



ORIGINAL RESEARCH PAPER

Using Artificial Neural Networks and Geospatial Information Systems in Mine Exploration for Producing Mineral Potential Map

T. Silavi¹, M. Kheirkhahzadeh^{*,2}¹ Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics, K.N.Toosi University of Technology, Tehran, Iran² Department of Computer Science, Faculty of Mathematics and Computer Science, Shahid Chamran University of Ahvaz, Ahvaz, Iran

ABSTRACT

Received: 06 March 2023
Reviewed: 9 April 2023
Revised: 07 May 2023
Accepted: 18 June 2023

KEYWORDS:

Mine Exploration
Copper Deposit
Geospatial Information System
Artificial Neural Network
Data Combination

* Corresponding author

✉ m.kheirkhahzadeh@scu.ac.ir

☎ (+98611) 33226600

Background and Objectives: Geospatial Information Systems provide required science and tools for various transactions related to spatial data. Such an ability caused use of Geospatial Information Systems in several fields. One of these fields is mine exploration which can be known as highly dependent field to the geology. On the other hand, the traditional methods are not suitable for requirements of mine exploration. Thus, the new methods are utilized more and more for mining as well as mine exploration. Artificial intelligence is one of the new sciences transforming human life. Artificial Neural Networks as a long-standing method of artificial intelligence have found many applications in mine exploration. The goal of this research is producing mineral potential map using artificial neural networks.

Methods: Artificial neural network is a classifier method in essence. This method acts like a black box which is trained at first, then it is capable of classifying the new data. In this research the data captured from exploration studies of porphyry copper deposit located in Yazd, Iran is used for producing mineral potential map. The mineral potential map is essential and very important for mining activities. The data is entered to a feedforward back propagation artificial neural network. The artificial neural network is used in two manners. The first manner is the usual one: The artificial neural network is trained by the aid of boreholes data and then it is used to forecast the potential of copper at every cell of the study area. In the second manner after training the network, its inner weights are extracted. These weights show the amount of importance that the neurons of the network have been considered for the input criteria. These weights are entered into the index overlay method. Afterwards, the criteria maps are combined by index overlay method and the mineral potential map is produced.

Findings: In this research more than testing the power of artificial neural networks in producing mineral potential map, testing the accuracy of its inner weights to be used in another method is aimed. At the training phase the values of criteria maps (essentially produced by exploration studies) at the positions of boreholes are entered into the artificial neural network and the network should forecast the potential of copper at that position qualitatively, while the true values are known from the data of boreholes. Then, the trained network forecast the potential of copper at every position of the deposit. The results revealed that the accuracy of artificial neural network when ignoring one of the non-efficient criteria can be reached up to 100 percent. However, the accuracy of index overlay method using the weights extracted from the artificial neural network is about 70 percent at maximum.

Conclusion: The results of this study revealed again the power of artificial neural networks in classification and combination of spatial data. Despite, the unique result of this research is that the inner weights of artificial neural network have the maximum performance in their network and using them for weighting and combining data by another method would not be useful. However, these weights can illustrate the order of importance of data.



NUMBER OF REFERENCES

32



NUMBER OF FIGURES

4



NUMBER OF TABLES

2

مقاله پژوهشی

استفاده از شبکه‌های عصبی مصنوعی و سامانه‌های اطلاعات مکانی در معدن کاوی جهت تولید نقشه پتانسیل معدنی

طلوع سیلاوی^۱، معصومه خیرخواهزاده^{۲*}^۱ گروه سیستم‌های اطلاعات مکانی، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی
^۲ گروه علوم کامپیوتر، دانشکده علوم ریاضی و کامپیوتر، دانشگاه شهید چمران اهواز، اهواز، ایران

چکیده

پیشینه و اهداف: سامانه‌های اطلاعات مکانی، علم و ابزار لازم برای انواع فعل و انفعالات مرتبط با اطلاعات مکانی را فراهم می‌آورند. چنین قابلیت‌هایی، سبب شده است که این سامانه‌ها در حوزه‌های متعدد و بسیار متنوعی به کار گرفته شوند. یکی از این حوزه‌ها، معدن کاوی است که می‌توان آن را یکی از حوزه‌های به شدت وابسته به زمین‌شناسی به حساب آورد. از سوی دیگر، روش‌های سنتی معدن کاوی و زمین‌شناسی جوابگوی نیازهای روزافزون این حوزه نمی‌باشند و به همین دلیل، فنون و علوم جدید، نقشی بی‌بدیل در کاوش‌های معدنی امروزی یافته‌اند. هوش مصنوعی، یکی از مهم‌ترین علوم جدید است که در حال تحول‌بخشی به زندگی انسان‌ها می‌باشد. شبکه‌های عصبی مصنوعی، به عنوان یکی از روش‌های دیرپای هوش مصنوعی، جای پای خود را در زمین‌شناسی و معدن کاوی نیز باز و در این مسیر، روش‌های سنتی را با چالش اساسی مواجه نموده‌اند. بر این اساس، هدف این تحقیق بر تهیه نقشه پتانسیل معدنی با کمک شبکه عصبی مصنوعی بنا نهاده شده است.

روش‌ها: شبکه عصبی مصنوعی، در واقع یک روش طبقه‌بندی به شمار می‌رود. این روش، به صورت یک جعبه سیاه عمل می‌کند که ابتدا آموزش می‌بیند و پس از یادگیری، قادر به طبقه‌بندی داده‌هایی است که در مرحله آموزش با آن‌ها مواجه نبوده است. در این پژوهش، با استفاده از اطلاعات مطالعات اکتشافی یک کانسار مس پرفیری واقع در استان یزد ایران و به کمک شبکه عصبی مصنوعی در صدد تولید نقشه پتانسیل معدنی مس در این منطقه هستیم. نقشه پتانسیل معدنی برای استخراج معدن مورد استفاده قرار می‌گیرد. بدین منظور، به دو صورت از شبکه عصبی مصنوعی استفاده می‌شود. روش اول به صورت معمول است یعنی شبکه عصبی مصنوعی با استفاده از اطلاعات چاه‌های اکتشافی آموزش می‌بیند و سپس میزان پتانسیل مس را در جای‌جای منطقه پیش‌بینی می‌نماید. روش دوم، به این صورت است که پس از آموزش دیدن شبکه عصبی مصنوعی، وزن‌های داخلی شبکه استخراج می‌شوند. این وزن‌ها در واقع، نشان‌دهنده میزان اهمیتی است که نرون‌های شبکه برای هر یک از معیارهای ورودی در نظر گرفته‌اند. این وزن‌ها، وارد رابطه روش همپوشانی شاخص می‌شوند و نقشه‌های معیار، با استفاده از روش همپوشانی شاخص، ترکیب و نقشه پتانسیل معدنی حاصل می‌شود.

یافته‌ها: در این تحقیق، غیر از آزمایش قدرت شبکه عصبی مصنوعی در تهیه نقشه پتانسیل معدنی، میزان دقت وزن‌های مستخرج از شبکه برای استفاده در یک روش تلفیق دیگر، مد نظر بوده است. در مرحله آموزش شبکه، مقادیر نقشه‌های معیار که اساساً همان نقشه‌های حاصل از مطالعات اکتشافی هستند در نقاط چاه‌های اکتشافی، به عنوان ورودی وارد شبکه می‌شوند و باید عیار مس را به صورت کیفی در آن نقطه، پیش‌بینی نمایند در حالی که خروجی صحیح حاصل از چاه‌های اکتشافی در دست است. پس از آموزش، شبکه مقادیر پتانسیل معدنی را در جای‌جای کانسار به دست می‌آورد. نتایج، نشان داد که دقت طبقه‌بندی شبکه عصبی مصنوعی پس از کنار گذاشتن یکی از معیارها که غیر مؤثر تشخیص داده شد، می‌تواند تا ۱۰۰ درصد برسد و این، در حالی است که دقت حاصل شده از روش همپوشانی شاخص و با استفاده از وزن‌های مستخرج از شبکه، تا حدود ۷۰ درصد است.

نتیجه‌گیری: نتایج این تحقیق، یک بار دیگر قدرت شبکه‌های عصبی مصنوعی را در طبقه‌بندی و تلفیق اطلاعات مکانی، نشان داد. اما نتیجه منحصراً به فرد این تحقیق آن بود که وزن‌های داخلی شبکه عصبی مصنوعی بیشترین

تاریخ دریافت: ۱۵ اسفند ۱۴۰۱
تاریخ دوری: ۲۰ فروردین ۱۴۰۲
تاریخ اصلاح: ۱۷ اردیبهشت ۱۴۰۲
تاریخ پذیرش: ۲۸ خرداد ۱۴۰۲

واژگان کلیدی:

اکتشاف معدن
کانسار مس
سامانه اطلاعات مکانی
شبکه عصبی مصنوعی
تلفیق اطلاعات

* نویسنده مسئول

✉ m.kheirkhazadeh@scu.ac.ir

③ ۰۶۱۱-۳۳۲۲۶۶۰۰

کارایی را در داخل خود شبکه دارند و استفاده از آن‌ها، برای وزن‌دهی و تلفیق اطلاعات در یک روش دیگر، چندان مفید نخواهد بود. با این وجود، این وزن‌ها در هر صورت، می‌توانند نمایش‌گر ترتیب صحیح اهمیت داده‌های ورودی باشند.

مقدمه

درج‌گرد و همکاران، مدل‌سازی پیش‌بینی آینده‌نگرانه مواد معدنی را برای منطقه سنگ معدن تانگ‌لینگ در شرق چین با استفاده از GIS و به کمک روش‌های یادگیری ماشین، از جمله ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی و جنگل تصادفی (RF) انجام دادند [۱۱]. چوبی (نام انگلیسی) و همکاران، اقدام به بررسی جامع و طبقه‌بندی مطالعات معدنی مبتنی بر GIS پرداختند و GIS و سه دسته مطالعات بر روی برنامه‌ریزی معدن، بهره‌برداری و مدیریت زیست محیطی و توصیف نقش GIS به عنوان یک ابزار پشتیبانی تصمیم‌گیری در توسعه معدن را، معرفی کردند. این بررسی، با طبقه‌بندی مطالعات قبلی مبتنی بر GIS در چندین موضوع فرعی که به فعالیت‌های توسعه معدن و محدوده محیط‌هایی که باید مدیریت شوند، انجام شد. نتیجه قطعی بررسی ایشان، این بود که از آن‌جایی که استفاده از GIS برای مدیریت داده‌های مکانی مرتبط با ذخایر معدنی و شرایط محیطی معدن در مقیاس‌های مختلف مناسب است، کاربرد روش‌های مبتنی بر GIS در توسعه معادن، باید بیشتر گسترش یابد [۱۲]. کوهر (نام انگلیسی) و همکاران نیز، با توجه به اهمیت و تقاضای فزاینده لیتیم (Li) برای کاربردهای صنعتی، به ویژه باتری‌های لیتیم یون قابل شارژ، از شبکه‌های عصبی مصنوعی (ANN) برای شناسایی اهداف اکتشافی، استفاده کردند. در این تحقیق، با یک رویکرد یکپارچه، از شبکه‌های عصبی مصنوعی برای تفسیر داده‌های مرتبط با اکتشاف معادن لیتیم، استفاده می‌شود [۱۳]. در نهایت، می‌بینیم که به دلیل تخصص GIS در کار با انواع اطلاعات مکانی [۱۴، ۱۵] و از سوی دیگر قابلیت‌های شبکه‌های عصبی مصنوعی در طبقه‌بندی که منجر به یافتن ارتباط پنهان بین عوامل می‌شود، استفاده از این دو، در پتانسیل‌یابی معدنی می‌تواند بسیار مؤثر واقع شود. در این تحقیق، از نرم‌افزار ArcGIS جهت آنالیز و نمایش داده‌ها و از نرم‌افزار MATLAB برای برنامه‌نویسی شبکه‌های عصبی، استفاده شده است.

مواد و روش‌ها

در این بخش، مبانی مورد استفاده در روش پژوهش انجام گرفته، تشریح می‌شود.

شبکه‌های عصبی مصنوعی

سامانه‌های هوشمند، به دلیل ویژگی‌های جدید و منحصر به فرد خود در شاخه‌های مختلف علوم، به کار گرفته شده‌اند. امروزه، شبکه‌های عصبی مصنوعی که یکی از انواع سامانه‌های هوشمند به شمار می‌روند در علوم زمین با موفقیت به کار گرفته و در کاربردهایی نظیر سنجش از دور و طبقه‌بندی تصاویر، کاملاً نهادینه شده‌اند [۱۶].


معدن‌کاوی و یافتن ذخیره‌های معدنی، متکی بر مطالعات و کاوش‌های فراوان و دامنه‌داری است که در مناطق مستعد وجود ذخیره معدنی، انجام می‌پذیرد. معمولاً در بدو امر، لایه‌ها و نقشه‌های زمین‌شناسی، کوچک مقیاس هستند که تخمین وجود یک کانسار را در مناطق مختلف، میسر می‌سازند. در پی آن، مطالعات زمین‌شناسی دقیق‌تر انجام پذیرفته و در صورت تأیید شواهد، مطالعات ژئوفیزیکی و ژئوشیمیایی و در نهایت حفر چاه‌های اکتشافی، از دیگر اقداماتی است که برآورد کامل‌تری را از ویژگی‌های آن کانسار، ارائه می‌دهند.

تلفیق و ترکیب انواع داده‌ها و اطلاعات مکانی و استخراج نتایج و اطلاعات جدید از آنها، از ویژگی‌های سامانه‌های اطلاعات مکانی است. اطلاعات تلفیق‌شونده، دارای اعتبار و اهمیت یکسانی نیستند و به نسبت تأثیری که می‌توانند در نتایج نهایی داشته باشند، با اهمیت‌های نسبی متفاوت در تلفیق شرکت داده می‌شوند [۱].

معیاری که نشان‌دهنده اهمیت نسبی اطلاعات است، اصطلاحاً وزن و تعیین این وزن‌ها، عملیات وزن‌دهی خوانده می‌شود [۲، ۳]. روش‌های تعیین وزن، بسیار متنوع و گوناگونند ولی در دو دسته کلی داده-مبنا و دانش-مبنا، تقسیم‌بندی می‌شوند [۴].

در روش‌های دانش-مبنا یک کارشناس و یا گروهی از کارشناسان از طریق روال‌ها و روش‌های معین مبادرت به تعیین وزن‌ها می‌کنند و سپس داده‌ها با وزن‌های اختصاص یافته، توسط روش‌های تلفیق، مورد استفاده قرار می‌گیرند. روش‌های Analytical Hierarchy Process (AHP)، Delphi و تخمین نسبت را می‌توان نمونه‌هایی از این روش‌ها دانست [۴، ۵].

روش‌های دانش-مبنا، وابستگی اساسی به نظرات کارشناسی دارند و به همین دلیل، شدیداً از اشتباهات و نواقص نظرات کارشناس، متأثر می‌شوند. از این روست که در پارهای موارد، از روش‌های داده-مبنا استفاده می‌شود. در این روش‌ها، از شواهدی که در خود داده‌ها موجود است برای وزن‌دهی آن‌ها استفاده می‌شود. شواهدی که روش‌های داده-مبنا احتیاج دارند، نمونه‌هایی از جواب است [۶، ۷]. به عنوان مثال، نمونه‌هایی از رویداد رانش زمین، می‌توانند جهت وزن‌دهی اطلاعات مؤثر در پیش‌بینی رانش زمین، مورد استفاده قرار گیرند [۸]. روش شبکه‌های عصبی مصنوعی، که در این مقاله مورد استفاده قرار گرفته است، در زمره روش‌های داده-مبنای طبقه‌بندی به شمار می‌رود که قابلیت تلفیق اطلاعات را نیز، دارا هستند [۹، ۱۰]. پیشینه تحقیق در حیطه استفاده از سامانه‌های اطلاعات مکانی و شبکه‌های عصبی در مورد اکتشافات و ذخیره‌سنجی معادن، نشان می‌دهد که این موضوع همچنان جزء موضوعات روز و پژوهش‌های جاری در زمینه کاربردهای تحلیل اطلاعات مکانی می‌باشد. تائو سان (پیشنهاد می‌شود که نام انگلیسی اندیشمند



شکل ۱: نمایی از یک شبکه عصبی پرسپترون چند لایه، دایره‌ها نشان دهنده نرون‌ها هستند

Fig. 1: A multi-layer Perceptron network. The circles show the neurons

لایه ابتدایی، لایه ورودی، لایه انتهایی، لایه خروجی و لایه یا لایه‌های مابین، لایه‌های پنهان نامیده می‌شوند [۲۶]. تعداد نرون‌های لایه‌های ورودی به اندازه ورودی‌ها و به همین شکل، تعداد نرون‌های لایه خروجی به تعداد خروجی‌های مورد انتظار است ولی تعداد لایه‌های پنهان و تعداد نرون‌های موجود در هر یک، به طراحی شبکه بستگی دارد و معمولاً توسط روش سعی و خطا، تعیین می‌گردد [۲۷].

اکتشاف معدن و نقشه پتانسیل معدنی

اکتشاف معدن، در مراحل متعددی انجام می‌گیرد که این مراحل، از مرحله پی جویی اولیه آغاز گشته، تا مرحله تفصیلی ادامه می‌یابد. در خلال این روند، متناسب با پیشرفت مراحل، از نقشه‌ها و عکس‌های هوایی بزرگ مقیاس‌تر و داده‌های دقیق‌تر، استفاده می‌شود به طوری که در مرحله تفصیلی، کار تماماً روی داده‌ها و نقشه‌هایی با مقیاس بزرگتر از ۱:۵۰۰۰، صورت می‌پذیرد.

مطالعات اکتشافی معدن، شامل جمع‌آوری اطلاعات و داده‌ها و همچنین، تهیه نقشه‌هایی می‌شود که نشانه‌هایی برای وجود ماده معدنی مورد نظر، به شمار می‌روند. در این راستا، در مرحله تفصیلی سه دسته عمده از مطالعات صورت می‌پذیرد که عبارتند از: مطالعات زمین‌شناسی، ژئوشیمیایی و ژئوفیزیکی. در مطالعات زمین‌شناسی، لایه‌های سنگی تشکیل‌دهنده منطقه، انواع دگرسانی‌ها و عمر و دوران زمین‌شناسی تشکیل ساختارهای زمین‌شناسی موجود، تعیین و در قالب نقشه‌ها و گزارش‌های متنوع، تدوین می‌گردد [۲۷]. در مطالعات ژئوشیمیایی، جنس خاک منطقه از نظر عناصر شیمیایی، مورد آزمایش‌های دقیق قرار می‌گیرد و نقشه آنومالی ژئوشیمیایی که وضعیت منطقه را از نظر دارا بودن مواد معدنی مورد نظر نشان می‌دهد، تهیه می‌شود. در نهایت، مطالعات ژئوفیزیکی انجام می‌گیرد که در آن، منطقه از نظر ویژگی‌هایی نظیر قابلیت گذردهی الکتریسیته، مقاومت الکتریکی و شدت میدان مغناطیسی، با وسایل اندازه‌گیری مخصوصی مورد سنجش قرار می‌گیرد و نقشه‌های متنوعی نظیر نقشه‌های مقاومت ظاهری، شارژ بیلبیته و شدت کل میدان مغناطیسی، تهیه می‌گردد [۲۸].

شبکه عصبی، را می‌توان به شکل یک جعبه سیاه دانست که از یک سو ورودی‌هایی به آن وارد و از سوی دیگر جواب گرفته می‌شود. اتفاقاتی که درون این جعبه منجر به تولید جواب می‌شود، توسط خود شبکه، ساماندهی و کنترل می‌گردد [۸].

ایده اصلی شبکه‌های عصبی مصنوعی، از مغز انسان گرفته شده است. مغز، از واحدهای پردازشی کوچکی به نام نرون تشکیل شده است. بر خلاف کامپیوترها که پردازش را به صورت متوالی و با سرعت بسیار بالا انجام می‌دهند، مغز اطلاعات را در بین واحدهای پردازشگر کوچک، اما بسیار زیاد خود پخش می‌کند و پردازش را به صورت موازی ترتیب می‌دهد [۱۷]. در ایده شبکه‌های عصبی مصنوعی، سرعت چشمگیر کامپیوترها با ساختار موازی و کارآمد مغز، در هم آمیخته و سامانه‌ای با ویژگی‌های مفیدی نظیر قابلیت یادگیری و مقاومت در برابر خطا را، تشکیل داده است [۱۸].

یادگیری در شبکه‌های عصبی مصنوعی

آموزش‌پذیری، از مهم‌ترین ویژگی‌های شبکه‌های عصبی، به شمار می‌رود [۱۹، ۲۰]. میزان ارتباط بین نرون‌ها و اطلاعات ورودی به آن‌ها، توسط اعدادی که وزن نامیده می‌شوند، تعیین می‌شود. از آرایش مختلف نرون‌ها، شبکه‌های عصبی متنوع تولید می‌شوند و روند آموزش، روندی است که منجر به تنظیم وزن‌های درونی شبکه می‌گردد [۱۷، ۲۰، ۲۱]. پیش از استفاده از شبکه، باید آن را توسط داده‌های آموزشی، آموزش داد. با تکمیل روند آموزش، وزن‌های درونی شبکه تنظیم می‌شوند و می‌توان از این شبکه، جهت تحلیل داده‌های ورودی دیگر و ارائه خروجی، استفاده نمود [۱۹].

بر اساس نوع آموزش، شبکه‌های عصبی به دو دسته کلی با سرپرست و بدون سرپرست، تقسیم‌بندی می‌شوند [۲۲]. شبکه‌های عصبی با سرپرست، به انواعی اطلاق می‌گردد که در مرحله آموزش با جواب‌های صحیح، آموزش داده می‌شوند. به این معنی که، به ازای هر ورودی، پاسخ شبکه با پاسخ صحیح مقایسه می‌شود و با روندی که به پس‌انتشار خطا معروف است، وزن‌های درونی در جهت رسیدن به پاسخ‌های صحیح، تصحیح می‌گردند. در مقابل، در شبکه‌های بدون سرپرست، آرایش نرون‌ها به صورتی است که به جوابی همگرا گردد و پاسخ‌های صحیح، در دسترس نمی‌باشند [۲۳، ۲۴].

شبکه پرسپترون چند لایه

شبکه پرسپترون چند لایه، یکی از انواع پرکاربرد شبکه‌های با سرپرست است. این شبکه، از چند لایه نرون تشکیل یافته است که اطلاعات را لایه به لایه پردازش می‌کنند و خروجی هر لایه در اختیار لایه بعدی قرار می‌گیرد [۲۵]. نمای کلی این شبکه، در شکل ۱، نشان داده شده است.

منطقه مورد مطالعه و داده‌ها

کانسار مورد مطالعه در این تحقیق، کانسار مس پرفیری علی‌آباد واقع در ۷۵ کیلومتری جنوب غربی شهرستان یزد است. داده‌ها و اطلاعات این کانسار، از شرکت ملی صنایع مس ایران اخذ گشته‌اند. از ویژگی‌های بارز و مهم این کانسار، انجام هر سه دسته مطالعات زمین‌شناسی، ژئوشیمیایی و ژئوفیزیکی در منطقه و علاوه بر آن، وجود ۵۱ حلقه چاه اکتشافی است که تنها ۲۶ چاه از مجموعه مورد نظر در محدوده مشترک تمامی مطالعات، قرار می‌گیرد. این اشکال، به دلیل عدم استفاده از سیستم مختصات یکسان در مطالعات گوناگون و عدم لحاظ مراتب زمین- مرجع سازی، ایجاد شده است.

روش پژوهش

در این تحقیق، حاصل هر سه دسته مطالعات اکتشافی به عنوان داده‌های ورودی شبکه عصبی، مورد استفاده قرار گرفته است. علاوه بر آن، چاه‌های اکتشافی به عنوان شواهدی از جواب مسأله برای آموزش شبکه و وزن‌دهی داده‌ها، به کار گرفته شده‌اند. از میان ۲۶ چاه اکتشافی موجود در منطقه مشترک، ۱۶ چاه برای آموزش شبکه و ۱۰ چاه باقیمانده نیز برای آزمون نتایج، در نظر گرفته شده‌اند.

گرچه داده‌های متنوع زیادی می‌توانند به عنوان شواهدی بر وجود مس در این کانسار استفاده شوند، ولی چنانچه هیچ یک از چاه‌های اکتشافی در محدوده یکی از داده‌ها قرار نگیرد، شبکه عصبی و به طور کلی یک روش داده- مبنای قادر نخواهد بود اهمیتی برای آن قائل شود و لذا، این داده به صورت خودکار از زمره داده‌های ورودی، حذف خواهد گردید [۴]. با توجه به این مورد، داده‌هایی که امکان استفاده در این روش را دارند، عبارتند از: نقشه‌های آنومالی ژئوشیمیایی، ژئومغناطیس و ژئوالکترونیک، نقشه سنگ میزبان و آلتراسیون فیلک. پیش از ورود داده‌ها به شبکه، با تست‌های همبستگی صورت گرفته مشخص گردید که دو لایه آلتراسیون فیلک و سنگ میزبان دارای همبستگی مکانی غیر قابل نظر کردن هستند و لذا، این دو داده با استفاده از اپراتور منطقی *and*، با یکدیگر تلفیق شدند و لایه‌ای به نام فیلک- میزبان شکل گرفت.

مقادیر موجود در لایه‌های مورد نظر، ابتدا نرمالیزه شدند به صورتی که تمام مقادیر موجود در هر لایه، در محدوده بین صفر و یک، قرار گرفت. این نقشه‌ها، که همگی در قالب مدل داده‌ای رستر و به اندازه سلول 1×1 متر هستند، از نقشه‌های اولیه‌ای با مقیاس‌های $1:2000$ تا $1:5000$ به دست آمده‌اند و به همراه نقشه چاه‌های اکتشافی در شکل ۲، قابل ملاحظه هستند. شایان ذکر است که، آنومالی‌ها به سه دسته حد زمینه، حد واسط و آنومالی طبقه‌بندی شدند.

آموزش شبکه عصبی

در مختصات هر یک از ۱۶ چاه اکتشافی آموزشی، چهار داده از چهار لایه اخذ می‌گردد. بدین ترتیب، تعداد نرون‌های لایه ورودی برابر چهار

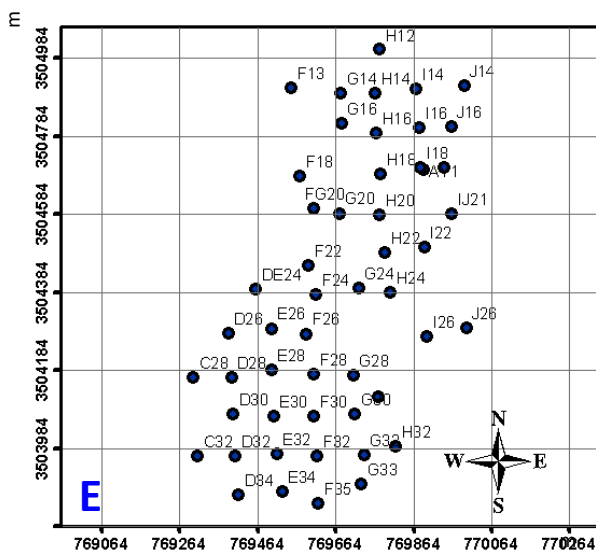
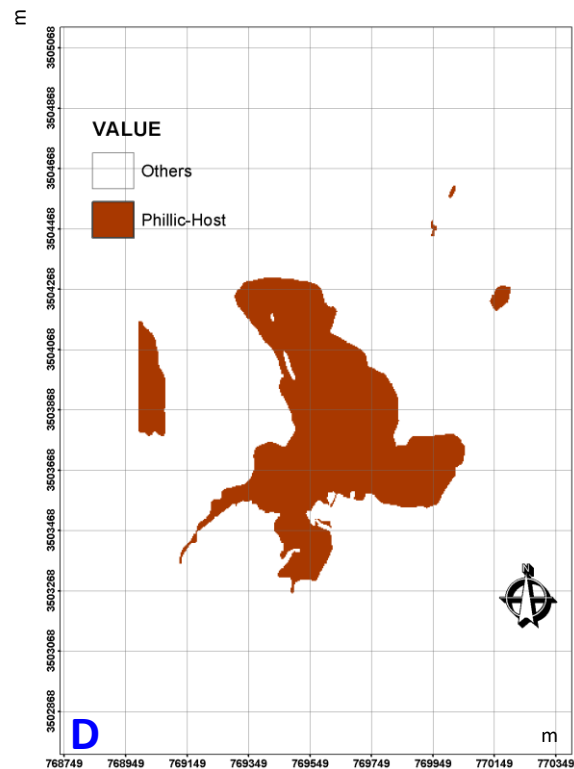
شایان ذکر است که، تمامی مطالعات فوق‌الذکر بر روی سطح زمین انجام می‌شوند و تنها، مطالعات ژئوفیزیکی می‌توانند اطلاعات اندکی راجع به درون زمین کسب نمایند، حال آن‌که معدن احتمالی در درون زمین واقع شده است.

محدوده‌ای که احتمال وجود ذخایر معدنی در آن داده می‌شود و مطالعات در آن صورت می‌پذیرد، کانسار نامیده می‌شود [۲۹]. مطالعات انجام گرفته، توسط کارشناسان به دقت تحلیل می‌شود و با تلفیق آنها، متخصصان حدس‌هایی در مورد کم و کیف مواد موجود در درون زمین می‌زنند. با این حال، این نظرات به هیچ وجه قطعی نیستند و وابستگی بسیار بالایی نیز به میزان تخصص و مهارت کارشناسان دارند. چنانچه این گمانه‌زنی‌ها مبنی بر وجود ذخایر معدنی قابل توجه و دارای صرفه اقتصادی باشد، لازم است که برای تعیین صحت و سقم این نظرات به اعماق زمین دسترسی یافت. این کار، از طریق چاه‌هایی که در محدوده کانسار حفر می‌شوند و چاه‌های اکتشافی نام دارند، انجام می‌گیرد [۳۰]. حفر چاه‌های اکتشافی، عملیاتی بسیار پرهزینه است و عدم دقت در گمانه‌زنی‌های اولیه، اتلاف زمان و هزینه‌ای هنگفت را به دنبال خواهد داشت. از این رو است که روش‌هایی که به بهترین شکل، محل وجود ماده معدنی را در عمق زمین پیش‌بینی نمایند، از اهمیت فوق‌العاده‌ای برخوردارند.

حاصل گمانه‌زنی‌های کارشناسان و یا روش‌های جایگزین، نقشه‌ای است که نشان‌گر مناطق دارای پتانسیل معدنی مختلف از پتانسیل پایین تا بالاست و نقشه پتانسیل معدنی، نام دارد [۳۱، ۳۲]. با حفر چاه‌های اکتشافی، صحت پیش‌بینی انجام شده برای محدوده‌های دارای پتانسیل معدنی بالا، سنجیده می‌شود. روش شبکه عصبی در این مقاله، جهت تعیین این نقشه به کار گرفته شده است.

کانسار مس پرفیری

اطلاق واژه پرفیری برگرفته از منشأ تشکیل کانسار است. در این تیپ کانسار، یک توده پرحرارت که به توده پرفیریتیک موسوم است، از اعماق زمین به لایه‌های بالایی، نفوذ می‌کند. این توده، سبب بروز دگرسانی-هایی در سنگ‌های اطراف خود می‌شود که این دگرسانی‌ها بر حسب نوع، به اسامی مختلفی همچون پتاسیک، فیلک، آرژیلیک و پروپیلیتیک، نامیده می‌شوند [۱۹]. آب‌های زیرزمینی که در طبقات مختلف زمین نفوذ می‌کنند به توده پرحرارت پرفیریتیک برخورد نموده، گرم شده، مجدداً به سمت بالا حرکت می‌کنند. در جریان برخورد آب‌ها با توده پرفیریتیک، مس با آب پرحرارت واکنش نشان داده، در آن حل می‌شود و این آب‌ها در لایه‌های بالاتر، همزمان با روند سرمایش، مس را در سنگ‌های عبوری به جای می‌گذارند و به تدریج کانی‌های اطراف را داری مس می‌کنند [۱۹]. غلظت مس در یک کانسار پرفیری معمولاً حداکثر تا یک درصد و عمق معدن نیز، حداکثر دو کیلومتر است [۱۷]. سنگ پایه‌ای که کانی‌های مس‌دار در آن رسوب کرده است، سنگ میزبان و سنگ‌های اطراف آن، سنگ‌های دیواره نامیده می‌شوند [۱۸].



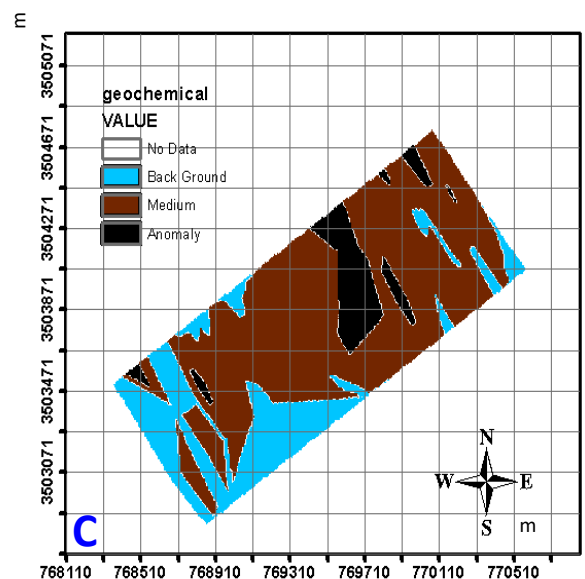


شکل ۲: نقشه‌های به ترتیب A: آنومالی ژئومغناطیس، B: آنومالی ژئوالکتریک، C: آنومالی ژئوشیمیایی، D: فیلیک میزبان و E: چاههای اکتشافی.

Fig. 2: The maps of A: Geomagnetic Anomaly, Goelectric Anomaly, C: Geochemical Anomaly, D: Phyllic-host, E: Boreholes

مطلوب و یا ضعیف بودن چاه‌ها با توجه به نتایج نمونه‌برداری آن‌ها در اعماق مختلف و توسط کارشناس مجرب، تعیین گردیده است. در نتیجه، جواب اولیه شبکه با جواب واقعی، مقایسه می‌شود و جهت آموزش شبکه، مورد استفاده قرار می‌گیرد. با تکرار روند آموزش، شبکه به جواب‌های مورد نظر، همگرا می‌گردد.

آنچه در این میان اهمیت زیادی دارد، تعیین مناسب‌ترین ساختار شبکه است که شامل تعیین تعداد لایه‌های پنهان و تعداد نرون‌های موجود در هر یک است. برای این منظور، از روش سعی و خطا استفاده

خواهد بود. خروجی شبکه به ازای این داده‌های ورودی باید مقدار یک، در مورد چاه‌های مطلوب و مقدار صفر، در مورد چاه‌های ضعیف باشد.



و وزن به دست آمده برای این لایه علاوه بر مقدار منفی، از نظر عددی بسیار بزرگ‌تر از سایر وزن‌هاست. از آن‌جا که دلایل قطعی مبنی بر وجود کانسار مطلوب، تنها از طریق مشاهده مستقیم و حفاری منطقه به دست می‌آید، وجود شواهدی نظیر آنومالی ژئومغناطیس، دلایلی قطعی به شمار نمی‌روند و کارشناسان، همگونی وجود این شواهد را با وجود مواد معدنی در موارد مختلف بررسی کرده، مدل‌هایی استخراج می‌کنند. در مطالعه موردی موضوع این مقاله، آنومالی ژئومغناطیس شاهد مناسبی برای وجود مس دیده نشد.

برای رفع این کاستی، تمام عملیات انجام گرفته، با حذف لایه آنومالی ژئومغناطیس، مجدداً انجام پذیرفت. نتایج این عمل، نشان‌گر بهبود چشمگیر $RMSE$ در صورت حذف این لایه است. به صورتی که کم‌ترین $RMSE$ در صورت حذف لایه آنومالی ژئومغناطیس به شکل محسوسی تقلیل یافته، با یک شبکه متشکل از دو لایه پنهان، شش نرون در لایه پنهان اول و چهار نرون در لایه پنهان دوم، به مقدار 0.1259 می‌رسد که این مقدار در حالت استفاده از آنومالی ژئومغناطیس، 0.2780 به دست آمده بود. وزن‌های به‌دست آمده از این شبکه نیز، به همان ترتیب استخراج گردید و در جدول ۱، قابل ملاحظه است.

تلفیق داده‌ها و تهیه نقشه پتانسیل معدنی

تلفیق داده‌های موجود، به دو صورت امکان‌پذیر می‌باشد. حالت اول، استفاده از شبکه عصبی طراحی شده و حالت دوم، استفاده از یک روش تلفیق جداگانه و به‌کارگیری وزن‌های به‌دست آمده از شبکه است. این دو حالت، هر دو در این مقاله مورد استفاده قرار گرفته‌اند. روش تلفیق مورد استفاده، همپوشانی شاخص نام دارد [۲۵]. روش همپوشانی شاخص با یک رویکرد خطی، مطابق رابطه (۱) به تلفیق داده‌ها می‌پردازد [۴]:

$$\bar{S} = \frac{\sum_{i=1}^n S_{ij} W_i}{\sum_{i=1}^n W_i} \quad (1)$$

که در آن، \bar{S} مقدار تلفیقی به‌دست آمده برای عارضه (پلیگن یا پیکسل)، W_i وزن i امین نقشه ورودی، S_{ij} امتیاز i امین کلاس از i امین نقشه و n تعداد نقشه‌های تلفیقی است. با به‌کارگیری این رابطه، نقشه پتانسیل معدنی در هر دو حالت استفاده و عدم استفاده از نقشه آنومالی ژئومغناطیس، تهیه گردید که در شکل ۳، به نمایش در آمده‌اند.

از سوی دیگر، نقشه‌های اولیه را می‌توان با استفاده از شبکه آموزش یافته نیز تلفیق کرده، مبادرت به تهیه نقشه پتانسیل معدنی نمود. بدین منظور، مقادیر متناظر با هر سلول در هر یک از سه یا چهار نقشه اولیه وارد شبکه شده و جواب، استخراج می‌گردد. این جواب، نشان‌گر میزان پتانسیل معدنی است که شبکه برای سلول مزبور، پیش‌بینی نموده است.

شد. بدین ترتیب که پس از آموزش و همگرا شدن شبکه، داده‌های موجود برای ۱۰ چاه باقی‌مانده به شبکه آموزش یافته، ارائه گردید و جواب شبکه با پاسخ‌های واقعی، مقایسه شد. معیار مقایسه، ریشه مجموع مربعات خطا ($RMSE$) بود و شبکه‌ای به عنوان بهترین شبکه، انتخاب گردید که دارای کمترین $RMSE$ بود. گفتنی است که شبکه تشکیل یافته، یک شبکه پرسپترون چند لایه با الگوریتم یادگیری پس انتشار خطا (از نوع $Levenberg-Marquart$) و یک لایه پنهان می‌باشد. تابع محرک در دو لایه اول به صورت خطی و در لایه خروجی از نوع تانزانت هیپربولیک است.

استخراج وزن از شبکه عصبی

وزن‌های درونی شبکه، نشانگر میزان اهمیتی است که نرون‌ها برای داده‌های ورودی قائل شده‌اند. بنابراین با دست بردن در این جعبه سیاه می‌توان به وزن‌ها دست یافت و از آن‌ها در مقاصد مفیدی از جمله روش‌های دیگر تلفیق داده، استفاده نمود [۱۹]. چنانچه شبکه پرسپترون به صورت یک لایه و در واقع فاقد لایه پنهان باشد، وزن‌ها مستقیماً قابل استفاده هستند اما چنانچه لایه پنهان وجود داشته باشد، چندین لایه دارای وزن، وجود دارد. در این حالت، وزن‌های نهایی مورد نظر با ضرب کردن ماتریس‌های وزن هر لایه از نرون‌ها، به دست می‌آید [۲۵].

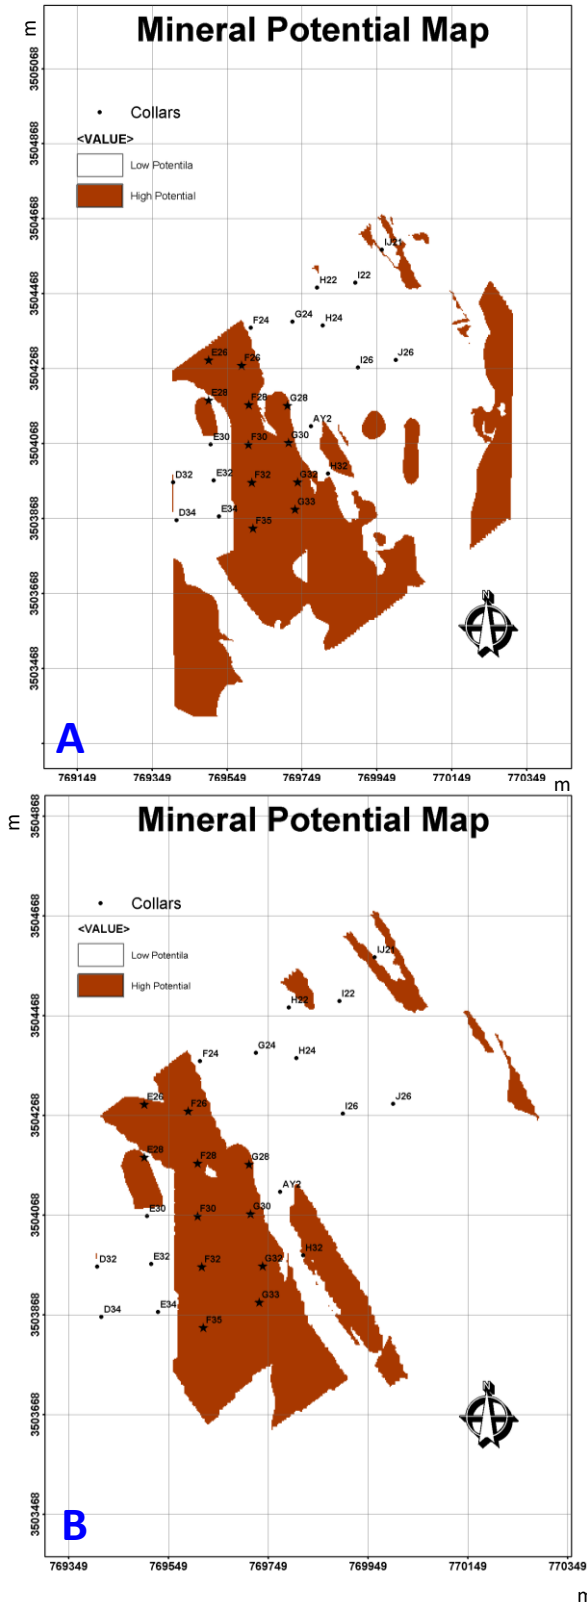
در این تحقیق، شبکه‌ای با دو لایه پنهان، هشت نرون در لایه پنهان اول و سه نرون در لایه پنهان دوم، کوچک‌ترین $RMSE$ را تولید نمود و به عنوان بهترین آرایش شبکه، مورد استفاده قرار گرفت. با ضرب نمودن ماتریس‌های وزن لایه‌ها، وزن‌های نهایی به دست آمد که در جدول ۱، قابل ملاحظه‌اند

جدول ۱: وزن‌های استخراج شده از شبکه عصبی در دو شرایط استفاده و عدم استفاده از لایه آنومالی ژئومغناطیس

Table 1: The extracted weights from the artificial neural network in two cases of using and not using the layer of Geomagnetic anomaly				
وزن به دست آمده	آنومالی ژئومغناطیس	آنومالی ژئوشیمیایی	آنومالی ژئوالکتریک	فیلیک-میزبان
Gained weight	Geomagnetic anomaly	Geochemical anomaly	Geoelectric anomaly	Filik-Host
با آنومالی ژئومغناطیس	-8.5420	0.1417	0.0909	0.0754
With geomagnetic anomaly				
بدون آنومالی ژئومغناطیس	-----	220.8821	45.7031	37.1522
No geomagnetic anomaly				

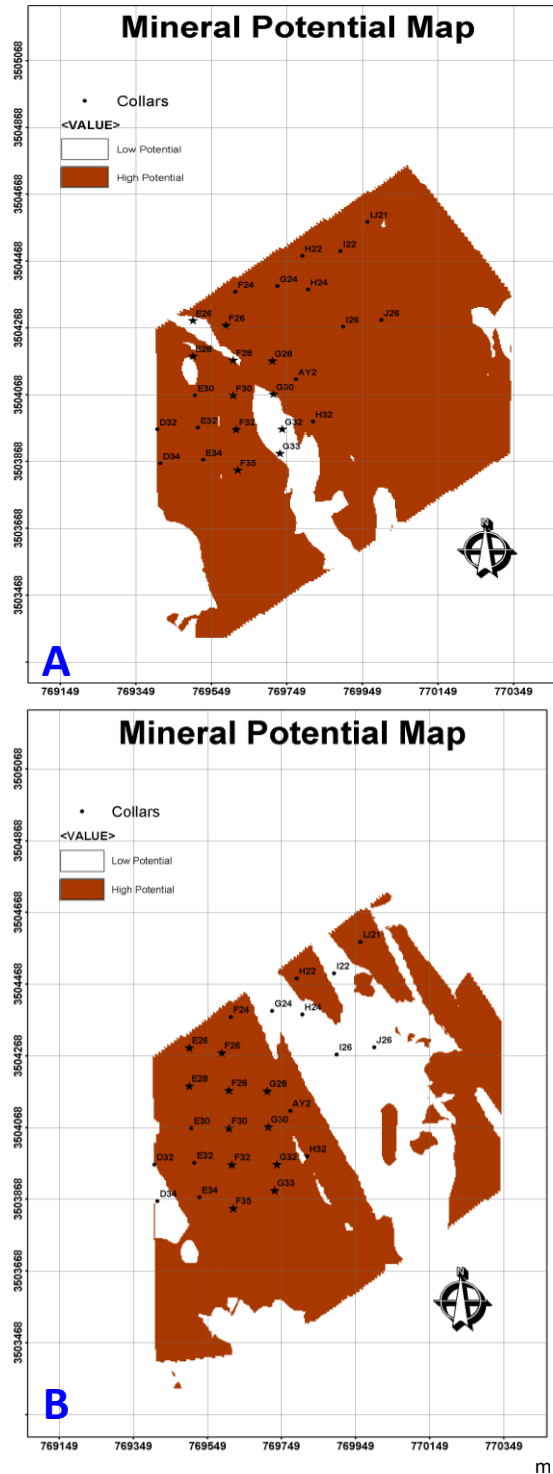
با مقایسه چاه‌های اکتشافی و لایه آنومالی ژئومغناطیس، این نکته مشهود است که این لایه، همگونی مطلوبی با شرایط چاه‌ها ندارد و حتی می‌تواند به صورت عکس به عنوان شواهدی مبنی بر عدم وجود ماده معدنی، تلقی گردد. این نکته در وزن‌های به‌دست آمده نیز، آشکار است

از کنار هم قرار گرفتن این جوابها در مختصات خود، نقشه پتانسیل معدنی بهدست خواهد آمد. این نقشه نیز، در دو حالت استفاده و عدم استفاده از نقشه آنومالی ژئومغناطیس، تهیه گردیده و در شکل ۴ قابل ملاحظه است.



شکل ۴: نقشه‌های پتانسیل معدنی به دست آمده با استفاده از روش تلفیق شبکه عصبی. A: با در نظر گرفتن لایه آنومالی ژئومغناطیس و B: بدون در نظر گرفتن لایه آنومالی ژئومغناطیس. جاهای ضعیف با علامت نقطه و جاهای مطلوب با علامت ستاره مشخص شده‌اند.

Fig. 4: The mineral potential map produced by artificial neural network in two cases of A: Considering geomagnetic anomaly and B: Ignoring geomagnetic anomaly. The low potential boreholes are signed by point and the high potential boreholes are signed by star



شکل ۳: نقشه‌های پتانسیل معدنی به دست آمده با استفاده از روش تلفیق همپوشانی شاخص در دو حالت A: با در نظر گرفتن لایه آنومالی ژئومغناطیس و B: بدون در نظر گرفتن لایه آنومالی ژئومغناطیس. جاهای ضعیف با علامت نقطه و جاهای مطلوب، با علامت ستاره مشخص شده‌اند.

Fig. 3: The mineral potential maps produced by Index Overlay method in two cases of A: Considering geomagnetic layer and B: Ignoring geomagnetic layer

جدول ۲: طبقه‌بندی چاه‌های اکتشافی با استفاده از روش‌های پیاده‌سازی شده. *a* مبین دقت تولید و *k* دقت کل می‌باشد

Table 2: The classification of boreholes based on the implemented methods. *a* shows the producer accuracy and *k* is the overall accuracy

روش همپوشانی شاخص و وزن‌های به دست آمده از شبکه عصبی با احتساب آنومالی ژئومغناطیس							
The index overlap method and the weights obtained from the neural network, including the geomagnetic anomaly							
	ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision		ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision
چاه مطلوب Desirable well	2	2	a= 50%	چاه مطلوب Desirable well	7	4	a= 63.64%
چاه ضعیف Weak well	6	0	a= 00%	چاه ضعیف Weak well	15	0	a= 00%
مجموع Total	8	2	k= 20%	مجموع Total	22	4	k=26.92%
روش همپوشانی شاخص و وزن‌های به دست آمده از شبکه عصبی بدون احتساب آنومالی ژئومغناطیس							
The index overlap method and the weights obtained from the neural network without considering the geomagnetic anomaly							
	ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision		ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision
چاه مطلوب Desirable well	4	0	a= 100%	چاه مطلوب Desirable well	11	0	a= 100%
چاه ضعیف Weak well	3	3	a=50%	چاه ضعیف Weak well	8	7	a=46.67%
مجموع Total	7	3	k=70%	مجموع Total	19	7	k= 69.23%
شبکه عصبی با احتساب آنومالی ژئومغناطیس							
Neural network including geomagnetic anomaly							
	ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision		ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision
چاه مطلوب Desirable well	3	1	a=75%	چاه مطلوب Desirable well	10	1	a=90.91%
چاه ضعیف Weak well	0	6	a= 100%	چاه ضعیف Weak well	0	15	a= 100%
مجموع Total	3	7	a= 90%	مجموع Total	10	16	k=96.15%
شبکه عصبی بدون احتساب آنومالی ژئومغناطیس							
Neural network excluding geomagnetic anomaly							
	ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision		ارزیابی مطلوب Favorable evaluation	ارزیابی ضعیف Poor evaluation	دقت Precision
چاه مطلوب Desirable well	4	0	a= 100%	چاه مطلوب Desirable well	11	0	a= 100%
چاه ضعیف Weak well	0	6	a= 100%	چاه ضعیف Weak well	0	15	a= 100%
مجموع Total	4	6	k= 100%	مجموع Total	11	15	k= 100%

با توجه به این‌که پاسخ‌ها در مرحله آموزش، صفر یا یک هستند، پس از اعمال داده‌های غیر آموزشی نیز، پاسخ‌های شبکه، پیرامون این دو مقدار قرار می‌گیرند و لذا، تمایز آن‌ها آشکار است. با توجه به این مطلب، می‌توان از شکست طبیعی برای طبقه‌بندی استفاده نمود. در این نوع طبقه‌بندی با رسم نمودار توزیع تجمعی داده‌ها، شکست‌های موجود در بین آن‌ها مشخص می‌گردد و این شکست‌ها به عنوان حدود تمایز در نظر گرفته می‌شوند [۸]. با بهره‌گیری از روش‌های فوق‌الذکر، نقشه‌های به دست آمده در دو کلاس، طبقه‌بندی شده‌اند.

از آن‌جا که چاه‌های اکتشافی به دو دسته چاه‌های مطلوب و چاه‌های ضعیف تقسیم‌بندی می‌شوند، لازم است که نقشه پتانسیل معدنی نیز برای ارزیابی جواب، در دو کلاس دارای پتانسیل معدنی بالا و پایین، طبقه‌بندی گردد. در حالت استفاده از روش همپوشانی شاخص، یک کارشناس با در نظر گرفتن معیارهای مورد نظر در طبقه‌بندی چاه‌ها، جواب‌ها را که در بازه بین صفر و یک، قرار می‌گیرند به دو دسته تقسیم‌بندی نمود و حد تمایز این دو طبقه، مقدار ۰/۴۵ تعیین گردید. در حالت استفاده از شبکه عصبی برای تلفیق داده‌ها، از روش تماماً داده- مینا استفاده گردید که در آن نظر کارشناسی حذف شده است.

بحث و تحلیل نتایج

وزن‌های به دست آمده از شبکه عصبی، همگونی مناسبی با روش تلفیقی همپوشانی شاخص ندارند و تنها می‌توانند برای رتبه‌بندی داده‌ها از نظر میزان اعتبار و اهمیت، مورد استفاده واقع شوند. در این حالت، وزن منفی به دست آمده برای لایه آنومالی ژئومغناطیس، نشان می‌دهد که شبکه نیز، وضع ظاهری موجود، مبنی بر عدم تأثیر مثبت آنومالی ژئومغناطیس در وجود پتانسیل معدنی مس را، کشف و تأیید می‌نماید. شبکه‌های عصبی، با نشان دادن این قابلیت‌ها، توانایی استفاده گسترده‌تر خود را در امر معدن‌کاوی و اکتشافات معدنی، متصور می‌سازند.

مشارکت نویسندگان

در این مقاله، نویسندگان به نسبت سهم برابر مشارکت داشته‌اند.

تشکر و قدردانی

بدین‌وسیله، از شرکت ملی صنایع مس ایران به دلیل در اختیار گذاشتن داده‌های لازم، صمیمانه تشکر می‌کنیم.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

منابع و مأخذ

- [1] Alesheikh AA, Soltani MJ, Nouri N, Khalilzadeh M. Land assessment for flood spreading site selection using geospatial information system. *International Journal of Environmental Science & Technology*. 2008;5(4):455-462.
- [2] Malczewski J. GIS and Multicriteria Decision Analysis: John Wiley & Sons; 1999.
- [3] Thorson JT, Monnahan CC, Hulson P-JF. Data weighting: An iterative process linking surveys, data synthesis, and population models to evaluate mis-specification. *Fisheries Research*. 2023;266:106762.
- [4] Bonham-Carter GF. Geographic Information systems for Geoscientists: Modelling with GIS: Elsevier Ltd; 1994.
- [5] Linston HA, Turoff M. The Delphi Method: Techniques and Applications: Addison Wesley Publishing Company; 1975.
- [6] Alesheikh AA, Sadeghi Naeeni Fard F. Design and implementation of a knowledge-based system to improve maximum likelihood classification accuracy. *Canadian Journal of Remote Sensing*. 2007;33(6):459-467.
- [7] Ahmed F, Kim K-Y. Recursive approach to combine expert knowledge and data-driven RSW weldability certification decision making process. *Robotics and Computer-Integrated Manufacturing*. 2023;79:102428.
- [8] Kanungo DP, Arora MK, Sarkar S, Gupta RP. A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide

با استفاده از نتایج به دست آمده و مقایسه روش‌ها، چاه‌های اکتشافی که در دو دسته مطلوب و ضعیف طبقه‌بندی شده‌اند، به خوبی نشانگر دقت روش‌ها در تعیین حدود مناطق دارای پتانسیل معدنی بالا هستند. چنان‌چه، یک چاه مطلوب در منطقه مطلوب و یک چاه ضعیف در منطقه ضعیف واقع شود، ارزیابی درست و در غیر این صورت ارزیابی نادرست، صورت پذیرفته است. نتایج ارزیابی چاه‌ها در دو حالت، یکی با استفاده از ۱۰ چاه و دیگری با استفاده از تمامی چاه‌ها در جدول ۲، آورده شده است. در این جدول، دقت کل حاصل جمع اعداد قطر اصلی به جمع اعداد کل جدول است. دقت تولید هم در هر سطر، حاصل تقسیم عدد واقع در قطر اصلی به جمع اعداد آن سطر می‌باشد.

با مرور نقشه‌ها، به آسانی مشخص می‌شود که وزن‌های به دست آمده از شبکه عصبی، همگونی مناسبی با روش همپوشانی شاخص ندارند. با این وجود، این وزن‌ها می‌توانند به عنوان یک راهنما در روش‌های دانش-مبنا برای هدایت کارشناسان، مورد استفاده قرار بگیرند، چراکه صرف نظر از مقادیر عددی به دست آمده برای آن‌ها، رتبه‌بندی داده‌ها از نظر میزان اهمیت، می‌تواند راهنمای خوبی برای کارشناسان قلمداد گردد. از سوی دیگر، نقشه آنومالی ژئومغناطیس در این کانسار، شاهد مناسبی برای پتانسیل معدنی مس به شمار نمی‌رود که این مهم، با توجه به وزن به‌دست آمده برای این لایه و نقشه‌های به‌دست آمده با در نظر گرفتن این لایه، کاملاً مشهود است.

نتیجه‌گیری

حجم اطلاعات در دنیای امروز، به شکل گسترده‌ای رو به فزونی و نیاز به سیستم‌هایی که قابلیت پردازش اطلاعات در حجم بالا را دارند، به شدت رو به افزایش است. در این میان، GIS به عنوان سامانه و علم تخصصی استفاده و پردازش اطلاعات مکانی، جایگاه مناسبی پیدا کرده است. لزوم تعیین اهمیت نسبی اطلاعات، سبب گشته است روش‌های تخصیص وزن در GIS نیز مطرح شده، به طور گسترده‌ای مورد توجه واقع شوند. در این پژوهش از GIS همراه با شبکه عصبی مصنوعی برای تولید نقشه پتانسیل معدنی یک کانسار مس پرفیری استفاده شد. نقشه پتانسیل معدنی تهیه شده، توسط روش تلفیق شبکه عصبی و بدون در نظر گرفتن لایه آنومالی ژئومغناطیس، تمامی ۲۶ چاه، اهم از ۱۶ چاه آموزشی و ۱۰ چاه باقی‌مانده را به صورت صحیح، طبقه‌بندی نموده است. این موفقیت، قابلیت استفاده و کاربرد شبکه‌های عصبی و به ویژه، شبکه پرسپترون چند لایه را در کاربردهای معدنی، رخ‌نمون می‌سازد. علاوه بر آن، با وجود این‌که نقشه آنومالی ژئومغناطیس در این کانسار، شاهد مناسبی در پتانسیل معدنی مس دیده نمی‌شود، استفاده از آن، موجب انحراف کامل شبکه عصبی نمی‌گردد و تنها، یک افت نسبی را در نتایج به دنبال دارد. این امر، نشان‌دهنده قابلیت انعطاف بالا و تحمل خطا، در شبکه‌های عصبی است. از سوی دیگر، دیده شد که

- [22] Basheer IA, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*. 2000;43(1):3-31.
- [23] Elminir HK, Abdel-Galil H. Estimation OF Air Pollutant Concentrations from Meteorological Parameters Using Artificial Neural Network. *Journal of Electricla Engineering*. 2006;57(2):105-110.
- [24] Fernando H, Surgenor B. An unsupervised artificial neural network versus a rule-based approach for fault detection and identification in an automated assembly machine. *Robotics and Computer-Integrated Manufacturing*. 2017;43:79-88.
- [25] Lee S, Evangelista DG. Earthquake-induced landslide-susceptibility mapping using an artificial neural network. *Nat Hazards Earth Syst Sci*. 2006;6(5):687-695.
- [26] Mehrotra K, Mohan CK, Ranka S. Elements of Artificial Neural Networks: MIT Press; 1997.
- [27] Lee S, Ryu J-H, Won J-S, Park H-J. Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. *Engineering Geology*. 2004;71(3):289-302.
- [28] Ford A, Hart CJR. Mineral potential mapping in frontier regions: A Mongolian case study. *Ore Geology Reviews*. 2013;51:15-26.
- [29] Wang F, Tian Y, Zhou K, Yang R, Tan T, Wang Y, et al. Using a triblock copolymer as a single additive in high aspect ratio through silicon via (TSV) copper filling. *Microelectronic Engineering*. 2021;244-246:111554.
- [30] Bièvre G, Crouzet C. Multi-proxy analysis of boreholes in remolded Quaternary paraglacial deposits (Avignonet landslide, French Western Alps). *Engineering Geology*. 2021;286:106073.
- [31] Ford A, Peters KJ, Partington GA, Blevin PL, Downes PM, Fitzherbert JA, et al. Translating expressions of intrusion-related mineral systems into mappable spatial proxies for mineral potential mapping: Case studies from the Southern New England Orogen, Australia. *Ore Geology Reviews*. 2019;111:102943.
- [32] Davies RS, Groves DI, Trench A, Dentith M. Towards producing mineral resource-potential maps within a mineral systems framework, with emphasis on Australian orogenic gold systems. *Ore Geology Reviews*. 2020;119:103369.
- susceptibility zonation in Darjeeling Himalayas. *Engineering Geology*. 2006;85(3):347-366.
- [9] Świetlicka A, Kolanowski K. Homogeneous ensemble model built from artificial neural networks for fault detection in navigation systems. *Journal of Computational and Applied Mathematics*. 2023;432:115279.
- [10] Koocheki K, Pietruszczak S. Numerical analysis of large masonry structures: bridging meso and macro scales via artificial neural networks. *Computers & Structures*. 2023;283:107042.
- [11] Sun T, Chen F, Zhong L, Liu W, Wang Y. GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district, eastern China. *Ore Geology Reviews*. 2019;109:26-49.
- [12] Choi Y, Baek J, Park S. Review of GIS-Based Applications for Mining: Planning, Operation, and Environmental Management. *Applied Sciences [Internet]*. 2020; 10(7):2266.
- [13] Köhler M, Hanelli D, Schaefer S, Barth A, Knobloch A, Hielscher P, et al. Lithium Potential Mapping Using Artificial Neural Networks: A Case Study from Central Portugal. *Minerals [Internet]*. 2021; 11(10):1046 p.
- [14] Hosseinali F, Alesheikh AA, Weighting Spatial Information in GIS for Copper Mining Exploration. *American Journal of Applied Sciences*. 2008; 5(9):1187-1198.
- [15] Mohammdi M, Hosseinali F. Assessment and Comparison the Location of Six Universities in Tehran City Using GIS and Multi Criteria Decision Making Methods. *International Journal of Environment and Geoinformatics*. 2019;6(1):143-147.
- [16] Feng L, Liao W, Pang J, Hu R, Feng L. Artificial Neural Network in Classification of Multisource Remote Sensing Images. *International Transactions on Electrical Energy Systems*. 2022;2022:5439941.
- [17] Menhaj MB. The Fundamentals of Artificial Neural Networks: Polytechnic University of Tehran; 2016. Persian.
- [18] Alanis AY, Arana-Daniel N, Lopez-Franco C. Artificial Neural Networks for Engineering Applications: Elsevier Science; 2019.
- [19] Beale R, Jackson T. Neural Computing - An Introduction: CRC Press; 1990.
- [20] Guo Y, Peng W, Chen Y, Zhang L, Liu X, Huang X, et al. Joint A-SNN: Joint training of artificial and spiking neural networks via self-Distillation and weight factorization. *Pattern Recognition*. 2023;142:109639.
- [21] Korbar J, Oceppek D, Čepon G, Boltežar M. Training artificial neural networks using substructuring techniques: Application to joint identification. *Mechanical Systems and Signal Processing*. 2023;198:110426.

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



طلوع سیلاوی درجه کارشناسی در رشته مهندسی عمران-نقشه برداری را در سال ۱۳۸۳ از دانشگاه تهران اخذ نمود. وی سپس موفق به اخذ مدارک کارشناسی ارشد و دکتری تخصصی همین رشته با گرایش GIS به ترتیب در سال‌های ۱۳۸۵ و ۱۳۹۵ از دانشگاه تهران

گرایش شد و این دوره را نیز در سال ۱۳۸۶ پشت سر گذاشت. سرانجام وی موفق به اخذ مدرک دکتری تخصصی در رشته کامپیوتر گرایش هوش مصنوعی از دانشگاه علم و صنعت ایران شد. ایشان هم‌اینک استادیار دانشکده علوم ریاضی و کامپیوتر دانشگاه شهید چمران اهواز می‌باشد و علاوه بر تدریس به تحقیق در زمینه‌های متنوعی شامل هوش مصنوعی، یادگیری ماشین و شبکه‌های اجتماعی مشغول است.

Kheirkhazadeh, M. Assistant Professor at the Department of Computer Science, Faculty of Mathematics and Computer Science, Shahid Chamran University of Ahvaz, Ahvaz, Iran

✉ m.kheirkhazadeh@scu.ac.ir

شد. وی هم‌اینک به عنوان کارشناس پژوهشی گروه مهندسی سیستم‌های اطلاعات مکانی در دانشکده مهندسی نقشه‌برداری دانشگاه صنعتی خواجه‌نصیرالدین طوسی تهران مشغول به فعالیت می‌باشد. زمینه‌های پژوهشی مورد علاقه ایشان کیفیت‌سنجی اطلاعات مکانی، GIS تحت وب و برنامه‌نویسی پیشرفته است.

Silavi, T. Laboratory expert at the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics, K.N.Toosi University of Technology, Tehran, Iran

✉ silavi@alborz.kntu.ac.ir



معصومه خیرخواه‌زاده در سال ۱۳۷۹ دوره کارشناسی خود را در رشته مهندسی کامپیوتر گرایش نرم‌افزار در دانشگاه شهید چمران اهواز آغاز و در سال ۱۳۸۳ به پایان رساند و در همین سال وارد دوره کارشناسی ارشد دانشگاه صنعتی امیرکبیر تهران در همین رشته و

Citation (Vancouver): Silavi T, Kheirkhazadeh M. [Using Artificial Neural Networks and Geospatial Information Systems in Mine Exploration for Producing Mineral Potential Map]. *J. RS. GEOINF. RES.* 2023; 1(1): 103-114

 <https://doi.org/10.22061/jrsgr.2022.1981>



COPYRIGHTS

© 2023 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (<https://creativecommons.org/licenses/by-nc/4.0/>)