



Optimization of Resource Allocation for Disaster Management Based on Artificial Intelligence and Smart Cities

Farshad kaveh ^a, Mahdi Karbasian ^{b*}, Omid Boyer ^c, Hadi Shirouyehzad ^d

^a Department of Industrial Engineering, Na.C., Islamic Azad University, Najafabad, Iran. Farshad.kaveh@iau.ac.ir

^b Department of Industrial Engineering, Malek ashtar University of Technology, Tehran, Iran. mkarbasian@yahoo.com

^c Department of Industrial Engineering, Na.C., Islamic Azad University, Najafabad, Iran. omidboyer@iau.ac.ir

^d Department of Industrial Engineering, Na.C., Islamic Azad University, Najafabad, Iran. Hadi.shirouyehzad@iau.ac.ir

Original Article

Use your device to scan and read the article online



Citation: kaveh F, Karbasian M, Boyer O, Shirouyehzad H. Optimization of Resource Allocation for Disaster Management Based on Artificial Intelligence and Smart Cities. *Industrial Innovations*. 2024; 2(3):301-319.

 <https://doi.org/10.61882/jii.2.3.301>

KEYWORDS

Artificial Intelligence;
Metaheuristic Algorithm;
Smart City;
Multi-objective Optimization;
Disaster Management.

ABSTRACT

Disaster management in metropolitan areas, particularly in the face of earthquakes, is one of the critical challenges of the modern era, requiring effective strategies for optimal resource allocation. This study develops a hybrid model based on artificial intelligence and metaheuristic algorithms with a multi-objective approach to optimize resource allocation. The primary aim of the proposed model is to reduce risk, cost, and response time in disaster situations. In the first phase, machine learning algorithms, namely KNN and XGBoost, are employed to predict the impact of earthquakes across 22 districts of Tehran. The prediction is carried out using three key indicators: urban deterioration, population density, and infrastructure intensity. After evaluating classification metrics such as accuracy, precision, recall, and f1-score, the superior algorithm is selected, and its outputs are incorporated into the mathematical model. The proposed model is then solved using a combination of an exact method and the NSGA-II metaheuristic algorithm. Results indicate that NSGA-II provides superior computational efficiency. Furthermore, integrating machine learning algorithms with the optimization model significantly enhances the objective functions, resulting in reduced risk, lower costs, and improved service response time. Sensitivity analysis reveals that increased demand for resources has the greatest influence on the risk objective function. Moreover, among the predictive variables, population density emerges as the most influential factor in estimating earthquake impact, while deterioration and infrastructure exhibit similar effects and rank lower. Consequently, population density is identified as the most critical feature in the proposed machine learning model.

Extended Abstract

1. Introduction

Crisis management in megacities, particularly in the face of earthquakes, represents one of the most complex challenges of the modern era. High population density, widespread urban deterioration, and fragile infrastructures amplify the vulnerability of these urban areas to disasters. Under such conditions, the optimal allocation of resources becomes a critical necessity to reduce risks and accelerate emergency response. Despite significant advances in disaster prediction, most previous studies have been constrained by linear models and small-scale analyses, limiting their ability to address multi-criteria decision-making at a metropolitan scale. Moreover, traditional resource allocation methods appear insufficient and ineffective when confronted with the nonlinear and uncertain nature of natural disasters.

* Corresponding author.

E-mail address: mkarbasian@yahoo.com

DOI: <https://doi.org/10.61882/jii.2.3.301>

Received: August 19, 2025; Received in revised form: August 30, 2025; Accepted: September 9, 2025.

Article type: Research Paper



To bridge this gap, the present study proposes a hybrid model based on artificial intelligence and metaheuristic algorithms to optimize resource allocation under crisis conditions through a multi-objective approach. In the first step, machine learning algorithms, namely KNN and XGBoost, are employed to predict earthquake impact severity across the 22 districts of Tehran using key indicators such as population density, urban deterioration, and infrastructure availability. The prediction outcomes are then fed into a multi-objective mathematical model, which is solved through an integration of exact methods and the NSGA-II metaheuristic. The primary objective of this research is to minimize risk, cost, and response time in the aftermath of an earthquake. Accordingly, the main innovation of this study lies in integrating intelligent prediction techniques with multi-objective optimization at a metropolitan scale, thereby offering both a scientific and practical tool for decision-makers in disaster management.

2. Methodology

In this study, the problem of resource allocation optimization for disaster management was designed within the context of a smart city framework. The primary goal of the model is to minimize risk, cost, and response time to earthquakes in Tehran megacity. At the first stage, earthquake impact severity was predicted using machine learning algorithms (KNN and XGBoost) based on three key indicators: infrastructure, population density, and urban deterioration. The predicted impact severity (Y), considered as a categorical output variable, was then incorporated into the mathematical optimization model, providing a predictive basis for subsequent decision-making.

The proposed mathematical model was formulated as a multi-objective optimization framework, encompassing three main objectives: (1) minimizing the expected citywide risk, calculated based on disaster probability, impact severity, and regional importance; (2) minimizing the total costs of resource allocation and reactive measures, including logistics, human resources, and equipment costs; and (3) minimizing response time, measured by the duration required to deliver resources to critical regions. A set of constraints was introduced to ensure model feasibility, including resource availability, minimum coverage for high-risk areas, regional capacity limitations, budgetary restrictions, and maximum allowable emergency response time.

The model parameters consist of disaster occurrence probability, machine learning-based impact severity, regional importance (in terms of population or critical infrastructures), allocation costs, absorption capacity, and operational budget. Decision variables include the level of resources allocated to each region, activation of the warning system, and priority indices for proactive management. The case study was conducted on the 22 districts of Tehran under a simulated scenario of a magnitude-7 earthquake. For solving the model, a combination of exact methods and the NSGA-II metaheuristic algorithm was employed to generate a set of Pareto-optimal solutions. This approach allows decision-makers to choose among efficient trade-offs between risk, cost, and response time according to their priorities. The methodological novelty lies in integrating machine learning-based intelligent prediction with multi-objective optimization at a metropolitan scale, thus providing an effective decision-support tool for disaster management in smart cities.

3. Findings

The findings of this study are presented in two main parts: results of machine learning implementation and optimization model performance. In the first stage, the performance of KNN and XGBoost algorithms was evaluated using data from the 22 districts of Tehran. The purpose was to identify the most effective method for predicting earthquake impact severity based on four metrics: Accuracy, Precision, Recall, and F1-score. The results indicated that XGBoost slightly outperformed KNN across all metrics. For instance, the accuracy of XGBoost was 0.968 compared to 0.965 for KNN. The ROC curve further confirmed the superiority of XGBoost, although the confusion matrices showed similar classification outcomes for both algorithms. Feature ranking analysis highlighted population density as the most significant predictor of earthquake impact severity, followed by urban deterioration and infrastructure, which exhibited equal importance.

In the second stage, the proposed optimization model for emergency resource allocation was tested under different dimensions. The model was solved using both the exact method (GAMS software) and the NSGA-II metaheuristic algorithm, and the results were compared. The exact method achieved lower risk values, whereas NSGA-II demonstrated higher efficiency in computational time. Moreover, both methods yielded very close results in terms of cost and service time, confirming the model's validity and robustness.

Finally, the integration of machine learning predictions into the optimization model was assessed. A comparison between the scenarios "with prediction" and "without prediction" revealed that the inclusion of machine learning significantly improved all three main objectives: risk reduction, cost minimization, and service time reduction. These findings emphasize the effectiveness of the proposed hybrid approach as a decision-support tool for disaster management in smart cities.

4. Conclusion

In this study, an integrated approach combining machine learning and metaheuristic methods was proposed to optimize resource allocation and assess earthquake risk in metropolitan areas. In the first step, the earthquake impact intensity was estimated using three key indicators: population density, urban deterioration, and infrastructure conditions, and the regions were systematically classified accordingly. Subsequently, a multi-objective mathematical model with three objectives—minimizing risk, cost, and response time—was developed and solved using both the exact method in GAMS and the NSGA-II metaheuristic algorithm. The results indicated that the two methods provided close solutions in terms of accuracy, with NSGA-II showing superiority in computational time, while the exact method performed better in reducing risk. Regarding machine learning, the XGBoost algorithm outperformed KNN, particularly in improving risk, cost, and computational time. Sensitivity analysis further revealed that increasing available resources had the greatest impact on risk reduction, followed by cost and response time. The findings also highlighted that population density is the most influential factor in earthquake impact intensity, while urban deterioration and infrastructure variables showed nearly equal contributions. Overall, the proposed framework demonstrates the capability of simultaneously addressing risk, cost, and response time, while leveraging machine learning

algorithms to provide more efficient and optimized solutions for earthquake risk management. These results can assist urban managers and crisis decision-makers in prioritizing high-risk areas and allocating resources more effectively, thereby reducing both human and financial losses and significantly enhancing the speed and efficiency of relief operations.

5. Limitations and Future Work

Despite the valuable outcomes of this study, several limitations should be acknowledged. First, the developed model captured only a subset of the inherent uncertainties in earthquake crisis conditions, while more complex aspects such as dynamic population changes, transportation network disruptions, and infrastructure constraints were not considered. Second, the dataset used was limited, whereas in real-world scenarios, incomplete, noisy, or delayed data are far more likely, which may affect the accuracy of the results. Third, the analysis was conducted only within the context of a single metropolitan area, and the generalization of findings to other regions with different social, economic, and physical structures requires further investigation. Fourth, in the comparison of metaheuristic approaches, only NSGA-II was employed, while other advanced and hybrid multi-objective algorithms, such as MOEA/D or NSGA-III, were not evaluated. Accordingly, future research is recommended to incorporate a broader treatment of uncertainty through scenario-based planning, robust optimization, stochastic modeling, or fuzzy approaches. Moreover, employing more realistic and real-time datasets, extending the model to diverse geographical scenarios, and testing advanced multi-objective optimization algorithms could significantly enrich and strengthen both the scientific development and the practical applicability of disaster management strategies.



بهینه‌سازی تخصیص منابع برای مدیریت بلایا مبتنی بر هوش مصنوعی و شهر هوشمند

فرشاد کاوه الف^{*}، مهدی کرباسیان ب^{*}، امید بویرحسینی ج^{*}، هادی شیرویه زاد^د

الف گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران. Farshad.kaveh@iau.ac.ir

ب گروه مهندسی صنایع، دانشگاه صنعتی مالک اشتر، تهران، ایران. mkarbasian@yahoo.com

ج گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران. omidboyer@iau.ac.ir

د گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران. Hadi.shirouyehzad@iau.ac.ir

چکیده	واژگان کلیدی
مدیریت بحران در کلان‌شهرها، به‌ویژه در مواجهه با زلزله، از چالش‌های حیاتی عصر حاضر محسوب می‌شود و نیازمند راهکارهایی برای تخصیص بهینه منابع است. در این پژوهش، مدلی ترکیبی بر پایه هوش مصنوعی و الگوریتم‌های فراابتکاری توسعه‌یافته که با رویکرد چندهدفه به بهینه‌سازی تخصیص منابع می‌پردازد. هدف اصلی این مدل کاهش ریسک، هزینه و زمان واکنش در شرایط بحرانی است. در گام نخست، الگوریتم‌های یادگیری ماشین KNN و XGBoost برای پیش‌بینی شدت اثر زلزله در مناطق ۲۲ گانه شهر تهران به کار گرفته شده‌اند. این پیش‌بینی بر اساس سه شاخص کلیدی؛ میزان فرسودگی بافت، تراکم جمعیت و تعداد زیرساخت‌ها انجام شده است. سپس با ارزیابی معیارهای طبقه‌بندی نظیر accuracy، precision، recall و fl-score، الگوریتم برتر انتخاب و داده‌های حاصل به‌عنوان ورودی مدل ریاضی استفاده گردید. مدل ریاضی پیشنهادی با بهره‌گیری از ترکیب روش دقیق و الگوریتم فراابتکاری NSGA-II حل شد. یافته‌ها نشان دادند که NSGA-II از نظر زمان محاسباتی عملکرد کارآمدتری دارد. همچنین ادغام روش‌های یادگیری ماشین با مدل بهینه‌سازی منجر به بهبود معنادار در توابع هدف، شامل کاهش ریسک، هزینه و زمان خدمت‌رسانی شد. نتایج تحلیل حساسیت نشان داد که افزایش نیاز به منابع بیشترین تأثیر را بر تابع هدف ریسک دارد. علاوه بر این، بررسی متغیرها بیانگر آن است که تراکم جمعیت مهم‌ترین عامل در پیش‌بینی شدت اثر زلزله محسوب می‌شود، درحالی‌که دو متغیر فرسودگی و زیرساخت‌ها اثر مشابهی داشته و در رتبه‌های بعدی قرار می‌گیرند. بدین ترتیب، تراکم جمعیت به‌عنوان اثرگذارترین ویژگی در مدل یادگیری ماشین معرفی می‌شود.	هوش مصنوعی؛ الگوریتم فراابتکاری؛ شهر هوشمند؛ بهینه‌سازی چندهدفه؛ مدیریت بلایا.
	تاریخ دریافت: ۱۴۰۴/۰۵/۲۸
	تاریخ بازنگری: ۱۴۰۴/۰۶/۰۸
	تاریخ پذیرش: ۱۴۰۴/۰۶/۱۸

۱- مقدمه

مدیریت بحران در کلان‌شهرها یکی از چالش‌های اصلی در عصر کنونی است. افزایش جمعیت، تغییرات اقلیمی و پیشرفت‌های سریع در فناوری‌های دیجیتال، منجر به پیچیدگی‌های بیشتری در نحوه پاسخگویی به فاجعه‌ها شده است. در این میان، تخصیص بهینه منابع برای مدیریت بحران و کاهش خطرات ناشی از بلایای طبیعی نظیر زلزله به یک اولویت حیاتی تبدیل شده است [۱]. در گذشته، مدیریت بحران معمولاً بر اساس رویکردهای سنتی مانند تخصیص منابع به‌صورت دستی و بدون در نظر گرفتن

* نویسنده مسئول؛

پیچیدگی‌های ناشی از فاجعه‌های متعدد صورت می‌گرفت، اما با گسترش هوش مصنوعی^۱ (AI) و الگوریتم‌های بهینه‌سازی، روش‌های نوینی برای حل این مسائل به وجود آمده است که به شدت کارایی و دقت مدیریت بحران را افزایش داده‌اند [۲، ۳].

یکی از روش‌های نوآورانه در این زمینه، استفاده از الگوریتم‌های فراابتکاری نظیر NSGA-II^۲ است. این الگوریتم به دلیل توانایی بالایی خود در حل مسائل بهینه‌سازی چندهدفه، به‌ویژه در شرایط پیچیده و با داده‌های بزرگ، توجه زیادی را به خود جلب کرده است. این الگوریتم با استفاده از جمعیت‌های متعدد و عملیات‌هایی چون، انتخاب، جهش و ترکیب، مجموعه‌ای از پاسخ‌های بهینه را در قالب جبهه‌های پارتو ارائه می‌دهد. در نهایت تصمیم‌گیرندگان بر اساس اولویت‌های مورد نظر پاسخ بهینه را انتخاب می‌کنند [۴]. استفاده از الگوریتم‌های فراابتکاری به همراه داده‌های شبیه‌سازی شده می‌تواند به بهبود کیفیت تخصیص منابع و کاهش ریسک‌های ناشی از فاجعه‌ها کمک کند [۵، ۶].

در این پژوهش، تا جایی که ما می‌دانیم؛ برای اولین بار ترکیب هوش مصنوعی و الگوریتم‌های فراابتکاری در مدل‌های بهینه‌سازی تخصیص منابع برای مدیریت بحران در کلان‌شهرها پیشنهاد شده است. در این تحقیق، از الگوریتم NSGA-II برای حل مسائل بهینه‌سازی چندهدفه استفاده شده است. به‌طور خاص، این پژوهش سعی دارد تا بر اساس چندین تابع هدف از جمله کاهش ریسک، هزینه و زمان واکنش، بهترین تخصیص منابع را در برابر زلزله پیش‌بینی کند. این نوآوری به تصمیم‌گیرندگان امکان می‌دهد که جبهه پارتو به‌دست‌آمده را بر اساس اولویت‌های خود تحلیل کرده و بهترین راه‌حل‌ها را انتخاب کنند [۷].

کلان‌شهرها، با تراکم بالای جمعیت، فرسودگی گسترده بافت شهری و پیچیدگی زیرساخت‌ها، در مواجهه با فجایع طبیعی مانند زلزله با چالش‌های جدی در مدیریت بحران روبه‌رو هستند. با وجود مطالعات گسترده در زمینه پیش‌بینی فجایع و تخصیص منابع، اغلب تحقیقات پیشین محدود به مدل‌های خطی، مقیاس‌های کوچک بوده‌اند و توانایی پاسخ به پیچیدگی‌های چندمعیاره و مقیاس کلان‌شهری را ندارند. این پژوهش باهدف پر کردن این شکاف، مدلی ترکیبی ارائه می‌دهد که از الگوریتم‌های یادگیری ماشین KNN و XGBoost برای پیش‌بینی شدت اثر زلزله بر اساس شاخص‌های تراکم جمعیت، فرسودگی بافت و زیرساخت‌ها و از مدل ریاضی چندهدفه با حل ترکیبی دقیق و فراابتکاری NSGA-II برای بهینه‌سازی تخصیص منابع استفاده می‌کند. هدف اصلی این پژوهش، کاهش ریسک، هزینه و زمان واکنش در شرایط بحرانی است. به‌منظور اثبات کارایی و اثربخشی پژوهش مطالعه موردی روی مناطق ۲۲ گانه تهران انجام گردیده است. با تحلیل حساسیت، اثر تغییرات منابع و شاخص‌های کلیدی بر نتایج مدل موردبررسی قرار می‌گیرد. به‌این‌ترتیب، پژوهش حاضر نه‌تنها ابزاری عملی و علمی برای تصمیم‌گیری در مدیریت بحران کلان‌شهرها فراهم می‌آورد، بلکه شکاف موجود در مطالعات پیشین، شامل محدودیت مقیاس، عدم ادغام پیش‌بینی هوشمند و بهینه‌سازی چندهدفه را به‌طور مؤثر برطرف می‌سازد و امکان تخصیص بهینه منابع و کاهش ریسک و زمان واکنش در شرایط بحرانی را فراهم می‌کند.

۲- پیشینه پژوهش

در دهه‌های اخیر، مدیریت بحران به‌عنوان یکی از حوزه‌های مهم در مطالعات کلان‌شهرها و توسعه پایدار شناخته شده است. فاجعه‌های طبیعی نظیر زلزله می‌توانند تأثیرات مخربی بر ساختارهای اجتماعی، اقتصادی و زیست‌محیطی داشته باشند. به همین دلیل، نیاز به مدل‌های بهینه‌سازی برای تخصیص منابع در شرایط بحرانی در این سال‌ها به‌طور فزاینده‌ای افزایش یافته است. در این زمینه، الگوریتم‌های فراابتکاری و هوش مصنوعی به‌عنوان ابزارهای اصلی برای طراحی مدل‌های بهینه‌سازی در شرایط پیچیده و عدم قطعیت مورد استفاده قرار گرفته‌اند [۸].

مدیریت بحران به فرآیند شناسایی، ارزیابی، برنامه‌ریزی و تخصیص منابع به‌منظور کاهش اثرات فاجعه‌ها و واکنش سریع به آن‌ها اطلاق می‌شود. این فرآیند شامل مراحل مختلفی از پیش‌بینی، آمادگی، پاسخ و بازسازی است [۷]. یکی از مشکلات اصلی در این زمینه، تخصیص بهینه منابع برای مقابله با فاجعه‌ها است. تخصیص منابع به‌طور مؤثر می‌تواند تأثیرات منفی فاجعه‌ها را

¹ Artificial Intelligence

² Non-dominated Sorting Genetic Algorithm II

کاهش دهد و زمان واکنش را به حداقل برساند. با این حال، تخصیص منابع به دلیل پیچیدگی‌های موجود در فاجعه‌ها و محدودیت منابع، به چالشی بزرگ تبدیل شده است [۸، ۹].

الگوریتم‌های فراابتکاری به‌عنوان ابزارهای کارآمد برای حل مسائل پیچیده بهینه‌سازی چندهدفه شناخته می‌شوند. این الگوریتم‌ها توانایی بالایی در حل مسائل با داده‌های پیچیده و غیرخطی دارند. یکی از پرکاربردترین الگوریتم‌های فراابتکاری در مدیریت بحران، الگوریتم NSGA-II است. این الگوریتم به دلیل ویژگی‌های خود در مرتب‌سازی غیر برتر و ارائه مجموعه‌ای از راه‌حل‌های بهینه در مدیریت بحران و تخصیص منابع اضطراری مورد استفاده قرار می‌گیرد [۱۰]. در مطالعات مختلف، استفاده از الگوریتم NSGA-II برای تخصیص منابع به مناطق بحرانی به‌دلیل توانایی در حل مسائل بهینه‌سازی چندهدفه، کاهش ریسک، هزینه و زمان واکنش به فاجعه‌ها، اثبات شده است. الگوریتم‌های دیگر مانند الگوریتم ژنتیک، شبیه‌سازی تبرید و الگوریتم‌های مبتنی بر ازدحام ذرات نیز به‌طور گسترده‌ای در مسائل مشابه به کار گرفته شده است [۱۱].

هوش مصنوعی و یادگیری ماشین^۱ ابزارهای قدرتمندی برای تجزیه و تحلیل داده‌های پیچیده و پیش‌بینی رفتارهای سیستم‌های غیرخطی هستند. در مدیریت بحران، این فناوری‌ها برای پیش‌بینی وقوع فاجعه‌ها، شبیه‌سازی سناریوهای مختلف و بهینه‌سازی تخصیص منابع به کار می‌روند. در مطالعات مختلف، مدل‌های پیش‌بینی مبتنی بر یادگیری ماشین توانسته‌اند به پیش‌بینی دقیق‌تری از وقوع فاجعه‌ها نسبت به روش‌های سنتی دست یابند [۱۲].

مدل‌های AI به‌ویژه در شبیه‌سازی و پیش‌بینی شدت فاجعه‌ها و احتمال وقوع آنها نقش حیاتی دارند. این پیش‌بینی‌ها می‌توانند به مدیران بحران کمک کنند تا تخصیص منابع را قبل از وقوع فاجعه به‌طور مؤثرتر انجام دهند. همچنین، استفاده از مدل‌های یادگیری عمیق^۲ برای تجزیه و تحلیل داده‌های حجیم و پیچیده، به‌ویژه در شبیه‌سازی فاجعه‌های طبیعی مانند زلزله، در چند سال اخیر مورد توجه قرار گرفته است [۱۳، ۱۴].

در مطالعات مختلف، مدل‌های چندهدفه برای تخصیص منابع به مناطقی که به‌شدت آسیب‌پذیر هستند یا احتمال وقوع فاجعه در آنها زیاد است، استفاده شده است. به‌طور کلی، مدل‌های بهینه‌سازی چندهدفه تلاش دارند تا بهترین تعادل ممکن بین اهداف مختلف ایجاد کنند. این نوع مدل‌ها در مدیریت بحران شهری به‌ویژه برای مدیریت محدودیت منابع، اهمیت دارند [۱۵].

در خصوص کلان‌شهر اثر هوش مصنوعی و اینترنت اشیا بر تحول کلان‌شهر بررسی شده است [۱۶]. پیش‌بینی مصرف انرژی در کلان‌شهرها انجام شده است [۱۷]. در ادامه هوش مصنوعی در کلان‌شهرها از نظر کاربردها و موانع بررسی شده است [۱۸]. راه‌حل‌های پیشرفته برای ارتقای ایمنی در حمل‌ونقل با استفاده از هوش مصنوعی در شهر استانبول ترکیه ارائه شده است. هوش مصنوعی برای پیشبرد بخش انرژی در کلان‌شهرها با استفاده از مرور ادبیات اعمال شده است [۱۹، ۲۰]. توصیف کلان‌شهرها بر اساس هوش مصنوعی انجام شده است. ترکیب تکنولوژی‌های شهر هوشمند با تحلیل پیشگویانه پیشرفته برای بررسی‌های ژئوتکنیکی انجام شده است [۲۱، ۲۲]. نقش هوش مصنوعی و کلان داده در ایمنی شهری در کلان‌شهرهای تاب‌آور و مشخصاً شهر توکیو مورد بررسی قرار گرفته است [۲۳]. نقش میانجی هوش مصنوعی در برنامه‌ریزی حمل‌ونقل شهری برای توسعه شهر هوشمند و مفاهیم آن برای شهر لس‌آنجلس ایالات‌متحده مورد بررسی قرار گرفته است. از هوش مصنوعی و تحلیل داده برای بهینه‌سازی تخصیص منابع در کلان‌شهرها استفاده شده است [۲۴، ۲۵].

یکی از چالش‌های اصلی در این حوزه، مدیریت داده‌های بزرگ و پیچیده است. استفاده از مدل‌های پیشرفته برای تحلیل داده‌های زلزله و پیش‌بینی تأثیرات آنها نیازمند توان محاسباتی بالا و الگوریتم‌های پیچیده است. در این راستا، مدل‌های بهینه‌سازی مبتنی بر AI و الگوریتم‌های فراابتکاری می‌توانند به‌طور مؤثری این چالش‌ها را رفع کنند.

نوآوری اصلی در این تحقیق، ترکیب هوش مصنوعی با الگوریتم فراابتکاری NSGA-II برای بهینه‌سازی تخصیص منابع در شرایط بحرانی است. این رویکرد به‌طور خاص برای مدیریت بحران در کلان‌شهرها طراحی شده و به‌طور مؤثری کاهش ریسک،

¹ Machine learning

² Deep Learning

کاهش هزینه و بهبود زمان واکنش را هدف قرار می‌دهد. تفاوت تحقیق حاضر با تحقیقات پیشین ارائه یک الگوی ترکیبی از یادگیری ماشین و فراابتکاری جهت تخصیص منابع در رخداد زلزله در شهر تهران می‌باشد.

۳- مدل ریاضی پژوهش

در این پژوهش، مسئله بهینه‌سازی تخصیص منابع برای مدیریت بلایا مبتنی بر هوش مصنوعی و شهر هوشمند طراحی گردیده است. در این پژوهش تلاش شده است با استفاده از هوش مصنوعی و یک مدل ریاضی چندهدفه، تصمیمات بهینه‌ای در خصوص تخصیص منابع، اولویت‌بندی مناطق پرخطر در شهر تهران، و واکنش سریع به زلزله اتخاذ گردد. فرض بر این است که داده‌های مرتبط با خطرات محتمل زلزله از طریق سنسورهای IoT، داده‌های ماهواره‌ای، و اطلاعات تاریخی در دسترس است. همچنین؛ زیرساخت کلان‌شهر شامل، منابع پاسخ اضطراری، وسایل امداد، نیروی انسانی، و ایستگاه‌های هشداردهنده است. در این پژوهش، شهر تهران به چند ناحیه تقسیم شده و در هر ناحیه احتمال وقوع زلزله در بازه‌های زمانی متفاوت وجود دارد. هدف این مدل آن است که با در نظر گرفتن محدودیت‌های منابع شهر تهران، زمان، و ظرفیت سیستم شهری، ریسک کلی سیستم را کاهش داده، واکنش سریع‌تر و کم‌هزینه‌تری ارائه و درعین حال سطح تاب‌آوری را افزایش دهد.

بنیان‌های اصلی مدل شامل نواحی شهری، منابع واکنش اضطراری و بازه‌های زمانی برنامه‌ریزی هستند. پارامترهای اصلی مدل شامل احتمال وقوع فاجعه در هر ناحیه، شدت تخریب، زمان موردنیاز برای پاسخ، میزان منابع در دسترس، هزینه تخصیص منابع، و اهمیت هر ناحیه از لحاظ جمعیت یا زیرساخت حیاتی می‌باشد. متغیرهای مدل شامل، میزان تخصیص منابع به هر ناحیه از شهر تهران، سطح هشدار اختصاص‌یافته، و اولویت‌بندی نواحی خاص جهت مدیریت پیشگیرانه است. در این راستا، مدل پیشنهادی دارای سه تابع هدف اصلی است. تابع هدف اول، به کمینه‌سازی میزان ریسک کل شهر می‌پردازد که بر پایه احتمال وقوع، شدت اثر و اهمیت ناحیه محاسبه می‌شود. تابع هدف دوم، به کمینه‌سازی هزینه تخصیص منابع و اقدامات واکنشی اختصاص دارد که شامل هزینه‌های لجستیکی، انسانی و تجهیزاتی می‌باشد. تابع هدف سوم، به حداقل سازی زمان واکنش اختصاص دارد و بر مبنای زمان رسیدن منابع به نواحی بحرانی و آماده‌سازی زیرساخت‌ها محاسبه می‌شود.

با استفاده از الگوریتم‌های یادگیری ماشین شدت اثر بر اساس سه متغیر زیرساخت، تراکم و فرسودگی منطقه پیش‌بینی و سپس این پارامتر وارد مدل ریاضی شده و بر اساس آن ریسک، هزینه و زمان پیش‌بینی می‌شود. بنابراین پارامتر شدت اثر پارامتری است که بر اساس عوامل سه‌گانه زیرساخت، تراکم و فرسودگی پیش‌بینی می‌شود و در نهایت اثر الگوریتم‌های یادگیری ماشین که به‌واسطه آن پیش‌بینی شدت اثر صورت گرفته بر نتایج حاصل از مدل یعنی ریسک، هزینه و زمان خدمت‌رسانی اثر می‌گذارد. در جدول ذیل متغیرهای پیش‌بینی‌کننده شدت اثر با استفاده از یادگیری ماشین ارائه شده‌اند.

جدول ۱ متغیرهای پیش‌بینی‌کننده شدت اثر

ردیف	متغیر	نماد متغیر	نوع متغیر	مقیاس متغیر
۱	زیرساخت	X1	ورودی	کمی
۲	تراکم	X2	ورودی	نسبتی
۳	فرسودگی	X3	ورودی	کمی
۴	شدت اثر	Y	خروجی	دسته‌ای

در ادامه مدل ریاضی تحقیق به تفکیک، مجموعه‌ها، پارامترها، متغیرها و توابع هدف و محدودیت‌ها معرفی می‌شوند. مدل ارائه‌شده، بر اساس ترکیبی از مقالات مشابه انجام‌شده در حوزه مورد مطالعه می‌باشد. مرجع [۱۹] و مرجع [۲۳] نمونه‌ای از تحقیقات مدل مشابه در شهر استانبول ترکیه در جهت بهینه‌سازی تخصیص منابع در زمان رخداد زلزله می‌باشند. داده‌های مدل ذیل بر اساس دیتاست منابع تحقیقاتی موجود در خصوص بهینه‌سازی تخصیص منابع در شهرهای هوشمند بدست آمده است. داده‌های زلزله مربوط به تمامی مناطق تهران می‌باشد که برای زلزله ۷ ریشتر با شدت بالا در نظر گرفته شده است.

مجموعه‌ها

Z مجموعه مناطق شهری، با اندیس Z
 R مجموعه منابع اضطراری موجود، با اندیس r
 T مجموعه بازه‌های زمانی تصمیم‌گیری، با اندیس t

پارامترها

P_z احتمال وقوع فاجعه زلزله در منطقه Z (درصد)
 S_z شدت اثر زلزله در منطقه Z پیش‌بینی شده با استفاده از الگوریتم‌های یادگیری ماشین (درصد)
 I_z اهمیت منطقه Z (مانند تراکم جمعیت یا زیرساخت حیاتی) (کمی)
 C_{zrt} هزینه تخصیص یک واحد از منبع r به منطقه Z در زمان t (به ریال)
 NC_{zt} هزینه فعال بودن سامانه هشدار در منطقه Z در زمان t (به ریال)
 A_{rt} تعداد کل منابع r موجود در زمان t (کمی)
 Q_{zr} حداکثر تعداد منبع r که منطقه Z می‌تواند دریافت کند (کمی)
 B سقف بودجه عملیاتی قابل استفاده (ریال)
 θ_{zdt} پارامتر دودویی (۱ اگر منطقه Z در معرض فاجعه زلزله در زمان t باشد، در غیر این صورت ۰) (باینری)
 τ_{zrt} زمان لازم برای رساندن منبع r به منطقه Z در زمان t (کمی)
 γ حداکثر زمان مجاز برای واکنش اضطراری (کمی)

متغیرها

$x_{zrt} \in \mathbb{Z}_+$ تعداد واحدهای تخصیص‌یافته از منبع r به منطقه Z در زمان t
 $a_{zt} \in \{0,1\}$ متغیر دودویی فعال بودن سامانه هشدار در منطقه Z در زمان t
 $p_{zt} \in [0,1]$ شاخص اولویت تخصیص برای منطقه Z در زمان t

توابع هدف

$$\min z1 = \sum_z \sum_t P_z S_z I_z p_{zt} \quad (1)$$

$$\min z2 = \sum_z \sum_r \sum_t C_{zrt} x_{zrt} + \sum_z \sum_t NC_{zt} a_{zt} \quad (2)$$

$$\min z3 = \sum_z \sum_r \sum_t \tau_{zrt} x_{zrt} \quad (3)$$

S.t

$$\sum_z x_{zrt} \leq A_{rt} \quad (4)$$

$$\sum_z x_{zrt} \geq \theta_{zdt} Q_{zr} \quad (5)$$

$$x_{zrt} \leq Q_{zr} \quad (6)$$

$$x_{zrt} \leq M \theta_{zdt} \quad (7)$$

$$a_{zt} \geq \theta_{zdt} \quad (8)$$

$$\sum_z \sum_r \sum_t C_{zrt} x_{zrt} + \sum_z \sum_t NC_{zt} a_{zt} \leq B \quad (9)$$

$$p_{zt} \geq \alpha P_z S_z \quad (10)$$

$$x_{zrt} \geq 0 \quad (11)$$

$$a_{zt} \in \{0,1\} \quad (12)$$

$$p_{st} \geq 0 \quad (13)$$

در مدل ریاضی برای تحلیل پیش‌بینانه و چندهدفه ریسک‌های فاجعه‌بار در کلان‌شهرها، سه تابع هدف و ده محدودیت اصلی لحاظ شده‌اند که هر یک از آن‌ها بُعدی از پیچیدگی‌های واقعی مدیریت بحران را پوشش می‌دهند. در ادامه، شرح تفصیلی و تحلیلی این توابع هدف و محدودیت‌ها به صورت ارائه می‌شود تا مفاهیم مدل به صورت دقیق و یکپارچه روشن می‌شود.

رابطه (۱) به دنبال کمینه‌سازی مقدار ریسک انتظاری کل شهر است. منظور ریسکی است که انتظار می‌رود شهر را به واسطه رخداد زلزله تهدید نماید. رابطه (۲) به منظور کمینه‌سازی هزینه‌های ناشی از واکنش در فاجعه تعریف شده است. این هزینه‌ها شامل تمامی مخارج عملیاتی مربوط به تخصیص منابع از جمله هزینه‌های لجستیکی، حمل‌ونقل، نیروی انسانی، سوخت و سایر عوامل مرتبط است. رابطه (۳) حداقل‌سازی زمان واکنش را با هدف افزایش رضایت از طریق بهبود سرعت واکنش تضمین می‌کند.

رابطه (۴) مربوط به محدودیت در منابع موجود است، به این معنا که مجموع منابع تخصیص‌یافته در هر زمان نباید بیشتر از منابع در دسترس باشد. این محدودیت تضمین می‌کند که مدل تصمیمات را در چارچوب منابع واقعی اتخاذ کند. رابطه (۵) ناظر بر پوشش حداقلی برای مناطق پر ریسک است. این محدودیت بیان می‌کند که در صورت وجود خطر برای یک منطقه، باید حداقل درصدی از ظرفیت منابع ممکن برای آن منطقه تأمین شود. هدف این محدودیت تضمین نوعی عدالت و توازن در توزیع منابع اولیه برای نواحی در معرض خطر است. رابطه (۶) به زمان پاسخ اضطراری اشاره دارد. این محدودیت تضمین می‌کند که زمانی که برای رساندن منابع به مناطق موردنیاز در نظر گرفته شده است، از یک آستانه مشخص بیشتر نباشد تا واکنش به بحران مؤثر باشد. اگر این زمان بیشتر از حد مجاز باشد، تخصیص بی‌اثر تلقی می‌شود. رابطه (۷) محدودیت ظرفیت جذب منابع توسط مناطق است. هر منطقه توان محدودی برای پذیرش منابع اضطراری دارد (برای مثال، ظرفیت تخت‌های بیمارستان یا ظرفیت پارکینگ ماشین‌های امداد) و این محدودیت از تخصیص بیش‌ازحد منابع به یک منطقه جلوگیری می‌کند. رابطه (۸) بیان می‌کند که تخصیص منابع فقط باید برای مناطقی انجام شود که واقعاً در معرض خطر هستند. این محدودیت با استفاده از یک پارامتر دودویی خطر، تضمین می‌کند که منابع به مناطق بی‌خطر اختصاص نیابند و کارایی سیستم کاهش نیابد. رابطه (۹) مربوط به محدودیت بودجه کلی عملیات است. مدل باید تضمین کند که مجموع هزینه‌های تخصیص منابع از سقف بودجه مشخص شده فراتر نرود. این محدودیت باعث می‌شود که مدل تصمیماتی اتخاذ کند که از نظر مالی قابل اجرا باشند. رابطه (۱۰) به سازگاری منطقی بین شدت ریسک و شاخص اولویت تخصیص اشاره دارد. به این معنا که اگر احتمال وقوع فاجعه و شدت آن در منطقه‌ای زیاد باشد، شاخص اولویت تخصیص منابع به آن منطقه باید به تناسب افزایش یابد و مدل باید این رابطه را رعایت کند. محدودیت‌های ۱۲ تا ۱۴ نشانگر بازه متغیرهای عدد صحیح مسئله است.

۴- روش حل مدل

به منظور حل مدل ارائه شده از الگوریتم‌های یادگیری ماشین و الگوریتم فرا ابتکاری NSGA-II و روش دقیق استفاده می‌شود. دو الگوریتم KNN و XGboost به منظور پیش‌بینی شدت اثر و در واقع دسته‌بندی آن استفاده می‌شود. هر دو الگوریتم دارای قابلیت دسته‌بندی متغیرهای خروجی می‌باشند البته آنها دارای ماهیت رگرسیونی نیز هستند اما در تحقیق حاضر این دو الگوریتم برای دسته‌بندی سطح ریسک و شدت اثر زلزله در مناطق استفاده می‌شود. الگوریتمی که دارای بیشترین دقت، precision، recall و f1score accuracy باشد به عنوان الگوریتم برتر انتخاب می‌شود این چهار شاخص برای تعیین قابلیت الگوریتم برای دسته‌بندی متغیر خروجی استفاده می‌شود. هر چه مقدار بدست آمده برای یک الگوریتم بالاتر باشد عملکرد بهتری را از یک الگوریتم نشان می‌دهد؛ به عنوان نمونه accuracy نشانگر دقت دسته‌بندی می‌باشد. ضمن اینکه نمودار ROC^۱ ماتریس سردرگمی و اولویت‌بندی عوامل اثرگذار به تفکیک هر الگوریتم ارائه می‌شود. این دو الگوریتم الگوریتم‌های مناسبی برای دسته‌بندی و به زبان پایتون پیاده‌سازی می‌شوند. پس از آن به منظور حل مدل ریاضی از دو الگوریتم اپسیلون محدودیت در نرم‌افزار گمز و الگوریتم NSGA-II به منظور بهینه‌سازی مسئله استفاده می‌گردد. سپس نتایج حاصل از توابع هدف به تفکیک هر روش با هم مقایسه شده و بهترین الگوریتم معرفی می‌شود. الگوریتم NSGA-II شکل دو هدفه الگوریتم ژنتیک می‌باشد که قادر به حل مسائل چند هدفه می‌باشد و در نرم‌افزار متلب پیاده‌سازی می‌شود. در ادامه تحلیل حساسیت پارامتری برای پارامتر منابع صورت گرفته و نتایج آن بر توابع هدف اندازه‌گیری می‌شود.

¹ Receiver Operating Characteristics

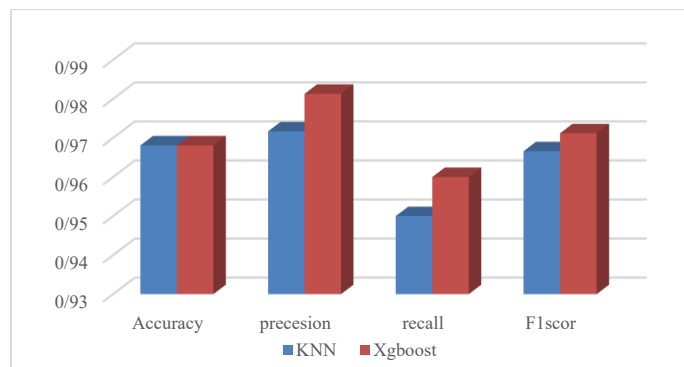
۵- تحلیل نتایج

در این بخش به تحلیل نتایج پرداخته می‌شود ابتدا نتایج پیاده‌سازی الگوریتم‌های یادگیری ماشین ارائه شده و سپس حل مدل با استفاده از دو روش دقیق و الگوریتم فراابتکاری انجام شده و نتایج با هم مقایسه می‌شود. نتایج پیاده‌سازی دو الگوریتم یادگیری ماشین به شرح ذیل است. داده‌ها برای مناطق ۲۲ گانه شهر تهران می‌باشد. لازم به ذکر است علت استفاده از دو الگوریتم یادگیری ماشین برای سنجش و شناسایی بهترین الگوریتم از نظر چهار معیار تعیین شده می‌باشد.

جدول ۲ نتایج حاصل از الگوریتم‌های یادگیری ماشین پیاده‌سازی شده


الگوریتم	Accuracy	precision	recall	F1scor
KNN	0.965	0.971	0.95	0.966
Xgboost	0.968	0.981	0.96	0.971

در جدول ۲ مقادیر پارامترهای Accuracy, precision, recall, f1score ارائه شده است. نتایج پارامترهای چهارگانه برای الگوریتم XGBoost بالاتر از الگوریتم KNN بوده و این نشانگر برتری الگوریتم XGBoost است. برای روشن شدن نتایج نمودارهای ذیل ارائه گردیده است.



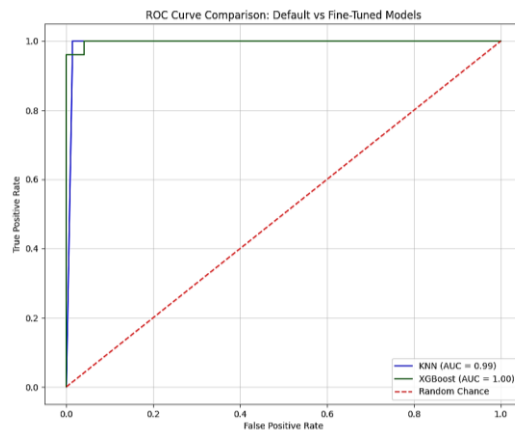
نمودار ۱ مقایسه مقادیر accuracy, precision, recall, f1score بین دو الگوریتم KNN و xgboost (در بازه بین صفر و ۱)

همان‌گونه که مشاهده می‌شود مقدار هر چهار معیار برای الگوریتم XGBoost بالاتر از KNN می‌باشد هر چند فاصله تقریباً نزدیکی بین دو الگوریتم از نظر معیارهای فوق وجود دارد اما الگوریتم XGBoost اندکی نتایج بهتری را کسب کرده است. بنابراین می‌توان گفت الگوریتم برتر در مقاله حاضر الگوریتم XGBoost می‌باشد.



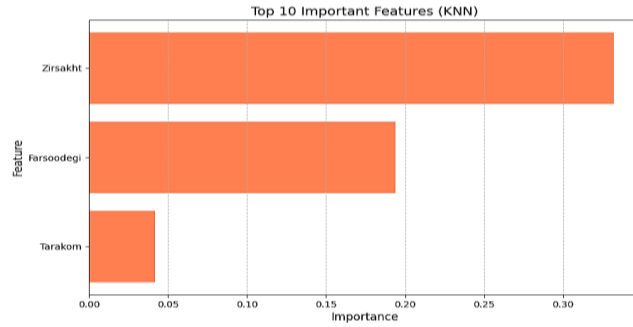
نمودار ۲ ماتریس درهم‌ریختگی الگوریتم‌های KNN و xgboost

نتایج نشان می‌دهد ماتریس درهم‌ریختگی برای هر دو الگوریتم نتایج مشابهی را بدست آورده‌اند که این امر نشانگر تشابه بالای دو الگوریتم از نظر کارآمدی می‌باشد. بنابراین از نظر ماتریس درهم‌ریختگی نمی‌توان گفت الگوریتم خاصی در بین دو الگوریتم مورد بررسی، برای پیش‌بینی شدت اثر زلزله، الگوریتم برتر می‌باشد. ماتریس درهم‌ریختگی ناشی از پیاده‌سازی کتابخانه confusion به زبان پایتون می‌باشد که نشان می‌دهد؛ قطر اصلی و قطر فرعی هر الگوریتم در چه میزان بوده و هر چه قطر اصلی بیشتر و قطر فرعی کمتر باشد، عملکرد بهتری از الگوریتم را نشان می‌دهد.

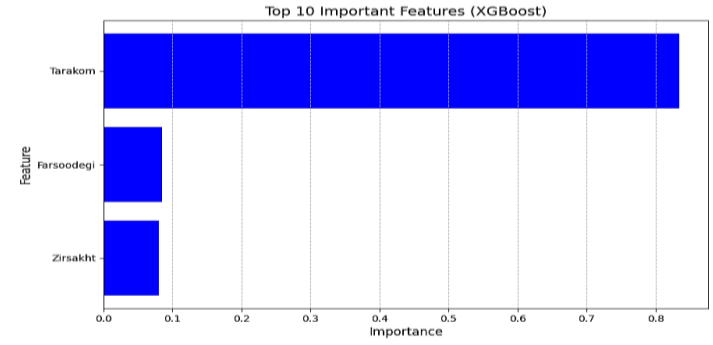


نمودار ۳ مقایسه‌ای ROC بین الگوریتم‌های KNN و XGBoost

بر اساس نمودار فوق می‌توان مشاهده کرد که عملکرد XGBoost در خصوص پیش‌بینی شدت اثر زلزله اندکی بهتر از KNN است. زیرا، نمودار سبز که مربوط به XGBoost می‌باشد، در سطح بالاتری نسبت به KNN قرار دارد. بنابراین در خصوص نمودار ROC نیز می‌توان شاهد برتری الگوریتم XGBoost نسبت به الگوریتم KNN بود. پس از تعیین الگوریتم برتر و مقایسه الگوریتم‌ها در دسته‌بندی شدت اثر در ادامه تعیین می‌شود که کدام ویژگی‌ها دارای اثر بیشتری می‌باشند. در نمودارهای ذیل رتبه‌بندی ویژگی‌ها ارائه شده است.



نمودار ۴ رتبه‌بندی ویژگی‌ها بر اساس الگوریتم KNN



نمودار ۵ رتبه‌بندی ویژگی‌ها بر اساس الگوریتم XGboost

بر اساس نمودارهای فوق رتبه‌بندی ویژگی‌ها صورت گرفته است اما باید اشاره شود باتوجه به اینکه الگوریتم XGboost الگوریتم برتر می‌باشد بنابراین نتایج رتبه‌بندی بر اساس این الگوریتم معیار می‌باشد. همان‌گونه که دیده می‌شود؛ تراکم دارای بیشترین اثر بوده و بیش از همه می‌تواند پیش‌بینی‌کننده شدت اثر زلزله باشد و پس از آن فرسودگی و زیرساخت با اثری برابر با یکدیگر قرار داشته و تفاوتی بین آنها دیده نمی‌شود از این لحاظ، تراکم اثرگذارترین ویژگی در مدل یادگیری ماشین را دارا می‌باشد.

در ادامه بخش دوم تجزیه و تحلیل مربوط به مسئله بهینه‌سازی انجام می‌شود. پس از تعیین شدت اثر زلزله با استفاده از الگوریتم‌های یادگیری ماشین به پیاده‌سازی مدل پرداخته می‌شود. پیش از آن ابعاد مدل در جدول ۳ ارائه شده است.

جدول ۳ ابعاد مدل پژوهش


مناطق	منابع اضطراری (هزار واحد)	بازه‌های زمانی (روز)
۱	۱	۱
۲	۱	۲
۳	۲	۳
۴	۲	۴
۵	۳	۵
۶	۳	۶
۷	۴	۷
۸	۴	۸
۹	۵	۹
۱۰	۵	۱۰
۱۱	۶	۱۱
۱۲	۶	۱۲
۱۳	۷	۱۳
۱۴	۷	۱۴

مناطق	منابع اضطراری (هزار واحد)	بازه‌های زمانی (روز)
۱۵	۸	۱۵
۱۶	۸	۱۷
۱۷	۹	۲۰
۱۸	۹	۲۲
۱۹	۱۰	۲۳
۲۰	۱۰	۲۵
۲۱	۱۰	۲۸
۲۲	۱۰	۳۰

در جدول ۳، ابعاد مسئله معرفی شده و مناطق در هر بعد نسبت به بعد قبلی افزایش یافته است. این کار باعث می‌شود امکان اعتبارسنجی مدل فراهم شود. پس از تعیین ابعاد مدل، مدل در ابعاد مختلف با استفاده از دو الگوریتم NSGA-II و نرم‌افزار گمز حل شده و نتایج حاصل از آن در جدول ۴ با هم مقایسه گردیده است.

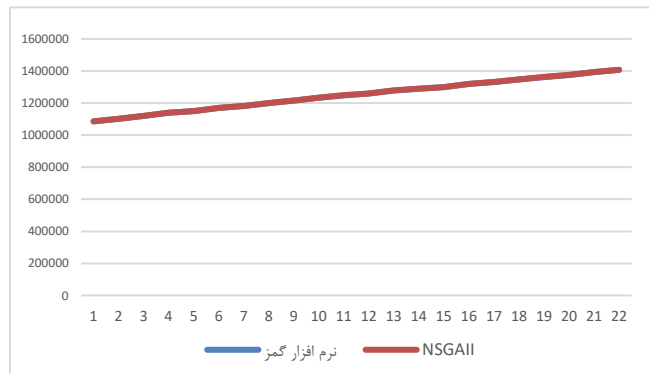
جدول ۴ حل مدل در ابعاد مختلف

مناطق	نرم‌افزار گمز				NSGA-II			
	ریسک (عدد)	هزینه (ریال)	زمان (ساعت)	زمان محاسبه (ثانیه)	ریسک (عدد)	هزینه (ریال)	زمان (ساعت)	زمان محاسبه
۱	۷.۸۲۴۰۸	۱۰.۸۵۷۳۴	۸۲۲۹۸	۹	۷.۴۰۲۶۴۵	۱۰.۸۵۵۸۱	۸۲۲۸۷	۸
۲	۹.۱۱۵۸۹۸	۱۱.۰۱۵۱۳	۸۴۱۵۴	۱۰	۸.۳۴۰۸۰۹	۱۱.۰۱۳۷۹	۸۴۱۳۸	۸
۳	۱۰.۱۰۶۴۶	۱۱۱۹۷۲۱	۸۵۳۹۱	۱۲	۹.۲۶۴۷۵	۱۱۱۹۵۶۲	۸۵۳۷۸	۱۲
۴	۱۰.۱۱۶۱۲	۱۱۳۹۲۲۲	۸۶۹۱۷	۱۲	۹.۲۳۴۶	۱۱۳۹۰۷۳	۸۶۸۹۷	۱۱
۵	۱۰.۸۰۱۱۳	۱۱۴۹۸۹۹	۸۸۳۱۶	۱۳	۱۰.۰۱۷	۱۱۴۹۷۱۴	۸۸۲۹۹	۱۲
۶	۱۲.۱۷۷۹۴	۱۱۶۸۹۰۶	۹۰۲۲۴	۱۴	۱۱.۲۷۵۰۱	۱۱۶۸۷۰۷	۹۰۲۱۲	۱۲
۷	۱۴.۰۲۸۱۶	۱۱۸۱۳۱۴	۹۱۷۸۳	۱۶	۱۳.۶۹۱۳۹	۱۱۸۱۱۳۳	۹۱۷۷۱	۱۴
۸	۱۴.۱۰۶۱۹	۱۱۹۹۳۳۹	۹۳۴۹۴	۱۸	۱۳.۸۷۰۸۲	۱۱۹۹۱۵۷	۹۳۴۷۹	۱۷
۹	۱۴.۴۹۱۶۴	۱۲۱۵۸۹۳	۹۴۶۲۰	۱۹	۱۴.۲۳۵۹۹	۱۲۱۵۷۶۹	۹۴۶۰۵	۱۷
۱۰	۱۶.۴۸۷	۱۲۳۴۵۲۰	۹۶۲۹۳	۲۱	۱۵.۹۷۹۶۶	۱۲۳۴۴۶۵	۹۶۲۸۲	۲۰
۱۱	۱۸.۴۷۸۷۶	۱۲۴۸۶۳۶	۹۷۳۵۸	۲۲	۱۷.۸۱۴۵۲	۱۲۴۸۴۳۶	۹۷۳۴۷	۲۰
۱۲	۱۸.۸۷۱۶۶	۱۲۵۸۷۹۵	۹۸۹۵۴	۲۴	۱۸.۷۰۵۵۲	۱۲۵۸۶۰۷	۹۸۹۳۴	۲۳
۱۳	۱۹.۸۶۷۲۵	۱۲۷۸۴۸۱	۱۰۰۶۷۴	۲۵	۱۹.۰۶۹۵۳	۱۲۷۸۲۸۴	۱۰۰۶۵۶	۲۳
۱۴	۲۰.۰۰۳۷۲	۱۲۸۹۲۴۵	۱۰۱۸۵۴	۲۷	۱۹.۱۴۸۵۹	۱۲۸۹۰۸۱	۱۰۱۸۳۴	۲۵
۱۵	۲۱.۳۵۶۴۹	۱۳۰۰۰۲۸	۱۰۳۱۹۲	۲۹	۲۰.۹۳۲۶۳	۱۲۹۹۸۶۰	۱۰۳۱۷۹	۲۷
۱۶	۲۲.۴۴۰۳۴	۱۳۱۸۵۶۵	۱۰۴۲۱۵	۳۱	۲۲.۳۱۹۳	۱۳۱۸۳۷۷	۱۰۴۲۰۲	۲۹
۱۷	۲۳.۵۱۰۱۶	۱۳۳۲۱۹۸	۱۰۵۸۹۷	۳۳	۲۳.۳۶۲۸	۱۳۳۲۰۵۸	۱۰۵۸۸۰	۳۳
۱۸	۲۴.۱۳۴۶۹	۱۳۴۸۱۲۲	۱۰۷۴۱۵	۳۳	۲۳.۶۳۸۱۷	۱۳۴۸۰۲۰	۱۰۷۳۹۷	۳۳
۱۹	۲۴.۶۴۹۰۱	۱۳۶۲۳۳۸	۱۰۹۱۳۰	۳۳	۲۳.۶۷۵۸۴	۱۳۶۲۲۰۳	۱۰۹۱۱۴	۳۲
۲۰	۲۶.۵۶۸۸۲	۱۳۷۵۱۵۴	۱۱۰۴۴۱	۳۴	۲۶.۴۲۹۷۵	۱۳۷۴۹۵۵	۱۱۰۴۲۴	۳۲
۲۱	۲۸.۰۶۶۲۲	۱۳۹۳۰۵۹	۱۱۱۷۶۷	۳۶	۲۸.۰۴۶۶۲	۱۳۹۲۹۲۰	۱۱۱۷۵۰	۳۵
۲۲	۲۸.۴۵۲۱۱	۱۴۰۷۱۴۲	۱۱۲۹۱۸	۳۷	۲۸.۴۵۲۱۱	۱۴۰۷۱۴۲	۱۱۲۹۱۸	۳۷




نمودار ۶ مقایسه روش دقیق و NSGA-II از نظر میزان ریسک

در نمودار ۶، محور افقی نشانگر مناطق و محور عمودی نشانگر میزان ریسک است. مشاهده می‌شود الگوریتم NSGA-II مقدار ریسک بیشتری را بدست آورده درحالی‌که روش دقیق که با استفاده از نرم‌افزار گمز پیاده‌سازی شده است به مقدار ریسک کمتری دست یافته و این امر نشان می‌دهد روش دقیق در بدست آوردن مقدار ریسک به مقدار بهینه‌تری دست یافته است.



نمودار ۷ مقایسه روش دقیق و NSGA-II از نظر هزینه


در نمودار ۷، محور افقی نشانگر مناطق و محور عمودی نشانگر هزینه است. در این نمودار می‌توان مشاهده کرد؛ با افزایش ابعاد، هزینه افزایش یافته است و این امر نشانگر عملکرد درست مدل است چرا که با افزایش ابعاد واکنش نشان داده است. در نمودار فوق مشاهده می‌شود فاصله اندکی بین روش دقیق و NSGA-II وجود دارد به‌گونه‌ای که نمودارهای روی هم قرار گرفته و بنابراین می‌توان نتایج دو روش را نزدیک به هم دانست. مبنای محاسبه هزینه نتایج حاصل از پیاده‌سازی مدل ریاضی می‌باشد.



نمودار ۸ مقایسه روش دقیق و NSGA-II از نظر زمان خدمت‌رسانی

در نمودار ۸، محور افقی نشانگر مناطق و محور عمودی نشانگر زمان خدمت‌رسانی است. بر اساس نمودار، دید تفاوتی بین دو روش از نظر زمان خدمت‌رسانی وجود نداشته و بنابراین دو روش دقیق و NSGA-II نتایج نسبتاً یکسانی را از نظر زمان


خدمت‌رسانی بدست آورده‌اند و نمی‌توان هیچ روشی را به روش دیگر برتر دانست.



نمودار ۹ مقایسه روش دقیق و NSGA-II از نظر زمان محاسبه

در نمودار ۹، محور افقی نشانگر مناطق و محور عمودی نشانگر زمان محاسبه است. زمان محاسبه به ثانیه معیار دیگری برای مقایسه روش دقیق و NSGA-II است که در نمودار ۹ این مقایسه صورت گرفته است. نتایج نشان می‌دهد الگوریتم NSGA-II زمان محاسبه کمتری را نسبت به نرم‌افزار گمز بدست آورده است و این امر بیان می‌کند که الگوریتم فراابتکاری انتخابی برای حل مدل از نظر زمان محاسبه برتری دارد. نکته حائز اهمیت دیگر این است که با افزایش ابعاد زمان محاسبه افزایش یافته که این نتیجه طبیعی حل مدل می‌باشد و بنابراین می‌توان اعتبار مدل را تأیید نمود.

در ادامه به مقایسه استفاده از الگوریتم‌های یادگیری ماشین در حل مدل بهینه‌سازی پرداخته می‌شود. مقایسه پیش‌بینی شدت اثر و عدم پیش‌بینی آن با استفاده از الگوریتم‌های یادگیری ماشین در نمودار ذیل ارائه شده است. این کار به تفکیک سه تابع هدف صورت گرفته است.




نمودار ۱۰ مقایسه پیش‌بینی با یادگیری ماشین و عدم پیش‌بینی با یادگیری ماشین در خصوص ریسک

در نمودار ۱۰، محور افقی نشانگر مناطق و محور عمودی نشانگر نتایج حاصل در خصوص ریسک می‌باشد. همان‌گونه که در نمودار مشاهده می‌شود، مقایسه پیش‌بینی و عدم پیش‌بینی با الگوریتم‌های یادگیری ماشین در خصوص هفت منطقه آخر ارائه شده است. منظور از عدم پیش‌بینی با استفاده از یادگیری ماشین این است که حالتی وجود دارد که پیش‌بینی شدت اهمیت با الگوریتم‌های یادگیری ماشین انجام نشود و لذا در نمودار ۱۰ هدف سنجش و مقایسه دو حالت استفاده و عدم استفاده از الگوریتم‌های یادگیری ماشین می‌باشد. بر اساس نمودار فوق می‌توان مشاهده کرد که استفاده از یادگیری ماشین باعث جواب بهتری در خصوص ریسک شده و در واقع جواب مرتبط با تابع هدف ریسک را بهبود بخشیده است.



نمودار ۱۱ مقایسه پیش‌بینی با یادگیری ماشین و عدم پیش‌بینی با یادگیری ماشین در خصوص هزینه

در نمودار ۱۱، محور افقی نشانگر مناطق و محور عمودی نشانگر نتایج حاصل در خصوص هزینه می‌باشد. نتایج نشان می‌دهد؛ استفاده از الگوریتم‌های یادگیری ماشین منجر به نتایج بهتری در خصوص هزینه می‌شود و تابع هدف هزینه با توجه به استفاده از الگوریتم‌های یادگیری ماشین بهینه می‌گردد.



نمودار ۱۲ مقایسه پیش‌بینی با یادگیری ماشین و عدم پیش‌بینی با یادگیری ماشین در خصوص زمان خدمت‌رسانی


در نمودار ۱۲، محور افقی نشانگر مناطق و محور عمودی نشانگر نتایج حاصل در خصوص زمان خدمت‌رسانی می‌باشد. استفاده از الگوریتم‌های یادگیری ماشین برای شدت اثر منجر به جواب بهتری در خصوص زمان خدمت‌رسانی شده و به‌طور کلی زمان خدمت‌رسانی با کمک الگوریتم‌های یادگیری ماشین بهبود یافته است.

۵-۱- تحلیل حساسیت

در ادامه به تحلیل حساسیت پارامتری پرداخته می‌شود. به این صورت که اثر منابع بر توابع هدف زمان، هزینه و ریسک اندازه‌گیری می‌گردد. در نهایت نیز، تابعی با بیشترین اثرگذاری در منابع، تعیین می‌شود.

جدول ۵ تحلیل حساسیت منابع مورد نیاز

تغییر در ریسک (درصد)	تغییر در هزینه (درصد)	تغییر در زمان (درصد)	ریسک (کمی)	هزینه (به ریال)	زمان (به ساعت)	حجم منابع مورد نیاز
-	-	-	۱۶.۴۸۷	۱۲۳۴۵۲۰	۹۶۲۹۳	%۰
۰.۰۱۵۳۶۶	۰.۰۱۵۲۷۲	۰.۰۱۱۲۰۵	۱۶.۷۴۰۳۳	۱۲۵۳۳۷۴	۹۷۳۷۲	%۱۰
۰.۰۱۷۰۰۳	۰.۰۲۶۸۶۷	۰.۰۲۵۷۱۶	۱۷.۰۲۴۹۸	۱۲۸۷۰۴۸	۹۹۸۷۶	%۲۰
۰.۰۴۵۶۲۳	۰.۰۴۰۷۷۹	۰.۰۳۵۸۸۴	۱۷.۸۰۱۷۱	۱۳۳۹۵۳۳	۱۰۳۴۶۰	%۳۰
۰.۰۷۱۴۱	۰.۰۴۷۷۵۵	۰.۰۵۱۴۶	۱۹.۰۷۲۹۳	۱۴۰۳۵۰۲	۱۰۸۷۸۴	%۴۰
۰.۱۱۸۲۲۹	۰.۰۵۸۳۹۷	۰.۰۶۲۴۵۴	۲۱.۳۲۷۸۹	۱۴۸۵۴۶۳	۱۱۵۵۷۸	%۵۰



نمودار ۱۳ تحلیل حساسیت منابع مورد نیاز

در نمودار ۱۳، محور افقی نشانگر افزایش درصدی و محور عمودی نشانگر افزایش در میزان منابع می‌باشد. در نمودار فوق مشاهده می‌شود؛ با افزایش نیاز به منابع بیش از همه عامل ریسک دچار تغییر می‌شود چرا که در وضعیت افزایش ۳۰ تا ۵۰ درصدی شاهد افزایش ریسک می‌باشیم. البته باید توجه داشت در وضعیت ۱۰ و ۲۰ درصد این افزایش دیده نمی‌شود. در مجموع می‌توان گفت با افزایش منابع ریسک خطر بیش از سایر توابع هدف افزایش می‌یابد و البته زمان و هزینه به میزان کمتری از افزایش نیاز به منابع تحت تأثیر قرار می‌گیرند.

۶- نتیجه‌گیری

در این پژوهش، ترکیبی از الگوریتم‌های یادگیری ماشین و روش‌های فراابتکاری برای بهینه‌سازی تخصیص منابع و ارزیابی خطرات زلزله در کلان‌شهرها به کار گرفته شد. در گام نخست، شدت اثر زلزله با استفاده از سه شاخص اصلی تراکم جمعیت، میزان فرسودگی بافت‌ها و وضعیت زیرساخت‌ها تخمین زده شد و بر اساس آن، مناطق مختلف دسته‌بندی گردید. در ادامه، یک مدل ریاضی چندهدفه با سه تابع هدف؛ کمینه‌سازی ریسک، هزینه و زمان توسعه داده شد و با استفاده از نرم‌افزار GAMS و الگوریتم NSGA-II حل گردید. نتایج نشان داد که راه‌حل‌های به‌دست‌آمده از نظر دقت به یکدیگر نزدیک هستند. الگوریتم NSGA-II در مقایسه با روش دقیق، از نظر زمان محاسباتی عملکرد بهتری داشت، درحالی‌که روش دقیق از نظر کاهش ریسک برتری نشان داد. در بخش یادگیری ماشین نیز الگوریتم XGBoost عملکرد بهتری نسبت به به‌ویژه در کاهش ریسک، هزینه و زمان محاسبه KNN ارائه داد. تحلیل حساسیت نشان داد که با افزایش منابع، بیشترین تغییر مربوط به ریسک است و پس از آن هزینه و زمان تحت تأثیر قرار می‌گیرند. همچنین مشخص شد که تراکم جمعیت بیشترین نقش را در شدت اثر زلزله دارد، درحالی‌که متغیرهای فرسودگی و زیرساخت اثر تقریباً برابری بر جای گذاشتند. به‌طور کلی، مدل پیشنهادی توانایی در نظر گرفتن هم‌زمان سه بعد ریسک، هزینه و زمان خدمت‌رسانی را دارد و با ترکیب الگوریتم‌های یادگیری ماشین می‌تواند راهکاری بهینه‌تر و کارآمدتر برای مدیریت خطرات زلزله ارائه کند. یافته‌های این پژوهش می‌تواند به مدیران شهری و تصمیم‌گیران حوزه مدیریت بحران کمک کند تا با اولویت‌بندی مناطق بر اساس ریسک و تخصیص بهینه منابع، نه‌تنها از خسارات جانی و مالی ناشی از زلزله بکاهد، بلکه سرعت و کارایی عملیات امداد و نجات را نیز به‌طور چشمگیری بهبود دهند.

۷- محدودیت‌ها و پیشنهادات آتی پژوهش

با وجود نتایج قابل توجه، این پژوهش با چند محدودیت همراه است. نخست، مدل توسعه‌یافته تنها بخشی از عدم قطعیت‌های ذاتی در شرایط بحران زلزله را پوشش می‌دهد و جنبه‌های پیچیده‌تر، از جمله تغییرات جمعیتی و اختلالات شبکه حمل‌ونقل، موردتوجه قرار نگرفت. دوم، داده‌های به‌کاررفته محدود بوده و احتمال وجود داده‌های ناقص یا نویزی در شرایط واقعی بسیار بیشتر است. سوم، مطالعه صرفاً در بستر یک کلان‌شهر انجام شد و قابلیت تعمیم نتایج به سایر مناطق با ساختارهای متفاوت نیازمند بررسی بیشتر است. چهارم، مقایسه روش‌های فراابتکاری به الگوریتم NSGA-II محدود شد و سایر الگوریتم‌های فراابتکاری نوین چندهدفه مورد ارزیابی قرار نگرفتند. براین اساس، پیشنهاد می‌شود؛ تحقیقات آینده با در نظر گرفتن ابعاد عدم قطعیت شامل

رویکردهای سناریو محور، استوار و احتمالی یا فازی تدوین گردند. همچنین، بهره‌گیری از داده‌های واقعی، تعمیم مدل به سناریوهای متنوع جغرافیایی، و ارزیابی الگوریتم‌های پیشرفته‌تر در حوزه بهینه‌سازی چندهدفه، مسیر توسعه علمی و کاربردی مدیریت بلایا را غنی‌تر می‌سازند.

۸- منابع

- [1] Safikhani H, Rafiee M, Ashtiani D. Numerical study of flow field in new design cyclones with different wall temperature profiles: Comparison with conventional ones. *Advanced Powder Technology*. 2021;32:3268-77.
- [2] Suresh N, Karthikeyan M, Sridhar G, Selvakumar A. Sustainable urban planning through AI-driven smart infrastructure: A comprehensive review. *Digital Transformation and Sustainability of Business*. 2025:178-80.
- [3] Yigitcanlar T, Desouza KC, Butler L, Roozkhosh F. Contributions and risks of artificial intelligence (AI) in building smarter cities: Insights from a systematic review of the literature. *Energies*. 2020;13:1473.
- [4] Han C, Zang S. A comprehensive review of disruptive technologies in disaster risk management of smart cities. *Climate Risk Management*. 2025:100703.
- [5] Bajwa A. AI-based emergency response systems: A systematic literature review on smart infrastructure safety. Available at SSRN 5171521. 2025.
- [6] Sudhi M, Aishwarya T, Shetty DK, Balakrishnan JM, Ahmad S, Sankaran PP. AI-driven innovations in emergency and disaster response: Strategies for effective planning. *Proceedings on Engineering*. 2025;7:1293-304.
- [7] Emmanuel O, Aria J, Jose D, Diego C. Cyber-Resilient Smart Cities: The Power of AI and Big Data in Defending Urban Landscapes.
- [8] Kaveh F, Karbasian M, Boyer O, Shirouyehzad H. Humanitarian Relief Logistics Network Design Using Distributional Robust Optimization for Disaster Management. *International Journal of Engineering*. 2025;38:2288-311.
- [9] Rane N, Choudhary S, Rane J. Artificial intelligence for enhancing resilience. *Journal of Applied Artificial Intelligence*. 2024;5:1-33.
- [10] Zia H, Fteiha B, Alrifaae N, Yousaf J, Ghazal M, Harris N. Advancing Smart Cities with Artificial Intelligence: A Systematic Literature Review of Challenges and Future Directions. Available at SSRN 5156689.
- [11] Shahrabani MMN, Apanaviciene R. An AI-based evaluation framework for smart building integration into smart city. *Sustainability*. 2024;16:8032.
- [12] Yigitcanlar T, Mehmood R, Corchado JM. Green artificial intelligence: Towards an efficient, sustainable and equitable technology for smart cities and futures. *Sustainability*. 2021;13:8952.
- [13] Chakrabarty S, Engels DW. Secure smart cities framework using IoT and AI. 2020 IEEE global conference on artificial intelligence and Internet of Things (GCAIoT): IEEE; 2020. p. 1-6.
- [14] Ali J, Singh SK, Jiang W, Alenezi AM, Islam M, Daradkeh YI, et al. A deep dive into cybersecurity solutions for AI-driven IoT-enabled smart cities in advanced communication networks. *Computer Communications*. 2025;229:108000.
- [15] Hilal AM, Alfurhood BS, Al-Wesabi FN, Hamza MA, Duhayyim MA, Iskandar HG. Artificial Intelligence Based Sentiment Analysis for Health Crisis Management in Smart Cities. *Computers, Materials & Continua*. 2022;71.

- [16] Van Hoang T. Impact of integrated artificial intelligence and internet of things technologies on smart city transformation. *Journal of technical education science*. 2024;19:64-73.
- [17] Agarwal D. Energy Consumption Forecasting in Smart Cities Using Predictive Analysis. *International Journal on Engineering Artificial Intelligence Management, Decision Support, and Policies*. 2024;1:9-17.
- [18] Wolniak R, Stecuła K. Artificial intelligence in smart cities—applications, barriers, and future directions: a review. *Smart cities*. 2024;7:1346-89.
- [19] Jagatheesaperumal SK, Bibri SE, Huang J, Rajapandian J, Parthiban B. Artificial intelligence of things for smart cities: advanced solutions for enhancing transportation safety. *Computational Urban Science*. 2024;4:10.
- [20] Camacho JdJ, Aguirre B, Ponce P, Anthony B, Molina A. Leveraging artificial intelligence to bolster the energy sector in smart cities: A literature review. *Energies*. 2024;17:353.
- [21] Cong Y, Inazumi S. Integration of smart city technologies with advanced predictive analytics for geotechnical investigations. *Smart cities*. 2024;7:1089-108.
- [22] Hammoumi L, Maanan M, Rhinane H. Characterizing smart cities based on artificial intelligence. *Smart cities*. 2024;7:1330-45.
- [23] Yedalla J. Building cyber-Resilient Smart Cities: The role of AI and big data in urban security. *International Journal of Science and Research (IJSR)*. 2025;14:648-52.
- [24] Ogundare E. Understanding the mediating role of artificial intelligence in urban transportation planning for smart city development and its implications for the United States. *International Journal of Innovative Science and Research Technology*. 2024;9:10.5281.
- [25] Rahman S, Islam M, Hossain I, Ahmed A. Utilizing AI and data analytics for optimizing resource allocation in smart cities: A US based study. *International journal of artificial intelligence*. 2024;4:70-95.