



Research Paper

# Presenting a Predictive Model of the Physical Vulnerability of Neighborhoods against Earthquakes (Case Study: District 1 of Tehran Municipality)

Maryam Mohammadi <sup>\*1</sup> , Marjan Vosooghi Nia <sup>2</sup> 

<sup>1</sup> Associate Professor, Department of Urban Design, Faculty of Urban Planning and Architecture, University of Art, Iran

<sup>2</sup> M.A. in Urban Design, Department of Urban Design, Faculty of Urban Planning and Architecture, University of Art, Iran



10.22080/USFS.2023.25302.2350

**Received:**

April 25, 2023

**Accepted:**

August 27, 2023

**Available online:**

December 2, 2023

**Keywords:**

Smart crisis management,  
Predictive model,  
Vulnerability, Machine  
learning, Morphology,  
Earthquake

## Abstract

The issue of the physical vulnerability of neighborhoods against earthquakes is the subject of this research. Crisis management and smart crisis management are generally considered in three stages: before, during, and after the crisis. The management of a smart crisis in all three stages, with emphasis on preparedness and anticipation of vulnerability against disasters such as earthquakes, can provide a way to predict vulnerability and increase power in decision-making. The purpose of this research is to present a predictive model for the vulnerability of the physical context against earthquakes in District 1 of Tehran municipality using machine learning. The research method is analytical and quantitative. Some of the data was collected from GIS and some were extracted from the map analysis. According to the use of a supervised learning approach in this research, labeling was performed by researchers in five different spectrums. Decision tree algorithm, support vector machine (SVM), and multilayer neural network (MLP) were used as machine learning algorithms. The portion of training data for the test was considered to be 70 to 30. By examining the accuracy of the model by the confusion matrix, it was found that the decision tree algorithm with an accuracy of 99.50, sensitivity of 99.42, and error of 0.5 has better performance than the other two algorithms. Moreover, the neural network with an accuracy of 97.85, sensitivity of 97.57, and error of 2.15 showed better performance than support vector machine.

**\*Corresponding Author:** Maryam Mohammadi

**Address:** Department of Urban Design, Faculty of Urban Planning and Architecture, University of Art, Iran

**Email:** m.mohammadi@art.ac.ir

## Extended Abstract

### 1. Introduction

The realization of safety quality is one of the main goals of urban planning and design and it is necessary to supply this quality in times of crisis. Due to the unexpected nature of disasters and the need for rapid and correct decisions, crisis management knowledge is considered. This field, as an applied science, is seeking to find a tool for preventing or decreasing effects, rapid relief, and improvement of the situation. This knowledge is referred to as a set of activities that can be done before, after, and during the crisis, to reduce the effects of disasters and decrease vulnerability. Regardless of these categories, smart management includes four parts: preparation, response, rehabilitation, and reduction. In this regard, with the development of technology (development of social networks, sensor networks, artificial intelligence, machine learning, internet of objects, etc.) and the creation of smart infrastructure, the knowledge of smart crisis management is converted to a new way of crisis management. Meanwhile, the application of machine learning in intelligent crisis management based on the preparation and prediction of accidents and disasters, the possibility of data analysis, and appropriate response during crisis management is emphasized. In this research, the management of the smart crisis has been considered at the level of vulnerability reduction and pre-earthquake susceptibility to earthquakes using this approach. The dimension emphasized for crisis management in this research is the morphology dimension, which is the result of space planning and design. According to the conducted studies, the factors affecting the

vulnerability of the city, especially against earthquakes, are the urban form and texture.

### 2. Research Methodology

The present study is descriptive and quantitative. Documents and maps were used in this research. The intended research approach is the use of supervised machine learning. In this type of machine learning, several data are labeled as input during the training process and corresponding output is generated. The data used in this study were the morphological features, which were selected through the expert-oriented approach. Moreover, the CRRIS PDM methodology was used as a data mining process. This methodology, which was presented for the first time in 1996, has a six-step cycle and is composed of problem recognition, data recognition, data preparation, modeling, model evaluation, and deployment. The process of machine learning in this research was done with the help of Rapid Miner software, which can enter other software applications such as Excel and is used in machine learning and predictive analysis. Decision Tree algorithm, Support Vector Machine (SVM), and Multilayer Neural Network (MLP) were used in machine learning. The volume of training data for the test was considered to be 70 to 30.

### 3. Research Findings

The findings of this study indicate a comparison between the results of the algorithms used and then an examination of the difference between this research with the existing knowledge structure. According to the comparison of the performance results, the Decision Tree performs better than the Multilayer Neural Network and supports Vector Machine techniques due to having more

accuracy and sensitivity and less error. Then, the Multilayer Neural Network algorithm has a better performance than the Support Vector Machine algorithm. To compare the accuracy of the algorithms, the Decision Tree and Multilayer Neural Network have a complete accuracy (100%). In this study, according to the aim of determining the predictive model of physical tissue damage to the earthquake, it was necessary to determine and select the indicators first, and in this research compared to other domestic and foreign studies, morphological features were especially considered (actually physical indicators that are important in determining the level of vulnerability to earthquakes). In addition, reviewing literature showed that in the stages of data collection in similar studies, quantitative methods and common urban planning techniques and tools such as spatial analysis in GIS were used. In this research, the machine learning approach was used to identify the predictive model and based on this approach, a set of labeled data was gathered in District 1 of Tehran Municipality based on different resources and maps, which can be used in other studies in this field with the machine learning approach. According to the proposed approach, it is possible to predict the amount of damage by giving new input to the trained and tested machine.

#### **4. Conclusion**

One of the achievements of this research is that it has taken an effective step in fields such as vulnerability prediction, earthquake loss reduction, and detection of the vulnerability of physical texture with the ML approach. Moreover, since this approach can measure the vulnerability of the physical fabric of neighborhoods against earthquakes at high speed and in a

short time, it can be used by executive and management institutions. However, this research has some limitations which are classified into three sections: data collection, financial, and time constraints. In the stage of data collection and referral to relevant organizations, there is a lack of cooperation in some organizations and a lack of access to some information. Additionally, the lack of access to updated information and maps for some of the features, such as the structure of buildings, quality of buildings, and materials, is another limitation of this research. Moreover, since access to large databases needed adequate financial resources, it was not possible to use Deep Learning algorithms.

#### **Funding**

There is no funding support.

#### **Authors' Contribution**

The authors contributed equally to the conceptualization and writing of the article. All of the authors approved the content of the manuscript and agreed on all aspects of the work

#### **Conflict of Interest**

The authors declared no conflict of interest.

#### **Acknowledgments**

The authors appreciate all the scientific consultants in this paper



## علمی پژوهشی

## ارائه مدل پیش‌بینی کننده آسیب‌پذیری کالبدی محلات در برابر زلزله با استفاده از یادگیری ماشین (مطالعه‌ی موردی: منطقه ۱ شهرداری تهران)

مریم محمدی<sup>\*۱</sup> ID، مرجان وثوقی نیا<sup>۲</sup> ID

<sup>۱</sup> دانشیار گروه طراحی شهری، دانشکده معماری و شهرسازی دانشگاه هنر، تهران، ایران.  
<sup>۲</sup> آگروه طراحی شهری، دانشکده معماری و شهرسازی، دانشگاه هنر، تهران، ایران.

doi 10.22080/USFS.2023.25302.2350

## چکیده

مدیریت بحران هوشمند (در سه مرحله قبل، حین و پس‌از آن)، با تأکید بر آمادگی و پیش‌بینی آسیب‌پذیری در برابر زلزله، امکان پیش‌بینی، کاهش آسیب‌پذیری و افزایش قدرت در تصمیم‌سازی را فراهم می‌آورد. این مقاله بر آن است تا با استفاده از یادگیری ماشین، به ارائه مدل پیش‌بینی‌کننده آسیب‌پذیری کالبدی در برابر زلزله بپردازد. روش پژوهش کمی است. داده‌های ارائه‌شده به ماشین برای آموزش و تست، مربوط به پهنه‌های محلات منطقه ۱ شهرداری تهران بوده‌اند (که در محدوده خطر گسل شمال تهران قرار دارند). ویژگی‌های مورد تأکید که ماشین براساس آنها آموزش دیده تا مدل پیش‌بینی‌کننده را ارائه دهد، مشتمل بر موارد زیر هستند: ویژگی‌های الگوی قطعات و ساختار ابنیه، الگوی معبر، کاربری اراضی و موقعیت نسبت به گسل اصلی و فرعی بوده‌اند. مجموعه داده‌ها مشتمل بر ۱۹۹۷ سطر و ۲۶ ستون بوده است. برخی از داده‌ها از جی.آی.اس. منطقه استخراج و بخش دیگری از داده‌ها از تحلیل نقشه پهنه‌ها به دست آمد. با توجه به بهره‌گیری از رویکرد یادگیری ماشین نظارت‌شده، برچسب‌گذاری توسط محققان در پنج طیف انجام شد. برای آموزش ماشین از الگوریتم درخت تصمیم، ماشین بردار پشتیبان و شبکه عصبی چندلایه استفاده شد. حجم داده‌های آموزش به تست ۷۰ به ۳۰ در نظر گرفته شد. با بررسی دقت مدل توسط ماتریس درهم‌آمیختگی، مشخص شد که الگوریتم درخت تصمیم با دقت ۹۹٫۵۰، حساسیت ۹۹٫۴۲ و خطای ۰٫۵ دارای عملکرد بهتری نسبت به دو الگوریتم دیگر است. شبکه عصبی نیز با دقت ۹۷٫۸۵، حساسیت ۹۷٫۵۷ و خطای ۲٫۱۵، دارای عملکرد مناسبی است. بررسی میزان اعتمادپذیری مدل پیش‌بینی کننده با داده‌های مربوط به محله جوانمرد قصاب در منطقه ۲۰ نیز نشان داد که ماشین آموزش‌دیده، با دقت بالای ۹۷ درصد قابلیت پیش‌بینی پذیری دارد. بدین‌ترتیب ماشین آموزش‌دیده با دقت و سرعت بالا می‌تواند به پیش‌بینی میزان آسیب‌پذیری بافت‌های کالبدی در برابر زلزله بپردازد.

## تاریخ دریافت:

۰۵ اردیبهشت ۱۴۰۲

## تاریخ پذیرش:

۰۹ مهر ۱۴۰۲

## تاریخ انتشار:

۱۱ آذر ۱۴۰۲

## کلیدواژه‌ها:

مدیریت بحران هوشمند، مدل پیش‌بینی‌کننده، آسیب‌پذیری کالبدی، یادگیری ماشین، مورفولوژی، زلزله.

\* نویسنده مسئول: مریم محمدی

آدرس: دانشیار گروه طراحی شهری، دانشگاه هنر، تهران، ایران ایمیل: m.mohammadi@art.ac.ir



## ۱ مقدمه

همچنین وجود پژوهش‌های حوزه آسیب‌پذیری کالبدی در برابر زلزله، با روش‌های سنتی، کمک می‌نماید تا معیارهای کالبدی مؤثر در این پژوهش‌ها شناسایی و مورد استفاده قرار گیرند. به دلیل آنکه برای بهره بردن از یادگیری ماشین نیاز به داده‌های مناسب و مکفی است، در این پژوهش به دلیل نبود مجموعه داده‌های مناسب و زمان و هزینه زیاد برای جمع‌آوری آنها در سطح شهر تهران، منطقه ۱ شهرداری تهران به دلیل آنکه بر روی گسل‌های شمال تهران قرار گرفته و در معرض خطر آسیب‌پذیری است، به عنوان منطقه منتخب برای تهیه مجموعه داده‌ها انتخاب شده است.

### ۱/۱ پیشینه پژوهش

در ادامه مروری بر پیشینه پژوهش‌های انجام‌شده در حوزه مدیریت بحران هوشمند ارائه می‌شود. جین کریستف<sup>۱</sup> در مقاله‌ای با عنوان «به سوی بستر نرم‌افزاری مشترک برای مدیریت بحران شهری» در سال ۲۰۱۱، با استفاده از نرم‌افزار سیمفور<sup>۲</sup> به شبیه‌سازی بحران در فضاهای شهری پرداخت. این پژوهش با شبیه‌سازی سناریوهای مختلف در قالب بازی‌های رایانه‌ای، به مدیریت ریسک در فضاهای شهری پرداخته است (Chambelland et al., 2011). مارکو، در پژوهشی، سیستم حمایت از تصمیم‌گیری در زمان واقعی برای مدیریت بحران زلزله را بررسی نمود. در این پژوهش با به‌کارگیری الگوریتم تشخیص انفجار، کاربران در شبکه‌های اجتماعی هم امکان اطلاع‌رسانی رویدادها و مطلع شدن از آنها را دارند. این سیستم که شامل مراحل آموزش، فیلتر، تشخیص داده و ارزیابی خسارت بوده و می‌تواند به شناسایی مناطقی که احتمالاً آسیب خواهند دید، کمک نماید. اطلاعات به‌دست‌آمده توسط این سیستم به شناسایی محل تمرکز تیم‌های نجات و پاسخ اضطراری فوری کمک می‌کند (Avvenuti et al., 2014). آلازوی، در مقاله‌ای با عنوان «سیستم مدیریت بحران هوشمند برای شهرهای آینده» به بررسی نحوه استفاده از

تحقق کیفیت ایمنی یکی از اهداف اصلی برنامه‌ریزی و طراحی شهری است که تأمین آن در مواقع بحران به‌منظور لزوم اتخاذ سریع و صحیح تصمیم‌ها ضروری است. این حوزه، به‌عنوان یک علم کاربردی، با مشاهده سامانمند بحران‌ها و تحلیل آنها در قبل، حین و پس‌از آن (فرجی و قرخلو، ۲۰۱۰) در جستجوی یافتن ابزاری برای پیش‌گیری یا کاهش اثرات، امدادسانی سریع و بهبود اوضاع است (شفیعی، ۲۰۱۵) و در آمادگی، واکنش، بازتوانی و کاهش آسیب‌پذیری مؤثر است. دانش مدیریت بحران هوشمند، با توسعه فناوری (توسعه شبکه‌های اجتماعی، شبکه‌های حسگر، هوش مصنوعی، یادگیری ماشین، اینترنت اشیا و غیره) و ایجاد زیرساخت‌های هوشمند، به شیوه‌ای نو در مدیریت بحران تبدیل شده است (فرزادینیا و منصفی، ۲۰۱۹ و Linardos et al., 2022).

این پژوهش بر آن است تا با توجه به اهمیت مدیریت بحران در برابر زلزله در شهر تهران که یکی از مهم‌ترین مصادیق بحران قریب‌الوقوع در شهر تهران است، به بررسی نحوه کاربست مدیریت بحران هوشمند در برابر زلزله در شهر تهران بپردازد.

از آنجاکه براساس پژوهش‌های انجام‌شده در این حوزه، به دلیل دسترسی محدود به اطلاعات، امکان انجام برخی از پژوهش‌های مشابه وجود ندارد، این مقاله بر آن است تا با توجه به اهمیت مقوله آسیب‌پذیری و مدیریت بحران پیش از وقوع زلزله و همچنین اهمیت بافت و فرم شهری در طراحی شهری به‌منظور دقیق‌تر شدن موضوع، مسأله آسیب‌پذیری کالبدی را هدف قرار داده و به جای روش‌های معمول کمی و فضایی که قابلیت استفاده در دیگر فضاها را ندارند، از یادگیری ماشین به‌عنوان یکی از رویکردهای مدیریت بحران هوشمند استفاده نماید.

<sup>2</sup> SIMFOR

<sup>1</sup> Jean-Christophe



ذکرشده می‌پردازد. همچنین به بررسی سیستم‌های سایبری-فیزیکی-اجتماعی می‌پردازد (Akerkar, 2018). سید شاهی و همکاران، در مقاله‌ای با عنوان «افزایش نقش تحلیل کلان داده‌ها و اینترنت اشیا در مدیریت بحران: پیشرفت‌ها، طبقه‌بندی و چشم‌انداز اخیر»، مزایای مدیریت بحران مبتنی بر اینترنت اشیا را ارائه داده‌اند. بررسی شهر هوشمند و روش‌های کاهش و ارزیابی ریسک نیز مورد توجه قرار گرفته است (Shahi & Hameed & Draheim, 2019).

در ادامه به منظور مشخص شدن روش و ابعاد مورد تأکید در مدیریت بحران زلزله در ایران، به بررسی پژوهش‌های انجام‌شده در این حوزه پرداخته شده است. قنواتی و همکاران (۲۰۰۹)، در مقاله‌ای با عنوان «توانمندسازی مدیریت بحران شهری در جهت کاهش بلایای طبیعی (زلزله) نمونه موردی: شهر خرم‌آباد» به بررسی بافت خرم‌آباد و مشکلات آن در زمان بحران پرداخته‌اند و راهکارهایی که در قبل، حین و بعد از حادثه لازم است را در سه سطح کوتاه‌مدت، میان‌مدت و بلندمدت ارائه شده‌اند (قنواتی و قلمی و عبدلی، ۲۰۰۹). توکلی و همکاران (۲۰۱۰) در مقاله‌ای با عنوان «بررسی روند کاهش فضاهای باز شهری در فرایند توسعه شهری با تأکید بر مدیریت بحران، نمونه موردی: کلان‌شهر تهران» به بررسی علل کاهش فضاهای باز شهری و راهکارهایی در جهت افزایش آن برای استفاده در زمان بحران به‌عنوان یک فضای حیاتی پرداخته‌اند (حسین‌پور، شمشیربند و توکلی، ۲۰۱۰). پیشگاهی-فرد و همکاران (۲۰۱۱)، در مقاله‌ای با عنوان «سیستم اطلاعات جغرافیایی جی.آی.اس. و نقش آن در مکان‌یابی مناطق مخاطره‌آمیز شهری جهت استفاده در مدیریت بحران (مطالعه موردی: منطقه ۸ شهرداری تبریز)» از ابزار جی.آی.اس. قبل، حین و پس از بحران، برای مکان‌یابی مناطق مخاطره‌آمیز شهری استفاده نموده‌اند (پیشگامی‌فرد و همکاران،

فناوری‌هایی چون آی.ای.اس.<sup>۱</sup>، وی.ای.آن، ای.ای.تی.اس.<sup>۲</sup>، شبکه اجتماعی و فناوری موبایل و... برای مدیریت بحران هوشمند در شهرها پرداخته است. با استفاده از این فناوری‌ها می‌توان با تعیین مکان وقوع حادثه و دریافت و انتقال اطلاعات به سیستم حمل‌ونقل هوشمند، تخلیه هوشمند اضطراری را تسهیل نمود (Alazawi et al., 2014). ال.فین، در مقاله‌ای با عنوان «بررسی داده‌های بحران بزرگ در عمل: اثرات مثبت و منفی بالقوه»، ضمن معرفی پروژه‌ای به نام بایت<sup>۳</sup> که مطالعه‌ای چندوجهی است، به دنبال شناسایی احتمالات با کم کردن تأثیرات خارجی مثبت و کاهش تأثیرات جانبی منفی داده‌های بزرگ است. بایت همچنین با بررسی چگونگی گسترش داده‌های بزرگ در زمان، در تلاش است تا نحوه خروجی گرفتن از کلان‌داده‌ها اعم از مثبت و منفی را برای مدیریت بحران هوشمند ارائه دهد (L. fin et al., 2015). بنابراین، در مقاله‌ای با عنوان «ارائه چارچوب مفهومی و مجموعه‌ای از ابزارها در مدیریت بحران»، به بررسی دو دیدگاه سازمانی و فنی در خصوص مدیریت داده‌ها در زمان بحران پرداخته است. در دیدگاه فنی، منبع کلان داده‌ها، نحوه جمع‌آوری، پالایش و ذخیره داده‌ها بررسی می‌شود که در این دیدگاه، سه مؤلفه: داده‌ها، اطلاعات و واکنش مطرح می‌شوند. در دیدگاه سازمانی، روشی برای مدیریت بحران ارائه شده که شامل سه مرحله تعریف، ادراک و حفاظت است. در این پژوهش، با ابزارهای معرفی‌شده و دیدگاه فنی، مدل پژوهش به‌عنوان دانش مدیریتی ارائه شده است (Benaben et al., 2017). آکرکار<sup>۴</sup> در سال ۲۰۱۸، در مقاله‌ای با عنوان «فناوری‌های هوشمند برای پاسخگویی اضطراری و مدیریت بحران» به بررسی کلان داده‌های قبل، حین و بعد از شرایط اضطرار و مزایای آنها در بحران می‌پردازد. همچنین به بررسی اهمیت رسانه‌های اجتماعی به‌عنوان یک منبع داده مناسب و همچنین کیفیت داده‌های دریافتی، امنیت و حریم خصوص داده‌های

<sup>3</sup> byte<sup>4</sup> Rajendra Akerkar<sup>1</sup> its<sup>2</sup> vanets



پرداخته‌اند. در نهایت مدل مفهومی پژوهش ارائه شده که شامل تأثیر مدیریت یکپارچه شهری در ۶ زمینه آمادگی برای بحران، سرعت ارائه خدمات، کیفیت ارائه خدمات، هماهنگی بین بخشی، برنامه‌ریزی در بحران و تأمین الزامات در بحران می‌شود (طالب‌پور و مجاهد دینی، ۲۰۱۹).

با مروری پیشینه پژوهش، مشخص شد که در پژوهش‌های خارجی بیشتر سیستم مدیریت بحران هوشمند بررسی شده و با استفاده از ابزارها و نرم‌افزارها تلاش شده تا با بهره‌گیری از کلان داده‌ها و فناوری‌های قابل دسترس مدیریت بحران هوشمند محقق شود. در نمونه‌های داخلی، به دلیل کمبود زیرساخت‌ها، ابزارهای جمع‌آوری و دسترسی به داده‌ها، بیشتر بر بررسی آسیب‌پذیری مناطق در زمان بحران با استفاده از نرم‌افزار جی.آی.اس. تکیه شده و راهکارهایی برای کاهش آسیب‌پذیری ارائه شده است. از آنجاکه این پژوهش در تلاش است تا با بهره‌گیری از رویکرد یادگیری ماشین به‌عنوان یکی از روش‌های مطرح در مدیریت بحران هوشمند، به ارائه مدلی پیش‌بینی کننده بافت بپردازد از حیث موضوع، روش و رویکرد واجد نوآوری است.

## ۲ مبانی نظری

### ۲/۱ مدیریت بحران و مدیریت بحران هوشمند

بحران، حادثه‌ای است که در اثر رخدادها و عملکردهای طبیعی و انسانی به‌طور ناگهانی رخ می‌دهد و مشقت و سختی را به یک مجموعه و یا جامعه انسانی تحمیل می‌کند که برطرف کردن آن نیاز به اقدامات اضطراری فوری و فوق‌العاده دارد (صلواتیان و مهربان، ۲۰۱۶). مدیریت بحران، فرایندی است که برای پیشگیری از بحران یا به حداقل رساندن اثرات آن، به هنگام وقوع صورت می‌گیرد. برای انجام این فرایند، باید برای مقابله با بدترین وضعیت‌ها نیز برنامه‌ریزی و سپس روش‌هایی برای اداره و انجام آن پیدا کرد (حسینی، ۲۰۱۵). مدیریت بحران به مجموعه اقداماتی اطلاق می‌شود که قبل، حین و

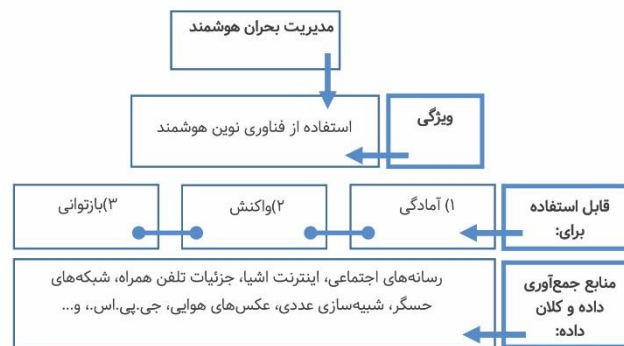
پس از وقوع می‌شود، پرداخته‌اند. سپس به بررسی ماهوی طراحی شهری و ویژگی‌های این دو بعد در فرایند بحران پرداخته‌اند (حسینی و امیدواری، ۲۰۱۸). صلواتیان و مهربان در مقاله‌ای با عنوان «کارکرد رسانه‌های اجتماعی در مدیریت بحران زلزله احتمالی شهر تهران»، کاربرد رسانه‌های اجتماعی در زمان زلزله با تحلیل داده‌هایی که از مصاحبه با خبرگان و متخصصان به‌دست آمده را بررسی نموده است. در این پژوهش سه مقوله بررسی شده‌اند: ۱- کارکرد رسانه‌های اجتماعی در زمان بحران؛ ۲- الزامات مدیریتی در زمان بحران؛ و ۳- چالش‌های مدیریتی و رسانه‌های اجتماعی در زمان بحران (صلواتیان و مهربان، ۲۰۱۶). طالب‌پور و مجاهد دینی در مقاله‌ای با عنوان «نقش مدیریت یکپارچه شهری در بهبود مدیریت بحران و افزایش کیفیت خدمات عمومی به شهروندان مطالعه موردی: استان تهران» به تعریف مدیریت یکپارچه شهری و خدمات عمومی



رویکردها و روش‌های هوشمند تلاش می‌کند تا شرایط بحرانی را مدیریت نماید. هدف اصلی مدیریت بحران هوشمند، استفاده از فناوری اطلاعات و ارتباطات، با افزایش فن‌آوری‌های مستقل است. سیستم باید به‌طور خودکار شرایط اضطراری را براساس آگاهی از زمینه و داده‌های زمان حقیقی پیگیری و نظارت کند. همچنین از مکانیسم‌های محاسباتی و فناوری‌های مبتنی بر دستگاه‌های خودتصمیم‌گیر برای محاسبه دانش در شرایط اضطراری استفاده می‌کند. در نتیجه، مدیریت بحران هوشمند، امکان اخذ تصمیمات خوبی با دقت بالا را فراهم می‌آورد (Sahoh & Choksuriwong, 2017). بدین ترتیب، مدیریت بحران هوشمند، استفاده از فناوری اطلاعات و ارتباطات جهت کاهش و کنترل حوادث، واکنش و تصمیم‌گیری سریع و به-موقع و همچنین استفاده در مرحله پیش‌بینی و آمادگی حادثه را فراهم می‌آورد.

بعد از وقوع سانحه، جهت کاهش هر چه بیشتر آثار و عوارض آن انجام می‌گیرد (قنواتی، قلمی و عبدلی، ۲۰۰۹). هدف کلی مدیریت بحران، بهینه‌سازی فعالیت‌های مقابله با بحران و به حداقل رساندن خسارات ناشی از آن است (شفیعی، ۲۰۱۵).

مدیریت بحران را می‌توان در دو دسته مدیریت بحران سنتی و هوشمند بررسی نمود. در مدیریت بحران سنتی، مرحله پس از بحران و موضوع امداد و نجات و کمک‌رسانی از اهمیت بیشتر برخوردار است. به این معنی که از میان سه مرحله مدیریت، مرحله سوم یعنی مرحله واکنش و بازتوانی بیشتر اجرایی می‌شود. امروزه نگرش جدیدی به مدیریت بحران وجود دارد که در مقابل مدیریت بحران سنتی قرار می‌گیرد و در آن بر مراحل دیگر مدیریت بحران از جمله مرحله پیش از بحران، ضرورت پیش‌بینی، بررسی نقاط بحران‌خیز و آسیب‌پذیر و کسب آمادگی برای رویارویی با بلایا نیز تأکید دارد (شفیعی، ۲۰۱۵). مدیریت بحران هوشمند، با استفاده از



تصویر ۱- مدیریت بحران هوشمند، منابع و قابلیت استفاده آن در سطوح مختلف (فرجی و قرخلو، ۲۰۱۰؛ شفییعی، ۲۰۱۵؛ فرزادینیا و منصفی، ۲۰۱۹ و Linardos et al., 2022)

## ۲٫۲ انواع داده‌ها و روش‌های تحلیل آنها

در مدیریت بحران هوشمند، داده‌ها نقش ویژه‌ای دارند. تحلیل داده‌ها می‌تواند به مدیریت بحران کمک نموده و از طریق تحلیل آنها می‌توان خطرات را تشخیص و رویکردی راهبردی برای مدیریت بحران اتخاذ نمود (Liu et al., 2018). با استفاده از

مجموعه داده‌ها، می‌توان به تحلیل داده‌های فاجعه‌های گذشته و توسعه سناریوهای آینده، احتمالات وقوع بلایا و خسارات ناشی از آنها پرداخت. داده‌ها را می‌توان از لحاظ ساختار، نوع و قابلیت استفاده در مراحل مدیریت بحران هوشمند بررسی نمود. از حیث ساختار، داده‌ها به دو دسته ساختاریافته و بدون ساختار قابل دسته‌بندی هستند.





داده‌های ساختاریافته، کمی و برای استفاده توسط نرم‌افزارهای تحلیل داده‌ها، آسان هستند. داده‌های بدون ساختار، داده‌هایی هستند که سازمان‌دهی مشخص ندارند و در چهارچوبی تعریف‌شده نمی‌گنجد. ممکن است متنی یا غیرمتنی بوده و توسط انسان یا ماشین تولید شوند، برای مثال تصاویری که در شبکه‌های اجتماعی مجازی به اشتراک گذاشته می‌شوند (کریمی و نصر، ۲۰۱۳). داده‌ها را می‌توان از مواردی چون سنجش از راه دور، وب حسگر بی‌سیم، وی.اس.ان.<sup>۱</sup>، جمع‌سپاری<sup>۲</sup>، رسانه اجتماعی<sup>۳</sup>، جی.پی.اس.<sup>۴</sup> و اینترنت اشیا<sup>۵</sup> جمع‌آوری نمود (Liu et al., 2018). داده‌ها قابلیت استفاده در سه مرحله پیش از بحران (پیش‌گیری و آمادگی)، حین بحران (واکنش) و پس از بحران (کاهش و ریکاوری) را دارا هستند (Liu et al., 2018). با توجه به نوع و ماهیت داده‌ها، آنها پس از جمع‌آوری و ذخیره، نیازمند پاک‌سازی برای تحلیل هستند (Yu & Yang & Li, 2018). بسیاری از ابزارهای استخراج و تحلیل به‌صورت یکپارچه با استفاده از روش داده‌کاوی و یادگیری ماشین انجام می‌شود. داده‌کاوی فرایند استخراج اطلاعات مفید از حجم گسترده‌ای از داده‌ها است که برای کشف الگوهای جدید، دقیق و مفید در داده‌ها است. یادگیری ماشین، فرایند کشف الگوریتم‌هایی است که تجربه به‌دست‌آمده از داده‌ها را ارائه می‌دهد. این رویکرد، طراحی، مطالعه و توسعه الگوریتم‌هایی را مورد توجه قرار می‌دهد که به ماشین‌ها اجازه می‌دهد، بدون دخالت انسان یاد بگیرند.

### ۲/۳ کاربرد یادگیری ماشین در ارائه مدل‌های پیش‌بینی‌کننده در مدیریت بحران

همان‌طور که بیان شد، مدیریت بحران هوشمند در سه مرحله آمادگی، واکنش و بازتوانی مورد استفاده قرار می‌گیرد (Qadir et al., and Liu et al., 2018).

<sup>4</sup> Gps  
<sup>5</sup> IoT

<sup>1</sup> Vsn  
<sup>2</sup> crowdsourcing  
<sup>3</sup> Social Media



- شاخص‌های مربوط به الگوی قطعات و ساختار ابنیه: تعداد طبقات، دانه‌بندی قطعات، نظم و بی‌نظمی قطعات، تراکم ساختمانی بنا، کیفیت ابنیه (حییبی و همکاران، ۲۰۱۱؛ باقری و معتمدی مافی، ۱۳۹۹؛ Yariyan et al., 2020) و مصالح (Relph, 2014 & Kostov, 2004 & Williams et al., 2000) به نقل از Ibrahim et al., 2018; Stangl, 2018; Nadeem et al., 2021; Kropfs, 2009 نقل از (Mohemed et al, 2018).

- شاخص‌های مربوط به کاربری: وجود کاربری درمانی، فضای سبز (یاراحمدی و همکاران، ۲۰۱۹؛ حییبی و همکاران، ۲۰۱۱؛ باقری و معتمدی مافی، ۲۰۲۰ و Yariyan et al., 2020; Jenks & Jones, 2010) به نقل از (Nadeem, 2021).

- شاخص‌های مربوط به معابر و دسترسی: الگوی شبکه، دسترسی‌پذیری (به مراکز درمانی، به فضای سبز) (یاراحمدی و همکاران، ۲۰۱۹؛ حییبی و همکاران، ۲۰۱۱؛ باقری و معتمدی مافی، ۱۳۹۹ و Yariyan et al., 2020; Stangl, 2018)؛ نفوذپذیری (یاراحمدی و همکاران، ۲۰۱۹) و عرض معابر (حییبی و همکاران، ۲۰۱۱).

- سایر شاخص‌ها: فشردگی و فرسودگی.

در ادامه برخی از شاخص‌ها و سنجه‌های آنها ارائه می‌شوند. تعداد طبقات ساختمانی یکی از عوامل مؤثر در میزان آسیب‌پذیری در برابر زلزله است. طبق وزن دهی‌های مختلف در مقالات مورد مطالعه، ساختمان‌های یک طبقه کمترین وزن را در میزان آسیب‌پذیری و ساختمان‌های ۶ طبقه و بالای آن بیشترین میزان آسیب‌پذیری را دارند (نظم‌فر و علوی، ۲۰۱۸). در بحث آسیب‌پذیری تراکم کمتر از ۱۰۰، کمترین تأثیر را در میزان آسیب‌پذیری در برابر

برنامه‌های ارتقای طراحی برای کمک به قربانیان و خانواده‌هایشان، بازسازی املاک تخریب‌شده و بازسازی عملیات دولت و خدمات تحت شرایط اضطراری از جمله مواردی است که قابل انجام است (Liu et al., 2018).

## ۲٫۴ بررسی بعد فرم کالبدی به‌عنوان بعد مؤثر بر کاهش آسیب‌پذیری در برابر زلزله

ابعاد مختلفی در کاهش آسیب‌پذیری در برابر زلزله تأثیر دارند. با مرور پژوهش‌های انجام‌شده در این حوزه مشخص شد که بعد فرم یکی از ابعاد با تأثیرگذاری زیاد در کاهش آسیب‌پذیری است. برای نمونه براساس پژوهش‌های یاراحمدی و نیک‌پور و لطفی، ۲۰۱۹؛ حییبی و همکاران، ۲۰۱۱؛ باقری و معتمدی مافی، ۲۰۲۲؛ یاریان، ۲۰۲۰؛ علیزاده، ۲۰۱۸ و حیاتی و همکاران، ۲۰۱۶، بعد فرم بیشترین تأثیر را در کاهش آسیب‌پذیری دارد. با توجه به تأکید این پژوهش، در ادامه لازم است با توجه به رویکرد پژوهش که یادگیری ماشین است، ویژگی‌های مربوط به بعد فرم و بافت شناسایی شوند. بر این اساس به‌جای تعریف فرم، معرفی مکاتب مطالعه فرم کالبدی، روش تحلیل و سایر موارد مشابه، در اینجا شاخص‌های مورد توجه در پژوهش که به‌عنوان شاخص‌های بعد فرم و کالبد بر میزان آسیب‌پذیری تأثیر دارند، شناسایی شده است.

فرم قابلیت بررسی در مقیاس شهر، محله و قطعه را دارد. در این پژوهش بر مقیاس میانی و خرد تکیه شده است. براساس دیدگاه کانزن، چهار عنصر فرم کالبدی شامل: کاربری اراضی، معابر، الگوی قطعات و ساختار ابنیه است (کارمونا و همکاران، ۲۰۰۹). در ادامه شاخص‌های مربوط به هر عنصر که در آسیب‌پذیری در برابر بحران مؤثر هستند، ارائه می‌شود.

<sup>1</sup> Yariyan



زلزله، از منظر پیش‌بینی و آمادگی مورد تأکید قرار گرفته است.

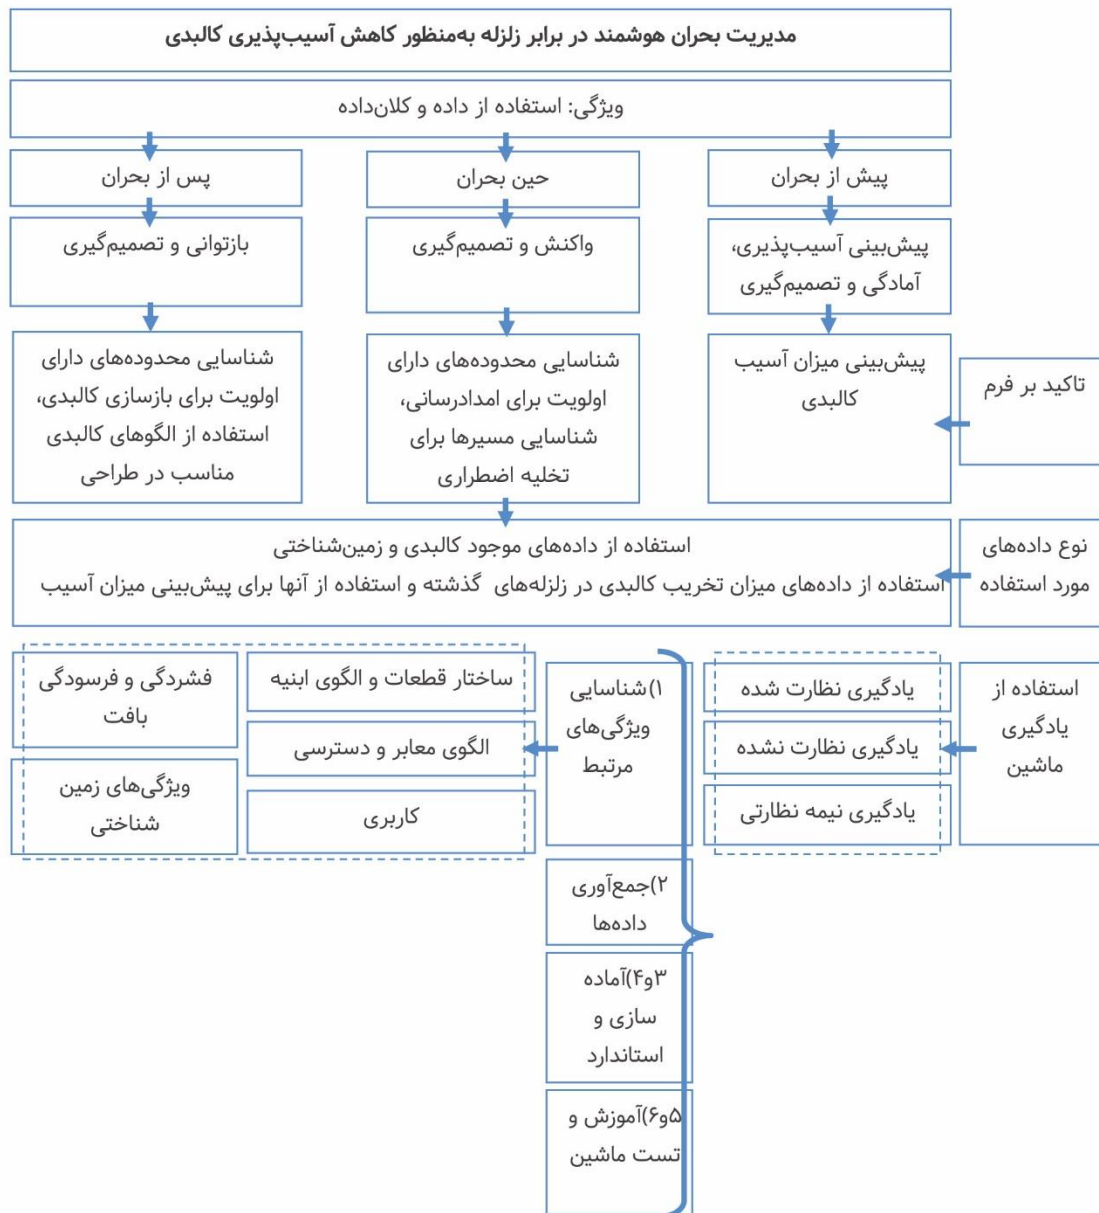
همان‌گونه که بیان شد، مدیریت بحران هوشمند با استفاده از داده‌ها و همچنین بهره‌گیری از منابع و ابزارهای دیجیتال جمع‌آوری داده‌ها و رویکردهایی چون هوش مصنوعی و یادگیری ماشین، در مقابل رویکرد مدیریت بحران به روش سنتی قرار گرفته است.

بنابراین این پژوهش بر آن است تا با تکیه بر مدیریت بحران هوشمند و با استفاده از یادگیری ماشین به ارائه مدل پیش‌بینی کننده آسیب‌پذیری در برابر زلزله در بعد فرم بپردازد. همان‌طور که بیان شد، بیشتر پژوهش‌های داخلی به‌منظور بررسی میزان آسیب‌پذیری کالبدی از جی.آی.اس. و تحلیل فضایی بهره برده‌اند، که در واقع روشی برای تحلیل و شناسایی میزان آسیب است. اما روش مورد استفاده در این پژوهش، با آموزش ماشین، امکان پیش‌بینی آسیب‌پذیری در سایر پهنه‌ها با دقت بالا را دارد. با توجه به رویکرد منتخب، لازم است تا مجموعه داده‌ها تهیه و فرایند آموزش و تست آنها انجام شود. مهم‌ترین گام در تهیه مجموعه داده‌ها، شناسایی ویژگی‌ها است. در این بخش با توجه به موارد بیان‌شده در مبانی نظری، ویژگی‌های مربوط به بعد مورفولوژی مرتبط با کاهش آسیب‌پذیری زلزله و ویژگی‌های مربوط به زمین‌شناسی و گسل با توجه به مبانی نظری، تعیین شده است. در نمودار زیر مدل مفهومی پژوهش ارائه شده است.

زلزله و تراکم بیش از ۲۰۰ بیشترین تأثیر را دارا است (نظم‌فر و علوی، ۲۰۱۸). شبکه‌های ارتباطی برای موتورسواری، دوچرخه‌سواری و... تردد عابران پیاده علاوه بر فرار از موقعیت‌های خطرناک و تسهیل در امداد رسانی و کمک‌رسانی در بیشتر مناطق زلزله‌زده جاده‌ها و خیابان‌ها برای عبور وسایل نقلیه نیاز است. تعداد تلفات همیشه به دلیل خود زلزله نیست، بلکه اغلب به دلیل مسدود شدن راه‌ها است. از این نظر عرض معابر در بحث پیش‌بینی آسیب‌پذیری نقش کلیدی دارد (Yariyan et al., 2020). دسترسی به خدمات بهداشتی مانند بیمارستان‌ها نقش کلیدی در کنترل بحران دارد. ارائه خدمات امداد و نجات زلزله و دسترسی سریع به امکانات پزشکی، تاب‌آوری در برابر زلزله را افزایش می‌دهد (Yariyan et al., 2020). نفوذپذیری را شاخصی از کیفیت کالبدی یک بافت و گستره دید به درون آن دانست که میزان، چگونگی و جهت ورود به بافت را تعیین کرده، سهولت و تنوع در زاویه دید، جابه‌جایی و دسترسی به فضاهای درون بافت را با ایجاد فرصت‌های متعدد و امکان انتخاب فراهم می‌آورد و بر نفوذ فعالیت‌ها، فرهنگ، روابط اجتماعی و پذیرش تغییرات مؤثر واقع می‌شود (سینافر و پرتوی و شکوهی، ۲۰۱۱). فرسودگی ناکارآمدی و کاهش کارایی یک بافت است که به سبب قدمت و یا فقدان برنامه و نظارت بر شکل‌گیری بافت شهری به وجود می‌آید (ناظمی، ۲۰۱۷). فرسودگی در دو دسته تقسیم‌بندی می‌شود: کامل و نسبی. فرسودگی کامل در هر دو عنصر کالبد و فعالیت است و فرسودگی نسبی در یکی از این دو اتفاق می‌افتد (شمین، ۲۰۱۲).

## ۲/۵ تدوین چارچوب مفهومی پژوهش

مسئله پژوهش، استفاده از مدیریت بحران هوشمند در برابر زلزله است. همان‌گونه که بیان شد مدیریت بحران هوشمند در سه مرحله و همچنین به‌منظور آمادگی، واکنش و بازتوانی مورد توجه قرار می‌گیرد. در این پژوهش مدیریت هوشمند بحران پیش از



نمودار ۲- مدل مفهومی پژوهش

با توجه به اهمیت شناسایی ویژگی ها در جدول زیر شاخص های مورد توجه پژوهش ارائه شده است. در این میان برخی از شاخص ها توسط خود محققان به عنوان معیار مؤثر بر آسیب پذیری فرم در برابر زلزله به لیست شاخص ها اضافه شده اند.



### جدول ۱- ویژگی‌های مورد توجه در ارائه مدل پیش‌بینی‌پذیری کننده میزان آسیب‌پذیری کالبدی در برابر زلزله

مربوط به زلزله	مربوط به بعد فرم کالبدی
قرارگیری در حریم اصلی گسل	میانگین تعداد طبقات/ میانگین تراکم ساختمانی/ کیفیت ابنیه (قدمت غالب بنا، اسکلت غالب بنا، جنس مصالح نما)/ انتظام یافتگی قطعات/ میانگین دانه‌بندی قطعات/ سطح اشغال (حییبی و همکاران، ۱۳۹۰؛ باقری و معتمدی مافی، ۱۳۹۹؛ Yariyan et al., 2020; Relph, 2014 & Kostov, 2004 & Williams et al., 2000 Ibrahim et al., 2018; Stangl, 2018; Nadeem et al., 2021; Kropfs, 2009 به نقل از Mohemed et al, 2018)
قرارگیری در حریم فرعی گسل	وجود فضای سبز/ وجود کاربری جاذب جمعیت/ وجود فضای باز (یاراحمدی و نیک‌پور و لطفی، ۱۳۹۸؛ حییبی و همکاران، ۱۳۹۰؛ باقری و معتمدی مافی، ۱۳۹۹ و Yariyan et al., 2020; Jenks & Jones, 2010)
گسل	نفوذپذیری/ دسترسی‌پذیری مناسب (به محدوده/ به فضای سبز)/ تعداد بن‌بست‌ها/ مجاورت با شریان‌های اصلی/ میانگین عرض معابر/ فاصله از مراکز آتش‌نشانی/ فاصله از مراکز سوخت/ فاصله از بیمارستان (یاراحمدی و نیک‌پور و لطفی، ۱۳۹۸؛ حییبی و همکاران، ۱۳۹۰؛ باقری و معتمدی مافی، ۱۳۹۹ و Yariyan et al., 2020, Stangl, 2018)
	نسبت مساحت فضای باز به کل پهنه (Stangl, 2018)/ نسبت مساحت فضای سبز به کل پهنه (Stangl, 2018)/ فشردگی بافت/ فرسودگی بافت

موجود در محدوده انتخابی و همچنین تحلیل مبتنی بر نقشه (توسط نویسندگان) و اطلاعات جایکا به دست آمده است.

از میان انواع سه‌گانه رویکرد یادگیری ماشین، در اینجا از رویکرد نظارت‌شده استفاده شده که در آن تعدادی از داده‌ها به‌عنوان ورودی طی فرایند آموزش برچسب‌گذاری و خروجی متناظر با آن تولید می‌گردد (وزان، ۲۰۲۱). به‌این‌ترتیب داده‌های ورودی ویژگی‌های مربوط به بعد فرم و زمین‌شناختی (گسل) هستند و خروجی، میزان آسیب‌پذیری کالبدی در برابر زلزله است.

در این پژوهش، مراحل مربوط به یادگیری ماشین، در نرم‌افزار ریپیدمایندر که قابلیت ورود کدهای دیگر از سایر نرم‌افزارها مانند اکسل را داشته و برای آنالیز پیش‌بینی استفاده می‌شود (احمدی و همکاران، ۲۰۱۹)، انجام شده است. پس از آماده‌سازی داده‌ها، با تقسیم داده‌ها به داده‌های آموزش و تست، ماشین با چند الگوریتم آموزش می‌بیند و با استفاده از داده‌های تست و ماتریس درهم‌آمیختگی،

### ۳ روش تحقیق

پژوهش حاضر با توجه به هدف پژوهش، از نوع کاربردی و از حیث ماهیت با توجه به استفاده از یادگیری ماشین (که ابزاری برای تجزیه و تحلیل داده‌ها است و ساخت مدل تحلیلی را به‌صورت خودکار انجام می‌دهد) از نوع همبستگی است. رویکرد این پژوهش نیز کمی است.

در این پژوهش از متدولوژی سی.آر.آی.اس.پی. دی.ام. که اولین بار در سال ۱۹۹۶ ارائه شده، به‌عنوان فرایند استانداردسازی داده‌کاوی استفاده شده است. این متدولوژی، از یک چرخه شش‌مرحله‌ای تشکیل شده و از گام‌های شناخت مسئله، شناخت داده‌ها، آماده‌سازی داده‌ها، مدل‌سازی، ارزیابی مدل و استقرار تشکیل شده است. با توجه به مسئله پژوهش، مجموعه داده‌هایی که باید به ماشین داده شود، مشتمل بر داده‌های مربوط به ویژگی‌های فرمی و برخی از زمین‌شناختی است که در چارچوب مفهومی ارائه شده است. داده‌های جمع‌آوری شده از جی.آی.اس.

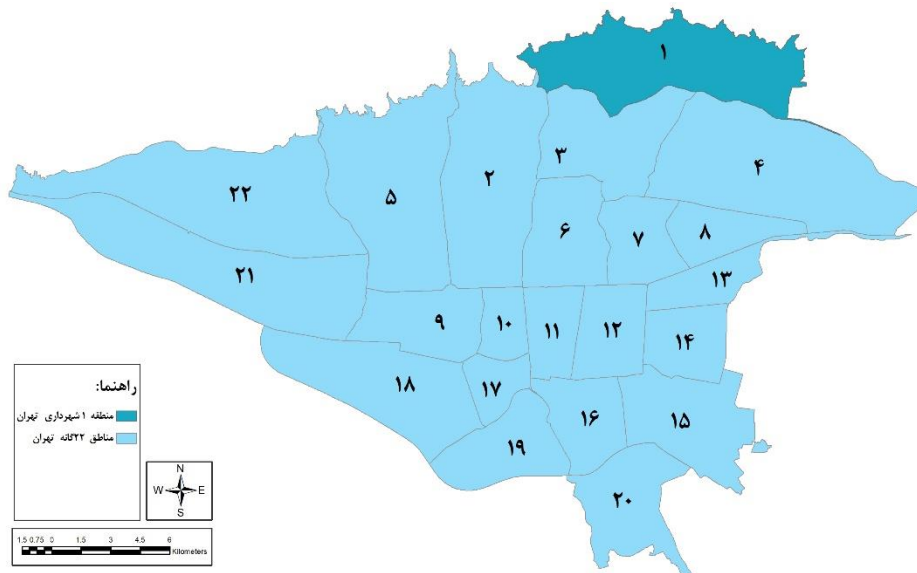


میزان اعتبار مدل آموزش‌دیده، سنجیده شده است. در بخش‌های بعد، گام‌های طی‌شده و نتایج به‌دست‌آمده به‌تفصیل ارائه می‌شود.

### گام اول: پهنه‌بندی بستر مورد نظر

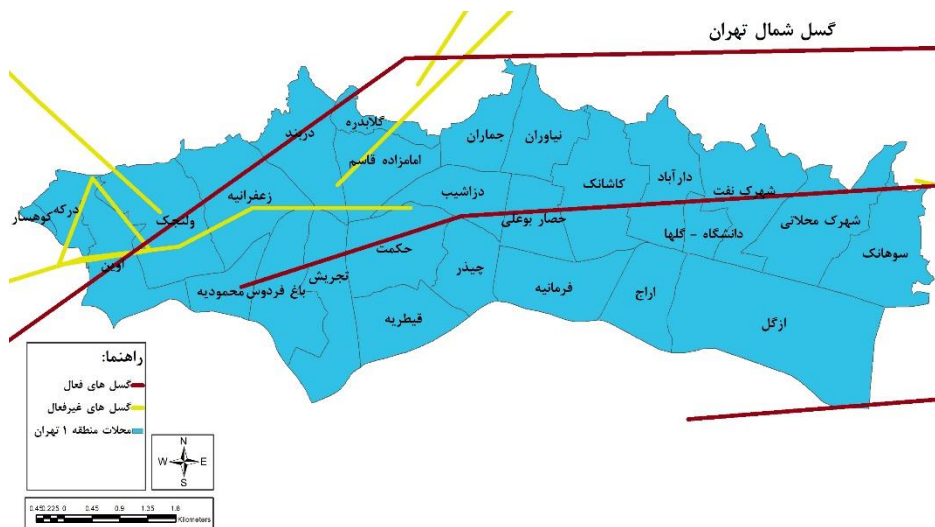
منطقه ۱ شهرداری تهران، با توجه به گسل‌هایی که از این منطقه عبور کرده و در پهنه خطرپذیری بالا قرار گرفته، به‌عنوان نمونه موردی انتخاب شده است. از جمله گسل‌های این منطقه که توان لرزه‌خیزی بالایی دارند، گسل شمال تهران است که دربرگیرنده کل غرب تهران و اشتهارد است. گسل شمال تهران توان ایجاد زلزله‌هایی با بزرگی ۶٫۵ تا ۷٫۵ درجه در مقیاس ریشتر را دارد. از طرفی دیگر با توجه به بافت منطقه، در این محدوده، علاوه بر بافت جدید، بافت فرسوده زیادی مشاهده می‌شود و در قسمت‌های شمالی نیز محلاتی مانند گلاب‌دره و دربند و قسمت‌های شمالی سوهانک و درکه بافتی فرسوده و آسیب‌پذیر از لحاظ زلزله‌خیزی دارند (زارع، ۱۳۹۵).

به‌منظور انجام پژوهش، پهنه‌بندی منطقه یک شهرداری تهران براساس محلات آن (۲۶ محله) انجام شد. با توجه به تأکید بر بعد مورفولوژی، از آنجاکه در مقیاس محله نیز پهنه‌بندی‌های مورفولوژیک متفاوتی قابل شناسایی است، در هر محله، پهنه‌بندی مورفولوژیکی انجام شد. معیارهای مورد توجه برای پهنه‌بندی مشتمل بر معیارهایی چون انتظام یافتگی قطعات، فضاها پر و خالی، سطح اشغال، دسترسی به مراکز مهم، دسترسی به فضای باز و... بوده است.



مجموعه تصاویر ۲- موقعیت منطقه ۱ شهرداری تهران در شهر تهران (تصویر بالا)

نقشه محلات شهر تهران (تصویر پایین)



تصویر ۳- نقشه گسل‌های فعال و غیرفعال منطقه ۱ شهرداری تهران



## گام دوم: انتخاب ویژگی‌ها

همان‌گونه که قبلاً نیز بیان شد، برای انجام فرایند یادگیری ماشین، لازم است ویژگی‌ها شناسایی شوند. ویژگی‌ها، همان شاخص‌هایی هستند که در چارچوب مفهومی ارائه شد. اما از آنجاکه تعداد ویژگی‌ها زیاد بوده و همچنین اولویت تأثیرگذاری آنها مشخص نبود، با رویکرد کارشناس محور و در قالب پرسش‌نامه متخصصین (۲۰)، شاخص‌ها بررسی و از

آنها خواسته شد تا از طیف ۱ تا ۵، به شاخص‌ها امتیاز دهند. روش انتخاب متخصصان طراحی شهری (به دلیل انتخاب فرم کالبدی به عنوان بعد تأثیرگذار) به شکل تصادفی و متخصصین ژئوفیزیک، مدیریت بحران و مهندسی عمران به صورت گلوله برفی بوده است.

جدول ۲- ویژگی متخصصین مشارکت کننده در فرایند امتیازدهی به شاخص‌ها

نوع تخصص	تعداد افراد	جنسیت		تحصیلات		سابقه کار	
		مرد	زن	کارشناس ارشد	دکتر	مرتبط و بالای ۷	مرتبط و بین ۳ تا
طراحی شهری	۱۵	۹	۶	۱۱	۴	۶	۹
زلزله	۵	۲	۳	۱	۴	۳	۲

## گام سوم: تهیه مجموعه داده‌ها

پس از پهنه‌بندی و شناسایی ویژگی‌ها، برای جمع‌آوری داده‌های مربوط به هر ویژگی، از منابع و روش‌های مختلفی از جمله اطلاعات مربوط به منطقه در شیپ‌فایل‌های جی.آی.اس.، نقشه‌های هوایی و نقشه‌های سازمان مدیریت بحران استفاده شد. در میان ویژگی‌ها منتخب توسط متخصصین، اطلاعات مربوط به ویژگی‌هایی چون: مصالح نمای ساختمان‌ها، اسکلت غالب ساختمان‌ها، کیفیت ساختمان‌ها و قدمت، ابتدا از طریق نقشه‌های سازمان مدیریت بحران تهیه و سپس جهت تأیید صحت این اطلاعات محله‌های دزاشیب، تجریش، چیدر و دربند به عنوان نمونه انتخاب و با برداشت میدانی، ویژگی‌های مذکور در آنها بررسی شد. برای تعدادی از ویژگی‌ها از جمله انتظام یافتگی،

نفوذپذیری، دسترسی‌پذیری، دسترسی به فضای باز نیز از عکس هوایی با رزولوشن بالا استفاده شد.





### جدول ۳- ویژگی اطلاعات سازمان‌های مرتبط برای تهیه مجموعه داده‌ها

نوع اطلاعات	اطلاعات دریافتی	سازمان
جی.آی.اس. نقشه (داده مکانی)	لایه‌های گسل، بافت فرسوده، زیرساخت، وضع موجود، لایه تعداد طبقات طرح تفصیلی	شهرداری منطقه یک شهرداری تهران
شیپ فایل جی.آی.اس. نقشه (داده مکانی)	لایه محلات منطقه، لایه سطح اشغال	سازمان فناوری اطلاعات و ارتباطات شهرداری تهران
متنی	اطلاعات جمعیتی، فرهنگی و اجتماعی منطقه یک مطالعات شناخت منطقه یک شهرداری تهران	سازمان فرهنگی و اجتماعی شهرداری تهران
نقشه (داده‌های مکانی)	نقشه‌های آسیب‌پذیری محلات منطقه یک براساس برآورد شش شاخص	سازمان مدیریت بحران تهران

یادگیری ماشین خطا ایجاد شود، بنابراین با تبدیل داده‌های ورودی در بازه [۰،۵]، نرمال‌سازی انجام شد. استانداردسازی نیز به دو صورت متنی و عددی انجام گرفت. نمونه‌ای از استانداردسازی متنی و عددی داده‌ها در جدول زیر ارائه شده است.

### گام چهارم: استانداردسازی داده‌ها

پیش از پردازش داده‌ها، به‌منظور بالا بردن دقت پیش‌بینی، به نرمال‌سازی داده‌ها نیاز است. برای نمونه به دلیل اختلاف زیاد اعداد در ویژگی سطح اشغال در پهنه‌های مختلف، از آنجاکه با ورود اعداد در بازه‌های مختلف به ماشین ممکن است در روند

### جدول ۴- استانداردسازی ویژگی‌ها

شاخص	جنس مصالح نما در پهنه	کیفیت ابنیه	دسترسی‌پذیری پهنه	دسترسی به فضای باز
استانداردسازی	۰۱: بلوک سیمانی ۰۲: سنگ ۰۳: آجرنما ۰۴: بتن ۰۵: خشت	۰۱: نوساز ۰۲: قابل نگهداری ۰۳: در حال ساخت ۰۴: تخریبی	۰۱: پایین ۰۲: متوسط ۰۳: پایین	۰۱: دارد ۰۲: ندارد
شاخص	سطح اشغال (متر)	فاصله از بیمارستان (متر)	تعداد طبقات ساختمانی	میانگین عرض معابر (متر)
استانداردسازی	۰۱: ۰-۲۵ ۰۲: ۲۵-۳۵ ۰۳: ۳۵-۴۵ ۰۴: ۴۵-۶۵	۰۱: ۰-۱۰۰۰ ۰۲: ۱۰۰۰-۲۰۰۰ ۰۳: ۲۰۰۰-۳۰۰۰ ۰۴: ۳۰۰۰-۴۰۰۰ ۰۵: ۴۰۰۰-۵۰۰۰	۰۱: ۰-۵ ۰۲: ۵-۱۰ ۰۳: ۱۰-۲۰ ۰۴: ۲۰-۵۰	۰۱: ۵-۸ ۰۲: ۹-۱۲ ۰۳: ۱۲-۲۰



عدد، تعداد سطرها به همان تعداد تکرار می‌شود. بنابراین در مجموع فایل نهایی شامل تعداد کلی ۱۹۹۷ سطر و ۲۶ ستون بوده است.

از نرم‌افزار اکسل برای دسته‌بندی، مرتب‌سازی و آماده‌سازی داده‌ها برای ورود به ماشین استفاده شده است. شاخص‌ها در ستون‌ها و پهنه‌بندی محلات منطقه یک تهران در سطرها تنظیم شده است. تعداد عددهای واردشده در هر سلول، باید یک عدد باشد، از این رو در صورت وجود بیش از یک

جدول ۵- اطلاعات کلی مجموعه داده‌ها

ویژگی مجموعه داده	تعداد ویژگی‌ها	تعداد رکوردها	روش داده‌کاوی	داده‌های گم‌شده
چندمتغیره	۲۶	۱۹۹۷	دسته‌بندی	ندارد

خیلی بالا، بالا، متوسط، پایین و خیلی پایین تعیین شده است. براساس این روند، در جدول پیش رو میزان آسیب‌پذیری هر پهنه از هر منطقه در طیف ۵ کلاس تعریف‌شده، ارائه شده است.

### گام پنجم: برچسب‌زنی داده‌ها

برچسب‌گذاری داده‌ها براساس میزان آسیب‌پذیری پهنه‌ها در برابر زلزله تعیین شده است. برای تعیین میزان آسیب‌پذیری از نقشه‌های جایکا استفاده شده و این طبقه‌بندی در ۵ کلاس با آسیب‌پذیری

جدول ۶- برچسب‌زنی داده‌ها براساس میزان آسیب‌پذیری

بسیار بالا	بالا	متوسط	پایین	بسیار پایین
۰-۲۰:۰۱	۲۰-۴۰:۰۲	۴۰-۶۰:۰۳	۶۰-۸۰:۰۴	۸۰-۱۰۰:۰۵

از آنجاکه مهم است که در هر کلاس، چه درصدی از داده‌ها قرار می‌گیرند، در جدول زیر درصد و فراوانی تعداد داده‌ها در هر کلاس آسیب‌پذیری ارائه شده است.

جدول ۷- درصد و فراوانی داده‌ها در کلاس‌های آسیب‌پذیری

کلاس‌های آسیب‌پذیری	فراوانی	درصد
۰-۲۰	۲۸۲	۱۴,۱
۲۰-۴۰	۶۵۶	۳۲,۹
۴۰-۶۰	۷۸۵	۳۹,۳
۶۰-۸۰	۱۱۵	۵,۸
۸۰-۱۰۰	۱۵۸	۷,۹
جمع	۱۹۹۶	۱۰۰

ساخت مدل و ۳۰ درصد داده‌های آزمایش و تست اعتبارسنجی مدل، تقسیم شدند. براساس منابع نسبت ۷۰ به ۳۰، برای نسبت آموزش به تست

### گام ششم: تعیین حجم داده تست و آزمون

پس از نرمال‌سازی داده‌ها در مرحله پیش‌پردازش، داده‌ها به دو بخش، ۷۰ درصد داده‌های آموزشی برای



جداکنندگی بهتری نسبت به یک ویژگی خواهد داشت.

**گام هشتم: ارزیابی دقت مدل و اعتبارسنجی**  
به منظور بررسی دقت مدل از روش‌هایی مانند ماتریس درهم‌آمیختگی، ماتریس همبستگی و نمودار آر.او.سی.<sup>۱</sup> استفاده می‌شود. در این پژوهش دقت مدل درخت تصمیم، ماشین بردار پشتیبان و شبکه عصبی با استفاده از ماتریس درهم‌آمیختگی سنجیده شده است.

## ۴ تحلیل داده‌ها

### ۴٫۱ آموزش و تست ماشین براساس الگوریتم‌های منتخب

#### الگوریتم درخت تصمیم

روش انتخاب ویژگی درخت تصمیم برای گره ریشه، در این پژوهش، به دست آوردن اطلاعات بوده است، به این معنی که یک ویژگی، چقدر اطلاعات درباره یک کلاس می‌دهد. در این پژوهش پهنه به عنوان گره ریشه انتخاب شده است. درخت تصمیم مورد استفاده دارای متغیرهای پیوسته است. با توجه به هدف پژوهش و نوع مسأله که از نوع پیش‌بینی است، از درخت رگرسیون استفاده شده است. از میان الگوریتم‌های درخت تصمیم در یادگیری ماشین، مانند آی.دی.سی، سی.۴٫۵، سی.۵ و سی.ای.آر.تی. در اینجا از الگوریتم سی.۴٫۵ بهره برده شده است. الگوریتم درخت‌های آموزش‌دیده را به مجموعه‌ای از قوانین اگر-آنگاه تبدیل می‌کند.

در این پژوهش ابتدا داده‌های آموزشی در اختیار درخت تصمیم قرار داده شد تا دانش حاکم بر داده‌ها مدل‌سازی شود و در ادامه برای پیش‌بینی کلاس از داده‌های آزمایشی استفاده شد. جدول زیر نشان‌دهنده وزن‌های هر یک از ویژگی‌ها است که به عنوان ورودی به مدل ارائه شده است. همان‌طور که مشاهده می‌شود، قدمت غالب بنا بیشترین وزن را

نسبتی قابل قبول است (صنعتی‌آباد، محمودی و طاهرپور، ۱۳۹۱).

### گام هفتم: الگوریتم‌های منتخب در یادگیری ماشین

با توجه به هدف پژوهش که به دست آوردن بهترین و دقیق‌ترین پیش‌بینی است و همچنین نوع مسأله که از نوع دسته‌بندی است، از الگوریتم‌های درخت تصمیم، ماشین بردار پشتیبان و شبکه عصبی چندلایه استفاده شده است. با اینکه درخت تصمیم روشی پرکاربرد و با محبوبیت زیاد است اما مشکلاتی نیز دارد. یکی از معایب وارد شده به درخت تصمیم، ناپایداری درخت‌های تصمیم است، زیرا حتی تغییرات کوچک در داده‌ها ممکن است، درختی کاملاً متفاوت را ایجاد کند. این موضوع که واریانس نامیده می‌شود با استفاده از روش‌های بگینگ و بوستینگ قابل کاهش دادن است. در رابطه با انتخاب ماشین بردار پشتیبان، می‌توان گفت که ماشین بردار پشتیبان، یک الگوریتم دسته‌بندی بسیار قدرتمند است و هنگامی که قدرت پیش‌بینی بالا مورد نیاز باشد، یک گزینه بسیار عالی است. در رابطه با توجیه استفاده از شبکه عصبی می‌توان بیان نمود که در یادگیری ماشین، دو رهیافت برای یادگیری وجود دارد: یادگیری نمادی و یادگیری زیر نمادی. درخت تصمیم یک روش نمادی است که دارای تفسیرپذیری و قابلیت فهم بالایی است. شبکه عصبی یک روش زیر نمادی است که دارای پایداری و انعطاف‌پذیری بالایی است. درخت شبکه عصبی، یک مدل یادگیری ترکیبی است که ساختار اصلی آن درخت تصمیم و هر گره داخلی آن، یک شبکه عصبی خیره خواهد بود و سعی دارد تا مزیت‌های درخت تصمیم و شبکه عصبی را با هم ترکیب کند. نتایج پژوهش‌ها نشان می‌دهد که در حالت کلی، درخت شبکه عصبی بهتر از درخت تصمیم معمولی عمل خواهد کرد، زیرا شبکه عصبی

<sup>1</sup> Receiver Operating Characteristic (ROC)

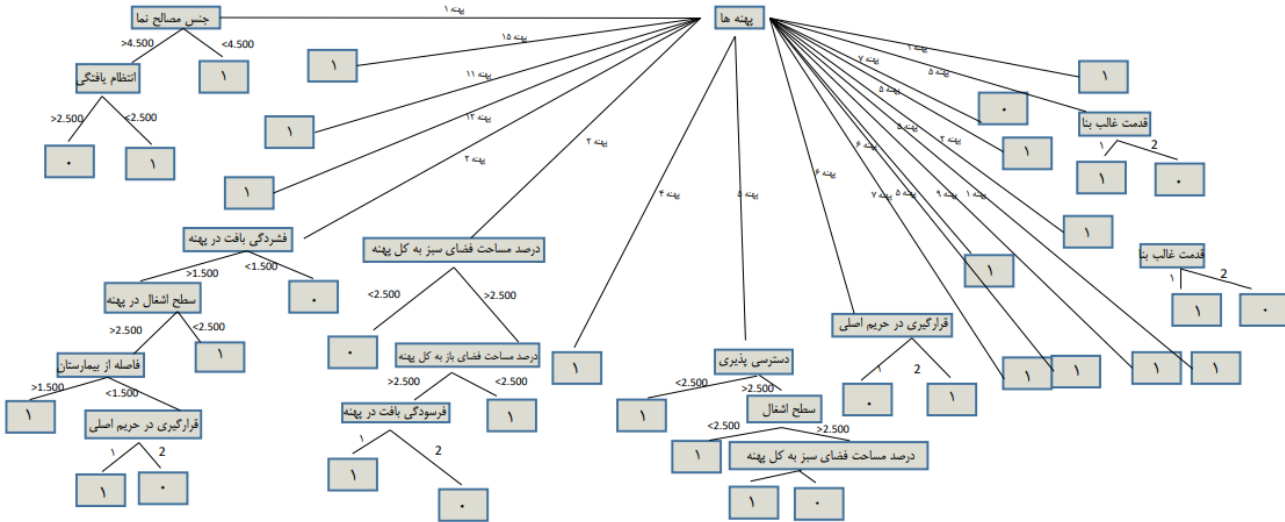


داشته و پس از آن فرسودگی، انتظام یافتگی، قرارگیری در حریم فرعی گسل و سطح اشغال قرار دارند. سایر ویژگی‌ها دارای اهمیت کمتری هستند.

#### جدول ۸- اهمیت متغیرهای پژوهش در الگوریتم درخت تصمیم

وزن	متغیر
۰,۲۳۸	قدمت غالب بنا
۰,۱۳۱	فرسودگی بافت در پهنه
۰,۱۲۹	انتظام یافتگی
۰,۱۰۲	قرارگیری در حریم فرعی گسل
۰,۰۹۱	سطح اشغال در پهنه
۰,۰۸۴	قرارگیری در حریم اصلی گسل
۰,۰۶۸	نسبت مساحت فضای سبز به کل پهنه
۰,۰۵۰	دسترسی پذیری پهنه
۰,۰۲۹	فاصله از بیمارستان
۰,۰۲۶	نسبت مساحت فضای باز به کل پهنه
۰,۰۲۲	فشرده‌گی بافت در پهنه
۰,۰۱۸	پهنه‌ها
۰,۰۱۲	جنس مصالح نما در پهنه

براساس موارد پیش گفته، می‌توان درخت تصمیم ایجادشده را مشاهده کرد.



تصویر ۴- درخت تصمیم با الگوریتم سی و آر ت<sup>۱</sup>

آسیب‌پذیری متوسط روبه‌بالا (یعنی بالای ۶۰ درصد) است و اگر بیشتر از ۲٫۵ باشد، آسیب‌پذیری کم است.

با آموزش ماشین براساس این الگوریتم و استفاده از ماتریس درهم‌آمیختگی برای بررسی صحت مدل، مشخص شد، معیار دقت که نشان‌دهنده تعداد پیش‌بینی‌های درست است، ۹۹٫۵۰٪ است. به این معنا که ۰٫۰۵٪ از نمونه‌ها به اشتباه در کلاس دیگر طبقه‌بندی شده‌اند.

همان‌طور که مشاهده می‌شود، پهنه به‌عنوان ریشه گره انتخاب‌شده که نشان‌دهنده بالا بودن اهمیت و تأثیرگذار بودن آن نسبت به سایر ویژگی‌ها است و براساس مجموعه‌ای از قوانین اگر-آنگاه قابل بررسی است. برای مثال در پهنه ۱ جنس مصالح نما، اهمیت دارد و اگر جنس مصالح نما در پهنه کمتر از مقدار عددی ۴٫۵ باشد، میزان آسیب‌پذیری متوسط روبه‌بالا خواهد بود. اگر جنس مصالح نما در پهنه ۱، بیشتر از مقدار عددی ۴٫۵ باشد، معیار انتظام-یافتگی برای تصمیم‌گیری انتخاب می‌شود. اگر معیار انتظام‌یافتگی کمتر از مقدار عددی ۲٫۵ باشد، میزان

جدول ۹- ماتریس درهم‌آمیختگی الگوریتم درخت تصمیم

کلاس صحیح	واقعی ۰	واقعی ۱	دقت: ۹۹٫۵۰٪
۹۹٫۴۲٪	۷	۱۲۰۶	پیش‌بینی ۱.
۱۰۰٫۰۰٪	۱۸۴	۰	پیش‌بینی ۰.
	۹۶٫۳۴٪	۱۰۰٫۰۰٪	فراخوانی کلاس‌ها

براساس مفهوم تصمیم‌گیری است و مرزهای تصمیم‌گیری را تعریف می‌کند. این روش بر طبق نظریه یادگیری آماری معرفی شده و از جمله روش-

### الگوریتم ماشین بردار پشتیبان

این الگوریتم یکی از روش‌های مناسب و کارا در حوزه طبقه‌بندی داده‌ها است. ماشین بردار پشتیبان

<sup>۱</sup> C&RT



در این قسمت پس از انجام مراحل در نرم افزار ریپید ماینر، نتایج روش ماشین بردار پشتیبان ارائه شده، براساس معیارهای اندازه گیری، معیار دقت، ۷۹،۸۱٪ به دست آمده است. به این معنا که ۲۰،۱۹٪ از نمونه ها به اشتباه در کلاس دیگر طبقه بندی شده اند.

های یادگیری نظارت شده است. قدرت ماشین بردار پشتیبان در تشخیص الگوهای پیچیده با استفاده روش مبتنی بر هسته است و با نداشت داده ها به فضایی با ابعاد بالاتر به راحتی می تواند الگوها را طبقه بندی نماید. به همین منظور در این پژوهش مورد استفاده قرار گرفته است.

جدول ۱۰- ماتریس درهم آمیختگی الگوریتم ماشین بردار پشتیبان

کلاس صحیح	واقعی ۰	۱ واقعی	دقت: ۷۹،۸۱٪
۸۸،۵۰٪	۱۳۸	۱۰۶۲	پیش بینی ۱
۲۶،۹۰٪	۵۳	۱۴۴	پیش بینی ۰
	۲۷،۷۵٪	۸۸،۰۶٪	فراخوانی کلاس ها

است که مراحل زیر انجام شود. نرمال سازی مجدد داده ها برای اجرای شبکه عصبی در بازه ۱- تا ۱. نرمال سازی با رابطه زیر انجام شده است.

### الگوریتم شبکه عصبی مصنوعی

همان طور که در بخش انتخاب الگوریتم ها بیان شد، شبکه عصبی مصنوعی، الگوریتمی ترکیبی است و مزایای درخت تصمیم و شبکه عصبی را با هم ترکیب می کند. برای استفاده از این الگوریتم در ابتدا لازم

$$SF = \frac{SRmax - SRmin}{Xmax - Xmin} \quad \text{رابطه (۱)}$$


$$Xp = SRmin + (X - Xmin) * SF \quad \text{رابطه (۲)}$$

که در آن:

ارزش واقعی از یک ستون عددی	$X$
کمترین ارزش واقعی از ستون	$Xmin$
بیشترین ارزش واقعی از ستون	$Xmax$
پایین ترین حد محدوده مقیاس	$SRmin$
بالاترین حد محدوده مقیاس	$SRmax$
عامل مقیاس بندی	$SF$
داده پردازش شده	$Xp$

رگرسیون و طبقه‌بندی است، از این تابع برای خطای خروجی استفاده شد. برای تعیین تعداد نورون‌های لایه مخفی اول، شبکه‌ای با یک لایه پنهان ساخته شد که تعداد نورون‌های لایه پنهان آن بین ۱ تا ۳۰ نورون بود. تصویر زیر خطای شبکه را نسبت به تعداد نورون‌های لایه پنهان پس از ۲۰۰۰ بار تکرار مجموعه آموزشی نشان می‌دهد. همان‌طور که ملاحظه می‌شود ساختار با ۱۲ نورون دارای کمترین میزان خطا است. بنابراین ساختار ۱-۱۲-۲۶ به‌عنوان بهترین ساختار انتخاب شد.

پس از آن لازم است تا معماری شبکه، توابع فعال‌ساز و خطا انتخاب شوند. در این پژوهش از بین دو روش جستجوی اکتشافی و جستجوی تفصیلی برای معماری شبکه، روش جستجوی تفصیلی به‌دلیل جستجوی دقیق‌تر مورد استفاده قرار گرفت. در مسائل از نوع طبقه‌بندی، تعداد نورون‌های لایه ورودی برابر با تعداد متغیرهای مستقل و در اینجا ۲۶ متغیر ورودی است. از سه تابع فعال‌ساز لایه پنهان شامل لجستیک، هایپربولیک تانژانت و خطی، دومی به‌دلیل عملکرد بهتر انتخاب شده است. از آنجاکه تابع مجموع مربعات خطا، شایع‌ترین تابع خطا و مناسب‌ترین گزینه برای مسائل



تصویر ۵- خطای کلی شبکه نسبت به تعداد نورون‌های لایه پنهان

است که شبکه تا حالا روبه‌رو نشده و شبکه با آن تست می‌شود. با توجه به تصادفی بودن وزن‌ها در هر بار تکرار و الگوریتم بازگشتی، این رویکرد به‌دنبال حفظ شبکه نیست، بلکه به‌دنبال بهبود یادگیری شبکه است. تصویر زیر عملکرد شبکه را در قالب منحنی مشخصه عملکرد آ.ا.و.سی.<sup>۳</sup> نمایش می‌دهد. هرچه قدر مساحت سطح زیر منحنی بیشتر باشد، شبکه بهتر خواهد بود. نتایج نشان‌دهنده عملکرد رضایت‌بخش شبکه پرسپترون چندلایه در پیش‌بینی آسیب‌پذیری پهنه‌ها است، زیرا خطای آموزش شبکه ۲/۱۵ درصد و شبکه طراحی شده ۹۷/۸۵ درصد میزان آسیب‌پذیری کالبدی را به‌درستی پیش‌بینی کرد.

در ادامه تابع انتقال و الگوریتم آموزش تعیین شدند. در شبکه‌های عصبی دو نوع روش آموزشی وجود دارد که عبارت‌اند از: ۱) الگو به الگو،<sup>۱</sup> ایپاک به ایپاک<sup>۲</sup>. در روش اول یک الگو به شبکه عصبی داده می‌شود، سپس خطا محاسبه و وزن‌ها تغییر می‌یابد و الگوی بعدی با وزن‌های جدید محاسبه می‌شود. در روش دوم تعدادی از ورودی‌ها به‌عنوان ایپاک در نظر گرفته می‌شود و تک‌تک ورودی‌های هر ایپاک به شبکه عصبی اعمال می‌شود، سپس خطای کلی محاسبه شده و بعد از تمام ورودی‌های ایپاک، وزن‌ها تغییر می‌یابد. خطای آموزش یعنی بعد از آموزش با داده‌هایی که با آنها شبکه آموزش داده می‌شود، خطا مشاهده می‌گردد. خطای آزمایش، خطا با داده‌هایی

<sup>3</sup> Receiver Operating Characteristic (ROC)

<sup>1</sup> pattern by pattern

<sup>2</sup> Epoch by Epoch



تصویر ۶- نمودار منحنی آر.او.سی.

آسیب‌پذیری پهنه‌ها با استفاده از شبکه عصبی به-خوبی ممکن است. اعتبارسنجی الگوریتم شبکه عصبی با ماتریس درهم‌آمیختگی نشان می‌دهد که معیار دقت ۹۷٫۸۵٪ است؛ به این معنا که صرفاً ۲٫۱۵٪ از نمونه‌ها به اشتباه در کلاس دیگر طبقه‌بندی شده‌اند.

به این دلیل که از یک سو، شبکه‌های عصبی قابلیت یادگیری رفتارهای پیچیده را دارا هستند و نتایج بهتری در مسائل پیچیده و فرایندهای غیرخطی دارند و از سوی دیگر با توجه به تعداد مربعات زیر منحنی آر.او.سی. در شبکه آموزش دیده این پژوهش (که برابر با ۶۷۴۵/۰ بوده و بهترین آستانه تعیین شده شبکه مقدار ۷/۰ بوده) و همچنین دقت ۹۷/۸۵ درصد در طبقه‌بندی صحیح داده‌ها در مرحله تست، می‌توان گفت که امکان پیش‌بینی

جدول ۱۰- ماتریس درهم‌آمیختگی الگوریتم شبکه عصبی چندگانه

دقت: ۹۷٫۸۵٪	۱ واقعی	۰ واقعی	کلاس صحیح
پیش‌بینی ۱.	۱۲۰۶	۳۰	۹۷٫۵۷٪
پیش‌بینی ۰.	۰	۱۶۱	۱۰۰٫۰۰٪
فراخوانی کلاس‌ها	۱۰۰٫۰۰	۸۴٫۲۹	

تکنیک‌های شبکه عصبی چندلایه و ماشین بردار پشتیبان، عملکرد بهتری دارد. پس‌از آن الگوریتم شبکه عصبی مصنوعی دارای عملکرد بهتری نسبت به الگوریتم ماشین بردار پشتیبان است. از جهت مقایسه صحت الگوریتم‌های مورد استفاده، درخت تصمیم و شبکه عصبی چندلایه دارای صحت کامل (۱۰۰٪) هستند.

## ۵ یافته‌ها و بحث

در این بخش در ابتدا، مقایسه‌ای میان الگوریتم‌های طبقه‌بندی استفاده شده، ارائه می‌شود. در ادامه به-منظور اطمینان از دقت ماشین آموزش دیده، با دادن داده‌های جدید، میزان دقت ارزیابی شد.

### ۵٫۱ مقایسه الگوریتم‌ها در از حیث

#### پیش‌بینی‌پذیری

با توجه به مقایسه نتایج عملکرد سه الگوریتم استفاده شده، درخت تصمیم به جهت دارا بودن دقت و حساسیت بیشتر و خطای کمتر نسبت به





## جدول ۱۱- مقایسه سه الگوریتم استفاده شده برای پیش‌بینی میزان آسیب‌پذیری کالبدی در برابر زلزله

عنوان	دقت (%)	صحت (%)	حساسیت (%)	خطا (%)
درخت تصمیم	۹۹،۵۰	۱۰۰	۹۹،۴۲	۰،۵۰
ماشین بردار پشتیبان	۷۹،۸۱	۸۸،۰۵	۸۸،۵۰	۲۰،۱۹
شبکه عصبی چندلایه	۹۷،۸۵	۱۰۰	۹۷،۵۷	۲،۱۵

روی گسل ری، انتخاب شد. در این محله نیز پهنه-بندی مورفولوژیکی انجام شد (۶ پهنه) و داده‌های مربوط به ویژگی‌های بعد مورفولوژی جمع‌آوری، داده‌ها آماده‌سازی، نرمال‌سازی و استانداردسازی شدند.

برای این محله، ابتدا میزان آسیب‌پذیری پهنه‌های محله با استفاده از نقشه‌های مدیریت بحران و اطلاعات جایکا به‌عنوان خروجی مورد انتظار شناسایی و با پیش‌بینی ماشین مقایسه شد.

## ۵،۲ بررسی دقت ماشین آموزش‌دیده در پیش‌بینی آسیب‌پذیری کالبدی با داده‌های جدید

به‌منظور بررسی دقت ماشین و سنجش عملکرد صحیح آن، داده‌های کالبدی مربوط به یک محله جدید به ماشینی آموزش‌دیده، ارائه و خروجی مورد انتظار از آن یعنی آسیب‌پذیری کالبدی در برابر زلزله بررسی شد.

محله منتخب، محدوده جوانمرد قصاب واقع در منطقه ۲۰ شهرداری است که به‌دلیل قرارگیری بر

## جدول ۱۱- میزان آسیب‌پذیری کالبدی مورد انتظار در برابر زلزله در محله جوانمرد قصاب

محل	پهنه‌ها	میزان آسیب‌پذیری کالبدی
جوانمرد قصاب	۱	آسیب‌پذیری متوسط
	۲	آسیب‌پذیری کم
	۳	آسیب‌پذیری کم
	۴	آسیب‌پذیری متوسط
	۵	آسیب‌پذیری زیاد
	۶	آسیب‌پذیری خیلی زیاد
	۷	آسیب‌پذیری خیلی زیاد
	۸	آسیب‌پذیری خیلی زیاد

دقت بالایی توانسته‌اند میزان آسیب‌پذیری را پیش‌بینی کنند. بنابراین ماشین آموزش‌دیده در داده‌های جدید هم به‌خوبی عمل کرده و قابلیت استفاده برای داده‌های جدید، برای ارائه میزان آسیب‌پذیری کالبدی را دارد. همان‌طور که در جدول مشاهده می‌شود، دو الگوریتم درخت تصمیم و شبکه عصبی مصنوعی دقت بالای ۹۷ درصد در پیش‌بینی‌پذیری را دارند.

جهت پیش‌بینی میزان آسیب‌پذیری و ارزیابی دقت مدل، از نرم‌افزار رپیدماینر که دیتاست نرم‌افزار امکان ورود اطلاعات جدید برای محلات جدید را می‌دهد، استفاده شد. ویژگی‌های مورفولوژیکی محله جدید به‌عنوان ورودی به ماشین داده و خروجی آن با نتایج جدول ۱۱ مقایسه شد.

همان‌طور که در جدول ۱۲ مشاهده می‌شود، الگوریتم درخت تصمیم و شبکه عصبی مصنوعی با



جدول ۱۲- نتایج دقت الگوریتم‌ها با داده‌های جدید

الگوریتم	درخت تصمیم	ماشین بردار پشتیبان	شبکه عصبی مصنوعی
ارزیابی مدل	ماتریس درهم‌آمیختگی	ماتریس درهم‌آمیختگی	نمودار آر.او. سی.
دقت	۹۸,۴۰٪	۸۱,۷۵٪	۹۷,۸۵٪

### ۵,۳ مقایسه با ساختار دانش موجود

همان‌طور که در پیشینه پژوهش بیان شد، پژوهش‌های کمی با رویکرد این پژوهش در حوزه زلزله انجام شده است. بنابراین برای مقایسه یافته‌های این پژوهش با ساختار دانش موجود، نمی‌توان به صورت دقیق به ارائه تفاوت یافته‌های کمی پرداخت. بنابراین به این منظور، برای انجام این مقایسه به بخش‌های مختلف پژوهش رجوع می‌شود. در پژوهش‌های مطالعه شده، برای تعیین آسیب‌پذیری شاخص‌های اجتماعی، اقتصادی، کالبدی و... مورد بررسی قرار گرفته، اما این پژوهش به صورت ویژه شاخص‌های مورفولوژی را مورد توجه قرار داده و با انتخاب یادگیری ماشین و همچنین مدیریت بحران هوشمند، مدل مفهومی مربوطه را تدوین نموده است.

از حیث نتایج بخش تحلیلی، در پژوهش‌های انجام شده از یک الگوریتم چون الگوریتم رگرسیون لجستیک، یا شبکه عصبی چندلایه و یا شبکه عصبی آر.بی.اف. استفاده شده، این پژوهش به بررسی سه الگوریتم پرداخته است. همچنین علی‌رغم آنکه درخت تصمیم، دقت بسیار بالایی در پیش‌بینی را فراهم می‌کند، به دلیل معایب آن که پیش‌از این بیان شد، با دو الگوریتم دیگر نیز ماشین آموزش و تست گردید. بر این اساس از آنجاکه دقت ماشین آموزش‌دیده، با شبکه عصبی مصنوعی نیز بسیار بالا بود، بنابراین ماشین به خوبی قابلیت دسته‌بندی و پیش‌بینی‌پذیری کالبدی در برابر زلزله را دارد.

### ۶ جمع‌بندی و نتیجه‌گیری

در این پژوهش با توجه به هدف، در ابتدا مدیریت بحران هوشمند معرفی و ابعاد تأثیرگذاری آن در مراحل مختلف بحران بیان شد. در ادامه رویکرد یادگیری ماشین به‌عنوان رویکردی نسبتاً نو نسبت به روش‌های متداول شهرسازی کمی (چون تحلیل فضایی)، برای تعیین و ارائه مدل پیش‌بینی کننده آسیب‌پذیری کالبدی انتخاب شد. در ادامه، چارچوب مفهومی پژوهش و شناسایی ویژگی‌ها و تهیه مجموعه داده که به نوعی یکی از دستاوردهای این پژوهش نیز محسوب می‌شود تهیه و ماشین با الگوریتم‌های مناسب آموزش و تست شد. این مجموعه داده با بارگذاری در گیت‌هاب این امکان را برای سایر پژوهشگران فراهم می‌آورد که با استفاده از این مجموعه داده‌ها و با الگوریتم‌های دیگر، بتوانند مدل‌های پیش‌بینی‌کننده را بهبود بخشید.

یکی از دستاوردهای این پژوهش آن است که در زمینه‌هایی مانند مباحث پیش‌بینی آسیب‌پذیری، کاهش تلفات زلزله، شناسایی آسیب‌پذیری بافت با این رویکرد، گام مؤثری برداشته است. از آنجاکه این رویکرد با سرعت بالا و در زمان کم، قابلیت پیش‌بینی‌پذیری آسیب‌پذیری بافت کالبدی محلات در برابر زلزله را دارد، می‌تواند توسط نهادهای اجرایی و مدیریتی مورد استفاده قرار گیرد. بنابراین با ارائه داده‌ها در قالب ویژگی‌های کالبدی و مربوط به گسل به ماشین، می‌توان محدوده‌های با خطر بالا را شناسایی نمود. با این وجود این پژوهش با محدودیت‌هایی نیز مواجه بوده است. این محدودیت‌ها در سه بخش قابل تقسیم‌بندی هستند، محدودیت‌های جمع‌آوری داده،



محدودیت‌های مالی و محدودیت‌های زمانی. در مرحله جمع‌آوری داده‌ها و مراجعه به سازمان‌های مرتبط، عدم همکاری در بعضی از سازمان‌ها و عدم دسترسی به اطلاعات برخی سازمان‌ها مانند فناوری اطلاعات و ارتباطات به دلیل دانشگاهی بودن پروژه، وجود داشت. همچنین عدم دسترسی به تعدادی از اطلاعات و نقشه‌های به‌روز از جمله نقشه‌های جی.آی.اس. مربوط به برخی از ویژگی‌ها مانند اسکلت ابنیه، کیفیت ساختمان‌ها، جنس مصالح نما از دیگر محدودیت‌های پژوهش بوده است. لازم به ذکر است که امکان انجام پژوهش، بدون نیاز به جمع‌آوری داده‌های مورفولوژیکی و از طریق داده‌های تصویری نیز ممکن است، برای این منظور می‌توان از تصاویر هوایی با کیفیت بالا و تکنیک پردازش تصویر، ویژگی‌های آماری و غیرآماري را شناسایی نمود و آنها را به ماشین داد، تا مدل پیش‌بینی کننده آموزش یابد. با توجه به عدم دسترسی به اطلاعات تصویری با جزئیات و کیفیت مناسب، امکان انجام آن با محدودیت مواجه بوده است.

در عین حال از آنجاکه دسترسی به مجموعه داده‌های بزرگ، نیاز به منابع مالی کافی دارد، امکان استفاده از الگوریتم‌های یادگیری عمیق، ممکن نبوده است.



## منابع

- Ahmadi, M. et al. (2018). Data Mining with RapidMiner: Data Access, Combination and Cleansing. Qom: Elham Noor Publication. [in Persian]
- Akerkar, R. (2018). Processing Big Data for Emergency Management. (Eds. Zhi Liu & Kaoru Ota) Smart Technologies for Emergency Response and Disaster Management. USA: IGI Publication.
- Alazawi, Z. et al. (2014). A Smart Disaster Management System for Future Cities. In Proceedings of the 2014 ACM International Workshop on Wireless and Mobile Technologies for Smart Cities (pp. 1-10).
- Alizadeh, M. et al., (2018). A Hybrid Analytic Network Process and Artificial Neural Network (ANP-ANN) Model for Urban Earthquake Vulnerability Assessment. Remote Sens, 10(6), 975, 1-34.
- Avvenuti, M. et al., (2014). EARS (Earthquake Alert and Report System): a Real Time Decision Support System for Earthquake Crisis Management, [Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining](#), 1749-1758.  
<https://doi.org/10.1145/2623330.2623358>.
- Baft Shahr Consulting Engineers. (2007). Preparation of Development Model and Detailed Plan of District 1 of Tehran Municipality. [in Persian]
- Bagheri N., Motamedi M. & Mafi E. (2022). Assessing the resilience of Shirvan city in the face of earthquakes. Journal of Applied researches in Geographical Sciences, 22 (64), 329-347. [in Persian]
- Benaben, F. et al., (2017). A Conceptual Framework and a Suite of Tools to Support Crisis Management. Proceedings of the 50<sup>th</sup> Hawaii International Conference on System Sciences, 237-246.
- Carmona, M., Tiesdell, S. Heath, T. & Oc, T. (2012). Public Places Urban Spaces, The Dimensions of Urban Design. Routledge, Taylor & Francis Group.
- Chambelland, J.C., et al., (2011). SIMFOR: Towards a Collaborative Software Platform for Urban Crisis Management. MCSIS CGVCVIP.
- Ebrahimzaeh, I., Kashefi, D., & Hosseini, S. A. (2015). Evaluating the Vulnerability of Urban Regions Against Earthquake, Case Study: the City of Piranshahr. Saptial Planning, 5(1), 1-26. [in Persian]
- Eliasian, I. (2021). Artificial Intelligence and Machine Learning. Tehran: Ketab-e Sabz Publication. [in Persian]
- Faraji, A. & Qarakhlo, M. (2009). Earthquake and Urban Crisis Management (Case Study: Babol



- City). *Journal of Geography*. 8(25), 143-164. [in Persian]
- Farzadenia, A. and Monsefi, D. (2018). The Impact of Smart Cities on Crisis Management, Case Study: Japan. Conference on Civil Engineering, Architecture and Urban Planning of the Islamic world. Azerbaijan-e Sharghi: Tabriz University. [in Persian]
- Golrokh, S. (2012). [Rethinking Fabric 'Deterioration'](#) Based on Place Deterioration. *Soffeh*, 2(2), 79-94. [in Persian]
- Habibi, Q. et al., (2013). Developing a Model to Assess Seismic Instability against Earthquake using Fuzzy & IHPW and GIS. *Scientific Quarterly Journal of Geosciences*, 22(87), 83-92. [in Persian]
- Hayati, S. et al., (2017). [Predicting the Location of a Possible Earthquake in Khorasan Razavi Province by Using Artificial Neural Network](#). *Journal of Geography and Environmental Hazards*, 5(20), 1-19. [in Persian]
- Hosseini, A. & Omidari, F. (2017). Analyzing the Role of Urban Design in the Crisis Management Cycle. *Memarishenasi*, 1(2), 1-8. [in Persian]
- Hosseini, R. (2015). Establishing Indices of Underground Space Development in Terms of Urban Crisis Management Criteria. *Bagh-e Nazar*, 12(35), 53-64. [in Persian]
- Hosseinpour, A., Shamshirband, M. & Tavakoli, A. (2009). Investigating the Process of Reducing Urban Open Spaces in the Process of Urban Development with an Emphasis on Crisis Management, a Case Study of Tehran Metropolis. *Geography*, (5), 141-154. [in Persian]
- Ibrahim, I., Abdullah, A., Ibrahim, M. & Farhana, F. (2018). Historical Urban Form: A Case Study of Melaka. *Journal of the Malaysian Institute of Planners*, 16(2), 153-163.
- Jung, D. et al., (2020). Conceptual Framework of an Intelligent Decision Support System for Smart City Disaster Management, *Applied Sciences*, 10(2) (666), 1-13. <https://doi.org/10.3390/app10020666>
- Karimi, S. & Nasr, A. R. (2013). The Methods of Analyzing Interview Data. *Ayar-e Pajohesh Dar Oloom-e Ensani*, 4(1), 71-94. [in Persian]
- L. Finn, R. et al., (2015). Exploring Big 'Crisis' Data in Action: Potential Positive and Negative Externalities. *ISCRAM*, 25 May, 1-10.
- Lee, S. et al., (2019). SEVUCAS: A Novel GIS-Based Machine Learning Software for Seismic Vulnerability Assessment. *Applied Science*, 9 (3495), 1-21.
- [Linardos](#). V., et al., (2022) Machine Learning in Disaster Management: Recent Developments in Methods and Applications. *Machine Learning*



- and Knowledge Extraction, 4(2), 446-473. <https://doi.org/10.3390/make4020020>.
- Liu, Y. et al., (2019). Seismic Vulnerability Assessment at Urban Scale Using Data Mining and GIS Science Technology: Application to Urumqi (China). *Geomatics, Natural Hazards and Risk*, 10(1), 958-985. <https://doi.org/10.1080/19475705.2018.1524400>.
- Mohammad Shafiei, M. R. & Mohammad Shafiei, A. H. (2014). Crisis and its Management Solutions. The Second International Research Conference in Science and Technology, Sarmad Hamyesh Karin Institute, March 24. [in Persian]
- Mohemed, A.S., Harun, N.Z. & Abdullah, A. (2018). Urban Morphological Analysis Framework for Conservation Planning and Management. *Journal of the Malaysian Institute of Planners*. 16(1), 360-371.
- Nadeem, M., et al. (2021). Scaling the Potential of Compact City Development: The Case of Lahore, Pakistan. *Sustainability*, 13 (5257), 1-22.
- Nazemi, E. (2016). Examining Concepts and Theoretical Foundations of Worn Texture [website]. Retrieved on 30 May 2022, [https://research.iaun.ac.ir/pd/nazemi/pdfs/UploadFile\\_8326.pdf](https://research.iaun.ac.ir/pd/nazemi/pdfs/UploadFile_8326.pdf) [in Persian]
- Nazmfar, H. & Alavi, S. (2019). Evaluating the vulnerability of urban buildings to various earthquake intensities Case study: District 9 of Tehran Municipality. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 27(108), 165-181. [in Persian]
- Piper, W. (2018). Crisis Management Under the Control of New Technologies. Spectrum Analysis Scientific Group [website]. Retrieved on 21 May 2021, from [https://teyf.ir/wp-content/uploads/2019/10/whitepaper\\_01.pdf](https://teyf.ir/wp-content/uploads/2019/10/whitepaper_01.pdf) [in Persian]
- Pishgahi Fard, Z. et al. (2010). GIS Geographic Information System and Its Role in Locating Risky Urban Areas for Use in Crisis Management (Case Study: District 8 of Tabriz Municipality). *Geographical Quarterly Journal of Environmental Based Territorial Planning*, 4(13), 91-104. [in Persian]
- Qadir, J. et al., (2016). Crisis Analytics: Big Data Driven Crisis Response. *Journal of International Humanitarian Action*, 1(1), 1-8.
- Qanawati, E., Qalami, S. & Abdoli, A. (2008). Empowering Urban Crisis Management to Reduce Natural Disasters (Earthquake), Case Study: Khorramabad City. *Journal of Natural Geography*, 4, 15-24. [in Persian]
- Sahoh, B. & Choksuriwong, A. (2017). Smart Emergency Management Based on Social Big Data Analytics: Research



- Trends and Future Directions. Proceedings of the 2017 International Conference on Information Technology, December, 1-6.
- Salvatián, S. & Mehraban, F. (2016). Role of Social Media in Disaster Management of possible Earthquake in Tehran. Disaster Prevntion and Management Knowledge. 6 (1), 9-22. [in Persian]
- Sanieizadeh, M., Mahmoudi, S. & Taher Parvar, M. (2012). Applied Data Mining. Tehran: Niازه-Danesh. [in Persian]
- Shahi, S.A., Hameed, S. & Draheim, D. (2019). The Rising Role of Big Data Analytics and IoT in Disaster Management: Recent Advances, Taxonomy and Prospects. IEEE Journal, 7, 24595-45614. <https://10.1109/ACCESS.2019.2913340>
- Sinafar, A. Partovi, P. & Shokouhi, M. (2015). Investigating the Role of Permeability in Promotion of Quality of Environment of Neighborhood Unit (Case Study: Tehran-Narmak). Hoviatshahr, 9(21), 91-100. [in Persian]
- Stangl, P. (2018). Prospects for Urban Morphology in Resilience Assessment. (Eds.) In Lecture Notes in Energy, (PP. 181-193).
- Taghvaei, M., Jozi Khamselouei (2012). Management and Planning of Crisis in Urban Spaces with Passive Defense Approach and SWOT Model. Case Study: Marching Routes of Isfahan City. Geographical Planning of Space Quarterly Journal, 2(6), 57-74. [in Persian]
- Talebpoor, A. & Mojahedini, M. (2019). [The Role of Integrated Urban Management in Improving Crisis Management and Improving the Quality of Public Services to Citizens \(Case Study: Tehran Province\)](#). Socio-Cultural Development Studies, 7(4), 67-92. [in Persian]
- Vazan, M. (2021). Machine Learning and Data Science: Fundamentals, Concepts, Algorithms and Tools. Tehran: Miaad-e Andisheh. [in Persian]
- Yarahmadi, M., Nikpour, A. & Lotfi, S. (2020). Evaluating the physical resilience of cities against earthquakes: A case study of Noorabad Mamassani. The Journal of Geographical Research on Desert Areas, 7(2), 147-171. [in Persian]
- Yariyan, P. et al., (2020). Earthquake Vulnerability Mapping Using Different Hybrid Models. Symmetry Journal, 12(3), 405. <https://doi.org/10.3390/sym12030405>.
- Yu, M., Yang, C.H. & Li. Y. (2018). Big Data in Natural Disaster Management: A Review. Geosciences Journal, 8(5), 1-26.



<https://doi.org/10.3390/geosciences8050165>.

Zare, M. (2015). The Faults of Tehran, Crisis Management and Earthquake Risk

in Tehran [website]. Retrieved on August 1, 2022, from <http://iranethics.ir/files/site1/files/khordad95.pdf> [in Persian]