

# Providing an Artificial Intelligence-Based Model for Predicting the Quantity of Municipal Solid Waste in Tabriz City

Masoumeh Piri<sup>1</sup> , Saeed Piri<sup>2</sup> , Hassan Taghipour<sup>3</sup> , Mohammad Hassan Sarbazan<sup>4</sup> , Mohammad Shakerkhatibi<sup>5\*</sup> 

<sup>1</sup> Student Research Committee, Tabriz University of Medical Sciences, Tabriz, Iran

<sup>2</sup> Information Technology Department, Urmia University of Technology, Urmia, Iran

<sup>3</sup> Department of Environmental Health Engineering, School of Health, Tabriz University of Medical Sciences, Tabriz, Iran

<sup>4</sup> Department of Environment, Malayer University, Malayer, Iran

<sup>5</sup> Health and Environment Research Center, Tabriz University of Medical Sciences, Tabriz, Iran

## ARTICLE INFO

**Article Type:**  
Original Article

## Article History:

Received: 8 Dec 2025

Revised: 6 May 2026

Accepted: 20 Sep 2026

ePublished: 30 Sep 2026

## Keywords:

Waste Management,  
Waste Quantity,  
Artificial Intelligence,  
Neural Networks

## Abstract

**Background.** Waste management is essential, for improving urban services. Predicting the quantity of waste generated can play an important role in designing and optimizing the collection, transportation, and disposal processes. In this regard, machine learning techniques have been introduced as powerful tools for predicting the quantities of generated waste. Therefore, this study was conducted with the aim of predicting the quantity of municipal solid waste (MSW) using neural networks in Tabriz city, Iran.

**Methods.** To predict the quantity of MSW, daily waste generation data from the Tabriz Municipality Waste Management Organization were used over a six-year period (2019–2024). The neural network employed consisted of an 8-layer LSTM network utilizing the Adam optimizer. The available data were divided into training and testing sets at an 85:15 ratio, and after the model training process, the predicted results were compared with the actual data to assess model accuracy. Root mean square error (RMSE), mean absolute error (MAE), and mean absolute percentage error (MAPE) were used to validate the proposed model.

**Results.** The results indicated good accuracy of the designed model in predicting the trend and quantity of waste generation; specifically, the RMSE, MAE, and MAPE values for the training and testing data were calculated as 50.62 and 70.47 tons/day, 32.61 and 53.02 tons/day, and 3.52% and 5.86%, respectively.

**Conclusion.** The analysis of the findings indicated the model's ability to reduce prediction deviation and increase reliability in estimating actual values. The low MAE values indicate that, on average, the model's prediction error compared to actual data was acceptable, and the model performed well in predicting the overall trend of waste generation. On the other hand, RMSE, which assigns greater weight to large errors, was also within a reasonable range, indicating that the model demonstrated good robustness against sudden fluctuations and outlier data. These results suggest that the trained model is capable of identifying hidden patterns in the time-series data and can be used as a suitable tool for data-driven prediction and management of municipal solid waste.

Piri M, Piri S, Taghipour H, Sarbazan MH, Shakerkhatibi M. Providing an Artificial Intelligence-Based Model for Predicting the Quantity of Municipal Solid Waste in Tabriz City. *Depiction of Health*. 2026; 17(3): 243-259. doi: 10.34172/doh.2026.20. (Persian)

\* Corresponding author; Mohammad Shakerkhatibi, E-mail: [shakerkhatibim@tbzmed.ac.ir](mailto:shakerkhatibim@tbzmed.ac.ir)



## Research Insights

- Accurate prediction of municipal solid waste quantity, considering temporal fluctuations in waste generation, is essential for planning collection, processing, recycling, and disposal capacities and, ultimately, for improving sustainable waste management.
- Conventional and traditional prediction methods may have limitations in accurately representing the complex patterns, temporal fluctuations, and nonlinear relationships involved in waste generation, which may reduce their ability to accurately predict waste quantities. This limitation highlights the need for more advanced, AI-based approaches for forecasting waste generation time series. However, the use of neural networks for predicting waste quantity involves challenges, including the model's dependence on the accuracy and validity of the data, limited access to sufficient data, and difficulty in determining an optimal network architecture. Therefore, further evaluation of neural network-based models for predicting waste quantity using real-world data is needed.
- In this study, an LSTM neural network was used to predict municipal solid waste quantity. Using daily municipal solid waste generation data from Tabriz, Iran, for the period 2019–2024, the LSTM model was trained to learn patterns in the data and predict waste quantity, and its performance was evaluated using RMSE, MAE, and MAPE.
- The findings showed that the trained model was capable of identifying complex and hidden patterns in waste data and could be used as a data-driven decision-support tool for estimating future waste quantities. These findings add to the existing evidence on the application of AI-based approaches for predicting municipal solid waste quantity, particularly using real-world data from Tabriz, and may provide a basis for future studies using longer time periods and larger datasets.

## Extended Abstract

### Background

In recent years, population growth, industrialization, increased urbanization, lifestyle changes, and shifts in consumption patterns have caused an increase in the quantity of municipal solid waste (MSW). Improper management of MSW constitutes a serious threat to public health and the environment, leading to pollution of water, soil, and air resources and causing various diseases in humans. Given the existing problems in managing MSW, moving toward sustainable and efficient waste management and employing novel technologies is essential. In this regard, smart technologies, and artificial intelligence in particular, have attracted attention as effective tools for transforming waste management. Accurate prediction of waste generation is one of the key components of sustainable waste management, as reliable information about waste quantities is required at various stages of reduction, collection, recycling, and disposal; such information can help prevent infrastructure failures, increase efficiency, and reduce costs. Since conventional and traditional methods are unable to accurately represent the complex, multi-factor dynamics of waste generation, the use of advanced algorithms and hybrid AI-based approaches has gained increasing attention. Considering the challenges in quantitatively assessing waste and the need to develop data-driven approaches in this field, this study aims to predict the quantity of MSW in Tabriz, to present an AI-based model, and to examine the accuracy of neural network-based algorithms.

## Methods

This study was carried out in Tabriz, with a population of over 1.7 million and an area of about 324 square kilometers. Daily waste generation data were obtained from the Waste Management Organization of Tabriz Municipality for the years 2019 to 2024. First, the data were checked and corrected for missing, outlier, or invalid values to ensure their accuracy and reliability for modeling. The model used was an LSTM-based neural network with an 8-layer architecture, each layer containing 50 hidden units. To predict waste quantities, a 16-time-step input sequence from the time series was fed into the model at each step, and a learning rate of 0.001 was adopted to balance learning speed and the prevention of overfitting. The training process used the Adam optimizer and was run for 600 epochs to ensure that the model reached satisfactory convergence. The model was implemented in Python using specialized libraries, including Pandas and NumPy for data processing, Matplotlib for data visualization, and the PyTorch framework for developing and training the LSTM network. These measures made it possible to design a stable and efficient model capable of extracting hidden patterns for data-driven waste management through time-series prediction. The RMSE, MAE, and MAPE metrics were used to evaluate the model's performance and accuracy.

## Results

Based on the available data, the average daily MSW generation in Tabriz was approximately 980 tons. The

daily tonnage data for waste were examined, and 11 implausible records were removed; these records were replaced using a 20-day moving average based on the 10 days preceding and the 10 days following each removed record. Model performance was evaluated in two phases. In the first phase, data from 2019 to 2024 were examined, with 85% of the data used for training and the remaining 15% used for testing. The RMSE and MAE values in this phase for the training and testing data were calculated as 52.58 and 72.91 tons/day, and 33.94 and 55.01 tons/day, respectively. In the second phase, data from 2024 were also incorporated into the model; similarly, 85% of the data from 2019 to 2024 were used for training and 15% for testing. The RMSE, MAE, and MAPE values for the training and testing data were 50.62 and 70.47 tons/day, 32.61 and 53.02 tons/day, and 3.52% and 5.86%, respectively. The low MAE values indicate that the model's prediction errors were small compared to the actual data and that the model performed well in predicting the overall trend of waste generation. The RMSE values were also within a reasonable range, indicating that the model demonstrated adequate robustness against sudden fluctuations and outliers. The low MAPE values likewise indicate acceptable results.

## Conclusion

This study developed an LSTM-based model to predict the quantity of MSW in Tabriz. The results show that neural networks can identify complex patterns, fluctuations, and nonlinear relationships in waste generation. Nevertheless, challenges remain in using neural networks to predict waste quantities. Such

challenges include the model's dependence on the accuracy and validity of the data, limited data availability, and difficulty in determining an optimal network structure. Extending the length of the data period could improve the model's long-term predictive performance. In general, the LSTM model may serve as an effective approach for forecasting MSW generation and can assist urban managers in more precise planning for waste reduction, collection, transportation, recycling, and disposal.

## Practical Implications of Research

The practical implications of this research include supporting more proactive and data-driven municipal solid waste management through the prediction of waste quantity using artificial intelligence. The application of the LSTM model can support urban decision-makers in anticipating future collection and treatment requirements, allocating resources efficiently, and improving recycling and resource recovery strategies. However, the practical implementation of the model requires the establishment of a coherent data infrastructure, continuous and standardized data collection, validation of the model under real-world conditions, and regular updating in response to changes in waste generation patterns. Overall, AI-based prediction can serve as a decision-support tool to shift municipal solid waste management from reactive decision-making toward a more data-driven, proactive, evidence-based, and sustainable approach.

## ارائه مدلی بر پایه هوش مصنوعی برای پیش‌بینی کمیت پسماندهای عادی شهر تبریز

معصومه پیری<sup>۱</sup>، سعید پیری<sup>۲</sup>، حسن تقی‌پور<sup>۳</sup>، محمد حسن سربازان<sup>۴</sup>، محمد شاکر خطیبی<sup>۵\*</sup>

<sup>۱</sup> کمیته تحقیقات دانشجویی، دانشگاه علوم پزشکی تبریز، تبریز، ایران

<sup>۲</sup> مرکز فناوری اطلاعات، دانشگاه صنعتی ارومیه، ارومیه، ایران

<sup>۳</sup> گروه مهندسی بهداشت محیط، دانشکده بهداشت، دانشگاه علوم پزشکی تبریز، تبریز، ایران

<sup>۴</sup> گروه محیط زیست، دانشگاه ملایر، ملایر، ایران

<sup>۵</sup> مرکز تحقیقات سلامت و محیط زیست، دانشگاه علوم پزشکی تبریز، تبریز، ایران

### چکیده

**زمینه.** مدیریت پسماندها امری ضروری و در عین حال پرهزینه در راستای ارتقای خدمات شهری است. پیش‌بینی کمیت پسماند تولیدی می‌تواند نقش مهمی در طراحی، بهینه‌سازی فرآیند جمع‌آوری، انتقال و دفع ایفا نماید. در این راستا، تکنیک یادگیری ماشین به عنوان ابزاری قدرتمند برای پیش‌بینی مقادیر پسماندهای تولیدی مطرح شده است. بنابراین، این مطالعه با هدف پیش‌بینی کمیت پسماندهای عادی شهر تبریز با استفاده از شبکه‌های عصبی انجام شد.

**روش کار.** به منظور پیش‌بینی کمیت پسماندهای عادی، از داده‌های روزانه تولید پسماند توسط سازمان مدیریت پسماند شهرداری تبریز در یک بازه زمانی شش ساله (۱۳۹۸ تا ۱۴۰۳) استفاده شد. شبکه عصبی مورد استفاده شامل یک شبکه ۸ لایه از نوع LSTM بوده که در آن از توابع فعال‌سازی Adam استفاده شده است. داده‌های موجود به دو قسمت یادگیری و آزمون به نسبت ۸۵ به ۱۵ تقسیم شده و پس از طی مراحل آموزش و یادگیری مدل، نتایج پیش‌بینی با داده‌های واقعی مقایسه و دقت مدل مورد بررسی قرار گرفت. به منظور اعتبارسنجی مدل ارائه شده از پارامترهای RMSE، MAE و MAPE استفاده شده است.

**یافته‌ها.** نتایج، نشان‌دهنده دقت خوب مدل طراحی‌شده در پیش‌بینی روند تغییرات و مقدار تولید پسماند بوده است؛ به طوری که، مقادیر RMSE، MAE و MAPE برای داده‌های آموزش و آزمون به ترتیب ۵۰/۶۲ و ۷۰/۴۷ تن در روز، ۳۲/۶۱ و ۵۳/۰۲ تن در روز و ۳/۵۲ و ۵/۸۶ درصد محاسبه گردید.

**نتیجه‌گیری.** تحلیل یافته‌ها حاکی از توانایی مدل در کاهش انحراف پیش‌بینی‌ها و افزایش قابلیت اطمینان در برآورد مقادیر واقعی بود. مقادیر پایین MAE بیانگر آن است که به طور میانگین، خطای پیش‌بینی شده مدل در مقایسه با داده‌های واقعی قابل قبول بوده و مدل در پیش‌بینی روند کلی تولید پسماند عملکرد مناسبی داشته است. از سوی دیگر، RMSE که به خطاهای بزرگ وزن بیشتری می‌دهد نیز در محدوده‌ای منطقی قرار داشت و نشان می‌دهد که مدل در برابر نوسانات ناگهانی و داده‌های پرت مقاومت مناسبی از خود نشان داده است. این نتایج حاکی از آن است که مدل آموزش‌دیده قادر به شناسایی الگوهای پنهان در داده‌های سری زمانی بوده و می‌تواند به عنوان ابزاری مناسب در پیش‌بینی و مدیریت داده‌محور پسماندهای عادی مورد استفاده قرار گیرد.

### اطلاعات مقاله

#### نوع مقاله:

مقاله پژوهشی

#### سابقه مقاله:

دریافت: ۱۴۰۴/۰۹/۱۷

اصلاح نهایی: ۱۴۰۵/۰۲/۱۶

پذیرش: ۱۴۰۵/۰۶/۲۹

انتشار برخط: ۱۴۰۵/۰۷/۰۸

#### کلیدواژه‌ها:

مدیریت پسماند،  
کمیت پسماند،  
هوش مصنوعی،  
شبکه‌های عصبی

## پیام‌های کلیدی

- پیش‌بینی دقیق کمیت پسماندهای جامد شهری، با توجه به نوسانات زمانی در میزان تولید برای برنامه‌ریزی ظرفیت جمع‌آوری، پردازش، بازیافت و دفع و در نهایت ارتقای مدیریت پایدار پسماند ضروری است.
- روش‌های سنتی و متداول پیش‌بینی، به دلیل محدودیت در نمایش الگوهای پیچیده، نوسانات زمانی و روابط غیرخطی موجود در فرایند تولید پسماند، ممکن است نتوانند کمیت پسماند را با دقت کافی پیش‌بینی کنند. این

\* پدیدآور رابط: محمد شاکر خطیبی، آدرس ایمیل: shakerkhatibim@tbzmed.ac.ir



محدودیت، ضرورت استفاده از روش‌های پیشرفته‌تر و مبتنی بر هوش مصنوعی را برای پیش‌بینی سری‌های زمانی تولید پسماند مطرح می‌کند. از طرفی، استفاده از شبکه‌های عصبی برای پیش‌بینی کمیت پسماند با چالش‌هایی از جمله وابستگی مدل به دقت و اعتبار داده‌ها، محدودیت در دسترسی به داده‌های کافی و دشواری تعیین ساختار بهینه شبکه همراه است. بنابراین، نیاز به بررسی عملکرد مدل‌های مبتنی بر شبکه‌های عصبی در پیش‌بینی کمیت پسماند در شرایط داده‌های واقعی وجود دارد.

- در این مطالعه، برای پیش‌بینی کمیت پسماندهای جامد شهری از شبکه عصبی LSTM استفاده شد. با استفاده از داده‌های روزانه تولید پسماند عادی شهر تبریز طی سال‌های ۲۰۱۹ تا ۲۰۲۴، مدل LSTM برای یادگیری الگوهای موجود در داده‌ها و پیش‌بینی کمیت پسماند به کار گرفته شد و عملکرد آن با استفاده از شاخص‌های MAE, RMSE و MAPE ارزیابی گردید.
- یافته‌ها نشان دادند که مدل آموزش‌دیده قادر به شناسایی الگوهای پیچیده و پنهان در داده‌های پسماند بوده و می‌تواند به عنوان ابزار تصمیم‌یار داده‌محور برای برآورد کمیت پسماند در آینده مورد استفاده قرار گیرد. این یافته‌ها به شواهد موجود درباره کاربرد روش‌های مبتنی بر هوش مصنوعی در پیش‌بینی کمیت پسماند شهری، به‌ویژه در شرایط داده‌های واقعی شهر تبریز، می‌افزاید و می‌تواند مبنایی برای مطالعات آینده با دوره‌های زمانی طولانی‌تر و داده‌های بیشتر باشد.

## مقدمه

عدم مدیریت صحیح پسماندها به عنوان یک تهدید جدی برای سلامت عمومی و محیط زیست مطرح می‌باشد.<sup>۸,۷</sup> مدیریت و دفع نادرست پسماندهای جامد باعث آلودگی منابع آب، خاک و هوا و بروز انواع بیماری‌ها در انسان می‌شود. از سوی دیگر، هر تن پسماند، بیش از ۱۰۰ مترمکعب متان و کربن دی اکسید تولید می‌کند که هر دو جزء گازهای گلخانه‌ای بوده و از عوامل گرم شدن کره زمین به شمار می‌روند.<sup>۹</sup> پسماندهای سمی رها شده در محیط نیز ممکن است بر باروری و سلامت خاک تاثیر گذاشته و سبب آلودگی خاک و اثر بر انسان از طریق ورود به زنجیره غذایی شوند.<sup>۱۱,۱۰</sup> گزارش‌ها حاکی از آن است سالانه در مجموع حدود ۷-۹ میلیارد تن انواع پسماند در جهان تولید می‌شود که حدود ۱/۲ میلیارد تن آن پسماند جامد شهری بوده و حدود ۳۳ درصد از پسماندهای عادی به صورت غیربهداشتی و ناایمن و در محل‌های دفع غیرقانونی و فاقد نظارت زیست محیطی و بهداشتی دفع می‌شود.<sup>۱۲</sup>

با توجه به مشکلات موجود در مدیریت پسماندهای عادی، حرکت به سمت مدیریت پایدار پسماند ضروری بوده و این امر مستلزم برنامه‌ریزی درست، استفاده از سیستم‌های مدیریت نوین، سرمایه‌گذاری در توسعه بازیافت و استفاده از ابزارهای محاسباتی مناسب برای

پسماند عادی به کلیه پسماندهایی که به‌صورت معمول از فعالیت‌های روزمره انسان‌ها در شهرها، روستاها و خارج از آنها تولید می‌شود و شامل پسماندهای خانگی و نخاله‌های ساختمانی می‌باشد، گفته می‌شود. در طی سال‌های اخیر، رشد جمعیت، تغییر شرایط اجتماعی و توسعه اقتصادی و به‌دنبال آن صنعتی شدن جوامع، افزایش شهرنشینی، تغییر سبک زندگی و الگوی مصرف، افزایش استانداردها و رفاه باعث افزایش کمی پسماندهای عادی شده است.<sup>۲,۱</sup> بر اساس گزارش بانک جهانی در سال ۲۰۱۲، میزان تولید سالانه پسماندهای عادی در جهان حدود ۱/۳ میلیارد تن بوده و پیش‌بینی شده بود که این رقم تا سال ۲۰۲۵ به حدود ۲/۲ میلیارد تن برسد.<sup>۵-۳</sup> با این حال طبق آخرین گزارش‌های بانک جهانی میزان پسماندهای عادی در سال ۲۰۲۲، ۲/۵۶ میلیارد تن در سال بود که نشان می‌دهد روند تولید پسماندهای عادی حتی فراتر از پیش‌بینی‌های پیشین بوده است و در سناریوی تداوم روند موجود این مقدار تا سال ۲۰۵۰ به ۳/۸۶ میلیارد تن در سال خواهد رسید. همین‌طور طبق نتایج به دست آمده از مطالعه گل حسینی و همکاران در ایران، میانگین تولید پسماندهای عادی ۶۳۰ گرم در روز به ازای هر نفر می‌باشد.<sup>۶</sup>

می‌رسد.<sup>۲۰</sup> بر اساس منابع علمی در دسترس، سابقه استفاده از هوش مصنوعی در کشور به منظور پیش‌بینی میزان پسماند جامد شهری به سال ۲۰۰۸ در شهر مشهد باز می‌گردد که در آن نوری و همکاران در یک مطالعه موردی با استفاده از مدل ماشین بردار پشتیبان توانستند میزان پسماند تولیدی در این شهر را پیش‌بینی نمایند.<sup>۲۱</sup>

از جمله مهم‌ترین موارد دیگر کاربرد هوش مصنوعی در پیش‌بینی نرخ تولید پسماند، می‌توان به مطالعه سونی (Soni) و همکاران در سال ۲۰۱۹ در هند،<sup>۲۲</sup> مطالعه عباسی و همکاران در سال ۲۰۱۶ در استرالیا،<sup>۲۳</sup> مطالعه کوبیلوس (Cubillos) در سال ۲۰۲۰ در دانمارک،<sup>۲۴</sup> مطالعه سونایانا (Sunayana) و همکاران در سال ۲۰۲۰ در شهر ناگیور هند،<sup>۲۵</sup> مطالعه آزادی و کریمی جشنی در سال ۲۰۱۶ در ایران<sup>۲۶</sup> و مطالعه کانانگارا (Kannangara) و همکاران در سال ۲۰۱۷ در کانادا<sup>۲۷</sup> اشاره نمود. در این راستا و در ادامه مطالعات، با توجه به وجود مشکلات جدی در ارزیابی‌های کمی پسماندهای عادی در ایران، این مطالعه با هدف پیش‌بینی کمیت پسماندهای عادی با ارائه مدلی بر پایه هوش مصنوعی در شهر تبریز انجام شده است.


## روش کار

### منطقه مورد مطالعه

این مطالعه در شهر تبریز، مرکز استان آذربایجان شرقی و بزرگ‌ترین شهر شمال غرب ایران انجام شده است. جمعیت این شهر بیش از ۱/۷ میلیون نفر و مساحت آن حدود ۳۲۴ کیلومتر مربع بوده و به‌عنوان یکی از بزرگ‌ترین شهرهای ایران شناخته می‌شود. این شهر در شمال مخروط آتشفشانی سهند و جنوب کوه عینالی در ارتفاع ۱۳۴۰ متری از سطح دریا، در عرض جغرافیایی ۳۸/۰۷ درجه شمالی و طول جغرافیایی ۴۶/۲۸ و ۲۹۲ درجه شرقی قرار دارد (شکل ۱). شهر تبریز یکی از مهم‌ترین مراکز صنعتی، اقتصادی، فرهنگی، سیاسی و آموزشی ایران است. بر اساس آخرین گزارش‌های صورت گرفته، سرانه تولید پسماند در این شهر ۷۱۶/۰ کیلوگرم در روز به ازای هر نفر می‌باشد.<sup>۲۷</sup> مرکز دفن پسماندهای شهری تبریز در شمال غربی این شهر واقع شده و طی سال‌های گذشته، دفن پسماندهای عادی در این شهر به‌صورت غیراصولی انجام شده است.<sup>۲۸</sup>

پیش‌بینی وضعیت تولید پسماند در آینده خواهد بود.<sup>۱۳</sup> طی سال‌های اخیر، تلاش‌های جدی برای متحول کردن صنعت مدیریت پسماند با رویکرد حرکت به سمت پایداری و سودآوری و ارتقای خدمات مدیریت جامع با استفاده از فناوری‌های پیشرفته و سیستم‌های هوشمند صورت گرفته است. یکی از این فناوری‌ها، تکنیک نوظهور هوش مصنوعی (Artificial Intelligence: AI) می‌باشد که در زمینه‌های مختلف از جمله محیط زیست مورد استفاده قرار گرفته است.<sup>۱۴</sup> هوش مصنوعی به دلیل قابلیت بالا در مدل‌سازی مکانیسم‌های پیچیده، در بسیاری از زمینه‌ها از جمله بهینه‌سازی فرآیندهای مدیریت پسماند، تصفیه‌خانه آب و فاضلاب، آلاینده‌های هوا به‌طور موفق به کار گرفته شده است.<sup>۱۵</sup>

کاربرد هوش مصنوعی در مدیریت پسماندهای عادی به‌طور گسترده برای پیش‌بینی الگوهای تولید پسماند، بهینه‌سازی مسیرهای جمع‌آوری پسماند، مکان‌یابی محل دفن پسماند، شبیه‌سازی فرآیندهای تبدیل پسماند، بهینه‌سازی فرآیندهای تغییر و تبدیل پسماند و سایر موارد مورد استفاده قرار گرفته است.<sup>۱۶</sup> پیش‌بینی قابل اعتماد میزان پسماندهای عادی در موفقیت سیستم مدیریت پایدار پسماند بسیار موثر بوده و اساس کار این سیستم خواهد بود. علاوه بر آن، اطلاع درست از کمیت پسماندهای عادی امری مهم در بخش‌های مختلف مدیریت پسماند از جمله کاهش تولید، نگهداری موقت، جمع‌آوری، حمل و نقل، بازیافت و فرآوری، و انتخاب بهینه محل دفن به شمار می‌رود.<sup>۱۷، ۱۸</sup> پیش‌بینی نرخ تولید پسماند، مبنای را برای بهینه‌سازی عملیات مدیریت پسماندهای عادی فراهم می‌کند و از بسیاری از مشکلات زیرساختی در حیطه مدیریت پسماند جلوگیری می‌کند.<sup>۱۹</sup> از ابزارهایی که تاکنون برای پیش‌بینی نرخ تولید پسماند استفاده شده‌اند می‌توان به تحلیل آماری توصیفی، تحلیل رگرسیون و تحلیل جریان مواد اشاره نمود که هر کدام دارای نقاط ضعف و قوت می‌باشند. با توجه به اینکه عوامل متعددی بر تولید پسماندهای عادی موثرند و کمیت پسماندهای عادی تابع روابط پیچیده‌ای است، پیش‌بینی برای آینده با روش‌های متداول نمی‌تواند اطلاعات صحیحی در این راستا ارائه دهد. از طرفی، استفاده از روش‌های متعدد و ابزارهای نوین محاسباتی به جای تکیه بر یک روش، منطقی‌تر به نظر



شکل ۱. موقعیت شهر تبریز

### هوش مصنوعی

شبکه‌های عصبی مصنوعی (Artificial Neural Networks: ANN) یکی از پرکاربردترین الگوریتم‌های مورد استفاده در حوزه هوش مصنوعی هستند. این شبکه‌ها الهام گرفته از ساختار مغز انسان بوده و در راستای یادگیری و پردازش اطلاعات، با تقلید از عملکرد مغز انسان و با کمک اصول سازماندهی نورون‌های موجودات زنده ایجاد شده‌اند. شبکه‌های عصبی معمولاً از سه لایه تشکیل شده‌اند که شامل لایه ورودی (Input Layer)، لایه‌های پنهان (Hidden Layers) و لایه خروجی (Output Layer) می‌باشند. اطلاعات ورودی به شبکه در لایه ورودی وارد شده و از طریق لایه‌های پنهان پردازش می‌شوند تا در نهایت در لایه خروجی نتیجه تولید شود.<sup>۳۹،۲۰</sup> در پیش‌بینی نرخ تولید پسماند با استفاده از سیستم‌های هوش مصنوعی، در دسترس بودن و دقت داده‌های سری زمانی بسیار مهم است.<sup>۳۰</sup> داده‌های سری زمانی در واقع دنباله‌ای از داده‌های جمع‌آوری شده در یک دوره زمانی هستند. اگر  $X$  یک بردار باشد، سری زمانی را می‌توان به صورت زیر نشان داد که در آن  $t$  نشان‌دهنده زمان و  $X$  یک متغیر تصادفی است.<sup>۳۱</sup>

$$X(t), t = 0, 1, 2, 3, \dots$$

شبکه‌های عصبی حافظه کوتاه‌مدت بلند (Long Short Term Memory: LSTM) نوعی از شبکه‌های عصبی بازگشتی هستند که توانایی یادگیری وابستگی‌های بلندمدت را دارند و برای اولین بار در سال ۱۹۹۷ معرفی شدند.<sup>۳۲</sup> این شبکه‌ها

مانند شبکه‌های عصبی بازگشتی معمولی (Recurrent Neural Network: RNN) به صورت زنجیره‌ای تکرارشونده از ماژول‌های شبکه‌های عصبی هستند و تفاوت آنها با شبکه‌های عصبی بازگشتی معمولی در ساختار درونی ماژول است. در شبکه‌های عصبی بازگشتی معمولی، ساختار درونی به صورت ساده می‌باشد ولی در شبکه‌های عصبی LSTM، ساختار درونی هر ماژول مانند یک شبکه عصبی ۴ لایه دارای ارتباط خاص بوده و مهم‌ترین ویژگی LSTM وجود سلول حالت است که باعث می‌شود مانند یک حافظه برای شبکه‌های عصبی باشد و حالت‌های قبلی را نیز در حالت فعلی لحاظ کند که از این‌رو گزینه مناسبی برای داده‌هایی است که به صورت سری زمانی مرتب شده‌اند.<sup>۳۳</sup>

در سری‌های زمانی، یادگیری به صورت End-to-End وابستگی‌های زمانی می‌باشند و برخلاف مدل‌های سنتی مانند SVM، Random Forest که مجبور به ویژگی‌سازی دستی هست (مانند Moving Average Standard Division، Gini Index)، روش‌های مبتنی بر یادگیری با تکیه بر سری‌های زمانی بازنمایی‌های زمانی مناسب را به طور خودکار از روی داده‌های خام یاد می‌گیرد.

ویژگی‌های مربوط به LSTM در زیر به تفصیل ارائه شده‌اند:

۱. دروازه فراموشی (Forget Gate): یاد می‌گیرد چه چیزی را نادیده بگیرد و تعیین می‌کند کدام اطلاعات گذشته دیگر مرتبط نیستند. در صورتی که داده‌ها دچار

مؤلفه‌های دیگر توضیح داده نمی‌شوند) هستند که در داده‌های مورد استفاده با توجه به اینکه از نوع سری زمانی هستند تمامی موارد شامل اعیاد، اتفاقات خاص، شرایط بحرانی، همه‌گیری یک بیماری یا هر اتفاق دیگر به صورت پنهان وجود دارد و داده‌ها متأثر از آن می‌باشند.

### آماده‌سازی مدل

داده‌های وزنی پسماندهای عادی به صورت روزانه در بازه زمانی شش ساله از سال ۱۳۹۸ تا ۱۴۰۳ از سازمان مدیریت پسماند شهرداری تبریز اخذ شد. برای اطمینان از دقت و صحت داده‌ها و آماده‌سازی آنها برای استفاده در مدل، پاک‌سازی داده‌ها از لحاظ وجود داده ناقص یا نامعتبر انجام شده و نرمال‌سازی داده‌ها به منظور عملکرد بهتر مدل، تسریع همگرایی، جلوگیری از پدیده ناپدید شده یا انفجار گرادیان در محاسبات شبکه عصبی و هم‌چنین تسهیل توزین وزن‌ها در شبکه‌های عصبی به روش Min-Max Scale انجام شد.<sup>۳۴</sup>

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

در ادامه، آماده‌سازی سری زمانی و تقسیم داده‌ها به دو دسته داده‌های آموزش (Train) و تست (Test) به نسبت ۸۵ به ۱۵ انجام شد تا علاوه بر یادگیری، دقت آن بر روی داده‌های تست نیز سنجیده شود. مدل اجرایی در این مطالعه، یک شبکه عصبی هشت لایه می‌باشد که در هر لایه آن ۵۰ واحد محاسباتی قرار دارد. با انجام آزمایش‌های متعدد، مشخص شد که این مدل توانایی کافی برای استفاده در این مطالعه را دارا بوده و گسترش تعداد لایه‌های شبکه و واحدهای محاسباتی تأثیر چشمگیری در بهبود عملکرد شبکه نداشته و باعث ایجاد سربار زمانی و محاسباتی شد. برای محاسبه مقادیر مورد نظر، در هر گام از ۱۶ داده به عنوان دنباله ورودی برای مدل استفاده شد که با توجه به داده‌های موجود، از کارایی و دقت لازم برخوردار بود. نرخ یادگیری یک هزارم در نظر گرفته شد تا علاوه بر تسریع یادگیری، از بیش‌برازش نیز جلوگیری شود. در شبکه‌های استفاده شده، از تابع گرادیان کاهشی به عنوان تابع بهینه‌ساز استفاده شد و چرخه تکرار ۶۰۰ در نظر گرفته شد که علاوه بر رسیدن به همگرایی و داشتن کمترین میزان تابع خطا، یادگیری در بیش‌ترین

تغییر سطح ناگهانی شود، مثلاً مقدار یک داده از ۱۰ به ۱۰۰ تغییر داشته باشد و همانجا بماند، دروازه فراموشی وضعیت عادی قدیم (۱۰) را کنار می‌گذارد و حالت داخلی خود را برای تطابق با سطح جدید (۱۰۰) بازنشانی می‌کند.

۲. دروازه ورودی (Input Gate): یاد می‌گیرد چه اطلاعات جدیدی اهمیت دارد و به صورت انتخابی، حالت سلول حافظه را با اطلاعات جدید به روز می‌کند. وقتی داده جهت خود را تغییر می‌دهد، مثلاً از روند صعودی به نزولی، این واحد مقدار جاری را با مقدار حافظه ذخیره شده مقایسه می‌کند. اگر مقدار جدید با روند گذشته تناقض داشته باشد، دروازه ورودی حافظه قدیمی را حذف کرده و الگوی جدید را در حافظه می‌نویسد. در واقع LSTM تشخیص روند غیرخطی و پویا را بدون آن که شما ویژگی را بسازید، یاد می‌گیرد.


۳. دروازه خروجی (Output Gate): یاد می‌گیرد کدام بافت برای پیش‌بینی مناسب است (تغییر فصلی بودن یا نوسان‌پذیری)، حالت سلول را فیلتر می‌کند تا حالت پنهانی که برای پیش‌بینی استفاده می‌شود تولید شود. اگر داده شما نوسان‌پذیری متغیر داشته باشد، مثلاً نوسان‌های کوچک تبدیل به نوسان‌های بزرگ شوند، دروازه خروجی یاد می‌گیرد که حالت پنهان را متناسب با آن مقیاس‌گذاری کند. یعنی یاد می‌گیرد که ورودی‌های اخیر با دامنه بالا باید خروجی متفاوتی ایجاد کنند. این مشابه یادگیری «ویژگی مقیاس‌گذاری پویا» بدون دخالت شماست.

۴. حالت سلول (Cell State) به عنوان بردار ویژگی یادگرفته شده: حالت سلول (همان حافظه بلندمدت داخلی LSTM) خود بردار ویژگی است. در هر گام زمانی، LSTM این بردار را فقط با استفاده از ورودی خام و وضعیت قبلی خود تکامل می‌بخشد. پس از آموزش، حالت سلول در زمان  $t$  شامل یک بازنمایی سطح بالا و فشرده از تاریخچه دنباله است که برای وظیفه پیش‌بینی بهینه شده است.

اجزای اصلی داده‌های سری زمانی شامل چهار مؤلفه اصلی روند (حرکت بلندمدت و جهت‌دار سری زمانی صعودی، نزولی یا ثابت)، فصلی بودن (الگوهای تکرارشونده و منظم در بازه‌های زمانی ثابت مثلاً هر سال، هر ماه، هر هفته)، چرخه‌ای بودن (نوسانات بلندمدت‌تر و نامنظم‌تر که وابسته به چرخه‌های اقتصادی یا طبیعی هستند)، نویز/اختلال (تغییرات تصادفی و غیرقابل پیش‌بینی که توسط

کتابخانه‌های Numpy و Pandas برای پردازش داده‌ها، کتابخانه Matplotlib برای بصری‌سازی داده‌ها و نتایج و از فریم ورک Pytorch برای طراحی و آموزش مدل LSTM استفاده شده است. مراحل آماده‌سازی و اجرای مدل در شکل ۲ نشان داده شده است.

سطح انجام شود. با انتخاب بهینه تابع فعال‌ساز و نرخ یادگیری سعی شده است با توجه به محدودیت داده‌ها تا حد ممکن از بیش برآزش جلوگیری شود تا خللی در روند انجام کار مدل به وجود نیاید. در این مطالعه، از زبان برنامه‌نویسی پایتون برای کدنویسی و اجرای مدل،



شکل ۲. روند اجرای مدل

میانگین خطای مطلق بدون در نظر گرفتن جهت خطا، اختلاف مقداری هر داده واقعی و داده پیش‌بینی شده را اندازه‌گیری می‌کند. MAE، قدر مطلق تفاوت بین مقادیر پیش‌بینی شده و واقعی را اندازه می‌گیرد و به‌صورت زیر محاسبه می‌شود:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

که در آن،  $n$  تعداد داده‌ها،  $y$  مقدار واقعی متغیر و  $\hat{y}$  مقدار پیش‌بینی شده توسط مدل می‌باشد. زمانی که هدف، ارزیابی عملکرد یک مدل رگرسیون باشد، به‌طوری‌که وزن‌های مساوی برای همه‌ی خطاها و صرف‌نظر از دامنه‌ی آن‌ها باشد، MAE یک معیار مفید است. MAE برای درک این‌که چقدر پیش‌بینی‌ها از مقادیر واقعی دور هستند، یک معیار کاملاً قابل تفسیر است. علاوه بر این، نسبت به داده‌های پرت مقاوم است؛ زیرا، خطاهای بزرگ را با مربع کردنشان، بزرگ نمی‌کند. به‌طور خاص، برای مواردی که خطاهای بزرگ به‌طور قابل ملاحظه‌ای از خطاهای کوچک مهم‌تر نیستند، یک معیار مفید است.<sup>۳۴</sup>

### معیارهای ارزیابی

در این مطالعه، از معیارهای مجذور میانگین مربعات خطا (Root-Mean-Square-Error: RMSE)، میانگین خطای مطلق (Mean Absolute Error: MAE) و خطای میانگین درصدی مطلق (Mean Absolute Percentage Error: MAPE) برای ارزیابی عملکرد و کارایی صحیح مدل استفاده شده است. RMSE، یکی از معیارهای سنجش میزان خطای مقادیر پیش‌بینی شده توسط مدل و مقدار واقعی داده‌ها است. RMSE در واقع نشان می‌دهد که مقادیر پیش‌بینی شده به‌طور متوسط چقدر از مقادیر مشاهده شده در تحلیل رگرسیون فاصله دارند. بنابراین، هر چقدر مقدار آن کمتر باشد، بهتر و دقیق‌تر خواهد بود. این پارامتر یک ابزار مناسب برای مقایسه خطاهای پیش‌بینی شده توسط یک مجموعه داده است. RMSE از رابطه زیر محاسبه می‌شود که در آن  $n$  تعداد داده و  $y$  مقدار واقعی متغیر و  $\hat{y}$  مقدار پیش‌بینی شده توسط مدل می‌باشد.<sup>۳۵</sup>

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

### یافته‌ها

بر اساس داده‌های ثبت شده طی سال‌های ۱۳۹۸ تا ۱۴۰۳ توسط سازمان مدیریت پسماند شهرداری تبریز، متوسط تولید روزانه پسماند عادی شهر حدود ۹۸۰ تن بوده است. میانگین پسماند تولید شده در شهر تبریز در این بازه زمانی به تفکیک ماه و سال در جدول ۱ ارائه شده است. داده‌های به‌دست آمده مربوط به تناژ جمع‌آوری شده توسط سازمان مدیریت پسماند شهرداری تبریز می‌باشد و بخشی از پسماند تولیدی به دلایلی همچون تفکیک و یا بازیافت غیرقانونی، در مقادیر ارائه شده لحاظ نشده است. داده‌های تناژ روزانه پسماند عادی تبریز پس از بررسی اولیه و حذف داده‌های غیرمنطقی (۱۱ مورد) و جایگزینی داده‌های حذف شده با میانگین بیست روزه (۱۰ روز ماقبل و ۱۰ روز مابعد داده‌های حذف شده) مورد استفاده قرار گرفت.

خطای میانگین درصدی مطلق (MAPE) که به‌عنوان میانگین درصد انحراف مطلق (MAPD) نیز شناخته می‌شود، معیاری برای ارزیابی دقت یک روش پیش‌بینی در علم آمار بوده و با استفاده از فرمول زیر تعیین می‌شود.

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

که در آن،  $n$  تعداد داده‌ها،  $y$  مقدار واقعی متغیر و  $\hat{y}$  مقدار پیش‌بینی شده توسط مدل می‌باشد. این معیار، میانگین تفاوت نسبی بین مقادیر پیش‌بینی شده و حقیقی را محاسبه و به‌صورت درصد بیان می‌کند. معیار MAPE در تحلیل سری‌های زمانی کاربرد گسترده‌ای دارد. سری‌های زمانی، مجموعه‌ای از داده‌ها هستند که در طول زمان جمع‌آوری شده‌اند. تحلیل سری‌های زمانی به ما کمک می‌کند تا الگوهای داده را شناسایی کرده و پیش‌بینی دقیق‌تری از آینده داشته باشیم.<sup>۳۶</sup>


جدول ۱. میانگین پسماند تولیدی (بر حسب تن در روز) در شهر تبریز از سال ۱۳۹۸ تا ۱۴۰۳

| سال      | ۱۳۹۸    | ۱۳۹۹     | ۱۴۰۰    | ۱۴۰۱    | ۱۴۰۲    | ۱۴۰۳    |
|----------|---------|----------|---------|---------|---------|---------|
| ماه      | فروردین | اردیبهشت | خرداد   | تیر     | مرداد   | شهریور  |
| فروردین  | ۸۲۸/۶۰  | ۹۸۴/۵۶   | ۸۹۳/۰۸  | ۸۹۸/۸۶  | ۸۵۵/۰۶  | ۹۱۷/۰۳  |
| اردیبهشت | ۹۴۹/۳۷  | ۱۰۸۹/۶۴  | ۱۰۴۲/۰۲ | ۹۶۷/۸۷  | ۹۳۹/۰۹  | ۱۰۲۲/۰۶ |
| خرداد    | ۱۰۰۳/۴۶ | ۱۰۹۷/۸۱۶ | ۹۶۸/۴۷  | ۹۴۷/۱۹  | ۹۶۴/۱۱  | ۱۰۱۱/۵۶ |
| تیر      | ۱۰۴۱/۶۷ | ۱۰۶۱/۶۹  | ۹۹۴/۲۳  | ۱۰۰۱/۴۲ | ۱۰۱۱/۱۶ | ۱۰۰۶/۷  |
| مرداد    | ۱۱۲۳/۵۹ | ۱۰۸۱/۹۵  | ۹۹۲/۶۲  | ۱۰۶۹/۰۱ | ۱۰۳۲/۰۵ | ۱۰۹۵/۳۹ |
| شهریور   | ۱۰۷۰/۰۸ | ۱۰۷۱/۹۳  | ۹۹۵/۷۶  | ۱۰۰۲/۱۹ | ۱۰۲۹/۶۱ | ۱۰۸۹/۲۴ |
| مهر      | ۱۰۶۴/۷۱ | ۱۰۵۴/۷۷  | ۹۷۰/۲۸  | ۱۰۰۰/۹۰ | ۱۰۴۴/۸۱ | ۱۰۹۵/۳۶ |
| آبان     | ۱۰۰۶/۵۷ | ۱۰۲۳/۹۹  | ۹۷۲/۷۲  | ۹۹۷/۱۰  | ۱۰۲۸/۱۱ | ۱۰۲۱/۲۶ |
| آذر      | ۹۷۴/۸۶  | ۹۴۷/۳۴   | ۹۳۷/۵۵  | ۹۵۹/۷۸  | ۹۷۳/۲۵  | ۹۸۹/۹۷  |
| دی       | ۸۲۳/۴۸  | ۸۶۲/۵۷   | ۸۲۶/۰۳  | ۸۵۱/۲۸  | ۹۳۰/۶۰  | ۹۳۷/۱۰  |
| بهمن     | ۷۵۰/۸۸  | ۸۴۵/۸۲   | ۸۳۹/۹۲  | ۸۱۸/۳۶  | ۸۸۳/۴۲  | ۸۷۴/۳۹  |
| اسفند    | ۱۱۷۳/۰۹ | ۹۷۲/۸۶   | ۱۰۲۸/۱۴ | ۱۰۳۴/۱۲ | ۱۰۱۸/۲۸ | ۹۹۴/۴۳  |

است. با توجه به ماهیت مسئله که برآورد میزان عددی یک واحد می‌باشد و همین‌طور توجه به این مسئله که معیار مورد نظر یک واحد پیوسته می‌باشد و نه طبقه‌بندی، از این رو اعداد پیش‌بینی نمی‌توانند مانند مباحث طبقه‌بندی دقیقاً منطبق بر نتایج واقعی باشند. این اعداد اکثراً با فاصله قابل قبول از نتایج واقعی قرار می‌گیرند که در نمودار ارائه شده هم این مطلب به غیر از چند مورد می‌توان ادعا کرد که با فاصله قابل قبولی نتایج را نمایش می‌دهد.

در مرحله اول، داده‌های سال ۱۳۹۸ تا سال ۱۴۰۲ در اختیار مدل قرار گرفت؛ طوری که، ۸۵ درصد به‌عنوان داده آموزشی و ۱۵ درصد داده‌های باقیمانده به‌عنوان تست برای سنجش دقت مدل در نظر گرفته شد. پس از طی مراحل آموزش مدل، داده‌ها برای سال ۱۴۰۳ توسط مدل پیش‌بینی شده و با داده‌های واقعی همان سال مقایسه شد. مقایسه داده‌های واقعی سال ۱۴۰۳ و مقادیر پیش‌بینی شده برای همان سال در شکل ۳ نشان داده شده

مقادیر شاخص‌های MAE و RMSE در این مرحله در جدول ۲ ارائه شده است.



شکل ۳. مقایسه نتایج پیش‌بینی شده توسط مدل با داده‌های واقعی برای سال ۱۴۰۳

جدول ۲. نتایج معیارهای سنجش دقت مدل بر حسب تن برای سال‌های ۱۳۹۸-۱۴۰۲

| معیار | Train | Test  |
|-------|-------|-------|
| RMSE  | ۵۲/۵۸ | ۷۲/۹۱ |
| MAE   | ۳۳/۹۴ | ۵۵/۰۱ |

روند کلی تولید پسماند عملکرد مناسبی داشته است. از سوی دیگر، RMSE که به خطاهای بزرگ وزن بیشتری می‌دهد، نیز در محدوده‌ای منطقی قرار دارد و نشان می‌دهد که مدل در برابر نوسانات ناگهانی و داده‌های پرت مقاومت مناسبی از خود نشان داده است. مقادیر MAPE نیز برای آموزش و تست به ترتیب ۳/۵۲ و ۵/۸۶ درصد به دست آمده است که حاکی از قابل قبول بودن نتایج می‌باشد.


در مرحله دوم، ۸۵ درصد از داده‌های سال ۱۳۹۸ تا ۱۴۰۳ به‌عنوان داده‌های آموزشی و ۱۵ درصد به‌عنوان داده‌های تست وارد مدل شد. مقادیر شاخص‌های MAE، RMSE و MAPE در این مرحله در جدول ۳ ارائه شده است که نشان‌دهنده دقت قابل قبول مدل در پیش‌بینی کمیت پسماندهای عادی می‌باشد. مقادیر پایین MAE بیانگر آن است که به‌طور میانگین، خطای پیش‌بینی شده مدل در مقایسه با داده‌های واقعی ناچیز بوده و مدل در پیش‌بینی

جدول ۳. نتایج معیارهای سنجش دقت مدل بر حسب تن برای سال‌های ۱۳۹۸-۱۴۰۳

| معیار    | Train | Test  |
|----------|-------|-------|
| RMSE     | ۵۰/۶۲ | ۷۰/۴۷ |
| MAE      | ۳۲/۶۱ | ۵۳/۰۲ |
| MAPE (%) | ۳/۵۲  | ۵/۸۶  |

استفاده شده است. همان گونه که ملاحظه می شود، با توجه به نتایج مربوط به معیارهای ارزیابی، مقادیر پیش بینی شده بر مقادیر واقعی منطبق بوده و نشان دهنده دقت خوب مدل در پیش بینی کمیت پسماندهای عادی است.

به منظور ارائه نمای کلی از داده های واقعی و پیش بینی مدل، نتایج پیش بینی داده های آموزش و آزمون در شکل ۴ نشان داده شده است. در این شکل، رنگ آبی نشان دهنده مقادیر واقعی می باشد که در واقع همان تناژ پسماندهای روزانه شهر تبریز است و رنگ قرمز مربوط به داده های Train می باشد که از آن به منظور آموزش مدل



شکل ۴. نمودار مقادیر واقعی و پیش بینی شده تولید روزانه پسماند در شهر تبریز در مدل آموزش (Train)

مقادیر پیش بینی شده پسماند برای سال های ۱۴۰۴ و ۱۴۰۵ در جدول ۴ ارائه شده است.

جدول ۴. میانگین ماهانه پسماندهای تولیدی پیش بینی شده (بر حسب تن در روز) برای سال های آتی

| سال      | ماه | ۱۴۰۵   | ۱۴۰۴   |
|----------|-----|--------|--------|
|          |     |        |        |
| فروردین  |     | ۱۰۱۹/۲ | ۸۲۲/۳  |
| اردیبهشت |     | ۹۶۷/۶  | ۹۷۳/۶  |
| خرداد    |     | ۹۷۹/۰  | ۹۸۱/۱  |
| تیر      |     | ۹۸۹/۹  | ۸۷۵/۰  |
| مرداد    |     | ۹۹۹/۲  | ۹۰۰/۲  |
| شهریور   |     | ۱۰۶۷/۰ | ۹۸۳/۴  |
| مهر      |     | ۱۰۳۲/۷ | ۱۰۶۴/۰ |
| آبان     |     | ۱۰۳۶/۲ | ۱۰۲۰/۸ |
| آذر      |     | ۱۰۸۶/۸ | ۱۰۷۸/۶ |
| دی       |     | ۹۷۰/۱  | ۱۱۳۶/۷ |
| بهمن     |     | ۹۸۱/۵  | ۹۹۶/۹  |
| اسفند    |     | ۹۶۰/۰  | ۹۶۸/۴  |

## بحث

است. در این پژوهش، به جای آزمون و خطای صرف، از یک رویکرد جستجوی سیستماتیک ترکیبی با الگوریتم LSTM بهینه‌سازی استفاده شد. این روش نه تنها هزینه محاسباتی را کاهش داد، بلکه به ساختاری منجر شد که کمترین خطای تعمیم‌پذیری را نشان داد.

چالش سوم، پدیده بیش‌برازش (Overfitting) است که به‌ویژه در مدل‌های با تعداد پارامتر بالا و داده محدود رخ می‌دهد. در این مطالعه با استفاده از تنظیم دقیق پارامترهایی مانند نرخ یادگیری، تعداد نوروهای لایه میانی، تابع فعال‌سازی و نیز اعمال توقف زودهنگام (Early Stopping) و اعتبارسنجی متقاطع (Cross-Validation) پدیده بیش‌برازش تا حد امکان مهار شد.

جدول ۵ نشان می‌دهد که مدل پیشنهادی این مطالعه، با وجود استفاده از تنها یک متغیر ورودی (میزان تناژ پسماند روزانه تولیدی)، در مقایسه با مدل‌های پیچیده‌تر با ده‌ها متغیر عملکرد رقابتی و در بسیاری موارد برتری دارد.

نتایج حاصل از این پژوهش بیانگر توانایی شبکه‌های عصبی در شناسایی الگوهای پیچیده و غیرخطی موجود در داده‌های سری زمانی پسماند شهری است.<sup>۱۳</sup> با این حال، در راستای استفاده از شبکه‌های عصبی برای پیش‌بینی کمیت پسماندهای عادی، چالش‌هایی نیز وجود دارد. چالش نخست، وابستگی شدید مدل به کیفیت و تداوم داده‌های سری زمانی است. در بسیاری از کشورهای کمتر توسعه یافته و در حال توسعه، مشکلاتی نظیر اندازه‌گیری‌های گسسته، تغییر ناگهانی در روش‌های ثبت داده، یا فقدان ایستگاه‌های پایش مستمر، منجر به ایجاد سری‌های زمانی ناقص یا ناهمگن می‌شود. با این حال، در غیاب داده‌های کافی، توصیه می‌شود از روش‌های بازسازی داده (مانند درون‌یابی یا مدل‌های تولیدی ساده) استفاده شود.

چالش دوم، پیچیدگی انتخاب ساختار بهینه شبکه یکی از دشواری‌های اصلی در طراحی مدل‌های عمیق و سنتی

جدول ۵. مقایسه شاخص‌های ارزیابی ارائه‌شده در این مطالعه با شاخص‌های مطرح در مطالعات پیشین

| سال         | نویسندگان                                    | پارامترهای ورودی                                                                                                             | MAPE (%) | MAE (tone)   | RMSE (tone)  | مدل            |
|-------------|----------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|----------|--------------|--------------|----------------|
| ۲۰۲۱        | الشبوری و همکاران <sup>۳۷</sup> (Elshaboury) | جمعیت، نسبت اشتغال به جمعیت، درآمد سرانه، تعداد نهادها بر اساس نوع فعالیت تجاری و تعداد مشاغل ثبت شده (۲۰۰۳-۲۰۱۹)            | -        | -            | ۳۸۵۷۲        | ANN            |
|             |                                              |                                                                                                                              | -        | -            | ۱۱۳۴۳        | ANN-PSO        |
|             |                                              |                                                                                                                              | ۶/۸۵     | ۱۴۹          | ۱۷۷          | MLP            |
|             |                                              |                                                                                                                              | ۷/۸۰     | ۱۷۷          | ۲۳۲          | GA             |
| ۲۰۲۵        | آلم (Alam) و همکاران <sup>۳۸</sup>           | نرخ تولید پسماند (۲۰۱۷-۲۰۲۱)                                                                                                 | ۱۱/۶۴    | ۲۶۲          | ۳۲۸          | SVM            |
| ۲۰۱۵        | آزادی و همکاران <sup>۳۶</sup>                | جمعیت، میزان جمع‌آوری پسماند، حداکثر دمای فصلی و ارتفاع از سطح دریا (۲۰۰۹-۲۰۱۰)                                              | ۶        | (g/Cap)۳۷/۶۷ | (g/Cap)۵۳/۸۷ | ANN Train      |
|             |                                              |                                                                                                                              | ۸        | (g/Cap)۴۸/۳۷ | (g/Cap)۶۸/۳۲ | ANN Test       |
|             |                                              |                                                                                                                              | ۱۱       | (g/Cap)۶۳/۲۴ | (g/Cap)۸۱/۸۸ | MLR Train      |
|             |                                              |                                                                                                                              | ۱۳       | (g/Cap)۷۶/۳۸ | (g/Cap)۹۵/۱۳ | MLR Test       |
| ۲۰۲۱        | قنبری و همکاران <sup>۳۹</sup>                | بارندگی، نرخ بیکاری، حداکثر دما، جمعیت، اندازه خانوار، تعداد افراد با سواد به تفکیک مرد و زن و همین‌طور شاخص GDP (۱۹۹۱-۲۰۱۳) | -        | ۱۲/۹۲        | ۱۵/۵۸۲       | ANN Train      |
|             |                                              |                                                                                                                              | -        | ۱۷/۹۶        | ۲۰/۹۳        | ANN Test       |
|             |                                              |                                                                                                                              | -        | ۹/۶۶         | ۱۲/۴۸        | RF Train       |
|             |                                              |                                                                                                                              | -        | ۹/۸۸         | ۱۲/۱۶        | RF Test        |
|             |                                              |                                                                                                                              | -        | ۶/۹۰         | ۹/۰۱         | MARS Train     |
|             |                                              |                                                                                                                              | -        | ۱۳/۶۲        | ۱۶/۰۳        | MARS Test      |
|             |                                              |                                                                                                                              | -        | ۶/۴۵         | ۸/۴۵         | MARS-CSA Train |
|             |                                              |                                                                                                                              | -        | ۹/۱۴         | ۱۰/۹۱        | MARS-CSA Test  |
| مطالعه حاضر |                                              | میزان تناژ پسماند روزانه تولیدی                                                                                              | ۳/۵۲     | ۳۲/۶۱        | ۵۰/۶۲        | مدل Train      |
|             |                                              |                                                                                                                              | ۵/۸۶     | ۵۳/۰۲        | ۷۰/۴۷        | پیشنهادی Test  |

### نتیجه‌گیری

این پژوهش با هدف پیش‌بینی کمیت پسماندهای عادی تبریز با استفاده از شبکه عصبی LSTM انجام شد. ساختار LSTM به دلیل توانایی در یادگیری وابستگی‌های زمانی و الگوهای قابل قبول مدل در پیش‌بینی مقادیر و تطابق آن با داده‌های واقعی، نشان‌دهنده عملکرد به نسبت مناسب این روش در درک الگوهای پیچیده و نوسانات موجود در داده‌های تولید پسماند بوده است. استفاده از داده‌های تناژ روزانه پسماند طی یک بازه شش‌ساله، امکان شناسایی روندهای فصلی و الگوهای تولیدی را فراهم آورد و باعث شد تا مدل LSTM بتواند با دقت قابل قبولی، مقادیر را برآورد کند. اگرچه داده‌های شش‌ساله توانستند یک الگوی کلی را نمایان سازند، اما افزایش طول سری زمانی احتمالاً می‌توانست باعث بهبود عملکرد مدل شود. در مجموع، نتایج این پژوهش نشان می‌دهد که شبکه‌های عصبی با طراحی هوشمندانه (نه صرفاً پیچیده) می‌توانند ابزاری کارآمد، کم‌هزینه و دقیق برای پیش‌بینی پسماند عادی باشند. دقت به‌دست‌آمده (خطای حدود ۶ درصد) برای برنامه‌ریزی عملیاتی مدیریت پسماند مانند تخصیص مخازن و ناوگان جمع‌آوری، زمان‌بندی مسیرها و بهینه‌سازی فاصله زمانی جمع‌آوری، کاملاً قابل قبول است.

به کارگیری چنین مدلی می‌تواند به مدیران شهری در برنامه‌ریزی بهینه برای کاهش تولید، جمع‌آوری، حمل و نقل، بازیافت و فرآوری و دفع پسماند و همچنین تدوین سیاست‌های زیست محیطی کمک شایانی نماید. در مجموع بهره‌گیری از رویکردهای هوش مصنوعی، به ویژه شبکه‌های LSTM، چشم‌اندازی نوین و موثر در جهت پیش‌بینی هوشمند پسماندهای عادی فراهم آورد. با این حال، عملکرد آن به کیفیت و گستره داده‌های ورودی وابسته است. این امر اهمیت توسعه سیستم‌های جمع‌آوری و ذخیره‌سازی داده‌های جامع و استاندارد را در مدیریت شهری دوچندان می‌کند.

### پیامدهای عملی پژوهش

فراهم آوردن امکان پیش‌بینی مقادیر پسماندهای عادی، به‌منظور تخصیص کارآمدتر منابع انسانی و تجهیزات لازم و جلوگیری از هدر رفت منابع، همچنین استفاده از نتایج پیش‌بینی در برنامه‌ریزی‌های مربوط به ظرفیت

برای ارزیابی عملکرد مدل پیشنهادی در این پژوهش از شاخص‌های RMSE، MAE و MAPE استفاده شده است. جدول ۵ تحلیل مقایسه‌ای بین روش پیشنهادی و رویکردهای موجود در مطالعات پیشین را نشان می‌دهد. همان‌گونه که مشاهده می‌شود، مدل ارائه شده بر روی داده‌های آموزش توانسته است عدد ۳/۵۲ درصد را برای معیار ارزیابی MAPE به‌دست آورد و این معیار بر روی داده‌های آزمون، برابر با مقدار ۵/۸۶ درصد می‌باشد. معیار MAPE مستقل از پارامتر می‌باشد به این معنی که وابسته به واحد پارامتر نیست. این استقلال از پارامترها برای یک مقایسه عادلانه، ویژگی کاملاً مطلوبی است. این معیار به دلیل وابسته نبودن به مقیاس داده‌ها، می‌تواند تصویر واضح‌تری از مقایسه بین نتایج ارائه نماید. ۴۰ علاوه بر آن، مقادیر ۵۰/۶۲ تن برای داده‌های آموزش و ۷۰/۴۷ تن برای داده‌های آزمون معیار RMSE و مقادیر ۳۲/۶۱ تن برای داده‌های آموزش و ۵۳/۰۲ تن برای داده‌های آزمون برای معیار MAE به دست آمده‌اند.

برتری مدل حاضر را نمی‌توان تنها به نوع شبکه نسبت داد. تحلیل ما نشان می‌دهد که سه عامل کلیدی در این امر نقش داشته‌اند که شامل:

۱. پیش‌پردازش هدفمند شامل حذف روند (Detrending) و نرمال‌سازی مناسب که وابستگی به تغییرات مقیاس را کاهش داده است.
  ۲. انتخاب معماری بهینه با تعداد لایه‌ها و نوروهای متناسب با حجم داده (جلوگیری از پیچیدگی بی‌مورد).
  ۳. تنظیم منظم‌کننده‌ها (Regularization) مانند تابع هزینه یا Dropout (در صورت استفاده) که منجر به تعمیم‌پذیری بهتر شده است.
- این نتایج، کارایی و اثربخشی روش پیشنهادی را تأیید می‌کند و نشان می‌دهد که می‌تواند به‌عنوان جایگزینی قابل اعتماد برای روش‌های موجود در حوزه‌ی برآورد مقادیر پسماندها مورد استفاده قرار گیرد. در مجموع، نتایج این پژوهش بیانگر آن است که شبکه‌های عصبی می‌توانند ابزار کارآمدی در پیش‌بینی مقادیر پسماند عادی باشند و دقت پیش‌بینی قابل قبولی را فراهم آورند. به کارگیری چنین مدلی به مدیران شهری کمک می‌کند تا برنامه‌ریزی بهینه‌تری در خصوص طراحی مدیریت پسماند انجام دهند.

## ملاحظات اخلاقی

این مطالعه توسط کمیته اخلاق در پژوهش‌های زیست پزشکی دانشگاه علوم پزشکی تبریز به شماره کد اخلاقی IR.TBZMED.REC.1403.634 تایید و تصویب شده است.

## استفاده از هوش مصنوعی

اعلام می‌گردد که از ابزار هوش مصنوعی ChatGPT (OpenAI) و Claude AI به منظور جست‌وجو و شناسایی اولیه منابع مرتبط با موضوع پژوهش، بررسی و اصلاح نگارشی چکیده و بخش‌های انگلیسی مقاله و ویرایش زبانی و ساختاری متن استفاده شده است. کلیه منابع و اطلاعات علمی به صورت مستقل توسط نویسندگان بررسی و ارزیابی شده و تحلیل داده‌ها، تفسیر نتایج و نگارش علمی نهایی مقاله توسط نویسندگان انجام شده است. مسئولیت صحت و اعتبار علمی مطالب، نتایج و محتوای نهایی مقاله بر عهده نویسندگان می‌باشد.

## تعارض منافع

در این مطالعه، داده‌های مربوط به مقادیر پسماندهای تولیدی از سازمان مدیریت پسماند شهرداری تبریز دریافت شده است؛ اما هیچ‌گونه بودجه یا قراردادی با شهرداری وجود ندارد. از نرم‌افزار رایگان Python نیز در این زمینه استفاده شده است. هیچ یک از نویسندگان در شرکت یا سازمانی که از نتایج سود می‌برد فعالیت نمی‌کند. بنابراین هیچ تعارض منافی وجود ندارد.

تاسیسات دفع نهایی، سرمایه‌گذاری در تأسیسات بازیافت و فرآوری پسماندها از مهم‌ترین پیامدهای این مطالعه محسوب می‌شوند. لازم به توضیح می‌باشد با توجه به اینکه مدل با استفاده از تنها یک متغیر (میزان پسماند روزانه) به دقت قابل قبولی رسیده است، این روش به راحتی می‌تواند در سایر جوامع در حال توسعه که داده‌های پیچیده اجتماعی-اقتصادی در دسترس نیست، پیاده‌سازی شود.

## قدرانی‌ها

بدین وسیله مراتب امتنان خود از مساعدت‌های بی‌دریغ مسئولان محترم سازمان مدیریت پسماند شهرداری تبریز و نیز تمامی عزیزانی که در مراحل گردآوری داده‌ها ما را همراهی کردند اعلام می‌داریم.

## مشارکت پدیدآوران

معصومه پیری در ایده‌پردازی و طراحی مطالعه، تحلیل داده‌ها و تفسیر نتایج، تدوین نسخه اولیه مقاله؛ سعید پیری در برنامه‌نویسی و پیاده‌سازی نرم‌افزاری؛ حسن تقی‌پور در بازبینی و ویرایش علمی؛ محمدحسن سربازان در گردآوری، سازمان‌دهی و مدیریت داده‌ها و محمد شاکر خطیبی در نظارت و مشاوره علمی، بازبینی و تأیید نهایی نسخه مقاله مشارکت داشتند. نسخه نهایی مقاله مورد تأیید تمامی نویسندگان می‌باشد.

## منابع مالی

این پژوهش فاقد هرگونه منبع مالی خارجی بوده است.

## References

1. Fokker E, Koch T, Dugundji ER. Short-term time series forecasting for multi-site municipal solid waste management. *Procedia Comput Sci.* 2023; 220(9): 170–179. doi: 10.1016/j.procs.2023.03.024
2. Kannangara M, Dua R, Ahmadi L, Bensebaa F. Modeling and prediction of regional municipal solid waste generation and diversion in Canada using machine learning approaches. *Waste Manag.* 2018; 74: 3–15. doi: 10.1016/j.wasman.2017.11.057
3. Aberger J, Shami S, Häcker B, Pestana J, Khodier K, Sarc R. Prototype of AI-powered assistance system for digitalisation of manual waste sorting. *Waste Manag.* 2025; 194: 366–378. doi: 10.1016/j.wasman.2025.01.027
4. Wu F, Niu D, Dai S, Wu B. New insights into regional differences of the predictions of municipal solid waste generation rates using artificial neural networks. *Waste Manag.* 2020; 107(9): 182–190. doi: 10.1016/j.wasman.2020.04.015
5. Anonymous. World Bank Group. 2024. [https://datatopics.worldbank.org/what-a-waste/trends\\_in\\_solid\\_waste\\_management.html](https://datatopics.worldbank.org/what-a-waste/trends_in_solid_waste_management.html)
6. Golhosseini Z, Jalili Ghazizade M. Municipal Solid Waste Status in Iran: From Generation to Disposal. *Environmental Protection Research.* 2024; 4(1): 16–29. doi: 10.37256/epr.4120243553
7. Ayeleru OO, Fajimi LI, Oboirien BO, Olubambi PA. Forecasting municipal solid waste quantity using

- artificial neural network and supported vector machine techniques: A case study of Johannesburg, South Africa. *J Clean Prod.* 2021; 289: 1-10. doi: 10.1016/j.jclepro.2020.125671
8. Khoshgoftar Manesh MH, Davadgaran S, Mousavi Rabeti SA. Gasification potential of municipal solid waste in Iran: Application of life cycle assessment, risk analysis, and machine learning. *J Clean Prod.* 2024; 434(4): 1-26. doi: 10.1016/j.jclepro.2023.140177
9. Liang G, Panahi F, Najah Ahmed A, Ehteram M, Band SS, Elshafie A. Predicting municipal solid waste using a coupled artificial neural network with archimedes optimisation algorithm and socioeconomic components. *J Clean Prod.* 2021; 315: 1-16. doi: 10.1016/j.jclepro.2021.128039
10. Buenrostro O, Bocco G, Vence J. Forecasting generation of urban solid waste in developing countries—A case study in Mexico. *J Air Waste Manag Assoc.* 2001; 51(1): 86–93. doi: 10.1080/10473289.2001.10464258
11. Avinash LS, Mishra A. Comparative evaluation of Artificial intelligence based models and kinetic studies in the prediction of biogas from anaerobic digestion of MSW. *Fuel.* 2024; 367: 131545. doi: 10.1016/j.fuel.2024.131545
12. Chen DM-C, Bodirsky BL, Krueger T, Mishra A, Popp A. The world's growing municipal solid waste: trends and impacts. *Environ Res Lett.* 2020; 15(7): 1-12. doi: 10.1088/1748-9326/ab8659
13. Mounadel A, Ech-Cheikh H, Lissane Elhaq S, Rachid A, Sadik M, Abdellaoui B. Application of artificial intelligence techniques in municipal solid waste management: a systematic literature review. *Environ Tech Rev.* 2023; 12(1): 316–333. doi: 10.1080/21622515.2023.2205027
14. Abdallah M, Talib MA, Feroz S, Nasir Q, Abdalla H, Mahfood B. Artificial intelligence applications in solid waste management: A systematic research review. *Waste Manag.* 2020; 109: 231–246. doi: 10.1016/j.wasman.2020.04.057
15. Lakhout A. Revolutionizing Urban Solid Waste Management with AI and IoT: A review of smart solutions for waste collection, sorting, and recycling. *Results Eng.* 2025; 25(7): 1-10. doi: 10.1016/j.rineng.2025.104018
16. Kumari N, Pandey S, Pandey AK, Banerjee M. Role of artificial intelligence in municipal solid waste management. *British Journal of Multidisciplinary and Advanced Studies.* 2023; 4(3): 5–13. doi: 10.37745/bjmas.2022.0180
17. Fang B, Yu J, Chen Z, Osman AI, Farghali M, Ihara I, et al. Artificial intelligence for waste management in smart cities: a review. *Environ Chem Lett.* 2023; 21(4): 1959–1989. doi: 10.1007/s10311-023-01604-3
18. Munir MT, Li B, Naqvi M, Nizami AS. Green loops and clean skies: Optimizing municipal solid waste management using data science for a circular economy. *Environ Res.* 2024; 243: 117786. doi: 10.1016/j.envres.2023.117786
19. Adamović VM, Antanasijević DZ, Ristić MĐ, Perić-Grujić AA, Pocajt VV. Prediction of municipal solid waste generation using artificial neural network approach enhanced by structural break analysis. *Environ Sci Pollut Res Int.* 2017; 24(1): 299–311. doi: 10.1007/s11356-016-7767-x
20. Paulauskaite-Taraseviciene A, Raudonis V, Sutiene K. Forecasting municipal solid waste in Lithuania by incorporating socioeconomic and geographical factors. *Waste Manag.* 2022; 140: 31–39. doi: 10.1016/j.wasman.2022.01.004
21. Noori R, Abdoli M, Ghasrodashti AA, Jalili Ghazizade M. Prediction of municipal solid waste generation with combination of support vector machine and principal component analysis: A case study of Mashhad. *Environ Prog Sustain Energy.* 2009; 28(2): 249–258. doi: 10.1002/ep.10317
22. Soni U, Roy A, Verma A, Jain V. Forecasting municipal solid waste generation using artificial intelligence models—a case study in India. *SN Appl Sci.* 2019; 1(2): 1-10. doi: 10.1007/s42452-018-0157-x
23. Abbasi M, El Hanandeh A. Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Manag.* 2016; 56: 13–22. doi: 10.1016/j.wasman.2016.05.018
24. Cubillos M. Multi-site household waste generation forecasting using a deep learning approach. *Waste Manag.* 2020; 115: 8–14. doi: 10.1016/j.wasman.2020.06.046
25. Sunayana, Kumar S, Kumar R. Forecasting of municipal solid waste generation using non-linear autoregressive (NAR) neural models. *Waste Manag.* 2021; 121: 206–214. doi: 10.1016/j.wasman.2020.12.011
26. Azadi S, Karimi-Jashni A. Verifying the performance of artificial neural network and multiple linear regression in predicting the mean seasonal municipal solid waste generation rate: A case study of Fars province, Iran. *Waste Manag.* 2016; 48: 14–23. doi: 10.1016/j.wasman.2015.09.034
27. Asadi MJ, Ghayebzadeh M, Seyed Mousavi M, Taghipour H, Aslani H. Investigating the amount of macro, meso, and microplastics in the surface soil around the landfill of Tabriz and the effect of the prevailing wind on their distribution. *Heliyon.* 2025; 11(2): 1-13. doi: 10.1016/j.heliyon.2025.e42143

28. Taheri M, Gholamalifard M, Ghazizade MJ, Rahimoghli S. Environmental impact assessment of municipal solid waste disposal site in Tabriz, Iran using rapid impact assessment matrix. *Impact Assessment and Project Appraisal*. 2014; 32(2): 162–169. doi: 10.1080/14615517.2014.896082
29. Golbaz S, Nabizadeh R, Sajadi HS. Comparative study of predicting hospital solid waste generation using multiple linear regression and artificial intelligence. *J Environ Health Sci Eng*. 2019; 17(1): 41–51. doi: 10.1007/s40201-018-00324-z
30. Nguyen XC, Nguyen TTH, La DD, Kumar G, Rene ER, Nguyen DD, et al. Development of machine learning-based models to forecast solid waste generation in residential areas: A case study from Vietnam. *Resour Conserv Recycl*. 2021; 167: 1-10. doi: 10.1016/j.resconrec.2020.105381
31. Beran J. Mathematical Foundations of Time Series Analysis. Springer; 2017.
32. Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Comput*. 1997; 9(8): 1735–1780. doi: 10.1162/neco.1997.9.8.1735
33. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D*. 2020; 404: 1-28. doi: 10.1016/j.physd.2019.132306
34. Cha GW, Choi SH, Hong WH, Park CW. Developing a prediction model of demolition-waste generation-rate via principal component analysis. *Int J Environ Res Public Health*. 2023; 20(4): 1-15. doi: 10.3390/ijerph20043159
35. Kumar A, Samadder SR. An empirical model for prediction of household solid waste generation rate—A case study of Dhanbad, India. *Waste Manag*. 2017; 68: 3–15. doi: 10.1016/j.wasman.2017.07.034
36. Intharathirat R, Abdul Salam P, Kumar S, Untong A. Forecasting of municipal solid waste quantity in a developing country using multivariate grey models. *Waste Manag*. 2015; 39: 3–14. doi: 10.1016/j.wasman.2015.01.026
37. Elshaboury N, Mohammed Abdelkader E, Al-Sakkaf A, Alfalah G. Predictive analysis of municipal solid waste generation using an optimized neural network model. *Processes*. 2021; 9(11): 1-16. doi: 10.3390/pr9112045
38. Alam S, Rokouzzaman M, Rahman KS, Tan WS. A comparative analysis of forecasting algorithms for predicting municipal solid waste generation in Chittagong City. *Int J Environ Sci Technol (Tehran)*. 2025; 22(14): 14213-14224. doi: 10.1007/s13762-025-06488-0
39. Ghanbari F, Kamalan H, Sarraf A. An evolutionary machine learning approach for municipal solid waste generation estimation utilizing socioeconomic components. *Arabian Journal of Geosciences*. 2021; 14(2): 1-16. doi: 10.1007/s12517-020-06348-w
40. Smailbegovic U, Kadric E, Glöser-Chahoud S. Assessing the Determinants of Municipal Solid Waste Generation in Europe: A Machine Learning Approach. *Waste Manag*. 2025; 205: 115033. doi: 10.1016/j.wasman.2025.115033