Journal of Iranian Association of Electrical and Electronics Engineers
Vol. 23 No. 1, 2026
DOI: 10.61882/jiaeee.23.1.126

Application of Neural Networks for Estimating Soil Resistivity in Grounding System of a Power Distribution Network

Mohammadreza Fadaei Tehrani[1*], Mina Dehghani[2]

[1] Assistant Professor and Faculty Member, Water and Power Industry Higher Education Complex, Research Institute of Power, Isfahan, Iran.
mfadaei@nri.ac.ir

[2] M.Sc. in Electrical Power Engineering and Training Specialist, Water and Power Industry Higher Education Complex, Research Institute of Power, Isfahan, Iran.
MiDehghani@nri.ac.ir

Abstract:

Soil resistivity, as a key parameter in grounding systems, indicates the soil's ability to conduct electric current and directly impacts the performance of grounding systems. This research aims to provide a practical and cost-effective method for estimating soil-resistivity through limited measurements and training a neural network for optimal design of the distribution network grounding system. In this study, soil resistivity was measured at 70 points in Isfahan at three different depths and used to train a neural network in MATLAB. Considering the scattered distribution of measurement points, for better estimation, the data was subjected to statistical analysis using two sequential k-means clustering before being applied as input to the neural network. The first clustering was based on the geographical location of the points, and the second clustering was based on depth. The cluster resulting from this analysis was fed into the neural network as input. According to the results of this research, the correlation coefficient R2 between the actual and estimated values by the model was 0.9567, which is completely satisfactory and confirms that the application of the proposed method is a useful tool for estimating the performance of ground-resistance over a wide geographical area and at different depths.

Keywords: Specific resistance, Grounding Earthing, Sequential two-step clustering, k-means

Article Type: Research

Received: 28. 12. 2024

Revised: 18. 08. 2025

Accepted: 07. 10. 2025

Corresponding author: Mohammadreza Fadaei Tehrani

Corresponding author's address: Water and Power Industry Higher Education Complex, Research Institute of Power, Isfahan, Iran.

Copyright © 2026 The Authors. Published by Iranian Association of Electrical and Electronics Engineers.
This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International license (https://creativecommons.org/licenses/by-nc/4.0/). Non-commercial uses of the work are permitted, provided the original work is properly cited.

1. Motivation of the work

The design of an efficient and low-impedance grounding system is critical for ensuring personnel safety and protecting electrical equipment in power distribution networks. A key parameter in this design is the soil electrical resistivity, which directly determines the grounding system's performance. However, this resistivity is highly variable, depending on geographical location, soil depth, moisture, temperature, and seasonal changes.

Conventional approaches require extensive and costly in-situ resistivity measurements at numerous points across a vast service area to achieve an accurate and site-specific design. This practice is often impractical for distribution companies, leading to the application of generalized, "one-size-fits-all" grounding designs. Such oversimplification results in either inefficient (and potentially unsafe) systems in some areas or over-engineered (and unnecessarily expensive) solutions in others, representing a significant waste of national resources.

To address this challenge, there is a compelling need for a practical, rapid, and cost-effective method to estimate soil resistivity at unmeasured locations using a limited set of initial measurements. While previous studies have utilized Artificial Neural Networks (ANNs) for related estimations, they often face challenges in determining optimal network architecture (like the number of hidden layers and neurons) and may not adequately handle the complex, non-linear, and clustered nature of geospatial and depth-dependent soil data.

Therefore, the primary motivation of this work is to develop and validate a novel, intelligent estimation model that combines a streamlined neural network structure with sequential data clustering. This hybrid approach aims to provide distribution companies with a reliable tool for optimizing grounding system designs based on accurate, wide-area soil resistivity predictions, thereby enhancing safety, reliability, and cost-efficiency.

2. Contributions

This work provides distinct contributions by introducing a novel, practical, and optimized framework for soil resistivity estimation, addressing key gaps in previous approaches.

Its primary advantage is the development of a hybrid intelligent model that uniquely combines sequential two-step k-means clustering with a streamlined Element neural network (ELM). Unlike conventional multi-layer perceptrons (MLPs) used in prior studies, which struggle with determining optimal hidden layers and neuron counts, the ELM architecture utilized here employs a single hidden layer. This fundamental choice simplifies the design process, reduces computational complexity, and effectively prevents overfitting, leading to a more robust and easier-to-optimize model.

Furthermore, the innovative two-stage clustering pre-processing represents a significant methodological advancement. By first grouping data geographically and then by resistivity-depth profile, the model intelligently structures the highly variable and non-linear field data. This allows the neural network to learn from logically grouped samples, enhancing its ability to capture the complex spatial and geophysical relationships inherent in soil properties.

The core objective and contribution of this review is to demonstrate that this integrated approach offers power distribution companies a superior, cost-effective tool. It enables accurate, wide-area soil characterization from minimal direct measurements, directly supporting the design of site-specific, safe, and economically optimized grounding systems—a decisive step beyond inefficient one-size-fits-all practices.

3. Procedures

This was a field data collection and computational modeling study. The "subjects" were 70 distinct geographical points across the city of Isfahan, Iran.

Procedure & Conditions: At each point, soil electrical resistivity was physically measured in-situ at three standard depths: 1.5, 3, and 6 meters below the surface. These measurements provided the core empirical dataset.

Analysis & Modeling: The collected data was then processed through a hybrid computational pipeline. First, statistical analysis and box-plot visualization were used to identify and remove outlier measurements. Next, the data underwent two sequential k-means clustering steps: initially based on geographical coordinates (latitude, longitude, altitude), and subsequently based on the resistivity values at the three depths. Finally, the resulting clustered data was used to train and validate a custom Element neural network in MATLAB. The network's inputs were geographical coordinates, and its outputs were the predicted resistivity values at the three depths.

Measurement & Comparison: The key variable measured was soil resistivity (in Ω·m). The study compared the model-predicted resistivity values against the actual, physically measured resistivity values for the test data points. Performance was evaluated using metrics like the correlation coefficient (R^2), maximum absolute error, and mean absolute error to quantify the accuracy of the proposed estimation model.

Duration: The timeframe for field measurements is not specified, but the computational modeling and analysis were conducted as a discrete research project.

4. Findings

The study yielded several significant findings that validate the proposed hybrid model. The core result was the model's high predictive accuracy, evidenced by a correlation coefficient (R^2) of 0.9567 between the actual measured soil resistivity values and the model's estimates. This indicates a very strong agreement between the predictions and real-world data.

A critical technical finding was the importance of model architecture and parameter tuning for generalization. The initial model with 10 hidden neurons showed perfect training fit but poor prediction (R^2=0.55 on test data), indicating severe overfitting. Optimizing the model by reducing hidden neurons to two successfully mitigated

this, drastically improving test performance (test R^2=0.98) while maintaining good training accuracy. This demonstrates that the simpler Element network structure is highly effective for this task.

Furthermore, the two-step sequential k-means clustering proved essential. Clustering first by geographic location and then by resistivity values at different depths effectively organized the complex, scattered data into meaningful groups. This pre-processing step was crucial for feeding coherent data subsets to the neural network, enabling it to learn the underlying spatial and geophysical patterns.

The utility and significance of these findings are substantial. The research provides a practical and validated methodology for power utilities to move away from costly, blanket grounding designs. By enabling accurate soil resistivity estimation from limited measurements, the model offers a significant reduction in survey costs and time while promoting the design of safer, more reliable, and economically optimized grounding systems tailored to specific local soil conditions.

5. Conclusion

The major outcome of this study is the successful development and validation of a novel, intelligent framework for accurately estimating soil resistivity over wide geographical areas and varying depths. By integrating a streamlined Element neural network with a two-step sequential k-means clustering pre-processing technique, the research addressed key limitations of previous methods, such as architectural complexity and handling of non-linear, clustered geospatial data.

The proposed model demonstrated high predictive accuracy, achieving a strong correlation coefficient (R^2 = 0.9567) between estimated and actual measured values. Crucially, the use of the single-hidden-layer Element network simplified the optimization process, effectively avoiding overfitting and facilitating the determination of optimal neuron counts compared to multi-layer perceptrons.

This work proves that a limited set of field measurements (70 points across Isfahan) can be intelligently extrapolated to predict resistivity at unmeasured locations. The outcome provides power distribution utilities with a practical, cost-effective, and reliable tool for designing optimized, site-specific grounding systems. This enhances electrical safety, protects infrastructure, and prevents the resource waste associated with generalized, inefficient grounding designs.

نشریه مهندسی برق و الکترونیک ایران

نشریه مهندسی برق و الکترونیک ایران، سال بیست و سوم، شماره اول، بهار ۱۴۰۵، صفحات ۱۲۶-۱۳۵

DOI: 10.61882/jiaeee.23.1.126

کاربرد شبکه عصبی برای تخمین مقاومت مخصوص خاک در سیستم زمین شبکهٔ توزیع برق

محمدرضا فدائی‌تهرانی[1*]، مینا دهقانی[2]

۱- استادیار و عضو هیات‌علمی، مجتمع عالی آموزشی و پژوهشی صنعت آب و برق، پژوهشگاه نیرو، اصفهان، ایران

mfadaei@nri.ac.ir

۲- دانش‌آموخته مقطع کارشناسی ارشد رشته برق قدرت و کارشناس آموزش، مجتمع عالی آموزشی و پژوهشی صنعت آب و برق، پژوهشگاه نیرو، اصفهان، ایران

MiDehghani@nri.ac.ir

چکیده: مقاومت ویژه الکتریکی خاک به عنوان یکی از پارامترهای کلیدی در سیستم‌های زمین، نشان‌دهنده توانایی خاک در هدایت جریان الکتریکی بوده و بر عملکرد سیستم زمین تأثیر مستقیمی دارد. هدف از این پژوهش، ارائه یک روش کاربردی، سریع و ارزان جهت تخمین مقاومت مخصوص خاک از طریق اندازه‌گیری‌های محدود و آموزش شبکه عصبی برای طراحی بهینه سیستم زمین شبکه توزیع است. در این تحقیق، ابتدا در ۷۰ نقطه از شهر اصفهان مقاومت مخصوص خاک در سه عمق اندازه‌گیری و برای آموزش شبکه عصبی در MATLAB، استفاده شد. با توجه به پراکندگی نقاط اندازه‌گیری، برای تخمین بهتر، پیش از اعمال ورودی به شبکه عصبی با استفاده از دو خوشه‌بندی متوالی k-means داده‌ها مورد تحلیل آماری قرار گرفت. خوشه‌بندی اول براساس موقعیت جغرافیایی نقاط و خوشه‌بندی دوم براساس عمق انجام شد و خوشه حاصل از این تحلیل به عنوان ورودی به شبکه عصبی داده شد. بنابر نتایج این پژوهش، بین مقادیر واقعی و تخمین زده شده توسط مدل، ضریب همبستگی R^2 برابر ۰.۹۵۶۷ مشاهده شد که بطور کامل رضایت بخش است و تصدیق می کند که کاربرد روش پیشنهادی، ابزار مفیدی برای تخمین عملکرد مقاومت زمین در گسترده جغرافیائی و اعماق مختلف خواهد بود.

کلمات کلیدی: مقاومت مخصوص، اتصال زمین، دو خوشه‌بندی متوالی، k-means

نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۱۰/۰۸

بازنگری: ۱۴۰۴/۰۵/۲۷

پذیرش: ۱۴۰۴/۰۹/۱۶

نام نویسنده‌ی مسئول: محمدرضا فدائی‌تهرانی

نشانی نویسنده‌ی مسئول: اصفهان، میدان استقلال، جنب دانشگاه صنعتی، مجتمع آموزشی و پژوهشی صنعت آب و برق پژوهشگاه نیرو

حق انتشار این مستند، متعلق به نویسندگان آن است. ۱۴۰۵ ©. ناشر این مقاله، انجمن مهندسین برق و الکترونیک ایران است.

این مقاله تحت گواهی زیر منتشرشده و هر نوع استفاده غیرتجاری از آن مشروط بر استناد صحیح به مقاله و با رعایت شرایط مندرج در آدرس زیر مجاز است.

Creative Commons Attribution-NonCommercial 4.0 International license
(https://creativecommons.org/licenses/by-nc/4.0/)

۱- مقدمه

هدف از احداث سیستم زمین در شبکه‌ها و تاسیسات الکتریکی، از دو منظر ایمنی افراد و حفاظت تجهیزات حائز اهمیت است. زمین کردن و هم‌بندی بخش‌های جدایی‌ناپذیر از طرح یک سیستم حفاظت الکتریکی مدرن می‌باشند. یک سیستم زمین کم امپدانس و موثر عنصر کلیدی در این راستا است. جهت اطمینان از ایمنی اشخاص و نیز برای حفاظت مطمئن دستگاه‌های مهم الکتریکی و به حداقل رساندن خروج آن‌ها از سرویس و هزینه‌های خاموشی، نقش سیستم زمین بسیار مهم می‌باشد. کاربرد سیستم‌های زمین دارای قدمتی برابر با کاربرد شبکه‌های برق است و موازی با آن توسعه یافته است. در واقع اتصال زمین با ایجاد مسیری برای شارش جریان از نقطه اتصالی به زمین و بازگرداندن آن به منبع، شناسایی اتصالی را ممکن می‌سازد [۱, ۲]. بین سال‌های ۱۸۸۰ تا ۱۸۹۲ خطوط انتقال و توزیع برق بدون این که نقطه نول آن‌ها زمین شود، احداث می‌شدند. در واقع هیچ نقطه‌ای از شبکه و تجهیزات زمین نمی‌شد و اساساً مفهومی به نام الکترود زمین وجود نداشت. چون در چنین وضعیتی، فیوزهای حفاظتی اتصال کوتاه‌های فاز به زمین را در شبکه تشخیص نمی‌دهند، آتش‌سوزی و برق گرفتگی‌های متعدد در سازمان‌ها و مکان‌های عمومی و حتی منازل مسکونی باعث ایجاد خسارت‌های فراوان می‌شد [۳]. در سال ۱۹۲۴ انجمن مهندسان برق در انگلستان با اجباری کردن اتصال بدنه‌های فلزی به زمین، اولین سیستم‌های زمین را شکل دادند و تا حدودی از خسارات وارده جلوگیری شد. هر چند کار بسیار دشواری بود اما بلافاصله فرانسه نیز استاندارد زمین را اجباری کرد. با گذشت تقریبا ۳ سال، اتصال نقطه نول ترانسفورماتورها به زمین در فرانسه مصوب شد. در سال ۱۹۳۵ استانداردهای جامع حفاظت اشخاص و تجهیزات تدوین و اجرایی گردید و ارتینگ همگانی شد [۴, ۵].

هدف هر سیستم ارتینگ، فراهم کردن مسیری با مقاومت کم برای جریان‌های خطا و صاعقه و تضمین حفاظت هر فرد در مجاورت تاسیسات ارت شده است [۱]. مقدار مقاومت زمین به شدت به سیستم ارتینگ و خواص خاک، جایی که سیستم در آن تعبیه شده است، بستگی دارد. یک سیستم ارتینگ خوب در حال تبدیل شدن به یک ضرورت در هر سیستم تولید، انتقال و توزیع برق برای کاهش خطر خرابی تجهیزات است. در هر پست برق، یک سیستم ارتینگ خوب مسیری با مقاومت کم برای جریان بالای خطا به زمین فراهم می‌کند که به نوبه خود باعث کاهش زمان خرابی و احتمال خرابی تجهیزات و کاهش احتمال تلفات انسانی ناشی از صاعقه یا جریان‌های خطا می‌شود [۶, ۷].

مقاومت ویژه زمین، به نوبه خود، با دما، رطوبت، میزان نمک و تراکم خاک تغییر می‌کند [۱, ۸-۱۰]. از آنجایی که این پارامترها در طول سال تغییر می‌کنند، سیستم ارتینگ نمی‌تواند با یک مقدار مقاومت مشخص شود. تاکنون چندین رویکرد، که بر اساس معادلات تجربی و تقریب هستند، برای تخمین مقاومت زمین توسعه یافته‌اند [۸].

پیش از ابداع و به‌کارگیری مدل‌های مبتنی بر هوش مصنوعی مانند شبکه‌های عصبی (ANN) برای تخمین مقاومت مخصوص خاک، جامعه مهندسی عمدتاً به روش‌های اندازه‌گیری مستقیم، مدل‌های تجربی و مداخلات فیزیکی-شیمیایی متکی بود که می‌توان به روش تک الکترودی و روش‌های چهار نقطه‌ای اشاره نمود. این روش‌ها به دلیل محدودیت‌های عملیاتی و عدم توانایی کافی در مدل‌سازی پیچیدگی‌های غیرخطی خاک‌های ناهمگن، محرک اصلی برای توسعه روش‌های هوشمند مبتنی بر داده بوده‌اند.

کورتاویس و وجویک در سال ۲۰۰۰، تحلیل‌های گسترده‌ای برای تعیین ولتاژ تماس و مقاومت زمین با درج یک ماده اضافی به ترانسفورماتور هادی انجام دادند و میزان تاثیر پارامترهای مختلف دخیل بر مقاومت ویژه خاک نظیر جنس خاک، رطوبت را تعیین نمودند [۱۱]. جین‌لیان و همکاران در سال ۲۰۰۵، در کنار سیستم ارتینگ قدیمی موجود، برای جلوگیری از مشکلات مربوط به ارتینگ از چاه زمین عمیق برای کاهش مقاومت زمین استفاده کردند [۱۲]. این چاه زمین توسط لوله فلزی با منافذ نفوذ آب در خاک با آب زیرزمینی تشکیل شده است که توانایی جمع آوری آب زیرزمینی و مرطوب کردن خاک اطراف را دارد. با این حال، در این سیستم، تامین مداوم آب مورد نیاز است. چن و همکاران در سال ۲۰۰۴ مقاومت ویژه خاک، مقاومت زمین و سایر پارامترهای مرتبط را در فصول مختلف اندازه‌گیری کرده است. آنها دریافتند که یخ زدن خاک سطحی و دما تأثیر بیشتری بر مقاومت ویژه و مقاومت خاک دارد [۱۳]. در العمار و همکاران در سال ۲۰۱۰، از ترکیبات مختلف مواد شیمیایی با خاک رس در آزمایشگاه برای کاهش مقاومت ویژه خاک استفاده کردند [۱۴].

استفاده از روش‌های مبتنی بر داده، مانند شبکه‌های عصبی، برای تخمین مقاومت مخصوص الکتریکی خاک، یک رویکرد مکمل برای روش‌های اندازه‌گیری مستقیم است و می‌تواند در بسیاری از موارد، مزایای قابل توجهی نظیر کاهش هزینه، حذف خطای انسانی و افزایش سرعت را به همراه داشته باشد . در سال ۲۰۰۶، محمدنور و همکاران نتایج مطالعات خود مبنی بر رویکرد بکارگیری ANN برای مدل سازی و پیش‌بینی رابطه بین مقاومت زمین و طول الکترود دفن شده، را ارائه نمودند [۱۵].

دهه گذشته شاهد رشد توانایی‌های شبکه‌های عصبی مصنوعی (ANN) از اولین نسل پرسپترون چند لایه (MLP) تا بسیاری از تکنیک‌های پیشرفته در نسل دوم شبکه‌های عصبی عمیق (DNN) بوده است. این دستاورد به شدت به مقدار زیادی داده‌های دارای برچسب و در دسترس بودن گسترده دستگاه‌های محاسباتی با کارایی بالا و همچنین واحدهای پردازش گرافیکی همه منظوره (GPU) بستگی دارد [۱۶, ۱۷].

برای یافتن شبکه‌های فشرده‌تری که می‌توانند عملکرد مشابهی را با پیچیدگی بسیار کمتر و تعداد پارامترهای کمتری نسبت به شبکه

اصلی داشته باشند، تکنیک‌های زیادی مانند کوانتیزاسیون [۱۸]، هرس [۱۶] و تقطیر دانش [۱۹] توسعه یافته‌اند. کوانتیزاسیون وزن‌ها و ورودی‌های شبکه را به انواع صحیح تبدیل می‌کند که باعث می‌شود عملیات کلی سبک‌تر از عملیات‌های نقطه شناور شود. در هرس، اتصالات یک شبکه به طور تکرارشونده در طول یا بعد از آموزش حذف می‌شوند. برای فشرده سازی یک شبکه عصبی بدون کاهش عملکرد، تقطیر دانش، دانش پیچیده‌ای را که توسط یک شبکه سنگین به نام معلم یاد گرفته شده است به یک شبکه سبک وزن به نام دانش‌آموز منتقل می‌کند [۱۷]. ترکیب روش‌های مختلف یادگیری ماشین، از جمله شبکه‌های عصبی، خوشه‌بندی و الگوریتم‌های کاهش ابعاد، در بسیاری از مسائل پیچیده داده‌کاوی و یادگیری ماشین، به منظور بهبود دقت و کارایی مدل‌ها، مورد استفاده قرار می‌گیرد.

یکی از اشکالات مبتلا به در شرکت‌های توزیع آن است که در همهٔ مناطق تحت پوشش (صرف‌نظر از نوع خاک آن‌ها) یک دستورالعمل واحد برای اجرای سیستم زمین وجود دارد. این امر باعث می‌شود که در برخی نقاط این طرح‌ها بسیار ناکارآمد باشند و در برخی نقاط بسیار بهتر از آنچه واقعاً نیاز بوده است (که به‌معنی هدررفت سرمایه‌های ملی می‌باشد). برای رفع این مشکل، روش صحیح آن است که هر شرکت توزیع به هنگام نیاز به نصب سیستم زمین در هر یک از نقاط تحت پوشش خود، نسبت به اندازه‌گیری مقاومت مخصوص خاک اقدام نموده و براساس آن طرح مناسبی برای الکترود زمین ارائه نماید. یک راه حل برای این‌کار، آن است که برای نقاط محدودی این اندازه‌گیری توسط یک مشاور انجام شود و سپس برای نقاط دیگری که اندازه‌گیری نمی‌شوند، با استفاده از روش‌های ریاضی هوشمند، عدد مقاومت مخصوص «برآورد شود». این ایده در مقاله حاضر با مدل برآورد ریاضی هوشمند مقاومت مخصوص با ترکیب شبکه‌های عصبی، خوشه‌بندی متوالی و الگوریتم k-means در پلتفرم متلب (MATLAB) مورد آزمون قرار گرفته است.

رویکرد پیشنهادی در این مقاله، بکارگیری قابلیت شبکه‌های عصبی مصنوعی (ANNs) با استفاده از داده‌های تجربی مقاومت ویژه زمین است تا پس از آموزش و راستی‌آزمائی، ابزار مناسب جهت برآورد سریع مقاومت زمین را فراهم آورد. بنابر بررسی‌های انجام شده، استفاده ترکیبی از شبکه‌های عصبی، خوشه‌بندی متوالی و ابزار k-means در پلتفرم متلب، به عنوان یک رویکرد قدرتمند برای تحلیل داده‌های پیچیده و استخراج اطلاعات پنهان، تاکنون برای تخمین مقاومت ویژه خاک مورد پژوهش قرار نگرفته است.

۲- مواد و روش‌ها

محدوده انتخابی برای انجام این پژوهش، شهر اصفهان به عنوان یکی از کلان‌شهرهای ایران و مرکز استان اصفهان است. این شهر با توجه به تاریخ غنی و جاذبه‌های گردشگری فراوان، همواره جمعیت قابل توجهی را به خود جذب کرده و با قدمتی چند هزار ساله، همواره در زمینه توسعه و پیشرفت زیرساخت‌ها پیشرو بوده است. ورود برق به این شهر نیز بخشی از همین روند توسعه بوده و می‌توان گفت که برق‌رسانی به این شهر در اوایل قرن بیستم میلادی آغاز شده است. در آن زمان، برق‌رسانی به صورت محدود و در برخی مناطق خاص شهر انجام می‌شد و بیشتر برای مصارف روشنایی و برخی صنایع کوچک مورد استفاده قرار می‌گرفت. امروزه شبکه توزیع برق در تمامی نقاط شهر اصفهان توسعه یافته و موتور محرک برای تمامی فعالیت‌های صنعتی، اجتماعی و فرهنگی محسوب می‌شود.

در این پژوهش، تحلیل آماری مورد مطالعه برای مقادیر اندازه‌گیری شده مقاومت در ۷۰ نقطه شهر اصفهان در سه عمق ۱/۵، ۳ و ۶ متری از سطح زمین با توجه به موقعیت جغرافیای هر نقطه انجام شده است که در شکل (۱)، موقعیت منطقه مورد مطالعه به همراه نقشه پراکندگی مربوط به طول و عرض جغرافیائی نقاط نمونه‌برداری و روش اندازه‌گیری مقاومت ویژه نشان داده شده است. فرآیند کلی شبیه‌سازی‌های انجام شده در این تحقیق به صورت مراحل زیر بوده است:

۱- انتخاب ۷۰ نقطه در سطح شهر اصفهان و اندازه‌گیری تجربی مقاومت مخصوص در سه عمق مختلف،

۲- تحلیل آماری داده‌ها با توجه به نمودار جعبه‌ای و حذف نقاط پرت،

۳- اجرای اولین خوشه‌بندی با در نظر گرفتن موقعیت‌های جغرافیایی نقاط،

۴- اجرای دومین خوشه‌بندی با در نظر گرفتن مقدار مقاومت در سه عمق، مربوط به نقاط خوشه‌ی انتخابی مرحله سوم،

۵- راستی‌آزمائی شبکه عصبی با در نظر گرفتن خوشه انتخاب شده به‌طوری‌که ورودی شبکه عصبی موقعیت‌های جغرافیایی و خروجی آن مقاومت مخصوص نقاط باشد.

با توجه به پراکندگی نتایج اندازه‌گیری شده، به منظور تخمین بهتر و پیش‌بینی صحیح‌تر، ابتدا و پیش از اعمال ورودی به شبکه عصبی با استفاده از دو خوشه‌بندی متوالی k-means داده‌ها مورد تحلیل آماری قرار گرفته و دسته‌بندی شد. خوشه‌بندی اول براساس موقعیت جغرافیایی نقاط (طول، عرض و ارتفاع جغرافیایی) و خوشه‌بندی دوم براساس مقاومت مخصوص خاک در سه عمق مذکور صورت گرفت. خوشه حاصل از این تحلیل به عنوان ورودی به شبکه عصبی داده می‌شود. شبکه عصبی مورد استفاده در این پایان‌نامه از نوع شبکه المان بوده به‌گونه‌ای که ورودی این شبکه موقعیت جغرافیایی نقاط و خروجی آن مقاومت مخصوص خاک باشد.

پس از اندازه‌گیری تجربی مقاومت مخصوص در تعداد کافی نقاط پراکنده در سطح اصفهان، طراحی یک شبکه عصبی مصنوعی شامل سه مرحله طراحی معماری شبکه، تعیین نوع تابع تبدیل و آموزش شبکه انجام شد به نحوی که استفاده ترکیبی از شبکه‌های عصبی، خوشه‌بندی متوالی و ابزار k-means در پلتفرم متلب، یک رویکرد

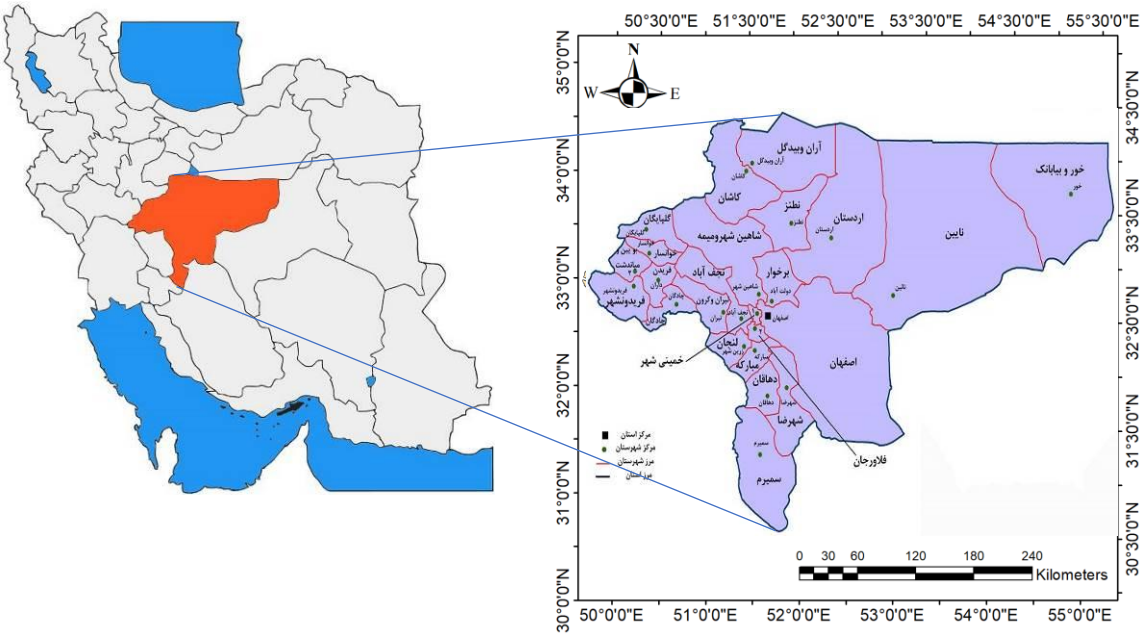

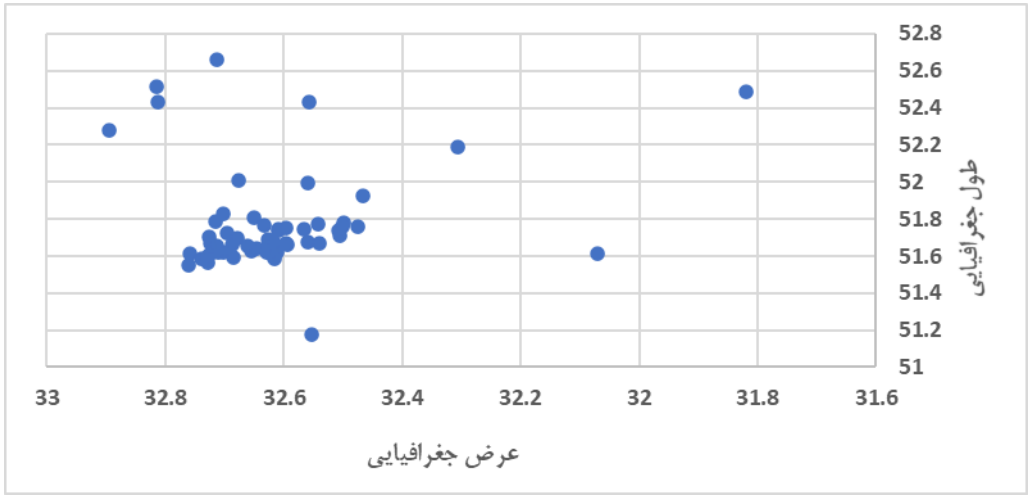

(الف)



(ب)

شکل (۱): الف) موقعیت جغرافیایی منطقه انتخابی برای انجام پژوهش، ب) روش اندازه‌گیری مقاومت مخصوص در هر یک از نقاط

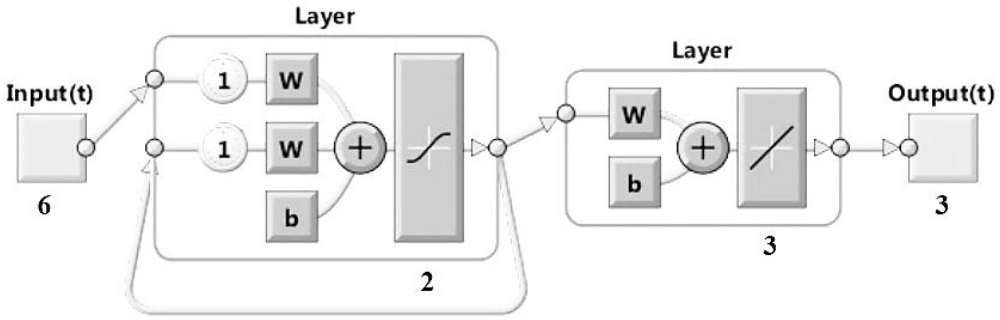

شکل (۲): معماری کلی شبکه عصبی مورد استفاده

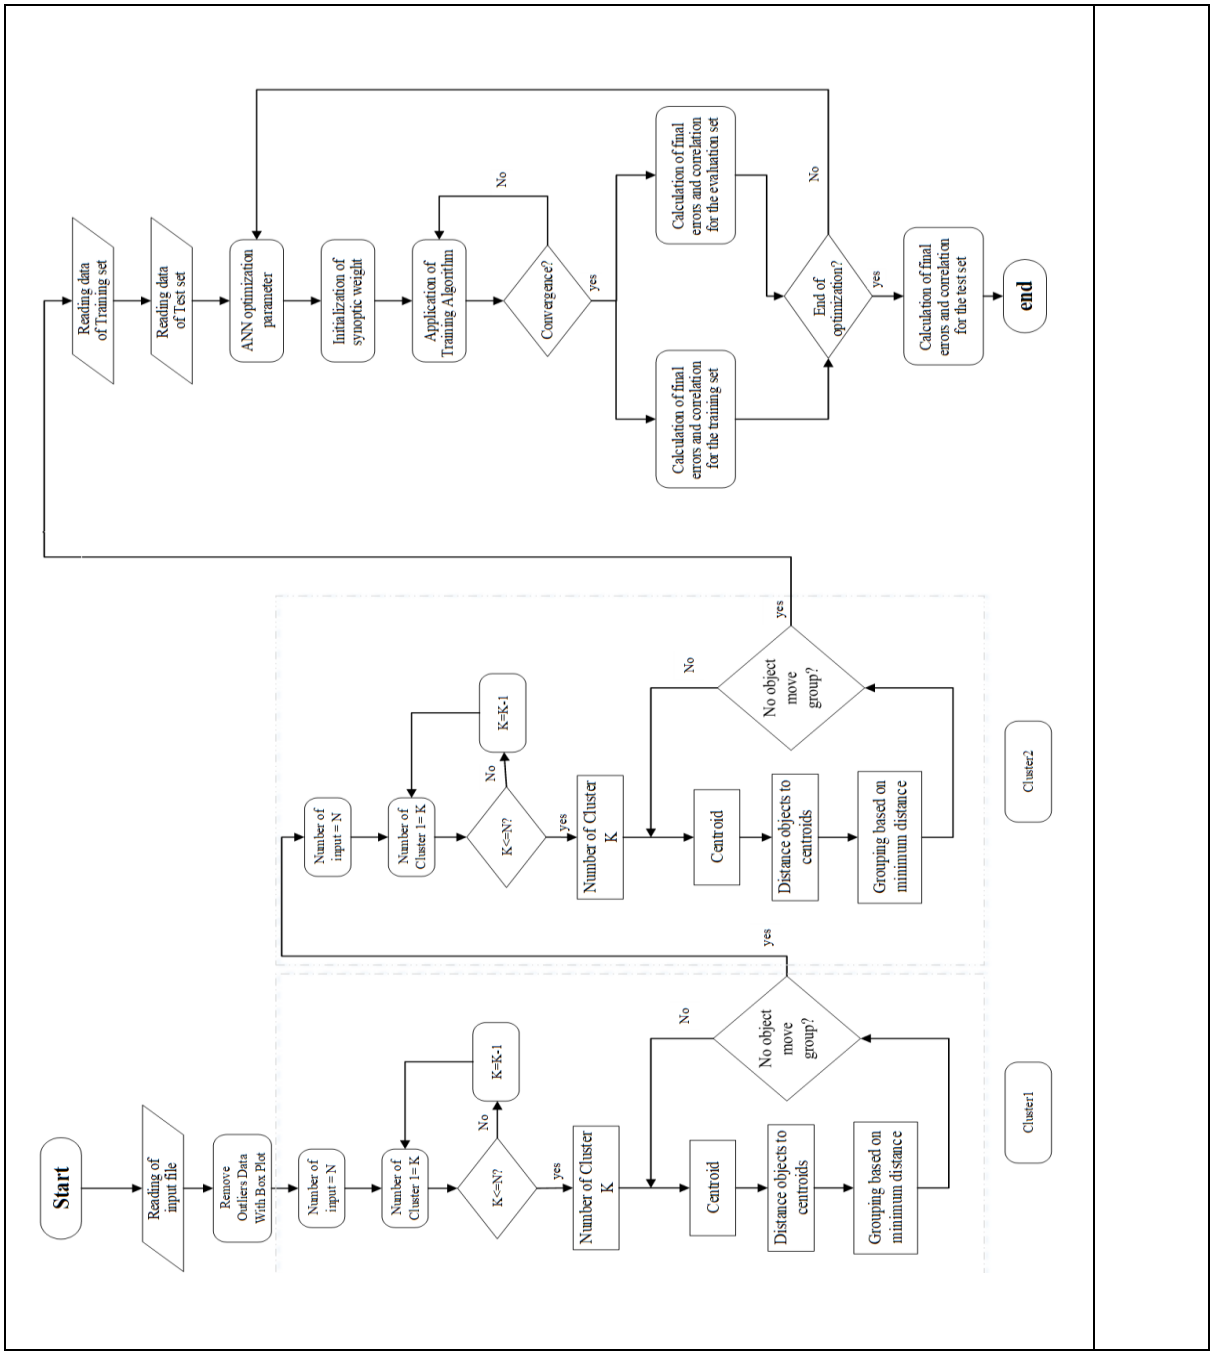

شکل (۳): فلوچارت پیش‌بینی مقاومت مخصوص خاک در این تحقیق

قدرتمند برای تحلیل داده‌های پیچیده و استخراج اطلاعات پنهان فراهم آورد. این روش به ویژه در مواردی که داده‌ها دارای ساختار پیچیده و غیرخطی هستند، بسیار مفید است.

خوشه‌بندی متوالی یک روش خوشه‌بندی سلسله مراتبی است که در آن داده‌ها به صورت سلسله مراتبی به خوشه‌های کوچک‌تر و کوچک‌تر تقسیم می‌شوند تا در نهایت به خوشه‌های تک عضوی برسند. این روش به دو صورت آگلومراتیو (ادغامی) و دیوایسیو (تفکیکی) انجام می‌شود. الگوریتم k-means یک الگوریتم خوشه‌بندی تقسیم‌بندی است که داده‌ها را به k خوشه تقسیم می‌کند. این الگوریتم به صورت تکراری مراکز خوشه‌ها را به‌روزرسانی می‌کند تا مجموع مربعات فاصله هر نقطه تا نزدیک‌ترین مرکز خوشه به حداقل برسد. در پژوهش حاضر، ترکیب شبکه‌های عصبی، خوشه‌بندی متوالی و k-means در متلب برای سناریوهای مختلف شامل پیش‌پردازش داده‌ها، انتخاب ویژگی و تحلیل نتایج بکار رفته است. پلتفرم متلب ابزارهای قدرتمندی برای پیاده‌سازی این روش در اختیار قرار می‌دهد. توابعی مانند kmeans, feedforwardnet, train, sim برای خوشه‌بندی، ایجاد شبکه‌های عصبی و آموزش آن‌ها به کار گرفته شده است [۱۶, ۲۰, ۲۱]. با توجه به پراکندگی نقاط علاوه بر این‌که بر روی مقدار مقاومت در هر عمق از خوشه‌بندی استفاده شد، از خوشه‌بندی دیگری نیز براساس موقعیت جغرافیایی نقاط نیز استفاده شد. بنابراین، بهترین روش برای تحلیل این داده‌ها استفاده از دو خوشه‌بندی متوالی است. خوشه‌بندی اول برحسب موقعیت‌های جغرافیایی نقاط و خوشه‌بندی دوم بر روی خوشه‌ی بدست آمده از مرحله قبل، برحسب مقدار مقاومت در سه عمق مورد نظر ایجاد شد.

ساختار شبکه مورد استفاده در بلوک دیاگرام شکل(۲) نشان داده شده است. در پژوهش حاضر، با توجه به مشخص بودن ساختار لایه اول و خروجی و مشخص نبودن لایه‌های میانی و هم‌چنین وابستگی عملکرد شبکه به تعداد نرون در لایه مخفی، که این تعداد باید با سعی و خطا مشخص شود، به جای استفاده از شبکه روبه جلو از شبکه المان که دارای یک لایه می‌باشد، استفاده شد. بدین ترتیب، با توجه به مشخص شدن معماری شبکه عصبی و استفاده از روش خوشه‌بندی و نمودارهای جعبه‌ای از بلوک دیاگرام کلی شکل (۳) جهت حذف داده‌های پرت، آموزش شبکه عصبی و پیش‌بینی مقدار مقاومت خاک استفاده شد.

۳- نتایج و بحث

۳-۱- پالایش و حذف داده‌های پرت

قبل از استفاده مقادیر اندازه‌گیری شده در شبیه‌سازی، داده‌های اندازه‌گیری شده از لحاظ آماری بررسی و مقادیر غیر طبیعی حذف شد. در شکل (۴) به ترتیب برای عمق‌های ۱/۵ متری ، ۳ متری و ۶ متری از سطح زمین نمودار پراکندگی رسم و در هر عمق چندین نقطه دارای مقاومت با مقدار غیرطبیعی نسبت به سایر نقاط حذف شد. این شیوه در مراجع مختلف از جمله مرجع [۲] تصدیق شده است. برای حذف داده‌های پرت، داده‌هایی که کوچک‌تر از $Q1-1.5IQR$ یا بزرگ‌تر از $Q3+1.5IQR$ باشند جزء داده¬های پرت خفیف و داده‌هایی که کوچک‌تر از $Q1-3IQR$ یا بزرگ‌تر از $Q3+3IQR$ باشند جزء داده‌های پرت قوی طبقه‌بندی و نمودار جعبه‌ای مربوط به مقاومت‌ها در سه عمق ۱/۵ متری، ۳ متری و ۶ متری ترسیم شد. به این ترتیب، ردیف‌های ۴۷، ۵۰، ۵۱، ۵۳، ۶۵، ۶۶ و ۶۷ از مجموع ۷۰ ردیف اطلاعات ورودی به عنوان داده‌های پرت و نامعتبر حذف گردید.

۳-۲- آموزش و راستی‌آزمائی - حالت اول

در شکل(۵) نتایج برای حالتی که در قسمت آموزش شبکه دو نقطه (دو نمودار اول) و در قسمت پیش‌بینی یک نقطه (نمودار سوم) قرار دارد با تعداد ۱۰ نرون در لایه مخفی شبکه عصبی مطابق جدول (۱) نمایش داده شده است. نقاط به رنگ آبی همان اهداف در قسمت آموزش یا تست می‌باشند و مقادیر شبیه‌سازی شده در قسمت آموزش و تست به رنگ قرمز نشان داده شده است. برای اتصال این نقاط از درون‌یابی با تابع اسپلین استفاده شد. لازم به ذکر است، تعداد نقاطی که در آموزش قرار دارند با تعداد خوشه‌بندی رابطه عکس دارند.

از آزمایش فوق مشخص می‌شود که پس از خوشه‌بندی یک دسته با سه نقطه به شبکه عصبی عرضه می‌شود؛ دو نقطه از این دسته به عنوان ورودی آموزش و نقطه سوم به عنوان نقطه پیش‌بینی در نظر گرفته می‌شود.

با توجه به نمودار شکل (۵) و جداول ۱ و ۲ مشاهده می‌شود در قسمت آموزش، شبکه عصبی به درستی عمل کرده است. ولی در قسمت پیش‌بینی مقدار قدر مطلق خطا افزایش یافته است. دلیل این امر را می‌توان به صورت زیر بیان نمود:

۱- با توجه به مقدار مقاومت در عمق ۶ متری مشاهده می‌شود که در دو نقطه اول، آموزش شبکه بسیار خوب عمل کرده است و همین امر باعث ایجاد تناسب بیش از حد بر روی شبکه می‌شود. به عبارت دیگر شبکه برای نقطه سوم مقادیری مشابه با مقادیر آموزش خود در نظر می‌گیرد. راه حل ساده برای جلوگیری از این موضوع کم کردن تعداد نرون‌ها در لایه‌های شبکه و یا کم کردن تعداد مراحل تکرار شبکه می‌باشد.

۲- برای این‌که هر شبکه‌ای (نه لزوما فقط شبکه عصبی) بتواند مقداری را صحیح پیش‌بینی کند باید در قسمت آموزش به درستی و با تعداد ورودی مناسب تغذیه شود. به‌طور حتم زمانی که فقط دو ورودی به شبکه داده شود نباید انتظار پیش‌بینی با درصد خطای خیلی کم را از شبکه داشت. بنابراین باید تعداد نقاط موجود در هر دسته را افزایش داد. البته باید به این نکته نیز توجه داشت که نقاطی که به هر دسته نسبت داده می‌شوند باید بیشترین شباهت را نیز به یکدیگر داشته باشند. منظور از شباهت در این‌جا، هم شباهت در موقعیت جغرافیایی و هم در مقدار مقاومت در سه عمق می¬باشد. همان‌طور که قبلا بیان

شد در انتخاب دسته بعد از حذف داده پرت دو مرتبه از تابع خوشه‌بندی استفاده شده است، یک مرتبه برحسب موقعیت جغرافیایی و یک مرتبه برحسب مقادیر مقاومت.

۳-۳- آموزش و راستی‌آزمائی - حالت دوم

هنگامی که از تابع خوشه‌بندی برای موقعیت جغرافیایی استفاده می‌شود این تابع فاصله طول، عرض و ارتفاع را تا مرکزثقل دسته مورد نظر، مورد محاسبه قرار می‌دهد. به عنوان مثال اگر فرض شود در یک دسته خاص فاصله نقاط از مرکز ثقل حداکثر ۱۰ متر باشد نقاط (x=0,y=0,z=10)و(x=0,y=10,z=0) و (x=10,y=0,z=0) نیز جزو نقاط آن دسته به حساب می‌آیند در صورتی که بیشترین فاصله را نسبت به یکدیگر دارند. از طرفی با توجه به این‌که لایه‌های خاک در موقعیت‌های مختلف متفاوت می‌باشد مسلما مقدار مقاومت نیز تغییر کرده و مسئله پیش‌بینی دچار مشکل می‌گردد. برای حل این مشکل راه‌حل‌های زیر قابل ارائه می‌باشند:

الف- به‌جای این‌که از یک تابع خوشه‌بندی برای موقعیت‌های x,y و z استفاده شود برای هر موقعیت از یک تابع خوشه‌بندی استفاده گردد. البته این‌کار هم حجم محاسبات را بالا می‌برد و هم باعث می‌شود تعداد نقاط موجود در هر دسته کاهش یابد و در نتیجه قسمت آموزش و تست دچار مشکل شود.

ب- راه حل دیگر محدود کردن فاصله نقاط نسبت داده شده به هر دسته می‌باشد برای این‌کار می‌توان تعداد دسته‌ها را افزایش داد که این عمل نیز خود باعث کاهش تعداد نقاط موجود در هر دسته می‌شود. بنابراین باید هم به تعداد دسته در خوشه‌بندی اول و دوم و هم به تعداد نرون در لایه مخفی توجه نمود. برای جلوگیری از ایجاد تناسب بیش از حد در قسمت آموزش شبکه تعداد نرون در لایه مخفی با کمی سعی و خطا برابر با دو نرون به‌دست آمد. در شکل (۶) شبیه‌سازی با دو نرون در لایه مخفی نمایش داده شده است. همان‌طورکه در این شکل دیده می‌شود از ایجاد تناسب بیش از حد در قسمت آموزش جلوگیری شده است.

با توجه به جداول (۳) و (۴) با استفاده از شبکه عصبی المان و اعمال پیشنهادات ۱ و ۲ در بخش قبل مقدار خطا هم در قسمت آموزش و هم در قسمت تست بسیار کاهش یافته و مقدار پیش‌بینی شده قابل قبول می‌باشد.

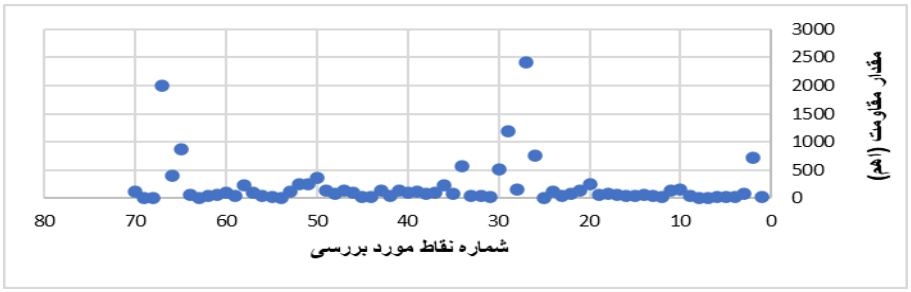

(الف)

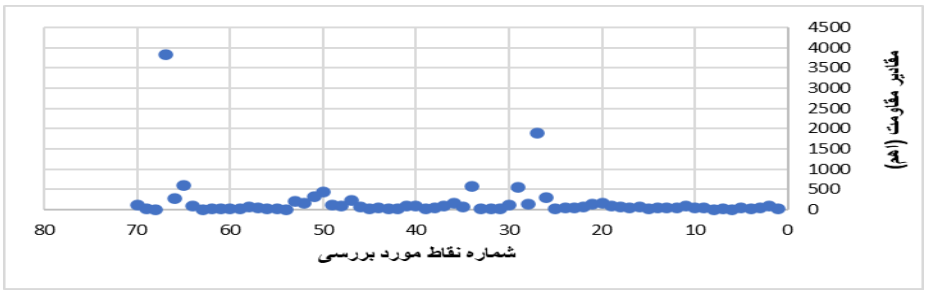

(ب)

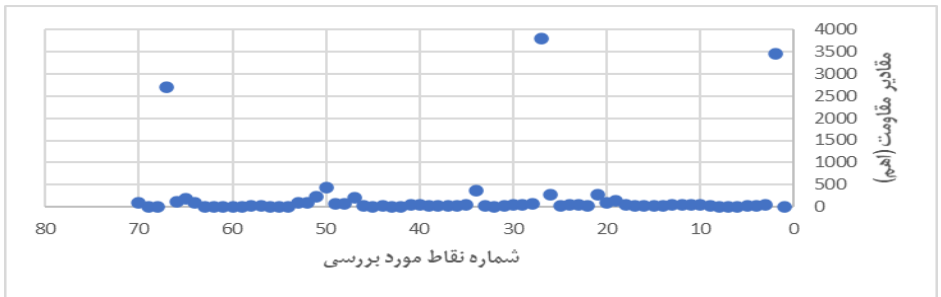

(ج)

شکل (۴): پراکندگی مربوط به مقاومت ، الف) عمق۱.۵ متری، ب) عمق۳ متری، ج) عمق۶ متری

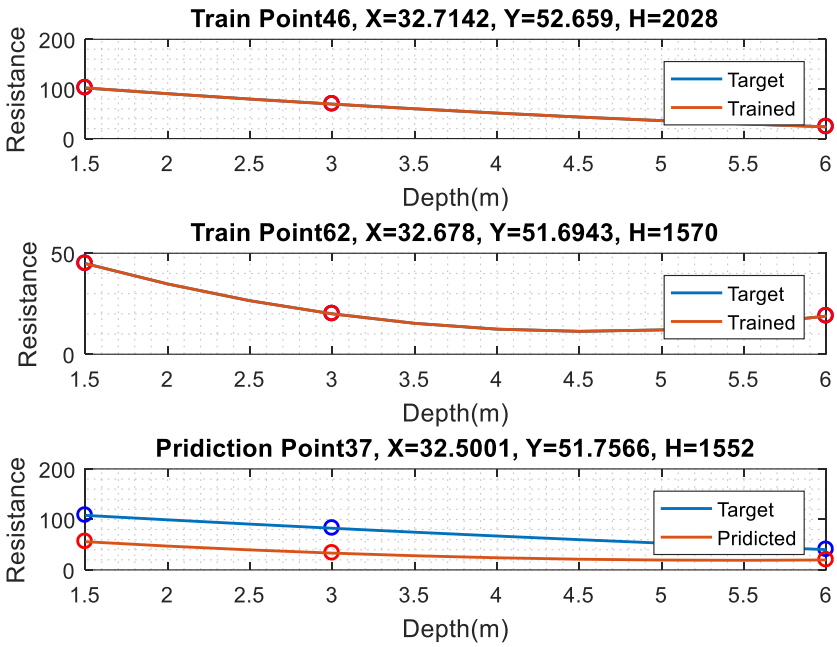

شکل (۵): نمودارهای آموزش و تست شبکه-شبکه عصبی با ساختار ۳-۱۰-۶ با تابع سیگموئید در لایه مخفی و تابع خطی در لایه خروجی با تعداد ۱۰ نرون در لایه مخفی

جدول (۱): مقدار مقاومت اندازه‌گیری و آموزش‌دیده‌شده (شبکه عصبی باساختار ۳-۱۰-۶ با تابع سیگموئید در لایه مخفی و تابع خطی در لایه خروجی با تعداد ۱۰ نرون در لایه مخفی)

عمق (m)	قسمت آموزش شبکه				قسمت تست شبکه	
	هدف		آموزش دیده		هدف	پیش‌بینی
	نقطه ۱	نقطه ۲	نقطه ۱	نقطه ۲	نقطه ۱	نقطه ۲
۱.۵	۱۰۲.۰۰	۴۴.۹۰	۱۰۲.۰۰	۴۴.۹۰	۱۰۸.۰۰	۵۵.۹۰
۳	۶۹.۵۰	۲۰.۰۰	۶۹.۵۰	۲۰.۰۰	۸۲.۵۰	۳۳.۲۵
۶	۲۳.۷۰	۱۸.۹۰	۲۳.۷۰	۱۸.۹۰	۴۰.۲۰	۱۹.۶۸

جدول (۲): مقایسه عملکرد شبکه در قسمت آموزش و تست با توجه به مقدار قدر مطلق ماکزیمم خطا،میانگین قدرمطلق خطا و رگرسیون خطی

قسمت آموزش			قسمت تست		
ماکزیمم خطای مطلق	متوسط خطای مطلق	رگرسیون	ماکزیمم خطای مطلق	متوسط خطای مطلق	رگرسیون
۰	۰	۱	۵۲.۱۰	۴۰۶۲	۰.۵۵

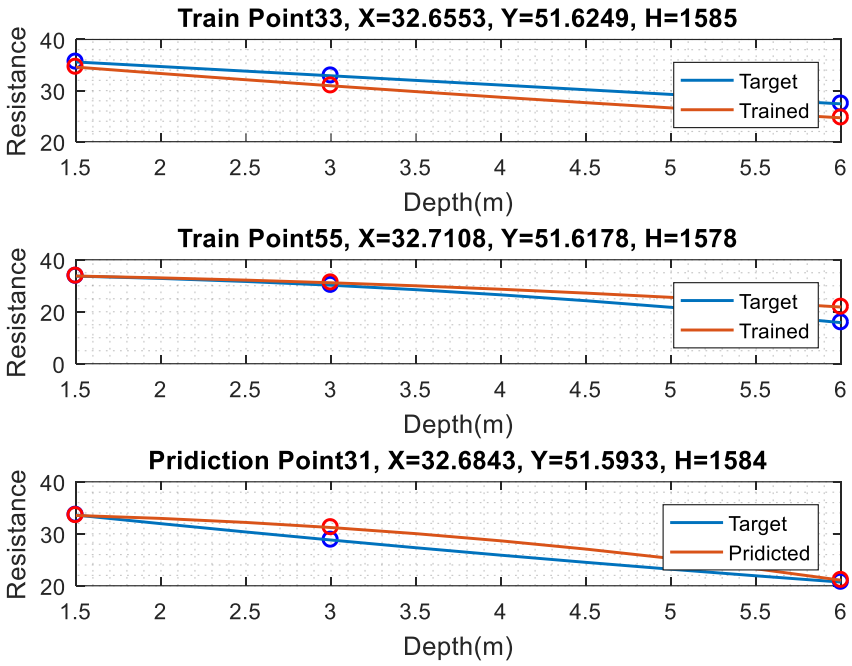

شکل (۶): نمودارهای آموزش و تست شبکه-شبکه عصبی باساختار ۳-۲-۶ با تابع سیگموئید در لایه مخفی و تابع خطی در لایه خروجی با تعداد ۲ نرون در لایه مخفی

جدول (۳): مقدار مقاومت اندازه‌گیری و آموزش‌دیده‌شده (شبکه عصبی باساختار ۳-۲-۶ با تابع سیگموئید در لایه مخفی و تابع خطی در لایه خروجی با تعداد ۲ نرون در لایه مخفی)

عمق (m)	قسمت آموزش شبکه				قسمت تست شبکه	
	هدف		آموزش دیده		هدف	پیش‌بینی
	نقطه ۱	نقطه ۲	نقطه ۱	نقطه ۲	نقطه ۱	نقطه ۲
۱.۵	۳۵.۶۰	۳۳.۷۰	۳۷.۶۰	۳۳.۷۵	۳۳.۵۳	۳۳.۶۰
۳	۳۲.۹۰	۳۰.۲۰	۳۰.۹۴	۳۱.۱۵	۳۱.۲۰	۲۸.۸۰
۶	۲۷.۴۰	۱۵.۸۰	۲۴.۶۷	۲۱.۸۱	۲۱.۰۶	۲۰.۷۰

جدول (۴): مقایسه عملکرد شبکه در قسمت آموزش و تست با توجه به مقدار قدر مطلق ماکزیمم خطا، میانگین قدرمطلق خطا و رگرسیون خطی

قسمت آموزش			قسمت تست		
ماکزیمم خطای مطلق	متوسط خطای مطلق	رگرسیون	ماکزیمم خطای مطلق	متوسط خطای مطلق	رگرسیون
۶.۰۱	۲.۱۱	۰.۹۳	۲.۴۷	۰.۹۴	۰.۹۸

در شکل (۶) نتایج برای حالتی که در قسمت آموزش شبکه دو نقطه (دو نمودار اول) و در قسمت پیش‌بینی یک نقطه (نمودار سوم) قرار دارد با تعداد ۱۰ نرون در لایه مخفی شبکه عصبی نمایش داده شده است. توجه شود نقاط به رنگ آبی همان اهداف در قسمت آموزش یا تست می‌باشند که متناسب با جدول (۳) بدست آمده است و مقادیر شبیه‌سازی شده در قسمت آموزش و تست به رنگ قرمز نشان داده شده است. همچنین ذکر این نکته لازم است که برای اتصال این نقاط از درون‌یابی با تابع اسپلین استفاده شده است. همان‌طور که قبلا بیان شد تعداد نقاطی که در آموزش قرار دارند با تعداد خوشه‌بندی رابطه عکس دارند.

۴- نتیجه‌گیری

هدف این پژوهش، تخمین مقاومت مخصوص خاک در یک منطقهٔ وسیع جغرافیایی مانند شهر اصفهان، از طریق اندازه‌گیری‌های محدود بود. براساس اندازه‌گیری‌های عملی در ۷۰ نقطه از شهر اصفهان، برای سایر نقاط دیگر که این اندازه‌گیری انجام نشده مقدار مقاومت مخصوص خاک با استفاده از شبکه عصبی تخمین زده شد. در مراجع قبلی از شبکه‌های عصبی با ساختار پرسپترون جهت پیش‌بینی مقادیر استفاده شده بود. مشکل اصلی در شبکه‌های پرسپترون، مشخص نمودن تعداد نرون در لایه‌های مخفی و هم‌چنین تعداد لایه‌ها است. با توجه به مشخص بودن ساختار لایه اول و خروجی و مشخص نبودن لایه‌های میانی و هم‌چنین وابستگی عملکرد شبکه به تعداد نرون در لایه مخفی که این تعداد باید با سعی و خطا مشخص شود. بنابر نتایج این پژوهش، توصیه شد به جای استفاده از شبکه روبه جلو از شبکه المان که دارای یک لایه می‌باشد استفاده نمود. هم‌چنین فیدبک موجود در آن خود باعث بهتر تصحیح شدن وزن‌های شبکه و عملکرد بهتر آن خواهد شد. با توجه به ساختار شبکه المان (وجود تنها یک لایه مخفی) نسبت به شبکه‌های چند لایه بسیار راحت‌تر می‌توان (با سعی و خطا) تعداد نرون در لایه مخفی را بدست آورد.

اجرای این روش بر روی داده‌های شهر اصفهان، بیانگر دقت خوب و کارآمدی روش در تخمین مقاومت مخصوص خاک می‌باشد. با توجه به شبیه‌سازی‌های صورت گرفته دیده می‌شود هر خوشه نهایتا دارای سه نقطه می‌باشدکه دو نقطه برای آموزش و یک نقطه برای تست شبکه مورد استفاده قرار می‌گیرد. هرچند شبکه‌ی طراحی شده به خوبی توانسته عمل پیش بینی و تخمین مقاومت نقطه تست را انجام دهد ولی هرچه‌قدر تعداد نقاط در آموزش یا به عبارت دیگر تعداد نقاط و یا حتی تمرکز نقاط اندازه‌گیری شده بیشتر باشد، دقت پیش‌بینی بهتر و معتبرتر خواهد بود.

مراجع

[1] V. Androvitsaneas, et al., Effect of Soil Resistivity Measurement on the Safe Design of Grounding Systems. Energies, 2020. 13: p. 3170.

[2] P. Dilushani, et al., Soil Resistivity Analysis and Earth Electrode Resistance Determination. IOSR Journal of Electrical and Electronics Engineering, 2022. Volume 15: p. 26-35.

[3] G. Adegboyega, and K. Odeyemi, Assessment of Soil Resistivity on Grounding of Electrical Systems: A Case Study of North-East Zone, Nigeria. Journal of Academic and Applied Studies, 2011. 1.

[4] S. Malanda, et al., Analysis of Soil Resistivity and its Impact on Grounding Systems Design. 2018.

[5] H. Seedher, and J.K. Arora, Estimation of Two Layer Soil Parameters Using Finite Wenner Resistivity Expressions. Power Delivery, IEEE Transactions on, 1992. 7: p. 1213-1217.

[6] D. Idoniboyeobu, T. Bala, and E. Okekem, Assessment and Evaluation of Soil Effect on Electrical Earth Resistance: A Case Study of Woji Area, Port-Harcourt, Nigeria. International Journal of Engineering and Technical Research, 2018. 8: p. 84-94.

[7] Y. Al-Shawesh, S. Lim, and M. Nujaim, Analysis of the Design Calculations for Electrical Earthing Systems. International Review of Electrical Engineering (IREE), 2021. 16: p. 104-117.

[8] F. Asimakopoulou, et al., AN ARTIFICIAL NEURAL NETWORK FOR ESTIMATING THE GROUND RESISTANCE. 2010.

[9] S. Khan, et al., Application of Mineral Compounds for a High-Voltage Portable Grounding System: An Experimental Study. Electronics, 2021. 10: p. 2043.

[10] O. Igbologe, and U. Okieke, Evaluation of the Earth's Electrical Properties of the Undeveloped Area at the Delta State University of Science and Technology, Ozoro, Nigeria. Advances in Research, 2022. 23: p. 1-10.

[11] M. Kurtovic, and S. Vujević, Earthing grid parameters with conductor surrounded by an additional substance. Generation, Transmission and Distribution, IEE Proceedings-, 2000. 147: p. 57-61.

[12] H. Jinliang, et al., Decreasing Grounding Resistance of Substation by Deep-Ground-Well Method. Power Delivery, IEEE Transactions on, 2005. 20: p. 738-744.

[13] L.-H. Chen, et al., A Study of Grounding Resistance Reduction Agent Using Granulated Blast Furnace Slag. Power Delivery, IEEE Transactions on, 2004. 19: p. 973-978.

[14] E. Al-Ammar, et al., Development of low resistivity material for grounding resistance reduction. 2010.

[15] N. Mohamad Nor, A. Haddad, and H. Griffiths, Performance of Earthing Systems of Low Resistivity Soils. Power Delivery, IEEE Transactions on, 2006. 21: p. 2039-2047.

[16] K. Yamazaki, et al., Spiking Neural Networks and Their Applications: A Review. Brain sciences, 2022. 12.

[17] Y. Ding, and D.-R. Chen, Optimization Based Layer-Wise Pruning Threshold Method for Accelerating Convolutional Neural Networks. Mathematics, 2023. 11: p. 3311.

[18] D. Zhang, J. Yang, and D. Ye, LQ-Nets: Learned Quantization for Highly Accurate and Compact Deep Neural Networks: 15th European Conference, Munich, Germany, September 8-14, 2018, Proceedings, Part VIII. 2018. p. 373-390.

[19] X. Jin, et al., Knowledge Distillation via Route Constrained Optimization. 2019. 1345-1354.

[20] S.M. Kia, Neural networks in Matlab. 2008.

Pradeep, T., et al., A Matlab-Based Neural Network Model for Predicting Blast-Induced Ground Vibration. Mining Revue, 2024. 30: p. 86-9.