقعیت خاص جغرافیایی و راهبردی آن و نیز به لحاظ وجود خطوط مختلف فرعی و اصلی راه‌آهن، ارتباط با آب‌های آزاد و اتصال شرق و غرب، امکانات بالقوه‌ای را برای تمرکز بر روی بخش حمل‌ونقل و افزایش درآمدهای ترانزیتی ناشی از جابه‌جایی بار و مسافر دارد [۱۳].

حمل کالا از یک نقطه به نقطه دیگر به دلیل دوری محل تولید کالا از محل مصرف آن پدید می‌آید که از گذشته‌های بسیار دور وجود داشته است. در سطح کشور، جاده همواره با بیش از ۹۰ درصد از سهم حمل کالا در میان روش‌های مختلف حمل‌ونقل، به‌عنوان عمده‌ترین روش حمل کالا بیان شده است. طی ۵ سال گذشته میزان رشد تعداد سفر کامیون حامل کالا در سطح کشور (با برنامه) بر اساس آمارهای ثبتی معادل ۲۵ درصد بوده است. طول راه‌های تحت حوزه استحفاظی وزارت راه و ترابری (منهای راه‌های روستایی) در سطح کشور تا پایان سال ۱۳۹۹ به ۸,۸۴ هزار کیلومتر رسیده است که ۳ درصد آن آزادراه‌ها، ۲۳ درصد آن بزرگراه‌ها، ۳۰ درصد آن انواع راه‌های اصلی، ۴۴ درصد آن انواع راه‌های فرعی و مابقی راه‌های درون‌شهری با نگهداری اداره راه است. با احتساب راه‌های روستایی که حدود ۱۳۵ هزار کیلومتر است، طول کل راه‌های تحت حوزه استحفاظی «وزارت راه و ترابری» به ۲۲۰ هزار کیلومتر می‌رسد که بیش از ۹۰ درصد از سهم حمل کالا در کشور از این مسیرها صورت می‌گیرد. طی ۵ سال گذشته میزان رشد تعداد سفر کامیون حامل کالا در سطح کشور (با برنامه) بر اساس آمارهای ثبتی معادل ۲۵ درصد و در مدت مشابه برای میزان تُن - کیلومتر حمل‌شده در سطح کشور این رشد به ۸۵ درصد می‌رسد (سالنامه آماری سازمان حمل‌ونقل جاده‌ای، ۱۴۰۰).

در دی‌ماه سال ۱۴۰۰ عوارض صدور هر بارنامه حمل جاده‌ای کالا از ۴ به ۹ درصد افزایش یافت (عوارض جابه‌جایی کالا بر اساس تُن - کیلومتر است)؛ بنابراین گمان می‌رفت که هم در تعداد بارنامه و هم در میزان تُن - کیلومتر حمل‌شده کشور تفاوت چشم‌گیر صورت پذیرد. در این میان نیاز به پیاده‌سازی مدلی برای سنجش این موضوع و پایش میزان تُن - کیلومتر و بارنامه حمل‌شده در استان‌های کشور موردنیاز بود. در پژوهش پیش رو سعی در سنجش و پیش‌بینی میزان تُن - کیلومتر و بارنامه حمل‌شده کشور به کمک مدل‌سازی آماری و همچنین پایش این میزان به کمک ابزارهای کنترل کیفیت آماری شده است. با توجه به گستردگی راه‌ها و سهم بسیار بزرگ حمل‌ونقل جاده‌ای از میزان حمل‌ونقل کالای کشور، تغییر ۵ درصدی تعرفه می‌تواند باعث تغییرات چشم‌گیری در میزان بارنامه و تُن - کیلومتر اعلامی شود که این امر، تأثیر شدید بر میزان درآمد داشته باشد؛ به‌خصوص که اصلی‌ترین درآمد این سازمان از طریق حمل‌ونقل کالا است. برای نمونه هند یکی از پرجمعیت‌ترین کشورهای جهان که دارای خطوط حمل‌ونقل ریلی بسیار گسترده‌ای است و حدود ۷۰ درصد از درآمد خود را از حمل‌ونقل بار به‌دست می‌آورد [۱۹].

۲. مبانی نظری و پیشینه پژوهش

شبکه عصبی حافظه کوتاه‌مدت طولانی^۱. شبکه عصبی حافظه کوتاه‌مدت طولانی نوعی شبکه عصبی بازگشتی است که برای غلبه بر محدودیت شبکه عصبی بازگشتی و حفظ اطلاعات طولانی‌مدت پیشنهاد شده است. این ویژگی عمدتاً بر اساس سلول‌های حافظه در لایه پنهان است. شبکه عصبی حافظه کوتاه‌مدت طولانی معمولاً از لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است.

در این پژوهش از میانگین مربعات خطا برای آموزش شبکه عصبی حافظه‌ی کوتاه‌مدت طولانی استفاده می‌شود. فرآپارامترهای در نظر گرفته شده شبکه عصبی حافظه‌ی کوتاه‌مدت طولانی شامل گره‌های پنهان، لایه‌های پنهان، نرخ یادگیری، اندازه دسته، نرخ خروج، تابع فعال‌سازی، بهینه‌ساز و جریمه هستند.

تابع فعال‌ساز تانژانت هایپربولیک است. مقادیر بررسی شده سایر فرآپارامترها در جدول ۱، ارائه شده است. برای تعیین فرآپارامتر بهینه از سعی و خطا استفاده می‌شود.

با آزمون و خطا، فرآپارامترهای بهینه شبکه عصبی حافظه‌ی کوتاه‌مدت طولانی تعیین می‌شود. توپولوژی شبکه عصبی حافظه‌ی کوتاه‌مدت طولانی از ۴ لایه پنهان و هر لایه شامل ۵ گره تشکیل شده است و ۰/۰۱، ۱۰۰، ۰/۴ و Adam به ترتیب برای نرخ یادگیری، اندازه دسته، نرخ خروج و بهینه‌ساز تنظیم شده‌اند. از آنجاکه الگوریتم‌های Adam الگوریتم‌های Momentum و RMSProp را ترکیب می‌کنند، در این پژوهش از Adam به عنوان بهینه‌ساز استفاده می‌شود [۱۲].

جنگل تصادفی. جنگل تصادفی یک مدل ناپارامتریک و غیرخطی است که نخستین بار توسط هو (۱۹۹۵)، ارائه شد [۸]. این مدل از مشکل بیش از حد برازش اجتناب می‌کند؛ زیرا همیشه همگرا می‌شود. پارامترهای اصلی جنگل تصادفی عبارت‌اند از: تعداد درخت تصمیم؛ حداکثر عمق درخت؛ حداقل تعداد نمونه‌های موردنیاز برای تقسیم یک گره داخلی؛ حداقل تعداد نمونه‌های موردنیاز برای قرارگرفتن در یک گره برگ و تعداد ویژگی‌هایی که باید در هنگام جست‌وجو برای بهترین تقسیم در نظر گرفته شوند. در این پژوهش، فرآپارامترها به کمک سعی و خطا جداگانه تعیین شده و در جدول ۲، آورده شده‌اند. در راستای سعی و خطا و به دست آوردن مقادیر بهینه جنگل تصادفی و شبکه عصبی LSTM از تابع Grid Search کتابخانه Sklearn پایتون استفاده شده است [۲].

1 LSTM

جدول ۱. پارامترهای شبکه عصبی حافظه کوتاه‌مدت طولانی

گره پنهان	۵-۱۰-۱۵-۲۰-۲۵-۳۰
لایه پنهان	۱ و ۲ و ۳ و ... و ۱۰
نرخ یادگیری	۰/۰۰۰۱-۰/۰۰۱-۰/۰۱-۰/۱
اندازه دسته	۵۰-۱۰۰-۲۰۰
نرخ خروج	۰/۵ و ... و ۰/۳ و ۰/۲ و ۰/۱
تابع جریمه	میانگین مربعات خطا
تابع بهینه‌ساز	SGD, RMSprop, Adam

جدول ۲. پارامترهای برآورد شده جنگل تصادفی

مقدار	پارامتر
۵۰۰	N_estimator
۱۳	Max-depht
۲	Min-samples-split
۱	Min-samples-leaf
۲	Random State

میانگین متحرک خودهمبسته یکپارچه^۱. مدل‌های سری زمانی مختلفی وجود دارند که می‌توانند برای تجزیه و تحلیل داده‌ها مورد استفاده قرار گیرند که یکی از آن‌ها میانگین متحرک یکپارچه اتورگرسیو است. دلایل متعددی برای محبوبیت مدل ARIMA وجود دارد؛ از جمله ویژگی‌های آماری آن و همچنین روش شناخته شده باکس - جنکینز^۲ برای ساخت مدل‌ها [۳]. در یک مدل میانگین متحرک یکپارچه اتورگرسیو، مقدار آینده یک متغیر تابعی خطی از چندین مشاهدات گذشته و خطاهای تصادفی فرض می‌شود. فرآیند زیربنایی که سری‌های زمانی را تولید می‌کند در رابطه ۱، آورده شده است.

$$y = \theta_0 + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (۱)$$

در معادله بالا، y_t و ε_t رتیب نشان‌دهنده مقادیر واقعی مشاهدات و خطای تصادفی در زمان t هستند. ϕ_i و θ_j پارامترهای مدل هستند که به ترتیب بخش خودهمبستگی (AR) و میانگین متحرک (MA) را نشان می‌دهند. p و q اعداد صحیح هستند و اغلب به عنوان مرتبه مدل شناخته می‌شوند. ε_t که خطاهای تصادفی مدل فرض می‌شود، به طور مستقل از یکدیگر و با

1. ARIMA
2. Box-Jenkins

میانگین صفر و واریانس ثابت σ^2 توزیع شده‌اند. اگر $q=0$ باشد، رابطه ۱، به یک مدل AR از مرتبه p تبدیل می‌شود و وقتی $p=0$ ، مدل به یک مدل MA از مرتبه q تبدیل می‌شود. یکی از وظایف اصلی مدل ARIMA، تعیین ترتیب مدل مناسب (p, q) است.

روش ETS (خطا، روند، فصلی)^۱. روش ETS رویکردی برای پیش‌بینی سری‌های زمانی تک‌متغیره است. این مدل ETS بر روند و اجزای فصلی تمرکز دارد. خطاها در مدل فضای حالت هموارسازی نمایی^۲ (به‌اختصار ETS) می‌توانند افزایشی^۳ یا ضربی^۴ باشند [۶، ۱۸]. همان‌طور که در جدول ۳، نشان داده شده است، هر روش دارای یک جزء روند و یک جزء فصلی است. هموارسازی نمایی ساده^۵ در سلول NN، درحالی‌که هموارسازی خطی هولت^۶ در سلول AN توصیف شده است. سلول‌های AA و AM به‌ترتیب با روش‌های افزایشی و ضربی هولت وینترز مطابقت دارند. سلول‌های دیگر نشان‌دهنده روش‌های کمترمورد استفاده اما مشابه هستند.

جدول ۳. ترکیب اجزای سری زمانی در یک مدل هموارسازی نمایی

مؤلفه فصلی			مؤلفه روند
M (multiplicative)	A (additive)	N (none)	
NM	NA	NN	N (none)
AM	AA	AN	A (additive)
MM	MA	MN	M (multiplicative)
DM	DA	DN	D (damped)

هیندمن^۷ و همکاران، (۲۰۰۲)، کار آورد^۸ و همکاران، (۱۹۹۷) را گسترش دادند و دو مدل را یکی با خطاهای افزایشی و دیگری با خطاهای ضربی برای هر روش به‌دست آوردند [۱۰، ۱۶]. هر دو مدل پیش‌بینی‌های نقطه‌ای یکسان تولید می‌کنند؛ اما فواصل پیش‌بینی آن‌ها متفاوت خواهد بود. مدل‌های خطای افزایشی برای مؤلفه‌های مختلف روند و فصلی در جدول ۴، نشان داده شده است، جایی که l نشان‌دهنده سطح سری در زمان t ، b_t نشان‌دهنده شیب در زمان t ، s مؤلفه فصلی مجموعه در زمان t و m نشان‌دهنده

1. Error, Trend, Seasonal
2. Exponential Smoothing State Space Model
3. Additive
4. Multiplicative
5. Exponential Smoothing
6. Holt's linear smoothing
7. Hyndman
8. Ord

تعداد فصل در سال و ε_t یک فرآیند نویز سفید گاوسی^۱ (خطا) با میانگین صفر و واریانس ثابت σ^2 است. با جایگزینی ε_t با $\mu_t \varepsilon_t$ در معادلات، می‌توان مدل‌های خطای ضربی را به‌دست آورد.

جدول ۴. تقسیم‌بندی‌های مختلف مدل فضای حالت هموارسازی نمایی (ETS) با فرض جمعی بودن خطا

مؤلفه روند	مؤلفه فصلی		
	N (none)	A (additive)	M $\mu_t = l_{t-1}s_{t-m}$ (multiplicative)
N (none)	$\mu_t = l_{t-1}$ $l_t = l_{t-1} + \alpha\varepsilon_t$	$\mu_t = l_{t-1} + s_{t-m}$ $l_t = l_{t-1} + \alpha\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$l_t = l_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / l_{t-1}$
A (additive)	$\mu_t = l_{t-1} + b_{t-1}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t$	$\mu_t = l_{t-1} + b_{t-1} + s_{t-m}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = (l_{t-1} + b_{t-1})s_{t-m}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / (l_{t-1} + b_{t-1})$
M (multiplicative)	$\mu_t = l_{t-1}b_{t-1}$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t / l_{t-1}$	$\mu_t = l_{t-1}b_{t-1} + s_{t-m}$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t / l_{t-1}$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = (l_{t-1}b_{t-1})s_{t-m}$ $l_t = l_{t-1}b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t / (s_{t-m}l_{t-1})$ $s_t = s_{t-m} + \gamma\varepsilon_t / (l_{t-1}b_{t-1})$
D (damped)	$\mu_t = l_{t-1} + b_{t-1}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \alpha\beta\varepsilon_t$	$\mu_t = l_{t-1} + b_{t-1} + s_{t-m}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \alpha\beta\varepsilon_t$ $s_t = s_{t-m} + \gamma\varepsilon_t$	$\mu_t = (l_{t-1} + b_{t-1})s_{t-m}$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t / s_{t-m}$ $b_t = \phi b_{t-1} + \alpha\beta\varepsilon_t / s_{t-m}$ $s_t = s_{t-m} + \gamma\varepsilon_t / (l_{t-1} + b_{t-1})$

1. Gaussian white noise

امتیاز Z^۱: امتیاز Z یک اندازه‌گیری آماری است که رابطه یک مقدار را با میانگین گروهی از مقادیر توصیف می‌کند. رابطه ۲، فرمول امتیاز Z را نشان می‌دهد که در آن μ مخفف میانگین، σ مخفف انحراف استاندارد و x مخفف مقدار مورد ارزیابی است. مقدار صفر برای امتیاز Z نشان می‌دهد که امتیاز نقطه داده برابر با میانگین است. یک انحراف استاندارد از میانگین با مقدار ۱ برای امتیاز Z نشان داده می‌شود. امتیاز Z مثبت نشان می‌دهد که نمره بالاتر از میانگین است؛ در حالی که امتیاز Z منفی نشان می‌دهد که آن کمتر از میانگین است.

$$z - score = \frac{x - \mu}{\sigma} \quad \text{رابطه (۲)}$$

در این مطالعه برای اینکه بتوان رفتار استان‌ها را رتبه‌بندی، ارزیابی و کنترل کرد، x به‌عنوان مقدار واقعی TKM و تعداد بارنامه، μ به‌عنوان پیش‌بینی نقطه و σ به‌عنوان انحراف استاندارد باقیمانده‌های پیش‌بینی در نظر گرفته می‌شود.

پیشینه پژوهش. ذوقی و علیپور (۱۳۹۱)، پژوهشی با عنوان «مدل افزایش قیمت جابه‌جایی کالا برحسب تَن - کیلومتر در حمل‌ونقل جاده‌ای پس از اجرای طرح هدفمندی یارانه» انجام دادند. آن‌ها کوشیدند عوامل تأثیرگذار در قیمت هزینه حمل کالا بر اساس تَن - کیلومتر را شناسایی کردند. آن‌ها برای این کار از مدل‌سازی آماری بهره گرفتند که داده‌ها شامل ۸۰۰۰۰ بارنامه‌های صادرشده از مبدأ شهرسازی به کل ایران در بازه سال‌های ۱۳۸۶ تا ۱۳۸۹ بود. مدل انتخابی در این پژوهش، مدل رگرسیون خطی چندگانه است. در این پژوهش از معیارهای عرض از مبدأ، تناژ بار، فاصله، نوع محموله، نوع بارگیری (وسیله) و هزینه نگهداری برای سنجش میزان تأثیر در قیمت حمل کالا حسب تَن - کیلومتر استفاده شد. این پژوهش اهمیت عوامل مؤثر بر هزینه حمل بار جاده‌ای را نشان داد و به اهمیت و همبستگی تناژ بار حمل‌شده در قیمت‌گذاری اشاره داشت؛ از این‌رو می‌توان به اهمیت تَن - کیلومتر و تأثیر مستقیم آن بر قیمت حمل کالا پی برد [۲۰].

سگال^۲ و همکاران (۲۰۱۷)، پژوهشی با عنوان «مدل‌های پیش‌بینی ناخالص تَن - کیلومتر برای قطارهای باری راه‌آهن شمال مرکزی هند» انجام دادند. آن‌ها از روش‌های مختلف سری زمانی برای پیش‌بینی تَن - کیلو متر ناخالص (GTKM) به‌دست‌آمده از بارنامه‌های صادره راه‌آهن هند، استفاده کردند. شبکه ریلی هند بیش از ۱۱۵۰۰۰ کیلومتر پراکنده شده است و مسیری بیش از ۶۷۰۰۰ کیلومتر را پوشش می‌دهد و حدود ۸۰۰۰ ایستگاه را که بین ۱۷ منطقه

1. Z-score

2. Sehgal

تقسیم شده است، به هم متصل می‌کند. راه‌آهن هند شامل بیش از ۲۴۵۲۶۷ واگن باری، ۶۶۳۹۲ واگن مسافری و ۱۰۴۹۹ لوکوموتیو (۴۳ بخار، ۵۶۳۳ دیزل و ۴۸۲۳ لوکوموتیو برقی) است. در این پژوهش از چندین روش مدل‌سازی سری زمانی نظیر خودهمبستگی، میانگین متحرک، میانگین متحرک وزنی، نمایی ساده، روش هولت^۱ و روش هلت وینتر^۲ استفاده شده است. در نهایت این پژوهش نشان داد که روش هولت وینتر از میان سایر روش‌ها با کمترین خطا مقادیر آتی تُن - کیلومتر ناخالص را پیش‌بینی می‌کند. این امر با توجه به حجم وسیع راه‌آهن هند و همچنین درآمد ۷۰ درصد راه‌آهن هند از این طریق بسیار حائز اهمیت و کاربردی است. این پژوهش از این نظر که برای نخستین بار به پیش‌بینی تُن - کیلومتر حمل‌شده ریلی می‌پردازد، بسیار حائز اهمیت بوده و نشان‌دهنده این مهم و نقش کلیدی آن بر درآمد دولت هند و توسعه آن است [۱۹].

پاتیل^۳ و همکاران (۲۰۱۵)، پژوهشی با عنوان «برآورد تقاضای حمل‌ونقل در بندر بمبئی با استفاده از مدل‌های رگرسیون و سری زمانی» انجام دادند. پیش‌بینی تقاضای حمل‌ونقل آتی در یک بندر دریایی برای برنامه‌ریزی و توسعه آن مهم است. هند ۱۳ بندر اصلی دارد که ۷۵ درصد از کل حمل‌ونقل بندر دریایی را انجام می‌دهد. در میان ۱۳ بندر بزرگ، بندر بمبئی که در رتبه سوم کشور برای سال ۲۰۱۳-۲۰۱۴ قرار دارد، حدود ۱۱ درصد از کل حمل‌ونقل را در بندر بزرگ دریایی هند انجام می‌دهد. با توجه به موارد گفته‌شده ضرورت انجام پیش‌تقاضای حمل‌ونقل آتی در یک بندر دریایی برای انجام برنامه‌ریزی آتی بیشتر از قبل به چشم می‌آید. در این مطالعه از روشی ترکیبی از رگرسیون خطی به همراه سری زمانی استفاده شده که در نوع خود جالب است. خطای به‌دست‌آمده از این روش نشان می‌دهد ترکیب این دو روش می‌تواند نتایج بهتری را به همراه داشته باشد. در این پژوهش تولید ناخالص داخلی و تولید نفت خام و همچنین ضریبی از تقاضای حمل‌ونقل در روز قبل، معیار پیش‌بینی تقاضای حمل‌ونقل آتی در یک بندر دریایی قرار گرفته است. این پژوهش نیز به مانند پژوهش قبلی از این منظر که به پیش‌بینی تقاضا در حمل‌ونقل دریایی و نقش آن در برنامه‌ریزی و توسعه می‌پردازد، حائز اهمیت است [۱۷].

خان^۴ و همکاران (۲۰۲۰)، پژوهشی با عنوان «برآورد تقاضا برای حمل‌ونقل ریلی در پاکستان: تحلیل سری زمانی» انجام دادند. هدف این مطالعه، ارائه کشش‌های کوتاه‌مدت و بلندمدت تقاضای حمل‌ونقل ریلی در پاکستان با استفاده از داده‌های سری زمانی سالانه از سال ۱۹۷۲ تا ۲۰۱۷ بود. نتایج این پژوهش نشان داد که نرخ بار و فعالیت اقتصادی به‌طور معناداری با

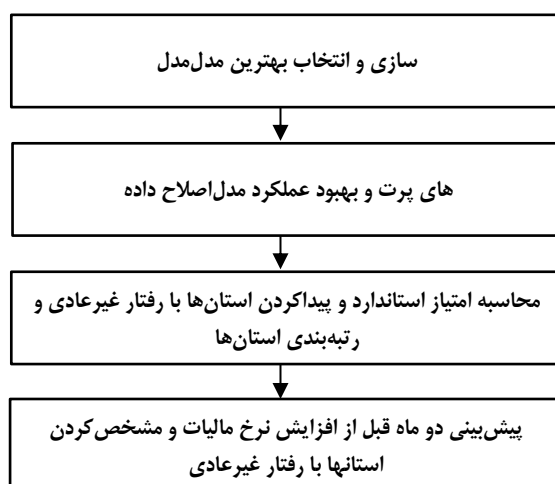
1. Holt
2. Holt Winter
3. Patil
4. Khan

تقاضای حمل‌ونقل ریلی در کوتاه‌مدت و بلندمدت مرتبط است. علاوه بر این، تقاضای حمل‌ونقل ریلی بلندمدت نیز به‌طور مثبت با هزینه حمل بار مرتبط است. این بدان معنا است که مقامات راه‌آهن می‌توانند با افزایش نرخ حمل‌ونقل، بدون ازدست‌دادن بیشتر بار، درآمد حمل‌ونقل را افزایش دهند. درآمد اضافی حمل‌ونقل ممکن است برای کاهش کسری هنگفت راه‌آهن پاکستان یا خرید واگن‌ها و لوکوموتیوهای باری بیشتر استفاده شود. این پژوهش به‌دلیل پیش‌بینی تقاضای بار ریلی از روش‌های مختلف سری زمانی و همچنین نشان‌دادن کشش افزایش قیمت حمل‌ونقل بدون از دست‌دادن بار دارای اهمیت است [۱۱].

چیکودیلی^۱ و همکاران (۲۰۲۱)، پنج روش برای شناسایی نقاط پرت در داده‌های سری زمانی ارائه کردند. این پژوهش نشان داد که ابزار کنترل کیفیت آماری امتیاز استاندارد یا امتیاز Z عملکرد بهتری در شناسایی نقاط پرت دارد؛ چراکه داده‌ها در این پژوهش به شکل سری زمانی بوده و برای شناسایی نقاط پرت و همچنین تشخیص عملکرد استان‌ها از این روش در این پژوهش نیز استفاده شده است [۴].

۳. روش‌شناسی پژوهش

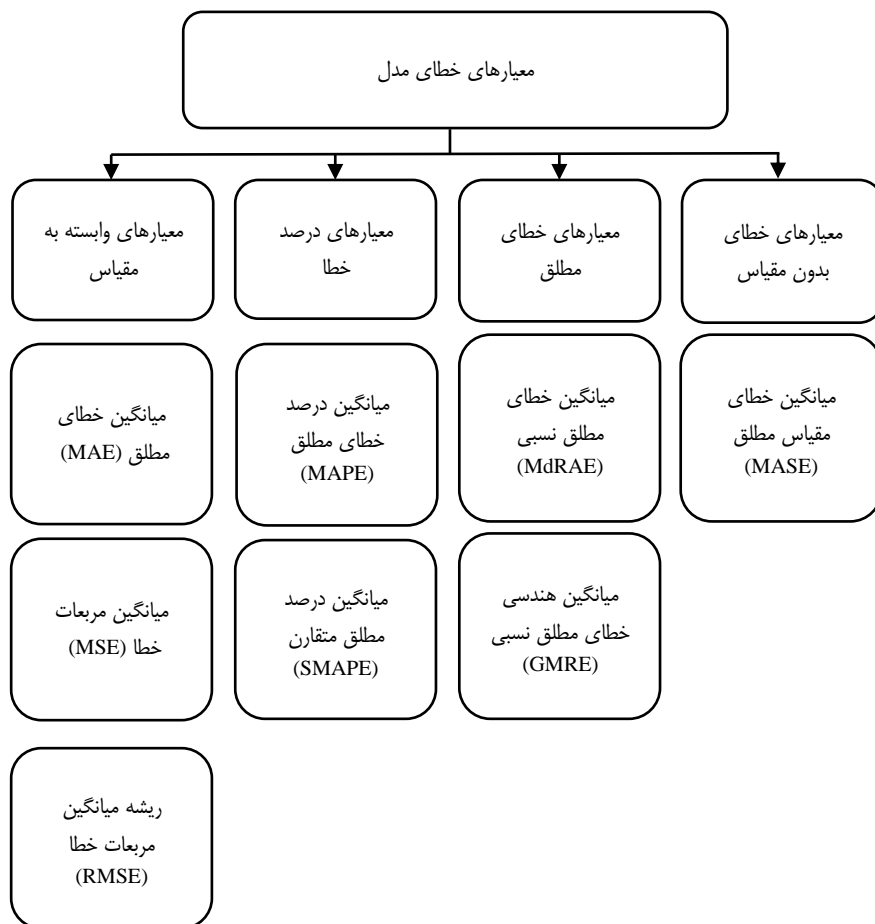
در این بخش ابزارهای مورد استفاده در پژوهش بررسی می‌شود. برای پیاده‌سازی مدل‌ها، از ۷۲ داده تُن - کیلومتر حمل‌شده جاده‌ای و ۷۲ بارنامه صادرشده جاده‌ای که از ۳۲ استان طی شش سال حداثی فروردین ۱۳۹۵ تا اسفند ۱۴۰۰ جمع‌آوری شده است، استفاده شد. این مقادیر در دو جدول به تفکیک میزان تُن - کیلومتر و تعداد بارنامه با ۳۲ ستون که نمایانگر ۳۲ استان و ۷۲ سطر نمایانگر داده‌های تعداد بارنامه صادره یا میزان تُن - کیلومتر حمل‌شده برحسب میلیون تُن در ماه‌های مختلف آورده شده است. در گام نخست، هدف پیش‌بینی متغیرهای وابسته، یعنی میزان تُن - کیلومتر و تعداد بارنامه در سه ماه دی، بهمن و اسفند و پس از تغییر تعرفه و افزایش آن است. برای پیش‌بینی میزان تُن - کیلومتر یا بارنامه یک استان به کمک روش‌های یادگیری ماشین و یادگیری عمیق علاوه بر در نظر گرفتن تُن - کیلومتر یا بارنامه سایر استان‌ها برای پیش‌بینی داده‌های گذشته ۳ دوره قبل هر استان نیز به‌عنوان یک ویژگی یا متغیر مستقل در نظر گرفته شده است. در روش‌های مبتنی بر سری زمانی فقط داده‌های گذشته هر استان جهت پیش‌بینی همان استان استفاده شده است؛ همچنین مراحل انجام کلی پژوهش در شکل ۱، آورده شده است.



شکل ۱. مراحل اجرای پژوهش

۴. تحلیل داده و یافته‌های پژوهش

در این بخش ابتدا نتایج پیش‌بینی ۴ مدل مختلف ارائه شده و با توجه به عملکرد آن‌ها بهترین مدل برای پیش‌بینی T_n - کیلومتر و بارنامه انتخاب می‌شود. در ادامه برای بهبود عملکرد مدل و پیش‌بینی دقیق‌تر، داده‌های پرت شناسایی شده و پس از پیدا شدن علل وقوع این داده‌ها مجدد پیش‌بینی می‌شوند؛ سپس این مقادیر پیش‌بینی شده با مقادیر قبلی جایگزین شده و مجدد مدل پیش‌بینی اجرا می‌شود. در نهایت در این پژوهش از ترکیب ابزار کنترل کیفیت آماری Z-Score و نتایج حاصل شده از پیش‌بینی برای تعیین رفتار غیرعادی استان‌ها استفاده می‌شود و سیستم نظارت و رتبه‌بندی شکل می‌گیرد.



شکل ۲. بررسی اجمالی معیارهای خطای پیش‌بینی

معیارهای انتخاب مدل مناسب برای پیش‌بینی. بسیاری از معیارهای دقت پیش‌بینی که در گذشته پیشنهاد شده‌اند، چهار دسته را برای معیارهای خطای پیش‌بینی پیشنهاد کرده‌اند [۹] (شکل ۲). آکایک^۱ معیار اطلاعات آکایک^۲ (AIC) را برای تخمین مقدار نسبی اطلاعات از دست‌رفته توسط یک مدل پیشنهاد کرد [۱]. هرچه یک مدل اطلاعات کمتری را از دست بدهد، کیفیت آن مدل بالاتر است. AIC هم با خطر بیش از حد برازش و هم با خطر عدم‌تناسب سروکار دارد.

برای اندازه‌گیری جامع عملکرد مدل‌های مختلف در فرآیند پیش‌بینی برای ۳ ماه، میانگین درصد مطلق خطا^۳، میانگین خطای مطلق مقیاس^۱، میانگین خطای مطلق^۲، ریشه میانگین مربع

1. Akaike

2. Akaike information

3. MAPE

خطا^۳، و مجذور میانگین مربعات خطا^۴ در این پژوهش استفاده شده است. در این پژوهش پنج معیار خطای پیش‌بینی رایج برای انتخاب بهترین مدل پیش‌بینی در نظر گرفته شده است. این معیارها به صورت زیر تعریف می‌شوند

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{رابطه (۳)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{رابطه (۴)}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} * 100 \right| \quad \text{رابطه (۵)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{رابطه (۶)}$$

$$MASE = \text{mean}(|q_t|), \quad q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |y_i - y_{i-1}|} \quad \text{رابطه (۷)}$$

اگر در این معادلات y_t نشان‌دهنده میزان واقعی مشاهده در زمان t و \hat{y}_t نشان‌دهنده پیش‌بینی مدل در زمان t باشد، خطای پیش‌بینی $e_t = y_t - \hat{y}_t$ تعریف می‌شود. توجه داشته باشید که در این پژوهش MAE، MAPE، MSE و RMSE به عنوان معیارهای کلیدی تعیین شده است؛ زیرا MAE نسبت به RMSE حساسیت کمتری نسبت به موارد پرت دارد و آن‌ها نقش مهمی در پیش‌بینی TKM دارند [۹]. ابتدا عملکرد چهار مدل پیش‌بینی کننده با هم سنجیده شده است. جدول ۴، نشان می‌دهد که جنگل تصادفی دارای کمترین MASE، RMSE، MAE، MAPE و MSE در میان سایر مدل‌ها برای پیش‌بینی ۳ ماه دی، بهمن و اسفند است.


جدول ۴. عملکرد مدل‌های مختلف سری زمانی

MSE	RMSE	MAE	MAPE	MASE	مدل
۵۳۰۸۲۸/۸۲۳	۷۲۸/۵۸۰	۵۳۸/۷۶۸	۲/۳۹۴	۲۳/۱۷۳	Random Forest
۷۱۸۴۸۷/۵۳۴	۸۹۷/۴۹۰	۶۳۵/۳۵۴	۳/۲۷۵	۲۳/۹۹۱	LSTM
۱۲۱۴۶۹۲/۶۰۵	۱۱۳۶/۵۵۳	۹۰۰/۱۸۶	۴/۱۰۳	۲۵/۸۴۲	ETS
۱۱۷۸۵۱۵/۶۴۹	۱۰۸۵/۵۹۵	۸۹۶/۹۱۱	۴/۰۶۴	۲۵/۷۶۱	ARIMA

1. MASE
2. MAE
3. RMSE
4. MSE

تشخیص و اصلاح داده‌های پرت. یکی از متداول‌ترین روش‌های آماری مورد استفاده برای تشخیص نقاط پرت، روش Z-score است. این روش انحراف معیار داده‌ها را محاسبه می‌کند و نقاط داده‌ای را که خارج از تعداد معینی انحراف استاندارد از میانگین قرار دارند، شناسایی می‌کند. تشخیص نقاط پرت با استفاده از باقیمانده‌های پیش‌بینی یک رویکرد رایج در تحلیل آماری است [۷]. باقیمانده‌ها تفاوت بین مقادیر مشاهده‌شده و مقادیر پیش‌بینی‌شده از یک مدل آماری هستند. نقاط پرت در داده‌ها می‌توانند باقیمانده‌های بزرگی ایجاد کنند که نشان‌دهنده تناسب ضعیف مدل با داده‌ها است. تشخیص نقاط پرت با استفاده از باقیمانده‌ها یک تکنیک مفید در تجزیه و تحلیل آماری است. این عمل می‌تواند به شناسایی مشاهداتی کمک کند که به خوبی با مدل مطابقت ندارند و ممکن است نشان‌دهنده نقاط پرت در داده‌ها باشند. با این حال بررسی بیشتر نقاط پرت مهم است تا اطمینان حاصل شود که آن‌ها به دلیل خطاهای اندازه‌گیری یا سایر منابع تغییرپذیری در داده‌ها نیستند. در این پژوهش از Z-Score بر روی باقیمانده‌های پیش‌بینی برای تشخیص نقاط پرت استفاده می‌شود. عموماً این مرحله قبل از مدل‌سازی و انتخاب مدل پیش‌بینی مناسب صورت می‌گیرد؛ اما از آنجاکه هدف پژوهش، پیش‌بینی یک مقدار پرت است، این عمل بعد از انتخاب مدل صورت می‌گیرد تا مدلی با عملکرد بهتر در مقابله با داده‌های پرت انتخاب شود و در نهایت پس از انتخاب مدل، داده‌های پرت در راستای بهبود عملکرد مدل اصلاح می‌شوند. به دلیل تعداد داده‌های کم در این پژوهش مقدار Z برای تشخیص داده‌های پرت ۲ در نظر گرفته شده است. پس از یافتن نقاط مورد نظر و بررسی آن‌ها به ریشه‌یابی و علل رخداد پرداخته می‌شود. در انتها پس از یافتن علت اصلی مشکل به منظور ساخت یک مدل دقیق‌تر با عملکرد بهتر، این نقاط به تنهایی پیش‌بینی شده و مقادیر پیش‌بینی‌شده با داده‌های واقعی متناظر جایگزین می‌شود. این عمل به بهبود عملکرد مدل و ارائه خروجی‌های مناسب‌تر منجر می‌شود.

با بررسی‌های انجام‌شده مشخص شد در دو تاریخ مهرماه سال ۱۳۹۷ و تیرماه سال ۱۴۰۰، افت چشم‌گیر در میزان تُن - کیلومتر حمل‌شده چند استان مشهود است. این مقادیر در شکل ۳، برای کل کشور مشخص شده‌اند. علت وقوع این مقادیر اعتصاب کامیون‌داران در چند استان گوناگون بوده است؛ بنابراین برای عملکرد بهتر مدل این دو نقطه با مدل به دست‌آمده از مرحله قبل پیش‌بینی شده و جایگزین شده و سپس بار دیگر نقاط مورد نظر، یعنی دی، بهمن و اسفند سال ۱۴۰۰ مجدد پیش‌بینی می‌شود.



شکل ۳. داده‌های پرت تَن - کیلومتر حمل شده کل کشور

پایش، تشخیص رفتار غیرعادی و رتبه‌بندی استان‌ها. در این پژوهش از ابزار کنترل کیفیت آماری با نام امتیاز Z برای رتبه‌بندی استان‌ها بر اساس عملکرد آن‌ها استفاده می‌شود. امتیاز Z یک مقدار آماری است که نشان می‌دهد یک مقدار خاص چند انحراف معیار از میانگین کل مجموعه داده فاصله دارد. در این بخش مطابق رابطه ۲، مقادیر واقعی مشاهدات تَن - کیلومتر و بارنامه در سه ماه از مقادیر پیش‌بینی شده توسط مدل جنگل تصادفی کم شده و بر انحراف استاندارد باقیمانده‌های مدل پیش‌بینی تقسیم می‌شود. نتایج در جدول ۸، نشان داده شده است. این جدول نشان می‌دهد که استان‌های فارس، زنجان و مازندران پس از اعمال و افزایش تعرفه دچار رفتار غیرعادی شده‌اند. نتایج پیش‌بینی‌ها و مقادیر واقعی هر استان در ماه‌های دی، بهمن و اسفند ۱۴۰۰ برای تَن - کیلومتر حمل شده در جدول ۵ و همچنین بارنامه صادر شده در جدول ۶، ارائه شده است.

جدول ۵. مقادیر مشاهده شده تَن - کیلومتر

استان	دی		بهمن		اسفند	
	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی
اردبیل	۸۷	۱۱۰	۹۸	۹۵	۹۳	۱۰۱
اصفهان	۲۰۱۶	۲۰۳۷	۱۹۳۱	۱۹۴۵	۱۹۹۹	۲۰۸۱
البرز	۲۵۱	۲۶۸	۲۳۷	۲۶۵	۲۸۰	۲۶۸
ایلام	۸۸	۹۳	۸۷	۹۱	۶۹	۸۹
آذربایجان شرقی	۷۵۹	۸۴۱	۸۴۳	۸۳۲	۸۳۶	۸۴۲
آذربایجان غربی	۴۸۲	۴۸۲	۵۴۷	۴۵۸	۴۹۸	۴۶۹
بوشهر	۵۸۰	۴۷۵	۵۶۰	۴۷۷	۵۷۰	۴۷۵

استان	دی		بهمن		اسفند	
	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی
تهران	۱۷۰۰	۱۵۳۴	۱۸۰۶	۱۵۱۴	۱۹۱۵	۱۵۴۰
چهارمحال و بختیاری	۱۹۶	۱۶۵	۱۹۶	۱۶۸	۱۷۸	۱۸۶
خراسان جنوبی	۲۹۴	۲۶۰	۲۸۹	۲۶۳	۳۶۷	۲۶۳
خراسان رضوی	۱۸۰۳	۱۸۵۵	۱۷۹۹	۱۷۲۷	۱۵۷۰	۱۷۹۹
خراسان شمالی	۱۲۶	۱۱۱	۸۳	۱۱۷	۱۰۸	۱۰۸
خوزستان	۲۷۸۷	۲۳۴۵	۲۹۰۶	۲۳۵۶	۲۶۲۸	۲۳۸۵
زنجان	۲۱۹	۲۷۴	۲۵۳	۲۶۲	۲۶۴	۳۰۲
سمنان	۴۲۲	۴۷۲	۴۱۸	۴۵۸	۴۲۸	۵۰۶
سیستان و بلوچستان	۵۹۱	۴۸۷	۶۱۱	۴۸۴	۶۲۲	۵۵۰
فارس	۱۰۱۸	۱۱۴۸	۱۰۵۱	۱۱۶۱	۱۰۷۸	۱۱۸۸
قزوین	۳۴۹	۳۴۸	۳۴۸	۳۲۵	۳۸۸	۳۴۸
قم	۲۳۹	۲۵۱	۲۳۳	۲۵۰	۲۳۱	۲۵۴
کردستان	۳۰۴	۲۸۱	۲۴۰	۲۹۸	۲۸۵	۳۰۶
کرمان	۱۴۰۹	۱۷۸۹	۱۷۳۳	۱۷۸۵	۱۶۶۳	۱۸۴۶
کرمانشاه	۳۵۲	۳۵۰	۳۸۱	۳۴۳	۳۷۲	۳۴۹
کهگیلویه و بویر احمد	۳۲	۴۳	۴۷	۳۸	۴۲	۴۲
گلستان	۱۶۶	۱۹۹	۱۵۴	۱۹۲	۱۷۹	۱۹۶
گیلان	۲۵۶	۲۸۳	۲۶۵	۲۹۳	۲۹۸	۲۹۶
لرستان	۱۴۷	۱۶۲	۱۵۵	۱۵۱	۱۲۹	۱۵۱
مازندران	۴۷۶	۵۷۸	۴۶۳	۵۰۹	۵۰۱	۴۸۹
مرکزی	۶۴۴	۶۹۹	۶۰۷	۷۰۵	۶۸۳	۶۹۹
هرمزگان	۲۰۱۲	۱۸۳۹	۲۱۲۲	۱۸۴۰	۲۴۹۴	۱۸۳۳
همدان	۳۵۶	۳۴۳	۲۹۸	۳۶۱	۳۳۸	۳۳۹
یزد	۱۶۲۹	۱۵۴۸	۱۶۱۷	۱۵۶۱	۱۶۵۵	۱۵۸۲
مجموع	۲۱۷۸۹	۲۱۲۷۵	۲۲۳۷۸	۲۱۴۲۱	۲۱۵۹۹	۲۱۹۰۲

جدول ۶- مقادیر مشاهده‌شده بارنامه

استان	دی		بهمن		اسفند	
	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی
اردبیل	۱۶	۱۸	۱۸	۱۸	۱۸	۲۱
اصفهان	۲۷۶	۲۷۲	۲۶۶	۲۷۶	۲۸۱	۲۹۶
البرز	۶۹	۶۶	۶۶	۶۷	۷۶	۶۹
ایلام	۱۱	۱۱	۱۱	۱۱	۱۰	۱۲
آذربایجان	۱۱۲	۱۲۴	۱۲۶	۱۲۸	۱۳۸	۱۳۹

استان	دی		بهمن		اسفند	
	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی
شرقی						
آذربایجان غربی	۵۶	۶۴	۶۳	۶۶	۷۱	۷۲
بوشهر	۵۶	۴۵	۵۴	۴۷	۵۱	۴۷
تهران	۳۱۶	۲۸۰	۳۲۶	۲۸۰	۳۵۵	۳۱۳
چهارمحال و بختیاری	۲۹	۳۰	۲۹	۲۹	۳۱	۳۳
خراسان جنوبی	۳۰	۳۰	۳۱	۳۰	۳۶	۳۲
خراسان رضوی	۱۷۰	۱۷۸	۱۷۰	۱۷۹	۱۷۴	۱۸۶
خراسان شمالی	۱۸	۱۷	۱۵	۱۷	۱۸	۱۸
خوزستان	۲۲۲	۱۹۴	۲۲۵	۱۹۹	۲۱۴	۲۰۳
زنجان	۴۶	۴۸	۴۸	۴۶	۵۲	۵۲
سمنان	۵۰	۵۱	۵۰	۵۲	۵۳	۵۷
سیستان و بلوچستان	۴۲	۴۵	۴۳	۴۶	۴۵	۴۶
فارس	۱۶۵	۱۸۷	۱۸۰	۱۸۳	۱۸۷	۲۰۳
قزوین	۶۰	۵۵	۶۰	۵۸	۶۶	۶۱
قم	۳۹	۴۱	۳۹	۴۱	۴۱	۴۴
کردستان	۳۷	۴۱	۳۷	۴۲	۴۰	۴۳
کرمان	۱۳۲	۱۵۲	۱۵۵	۱۵۴	۱۶۳	۱۵۷
کرمانشاه	۴۶	۴۵	۴۶	۴۶	۵۱	۴۸
کهگیلویه و بویر احمد	۱۰	۸	۸	۹	۹	۱۰
گلستان	۴۸	۴۷	۴۴	۴۸	۵۳	۵۱
گیلان	۵۶	۵۷	۵۸	۵۷	۶۴	۶۴
لرستان	۲۸	۳۰	۲۸	۲۹	۲۹	۳۰
مازندران	۱۳۸	۱۳۵	۱۲۰	۱۳۶	۱۳۰	۱۳۶
مرکزی	۱۰۲	۱۰۵	۹۸	۱۰۵	۱۱۴	۱۱۲
هرمزگان	۱۱۹	۱۱۷	۱۳۷	۱۱۸	۱۵۰	۱۲۰
همدان	۵۴	۵۳	۴۹	۵۷	۵۹	۵۹
یزد	۱۴۲	۱۲۴	۱۴۴	۱۲۶	۱۴۸	۱۳۲
مجموع	۲۶۹۵	۲۶۹۱	۲۷۴۴	۲۶۷۶	۲۹۲۸	۲۸۴۶

در ادامه برای بررسی بهتر و اجمالی‌تر و همچنین مشاهده این موضوع که آیا این رفتار غیرعادی پس از تغییر تعرفه بوده است یا قبل از افزایش تعرفه نیز این استان‌ها رفتار غیرعادی داشته‌اند. برای دو ماه آبان و آذر پیش‌بینی‌ها انجام شده و رفتار استان‌ها در جدول ۷، آورده شده است. جدول ۹، نشان می‌دهد که رفتار هر استان در هر ماه چه گونه بوده است. در این جدول رفتار عادی با امتیاز Z بین ۲ و -۲، با N ، رفتار غیرعادی و کاهش چشم‌گیر و دریافت امتیاز Z

کمتر از ۲- با D، رفتار غیرعادی و رشد چشم‌گیر و دریافت امتیاز Z بیش از ۲ با I نشان داده شده است. بررسی‌ها نمایانگر این موضوع هستند که استان فارس اگرچه رفتار غیرعادی داشته است، اما میانگین رفتار این استان در دو ماه قبل از اجرای قانون نیز غیرعادی بوده و این امر نمایانگر این موضوع است که رفتار غیرعادی این استان ارتباطی با افزایش مالیات و تعرفه نداشته است؛ اما دو استان زنجان و مازندران پس از افزایش مالیات با رفتار غیرعادی مواجه شده‌اند که این امر نمایانگر احتمال تقلب در این استان‌ها است.

جدول ۷. مقادیر مشاهده شده تن - کیلومتر و بارنامه در ماه‌های آبان و آذر

استان	تن کیلومتر- آبان		تن کیلومتر- آذر		بارنامه- آبان		بارنامه- آذر	
	مقدار پیش‌بینی	مقدار واقعی	مقدار پیش‌بینی	مقدار واقعی	مقدار پیش‌بینی	مقدار واقعی	مقدار پیش‌بینی	مقدار واقعی
اردبیل	۱۱۸	۱۲۵	۱۰۹	۱۱۸	۲۶	۲۳	۲۱	۲۴
اصفهان	۲۱۵۳	۲۰۰۷	۲۱۸۰	۲۰۸۰	۲۸۶	۲۷۴	۲۸۹	۲۹۵
البرز	۲۹۸	۲۹۳	۲۸۳	۲۸۲	۷۰	۷۲	۷۳	۶۹
ایلام	۸۰	۶۵	۸۳	۹۰	۱۱	۱۲	۱۲	۱۲
آذربایجان شرقی	۸۸۲	۸۸۶	۸۹۳	۸۷۶	۱۳۹	۱۴۰	۱۳۶	۱۴۰
آذربایجان غربی	۵۲۱	۶۵۲	۵۴۶	۶۱۴	۷۴	۸۱	۷۴	۷۸
بوشهر	۴۹۴	۵۴۸	۵۲۰	۵۵۵	۴۶	۴۵	۵۳	۴۵
تهران	۱۵۲۵	۱۴۶۲	۱۵۷۰	۱۷۸۶	۲۹۷	۳۱۵	۳۲۹	۳۱۵
چهارمحال و بختیاری	۱۶۲	۱۶۲	۱۸۰	۲۱۷	۳۰	۳۰	۳۲	۳۲
خراسان جنوبی	۲۷۲	۲۹۹	۲۷۸	۳۸۷	۳۰	۳۵	۳۶	۳۴
خراسان رضوی	۱۷۵۶	۱۸۱۲	۱۷۹۷	۲۰۱۳	۱۸۵	۱۸۶	۱۸۸	۱۸۹
خراسان شمالی	۱۲۷	۱۳۵	۱۲۳	۱۱۴	۲۳	۲۱	۲۰	۲۱
خوزستان	۲۳۶۵	۲۵۸۶	۲۳۶۹	۲۹۴۴	۲۰۶	۲۰۶	۲۲۸	۲۰۳
زنجان	۳۰۰	۳۱۵	۳۰۵	۳۰۹	۵۶	۵۶	۵۵	۵۴
سمنان	۵۰۵	۵۱۲	۵۱۳	۵۶۸	۵۴	۵۴	۵۸	۵۶
سیستان و بلوچستان	۴۵۱	۵۵۶	۴۷۰	۶۱۴	۳۹	۴۲	۴۴	۴۶
فارس	۱۲۹۹	۱۳۱۴	۱۲۱۸	۱۲۶۰	۲۱۱	۲۱۱	۱۹۴	۲۰۷
قزوین	۳۶۷	۳۵۴	۳۶۸	۳۷۱	۶۲	۶۲	۶۶	۶۳
قم	۲۶۲	۲۸۴	۲۶۶	۲۹۰	۴۳	۴۱	۴۳	۴۴
کردستان	۳۰۹	۲۶۴	۳۳۵	۲۶۶	۴۲	۴۲	۳۸	۴۵

استان	تن کیلومتر- آبان		تن کیلومتر- آذر		بارنامه- آبان		بارنامه- آذر	
	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی
کرمان	۱۴۷۶	۱۷۸۲	۱۵۵۷	۱۸۲۵	۱۴۱	۱۴۷	۱۵۴	۱۶۲
کرمانشاه	۴۳۴	۳۷۲	۴۳۴	۳۶۲	۶۴	۶۰	۶۰	۵۲
کهگیلویه و بویر احمد	۶۹	۴۶	۵۱	۴۵	۱۱	۱۰	۱۰	۱۰
گلستان	۲۰۵	۲۱۵	۲۰۱	۲۱۴	۵۳	۵۹	۵۴	۵۴
گیلان	۲۹۵	۲۹۸	۳۰۵	۳۰۲	۶۲	۶۴	۶۶	۶۵
لرستان	۲۱۱	۱۶۸	۱۹۶	۱۹۲	۴۳	۳۶	۳۷	۳۸
مازندران	۵۱۸	۵۰۸	۵۸۹	۶۲۱	۱۳۴	۱۲۷	۱۴۷	۱۲۸
مرکزی	۶۷۷	۷۱۹	۷۳۷	۷۵۲	۱۰۲	۱۰۷	۱۰۹	۱۱۳
هرمزگان	۱۷۸۹	۱۶۲۸	۲۱۶۸	۱۷۹۲	۱۰۸	۱۰۷	۱۲۸	۱۱۶
همدان	۳۵۰	۳۹۱	۴۱۷	۳۸۲	۶۰	۷۰	۶۴	۶۳
یزد	۱۶۷۳	۱۶۶۷	۱۶۹۶	۱۶۵۷	۱۴۴	۱۲۹	۱۵۰	۱۳۲
مجموع	۱۹۵۶۶	۲۱۶۳۵	۱۹۵۶۶	۲۲۲۰۶	۲۸۷۰	۲۸۱۸	۲۹۶۸	۲۸۶۳

جدول ۸. امتیاز استاندارد برای هر استان

استان	دی		بهمن		اسفند		میانگین امتیاز Z
	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	پیش‌بینی	مقدار واقعی	
زنجان	-۲/۳۲	-۲/۲۶	-۴	-۱/۲	-۲/۹۳	-۱/۵۲	-۲/۳۴
فارس	-۳/۶۸	-۲/۰۸	-۴/۵۳	-۰/۸۵	-۲/۳۲	-۰/۲۱	-۲/۲
مازندران	-۴/۹۷	-۰/۴۶	-۳/۱۹	-۲/۳۸	-۲/۲۵	-۱/۶۱	-۲/۰۴
سمنان	-۴/۵۱	-۱/۱۹	-۳/۱۶	-۱/۶۸	-۳/۲۳	-۱	-۱/۶۶
کهگیلویه و بویر احمد	-۰/۳۵	-۰/۰۹	-۱/۹۴	-۰/۸۹	-۱/۴	-۱/۳۸	-۱/۴۴
مرکزی	-۳/۵۳	-۰/۸	-۲/۶۸	-۱/۶۹	-۱/۹	-۰/۵۵	-۱/۴۲
گیلان	-۰/۷۷	-۱/۴۱	-۱/۸۷	-۰/۶۴	-۱/۲۳	-۰/۲۴	-۱/۳۴
کرمانشاه	-۱/۱۳	-۱/۳۳	-۱/۸	-۱/۱۱	-۰/۸۹	-۰/۲۲	-۱/۳۳
بوشهر	-۰/۵۲	۱	-۱/۳۹	-۰/۵۲	-۰/۷۶	-۰/۱۹	-۱/۲۹
خراسان رضوی	-۰/۶۴	-۰/۶۲	-۰/۶	-۱/۴۹	-۳/۴	-۰/۸۸	-۱/۲۹
قم	-۲/۱۱	-۰/۶۹	-۱/۴۵	-۱/۱۳	-۱/۶۴	-۰/۶۸	-۱/۲۸
یزد	-۱/۷۷	-۰/۸۴	-۱/۱۹	-۱/۱	-۱/۶۷	-۰/۸۲	-۱/۲۷
آذربایجان غربی	-۰/۸۲	-۲/۰۵	-۱/۹۸	-۰/۸۳	-۱/۶۶	-۱/۱۱	-۱/۳۳
گلستان	-۱/۸۷	-۰/۷۸	-۱/۴۶	-۱/۶۱	-۰/۴۴	-۰/۲۶	-۱/۰۸
کرمان	-۰/۴۲	-۱/۱	-۱/۱۴	-۰/۷۴	-۰/۴۶	-۰/۴	-۱/۰۱
آذربایجان غربی	-۰/۳۹	-۱/۹	-۱/۶۵	-۰/۵۲	-۱/۰۹	-۰/۱۹	-۰/۹۶
لرستان	-۱/۱۶	-۱/۳۳	-۲/۲۸	-۰/۴۴	-۱/۲۲	-۰/۰۴	-۰/۹۱

-۰/۷۳	-۰/۰۲	-۰/۰۴	-۱/۷	-۱	-۱/۰۸	-۱/۴۶	اصفهان
-۰/۵۶	-۰/۸۷	-۱/۲۳	-۰/۸۲	-۰/۷۱	-۰/۱۳	-۱/۹۱	ایلام
-۰/۵۵	-۱/۰۴	-۰/۰۶	-۰/۶۸	۱/۲	-۰/۴۴	-۱/۱۸	خراسان شمالی
-۰/۵۴	-۰/۳۸	-۰/۸۱	-۰/۱۹	-۰/۸۳	-۰/۵۴	-۱/۵۹	البرز
-۰/۴۸	-۰/۰۱	-۰/۰۳	-۱/۳۷	-۰/۶۶	-۱/۱۷	-۱/۶۷	همدان
-۰/۳۸	-۰/۶۹	۲/۳۱	-۰/۷۹	-۰/۶۴	-۰/۵۷	-۱/۴۴	خراسان جنوبی
-۰/۳۷	-۰/۰۵	-۰/۱۲	-۰/۲	-۱/۳۶	-۱/۰۵	-۰/۳۷	اردبیل
-۰/۲۷	-۰/۲۴	-۰/۲۱	-۱/۲۵	-۰/۳۳	-۰/۴۱	-۱/۲	قزوین
-۰/۲۵	-۰/۲۷	-۱/۴۴	-۰/۱۹	-۰/۶۹	-۰/۱۷	-۰/۶۳	سیستان و بلوچستان
-۰/۲۱	-۰/۷۴	-۱/۲۳	۱/۳	-۱/۰۸	۱/۱۵	-۰/۴۳	خوزستان
-۰/۱۶	-۱/۴	-۰/۳	-۱/۱۷	-۰/۱۱	-۱/۴۵	-۱/۸۸	کردستان
-۰/۰۷	-۰/۲۹	-۱/۱۹	-۰/۲۵	-۱/۱۲	-۰/۵۷	-۰/۶۵	چهارمحال و بختیاری
-۰/۲۵	۲/۴۲	-۰/۵۵	۱/۳۱	-۰/۲۵	-۰/۱۳	-۰/۵۹	هرمزگان
-۰/۴۷	-۰/۵۴	-۰/۷۹	-۰/۵۶	-۰/۵۲	-۱/۰۳	-۰/۸۳	تهران
-۱/۲۲	-۰/۰۳	-۱/۹۲	-۱/۱۱	-۱/۷۶	-۱/۱۲	-۱/۷۵	مجموع

جدول ۹. وضعیت ماهانه بارنامه‌های صادرشده و تُن - کیلومتر حمل‌شده

استان	قبل از افزایش مالیات		دی		بهمن		اسفند		مجموع رفتارهای غیرعادی	
	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه
فارس	D	N	D	D	D	N	D	N	۴	۱
زنجان	N	N	D	D	D	N	D	N	۳	۱
مازندران	N	N	D	N	D	D	D	N	۳	۱
سمنان	N	N	D	N	D	N	D	N	۳	۰
مرکزی	N	N	D	N	D	N	D	N	۳	۰
خراسان شمالی	N	D	N	N	D	N	N	N	۲	۰
آذربایجان شرقی	N	N	D	N	N	N	N	N	۱	۰
آذربایجان غربی	N	N	D	N	N	N	N	N	۱	۰
البرز	N	N	N	N	D	N	N	N	۱	۰
خراسان رضوی	N	N	N	N	N	N	D	N	۱	۰
قم	N	N	N	N	D	N	N	N	۱	۰
کرمان	N	N	D	D	N	N	N	N	۱	۱
کرمانشاه	N	N	D	D	N	N	N	N	۱	۱
کهگیلویه و بویر	N	N	D	N	N	N	N	N	۱	۰

استان	قبل از افزایش مالیات		دی		بهمن		اسفند		مجموع رفتارهای غیرعادی	
	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر	بارنامه	تُن - کیلومتر
احمد										
گلستان	N	N	N	N	D	D	N	N	۱	۱
گیلان	N	N	D	N	N	N	N	N	۰	۱
لرستان	N	N	D	N	N	N	N	N	۰	۱
یزد	N	N	N	N	D	N	N	N	۰	۱
اردبیل	N	N	N	N	N	N	N	N	۰	۰
اصفهان	N	N	N	N	N	N	N	N	۰	۰
ایلام	N	N	N	N	N	N	N	N	۰	۰
بوشهر	N	N	D	N	N	N	N	D	۲	۰
تهران	I	I	N	N	N	N	N	N	۰	۰
چهارمحال و بختیاری	N	N	N	N	N	N	N	N	۰	۰
خراسان جنوبی	N	I	N	N	N	N	N	I	۰	۰
خوزستان	I	I	N	N	N	N	N	N	۰	۰
سیستان و بلوچستان	N	N	N	N	N	N	N	N	۰	۰
قزوین	N	N	N	N	N	N	N	N	۰	۰
کردستان	N	N	N	N	N	N	N	N	۰	۰
هرمزگان	I	I	N	N	N	N	N	N	۰	۰
همدان	N	N	N	N	N	N	N	N	۰	۰
کل کشور	N	N	N	N	D	D	N	D	۲	۰

۵. نتیجه‌گیری و پیشنهادها

در این پژوهش، ترکیبی از پیش‌بینی و ابزارهای کنترل کیفیت برای ابداع روشی مقرون‌به‌صرفه برای نظارت و کشف رفتار غیرعادی و تقلب احتمالی در صنعت حمل‌ونقل کالا پیشنهاد شده است. این سیستم نه تنها قادر به کشف رفتار غیرعادی است، بلکه قادر است شرکت‌ها یا مراکز گزارش‌دهی را بر اساس عملکرد آن‌ها رتبه‌بندی کند؛ همچنین بحثی در مورد چگونگی تشخیص نقاط پرت و آنچه باید در هنگام شناسایی آن‌ها انجام شود، ارائه شده است. با توجه به مرور مبانی نظری، تاکنون پژوهشی برای پیش‌بینی تقاضا و میزان تُن - کیلومتر در حمل‌ونقل جاده‌ای انجام نشده بود؛ بنابراین این مطالعه از دو جهت دارای نوآوری است: ۱. برای نخستین بار پژوهشی بر روی تُن - کیلومتر حمل‌شده و تعداد بارنامه صادرشده حمل‌ونقل جاده‌ای انجام شده است؛ ۲. با

ترکیب مدل‌های پیش‌بینی و ابزارهای کنترل کیفیت آماری روشی برای شناسایی رفتار غیرعادی یا تخلف احتمالی ارائه شده است.

علاوه بر معرفی این سیستم، یک تحلیل تجربی جامع در این پژوهش انجام شده است. برای پیاده‌سازی مدل، از ۷۲ داده TKM و ۷۲ بارنامه که از ۳۲ استان طی شش سال حمل‌ونقل جاده‌ای جمع‌آوری شده است، استفاده شد. ابتدا برای پیش‌بینی، یک روش یادگیری ماشینی، یعنی جنگل تصادفی، یک روش یادگیری عمیق یعنی LSTM و دو روش سری زمانی یعنی ARIMA و ETS به تفصیل مورد بررسی قرار گرفته‌اند و پنج اندازه‌گیری متریک برای تعیین بهترین مدل پیش‌بینی انجام شده است. نتایج تجربی نشان می‌دهد که جنگل تصادفی از سایر مدل‌ها بهتر عمل می‌کند. در این پژوهش از امتیاز Z به عنوان ابزاری برای بررسی رفتار غیرعادی استفاده شده است. نتایج تجربی نشان می‌دهد که از ۳۲ استان، ۲ استان دارای رفتار غیرعادی هستند و رفتار غیرعادی در این استان‌ها کشف شد. در نهایت از Z-score برای امتیازدهی و ارزیابی عملکرد استان‌ها در اعلام میزان تُن - کیلومتر حمل‌شده و بارنامه صادرشده استفاده شده است.

پیشنهادات. نتایج حاصل از هر پژوهشی به امید ادامه یافتن راه تحقیق و پژوهش در خصوص آن موضوع و بهره‌برداری از نتایج آن به جامعه پژوهشگران و مسئولان ذی‌صلاح آن موضوع ارائه می‌شود؛ از این رو ارائه هر نوع پیشنهادی در این گزارش‌ها می‌تواند راه را برای مطالعات بعدی و نیز تصمیم‌گیری‌های اجرایی در آن خصوص هموار سازد. در این پژوهش نیز پیشنهادهایی در قالب پیشنهادهای پژوهشی برای کارهای مطالعاتی بعدی ارائه شده است:

- توسعه جامعه آماری پژوهش با در نظرگیری تمامی مسیرها و بارگیرها؛
- تعریف متغیرهای توصیفی بیشتر همچون شرایط آب‌وهوایی به تفکیک روز و مسیر، تعداد رانندگان فعال در هر بارگیر از نظر تعداد ساعات مجاز رانندگی، اطلاعات مالکیت هر ناوگان، نوع قراردادهای حمل در بارنامه مانند بازار نقدی و قراردادی.

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. Akaike H. (1987). Factor analysis and AIC. *Psychometrika*, 52(3), 317–32.
2. Bergstra J. B.Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(Feb), 281-305.
3. Box, G.E.P., & Jenkins GM. (1976). *Time Series Analysis: Forecasting and Control*. Holden Day, San Fr. (1970)
4. Chikodili, N.B., Abdulmalik, M.D., Abisoye, O.A., & Bashir, SA. (2021). Outlier Detection in Multivariate Time Series Data Using a Fusion of K-Medoid, Standardized Euclidean Distance and Z-Score. *Commun Comput Inf Sci [Internet]*. [cited 2023 Jun 19], 1350, 259–71.
5. Farazmand, M., Pishvae, M. S. (2018). Multimodal Transportation Network Design Model under Uncertainty Conditions (Case Study: Cement Transportation in Iran). *The Journal of Industrial Management Perspective*, 8(3), 115-139. (In Persian)
6. Fildes, R., Harvey A.C., West, M., & Harrison, J. (1991). Forecasting, Structural Time Series Models and the Kalman Filter. *The Journal of the Operational Research Society*, 42, 1031
7. Fox, J. (1995). *Applied Regression Analysis and Generalized Linear Models*. Sage Publ [Internet]. 2015, 1–817.
8. Ho, TK. (1995). Random Decision Forests. *Proc third Int Conf Doc Anal Recognit* 278–282 .
9. Hyndman, R.J., & Koehler, A.B. (2006). Another look at measures of forecast accuracy. *Int J Forecast*, 22(4), 679–88 .
10. Hyndman, R.J., Koehler, A.B., Snyder, R.D., & Grose S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *Int J Forecast*, 18(3), 439–54 .
11. Khan, M.Z., Khan, F.N. (2020). Estimating the demand for rail freight transport in Pakistan: A time series analysis. *J Rail Transp Plan Manag [Internet]*, 14(December 2019), 100176.
12. Kingma, D.P., & Ba, JL. (2015). Adam: A method for stochastic optimization. In: 3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings.
13. Mansourianfar, M.H., Haghshenas, H. (2018). Micro-scale sustainability assessment of infrastructure projects on urban transportation systems: Case study of Azadi district, Isfahan, Iran. *Cities*, 72, 149–59. (In Persian)
14. Mohaghar, A., Heydarzadeh Moghaddam, H., Ghasemi, R. (2023). Developing a Model to Optimize Maximum Coverage of Roadside Units Placement in Vehicular Ad-hoc Network for Intelligent Transportation System. *The Journal of Industrial Management Perspective*, 13(2), 211-240. (In Persian)
15. Nikbakhsh, E., Zegordi, S. H. (2014). Hub Arc Covering Location Problem under Disruption. *The Journal of Industrial Management Perspective*, 4(1), 9-29.
16. Ord, J.K., Ord, J.K., Koehler, A.B., & Snyder, R.D. (1997). Estimation and prediction for a class of dynamic nonlinear statistical models. *J Am Stat Assoc* 92(440), 1621–9.
17. Patil, G.R., & Sahu, P.K. (2016). Estimation of freight demand at Mumbai Port using regression and time series models. *KSCE J Civ Eng.*, 20(5), 2022–32.

18. Rob, J. Hyndman, Anne B. Koehler, Keith Ord. & Ralph Snyder. (2008). *Forecasting with Exponential Smoothing: The State Space Approach* Springer Series in Statistics [Internet]. Vasa. [cited 2023 Feb 19].
19. Sehgal, S., Suman, S., Patel, J., Chauhan, D.S., Singh, N.K., & Singh, R.K. (2017). Gross ton-kilometer forecasting models for freight trains of Northern-central Indian railways. *2017 Int Electr Eng Congr iEECON 2017*, (March), 8–10.
20. Zoghi, H., and Alipourvavossari, M. (2012). Model for Increasing Freight Transportation Price per Ton-Kilometer in Road Transport after Implementing Targeted Subsidy Plan. *9th Int Civ Eng Congr*.