

مدلسازی پتانسیل معدنی با به کارگیری شبکه خودرمنگار عمیق در پهنه اکتشافی دهسلم، شرق ایران

مجید کیخای حسین پور^{۱*}، امیر حسین کوهساری^۲، امین حسین مرشدی^۳، آلوک پُروال^۴

۱- دانشجوی دکتری، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

۲- دانشیار، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

۳- استادیار، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد

۴- استاد، مرکز مطالعات مهندسی منابع، موسسه تکنولوژی بمبئی هند، بمبئی، هندوستان

(دریافت: تیر ۱۳۹۸، پذیرش: دی ۱۳۹۸)

چکیده

شناسایی نواحی مستعد مرتبط با کانی‌سازی و تلفیق مجموعه داده‌های چندمنبعی اکتشافی در مدلسازی پتانسیل معدنی ضروری است. در این پژوهش، از روش تحلیل داده‌های حجیم و یک الگوریتم یادگیری عمیق بدون ناظر، جهت شناسایی اهداف اکتشافی مرتبط با کانی‌سازی مس - طلا پورفیری در پهنه اکتشافی دهسلم، شرق ایران استفاده شده است. بر اساس شرایط زمین‌شناسی و تشکیل این تیپ کانی‌سازی، در این پژوهش ۳۲ متغیر ورودی، شامل داده‌های زمین‌شناسی (لیتولوژی و ساختاری)، سنجش از دور (دگرسانی‌های آرژیلیک و اکسید آهن)، آنالیز ۲۷ عنصر ژئوشیمی رسوبات آبراه‌ای و نقشه برگردان به قطب مغناطیس هوا برد جهت مدلسازی اکتشافی مس و طلا پورفیری با به کارگیری الگوریتم شبکه خودرمنگار عمیق، استفاده و نتایج حاصل با خروجی مدل میانگین هندسی مقایسه گردید. ارزیابی عملکرد مدل‌های پتانسیل معدنی تولیدشده با استفاده از نمودار آهنگ پیش‌بینی - مساحت بهبودیافته بررسی شد. نتایج حاصل از این پژوهش نشان دهنده عملکرد مناسب مدل تولیدشده به روش خودرمنگار عمیق، در شناسایی اهداف اکتشاف جهت برنامه‌ریزی فعالیت‌های اکتشافی تفصیلی است. خروجی مدل تولید شده منجر به شناسایی اهداف اکتشافی جدیدی در قسمت‌های شرق، شمال، غرب و جنوب غرب منطقه مورد مطالعه شده است. نتیجه این پژوهش، نشان دهنده پتانسیل روش‌های مبتنی بر تحلیل داده‌های حجیم و یادگیری عمیق در مدلسازی پتانسیل معدنی است.

کلمات کلیدی

مدلسازی پتانسیل معدنی، داده حجیم، شبکه خودرمنگار عمیق، مس و طلا پورفیری، دهسلم

* عهده‌دار مکاتبات: majidkeykha@yahoo.com

۱- مقدمه

شناسایی اهداف اکتشافی تیپ خاص کانی‌سازی مورد جستجو در مقیاس ناحیه‌ای، با به کارگیری و تحلیل داده‌های اکتشافی تحت عنوان مدل‌سازی پتانسیل معدنی (MPM^۱) توسعه یافته است [۱]. وجود حجم بالای داده‌های اکتشافی با کیفیت بالا که طیف وسیعی از مقیاس‌ها را پوشش می‌دهند (شامل داده‌های زمین‌شناسی، ژئوفیزیکی، ژئوشیمیایی و سنجش از دور)، سبب ناتوانی روش‌های آماری مرسوم در کشف روابط حاکم بر فضای ورودی داده‌ها شده است [۲]. بنابراین توسعه و به کارگیری نظریه‌ها و روش‌های تحلیلی جدید، برای پتانسیل‌یابی، تفسیر و تلفیق اطلاعات اکتشافی متنوع برای افزایش میزان موفقیت و کاهش هزینه‌های اکتشاف مواد معدنی ضروری است [۳، ۴]. بر اساس تعریف، اصطلاح "داده‌های حجیم"^۲ نه تنها به معنای مجموعه داده‌های با حجم بالا، بلکه به خصوصیات ذاتی داده‌ها با انواع مختلف فرمت‌ها و منابع داده اشاره دارد [۵]. این تعریف در ارتباط با داده‌های مورد استفاده در حوزه علوم زمین، ذاتی و شناخته شده است [۶، ۷].

وجود مجموعه گسترده‌ای از داده‌های اکتشافی، فرصت مناسبی را برای اعمال رویکرد تحلیل داده‌های حجیم، برای حل محدودیت‌های روش‌های کلاسیک در مدل‌سازی پتانسیل معدنی فراهم کرده است [۸-۱۰]. نظریه تحلیل داده‌های حجیم، علاوه بر اینکه روش‌های جدیدی را برای اکتشاف و ارزیابی مواد معدنی ارائه می‌کند [۱۱]، می‌تواند برای تجزیه و تحلیل، شدت‌بخشی و استخراج اطلاعات اضافی از داده‌های از قبل موجود اکتشافی به کار گرفته شود [۱۲]. اهمیت تحلیل داده‌های حجیم در اکتشاف مواد معدنی افزون بر ایجاد انواع نقشه‌های ناهنجاری با استفاده از انواع مختلف داده‌های اکتشافی، سبب شناسایی ویژگی‌های آماری و فضایی توزیع، غنی و تهی‌شدگی عناصر متالوژنیک می‌شود [۱۱]. تجزیه و تحلیل داده‌های حجیم، از تمام داده‌های موجود در فرآیند مدل‌سازی استفاده می‌کند، که این امر امکان تجزیه و تحلیل اکتشافی دقیق‌تری از همبستگی‌های آماری بین تمامی داده‌ها را فراهم می‌آورد [۱۳]. عملکرد اصلی تجزیه و تحلیل داده‌های حجیم، پیش‌بینی است، که این امر یک رویکرد ایده‌آل

برای شناسایی اهداف اکتشافی در MPM است. به عنوان مثال، لیو و همکاران (۲۰۱۶) با استفاده از فاکتورهای مختلف زمین‌شناسی مشتق شده از فایل مدل ارتفاعی (DEM^۳)، شامل ارتفاع زمین، شیب، میزان انحنای سطح، وضعیت لیتولوژی و ...، محیط ژئومورفیک مطلوب برای میزبانی کانی‌سازی عناصر نادر خاکی در ناحیه شرق نانلینگ چین را مدل‌سازی کردند [۱۴]. لو و همکاران (۲۰۱۷) با تولید یک مدل پیش‌بینی کمی برای کانی‌سازی طلا بر اساس مجموعه داده‌های ژئوفیزیکی و ژئوشیمیایی، قابلیت روش تجزیه و تحلیل داده‌های حجیم را برای MPM نشان داده‌اند [۱۵].

روش‌های متعارفی که برای ارزیابی ناهنجاری‌های ژئوشیمیایی استفاده می‌شود، معمولاً بر روی تشخیص ناهنجاری‌های ژئوشیمیایی مثبت متمرکز هستند و ناهنجاری‌های ژئوشیمیایی منفی مرتبط با کانی‌سازی را نادیده می‌گیرند [۱۱]. تکنیک‌های تجزیه و تحلیل داده‌های حجیم با بررسی هم‌زمان کل مجموعه داده‌های ژئوشیمیایی برای شناسایی ناهنجاری‌های ژئوشیمیایی و تعیین ارتباطات آماری و فضایی آنها با الگوهای کانی‌سازی شناخته شده، می‌تواند بر این محدودیت‌ها غلبه کند. با پیشرفت‌های سریع محاسباتی، کارایی روش‌های یادگیری ماشین برای تجزیه و تحلیل داده‌های حجیم و کشف ارتباط ساختاری بین داده‌ها به اثبات رسیده است [۱۶]. روش‌های مختلف یادگیری ماشین مانند شبکه‌های عصبی [۱۷-۱۹]، ماشین بردار پشتیبان [۲۰، ۲۱] [۲۱] و جنگل تصادفی [۲، ۳، ۲۲]، در سال‌های اخیر در زمینه مدل‌سازی پتانسیل معدنی مورد استفاده قرار گرفته است. روش‌های یادگیری عمیق، به عنوان رویکردی تازه توسعه یافته در یادگیری ماشین، با استفاده از شبکه‌های عصبی چندلایه بر مبنای تفکیک ویژگی‌ها به صورت سلسله مراتبی به کشف ساختار پنهان بین داده‌ها می‌پردازند. عبارت یادگیری عمیق نیز برگرفته از همین خاصیت است، به گونه‌ای که شبکه آموزشی در هر مرحله با در نظر گرفتن یکسری ویژگی‌های شاخص اقدام به کشف رابطه و ویژگی‌های غیر خطی بین داده‌ها می‌نماید [۲۳]. در علوم زمین، یادگیری عمیق در طبقه‌بندی داده‌های سنجش از دور [۲۴-۲۶]، در مطالعات زلزله برای استخراج ویژگی شکل موج [۲۷، ۲۸]، در اکتشاف مواد معدنی برای

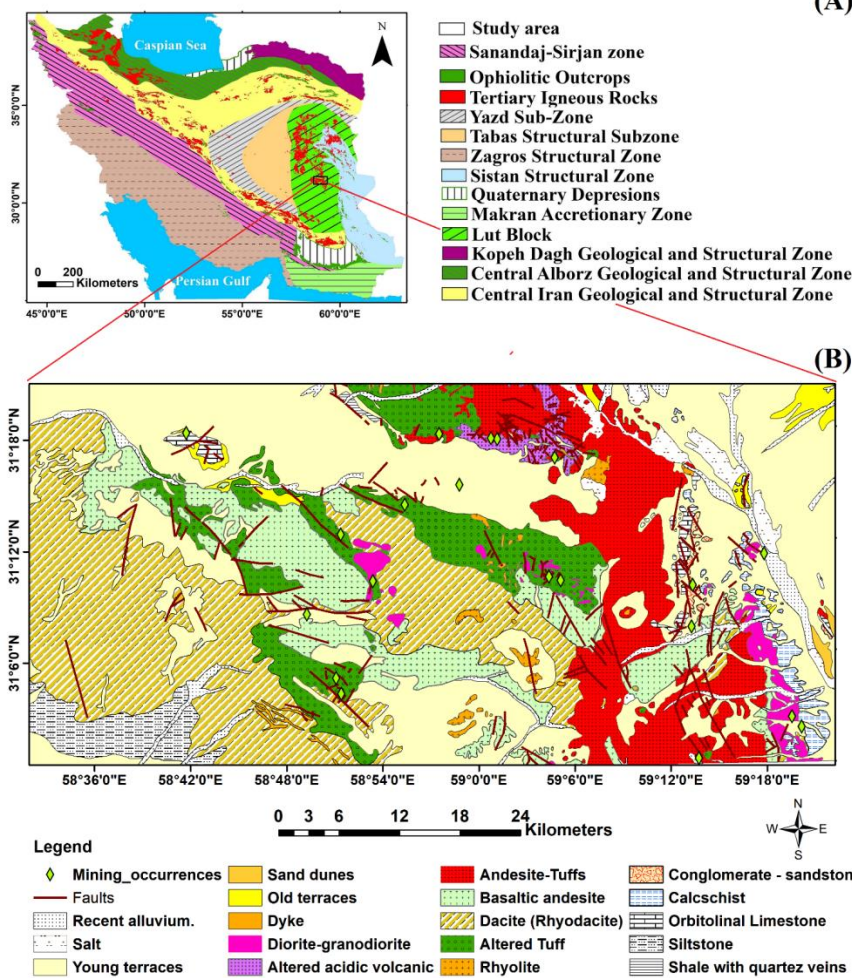
تحلیل داده‌های حجیم و روش‌های یادگیری عمیق، برای مدلسازی پتانسیل معدنی در مناطق بیابانی پوشیده از رسوبات تبخیری دهسلم است.

۲- محدوده مورد مطالعه

محدوده مورد مطالعه به وسعت تقریبی ۲۵۰۰ کیلومتر مربع در حدود ۳۰۰ کیلومتری جنوب- جنوب غربی بیرجند، در شرق ایران و در جنوب غربی نقشه ۱:۲۵۰۰۰۰ دهسلم واقع شده است (شکل ۱).

شناسایی آنومالی‌های ژئوشیمیایی [۶، ۱۱] و مدلسازی پتانسیل معدنی [۷، ۲۹، ۳۰] استفاده شده است.

در این پژوهش، تجزیه و تحلیل داده‌های حجیم با به کارگیری الگوریتم شبکه خودرمننگار عمیق برای یادگیری و کشف الگوهای معنی‌دار موجود در داده‌های اکتشافی، برای شناسایی اهداف معدنی در پهنه اکتشافی دهسلم، استفاده شده است. منطقه اکتشافی دهسلم در شرق ایران و در نیمه جنوبی بلوک لوت واقع شده است. بر اساس مطالعات انجام شده، این منطقه پتانسیل بالایی برای کانی‌سازی مس و طلای پورفیری و اپی‌ترمال وابسته به آن دارد [۳۱-۳۵]. هدف این پژوهش، بررسی اثربخشی تجزیه و



شکل ۱: (A) موقعیت زون‌های ساختاری ایران و (B) نقشه زمین‌شناسی ساده شده منطقه مورد مطالعه در بلوک لوت [۳۶]

سنگی منطقه سنگ‌های رسوبی کرتاسه هستند که در برخی نقاط در مجاورت توده‌های نفوذی دچار دگرگونی همبری شده‌اند. رخنمون اندکی از سنگ آهک اوربیتولین‌دار در شمال غربی و شرق محدوده به رنگ خاکستری و نخودی با لایه‌بندی نازک تا متوسط دیده

شرق ایران به دلیل وقوع موقعیت تکتونوماگمایی خاص که ناشی از فرورانده شدن بلوک افغان به زیر بلوک لوت در دوره ترشیاری بوده است، پتانسیل بالایی برای انواع کانی‌سازی به ویژه ذخایر پورفیری و اپی‌ترمال دارد [۳۱]. بر طبق نقشه زمین‌شناسی دهسلم، قدیمی‌ترین واحدهای


احتمال تشخیص پایینی دارند، با شدت ضعیفی کدگذاری می‌شوند و بنابراین با خطاهای بازسازی بالا در مدل DAN مرتبط هستند [۱۱، ۲۹]. با این حال، با توجه به آنکه کانی‌سازی یک نوع خاص از رویداد تکینگی^{۱۳} است و می‌تواند یک رویداد نادر باشد، مساحت نواحی امیدبخش به مراتب از نواحی فاقد کانی‌سازی کمتر است [۳۸]. بنابراین، خطاهای بازسازی بالا مرتبط با این ویژگی‌های احتمالی تشخیص پایین، می‌تواند برای شناسایی و تفکیک نواحی امیدبخش از نواحی فاقد کانی‌سازی مورد استفاده قرار گیرد. خطاهای بازسازی به صورت رابطه (۱) تعریف می‌شود [۷]:

$$E = \sqrt{\sum_{i=1}^n (O_i - I_i)^2} \quad (1)$$

که n معرف ابعاد داده و O داده بازسازی شده ورودی I است. آموزش شبکه در سه مرحله انجام می‌شود. در مرحله اول یا پیش‌آموزش، هر $CRBM^{14}$ به ترتیب با وزن‌های اولیه آموزش می‌بیند. در مرحله دوم همه $CRBM$ ها باز می‌شوند تا شبکه خودرمزگذار ساخته شود. در نهایت همه شبکه عمیق با پس انتشار (BP^{15}) تنظیم می‌شود تا همه پارامترهای آن همزمان اصلاح شوند [۶]. تابع فعال‌سازی DAN در طول فرآیند آموزش به صورت رابطه (۲) تعریف می‌شود [۲۹]:

$$f(x_i) = \theta_L + (\theta_H + \theta_L) \cdot \frac{1}{1 + \exp(-x_i)} \quad (2)$$

که در آن $f(x_i)$ تابع سیگموئید، و θ_H و θ_L ضرایب ثابت تابع سیگموئید هستند. $CRBM$ ها به طور معمول شبکه‌های عصبی تصادفی هستند^{۱۶} و معمولاً از طریق کمینه کردن واگرایی متضاد (MCD^{17}) آموزش می‌بینند (شکل ۲) [۳۹].



شکل ۲: ساختار نمونه‌گیری و واگرایی متعادل برای محدود کردن آموزش ماشین بولتزمن [۳۹]

با توجه به واحدهای آشکار (v_i)، واحدهای مخفی (h_j) به صورت رابطه (۳) محاسبه می‌شوند:

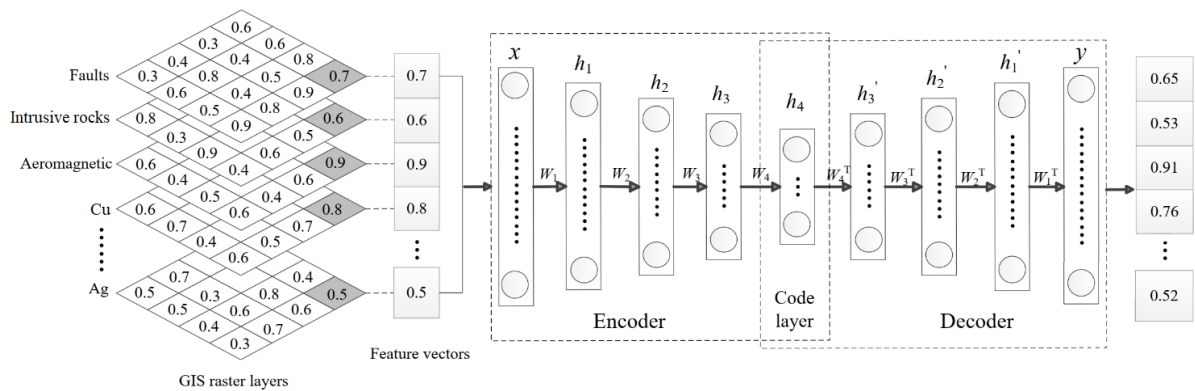
می‌شود. واحد کالک شیست با رخنمون بسیار جزئی در شرق محدوده مشاهده می‌گردد. کنگلومرا و ماسه‌سنگ قرمز کرتاسه نیز در شرق نقشه رخنمون دارد که به شدت گسل خورده است [۳۶].

بخش گسترده‌ای از منطقه مورد مطالعه، پوشیده از سنگ‌های آتشفشانی ائوسن است. گدازه‌های آندزیت بازالتی، آندزیتی و داسیتی-ریوداسیتی و واحد آذرآوری توف بلورین بیشترین گسترش را در محدوده دارند. گدازه‌های آندزیت بازالتی به رنگ سیاه تا خاکستری تیره از شرق تا غرب منطقه گسترش دارند و در برخی نقاط در مجاورت توده‌های نفوذی دچار دگرسانی شدید شده‌اند. مخلوطی از گدازه‌های آندزیتی و توف با روند شمالی-جنوبی در شرق محدوده دهسلم دیده می‌شود که در برخی نقاط دگرسان شده و دارای کانی‌سازی است. گدازه‌های داسیتی-ریوداسیتی به رنگ روشن در مرکز و جنوب غربی نقشه گسترش دارد. گدازه‌های ریولیتی با رخنمون‌های کوچک و پراکنده و سنگ‌های آتشفشانی به شدت دگرسان شده اسیدی در شمال محدوده، دیگر سنگ‌های آتشفشانی ائوسن هستند (شکل ۱). تنها واحدهای نفوذی و نیمه عمیق محدوده، گرانیت، دیوریت-گرانودیوریت و دایک‌های اسیدی ائوسن-الیگوسن هستند که به شکل استوک کوچک و دایک در واحدهای آتشفشانی نفوذ نموده‌اند. رخنمون این واحدها در جنوب، جنوب غربی و شرق نقشه مشاهده می‌شود [۳۶].

۳- شبکه خودرمزنگار عمیق

در این پژوهش، برای مدلسازی پتانسیل معدنی، روش بدون ناظر^۴ شبکه خودرمزنگار عمیق (DAN^5) به کار گرفته شده است. DAN یک مدل زایشی^۶ احتمال‌گرا^۷، متشکل از انباشته‌هایی^۸ از ماشین‌های بولتزمن محدود یا RBM^9 ها است [۳۷]. این شبکه می‌تواند ویژگی‌های سطح بالای ورودی‌های RBM ها را با کمک یک الگوریتم آموزش بدون ناظر لایه مانند تشخیص دهد [۶]. مدل DAN را که در گروه روش‌های یادگیری عمیق قرار دارد، می‌توان برای کدگذاری^{۱۰} و بازسازی^{۱۱} نمونه‌های آماری از یک توزیع احتمال چندمتغیره پیچیده نامعلوم آموزش داد. بر اساس نظر چن (۲۰۱۵) و ژو و جیانگ (۲۰۱۶)، نمونه‌های با احتمال کوچک^{۱۲} (مانند اندیس‌های معدنی) که اغلب

که η_w نرخ آموزش^{۱۸} وزن‌ها است. \hat{v}_i حالت بازسازی یکپارچه^{۱۹} واحدهای آشکار و \hat{h}_j حالت بازسازی یکپارچه واحدهای مخفی است [۴۰]. تمام CRBM‌های آموزش دیده برای ساخت یک DAN ترکیب می‌شوند و الگوریتم BP با تکنیک گرادیان نزولی^{۲۰} به منظور بهینه‌کردن پارامترهای شبکه، برای ارائه خطاهای بازسازی کمینه به کار گرفته می‌شود [۴۰]. اصول مدلسازی پتانسیل معدنی با خطاهای بازسازی شده توسط چن (۲۰۱۵) به تفصیل بیان و روند محاسبه DAN برای مدلسازی در شکل ۳ نشان داده شده است [۲۹].



شکل ۳: فرآیند محاسبه شبکه خودرمننگار عمیق به منظور مدلسازی پتانسیل معدنی [۷]

هستند [۴۳]. دگرسانی‌های مختلفی در کانسارهای پورفیری ایجاد می‌شوند. این دگرسانی‌ها تا چند کیلومتر به سمت بالا و در اطراف گسترش دارند و از نظر مکانی و زمانی دارای زون بندی هستند.

سیر تکاملی یک کانسار پورفیری، ابتدا در هسته سیستم دگرسانی پتاسیک ایجاد می‌شود که هاله دگرسانی پروپلیتیک آن را از اطراف احاطه می‌کند. گسترش سطحی و جانبی هاله‌های دگرسانی پروپلیتیک از هسته دگرسانی پتاسیک بیش از چند کیلومتر است [۴۴]. مجموعه دگرسانی‌های تأخیری شامل فیلک (کوارتز، سربیت، پیریت ± کالکوپیریت)، آرژیلیک متوسط (ایلیت، کلریت، پیریت، کوارتز، کلسیت، هماتیت ± احتمالاً کالکوپیریت)، آرژیلیک (کوارتز، کائولینیت، پروپلیت، دیکیت، پیریت ± انارژیت ± کولیت) هستند. این مجموعه غنی از کانی‌های رسی، اغلب توسط گسل‌ها متمرکز می‌شوند و در قسمت بالای سیستم بر روی دگرسانی‌های پتاسیک و پروپلیتیک که ابتدا شکل گرفته‌اند، دیده می‌شوند [۴۵].

$$h_j = f\left(\sum_i w_{ij} v_i + b_j + \sigma N(1,0)\right) \quad (3)$$

که w_{ij} نشان‌دهنده وزن بین واحدهای آشکار و مخفی و b_j نشان‌دهنده بایاس است. به صورت مشابه، واحدهای آشکار \hat{v}_i به صورت رابطه (۴) تعریف می‌شوند:

$$\hat{v}_i = f\left(\sum_j w_{ij} h_j + b_i + \sigma N(1,0)\right) \quad (4)$$

بنابراین وزن‌های w_{ij} به صورت رابطه (۵) به روزرسانی و بهینه می‌شوند:

$$\Delta w_{ij} = \eta_w \left(\langle v_i h_j \rangle - \langle \hat{v}_i \hat{h}_j \rangle \right) \quad (5)$$

۴- مشخصات سیستم کانی‌سازی مس و طلا و پورفیری

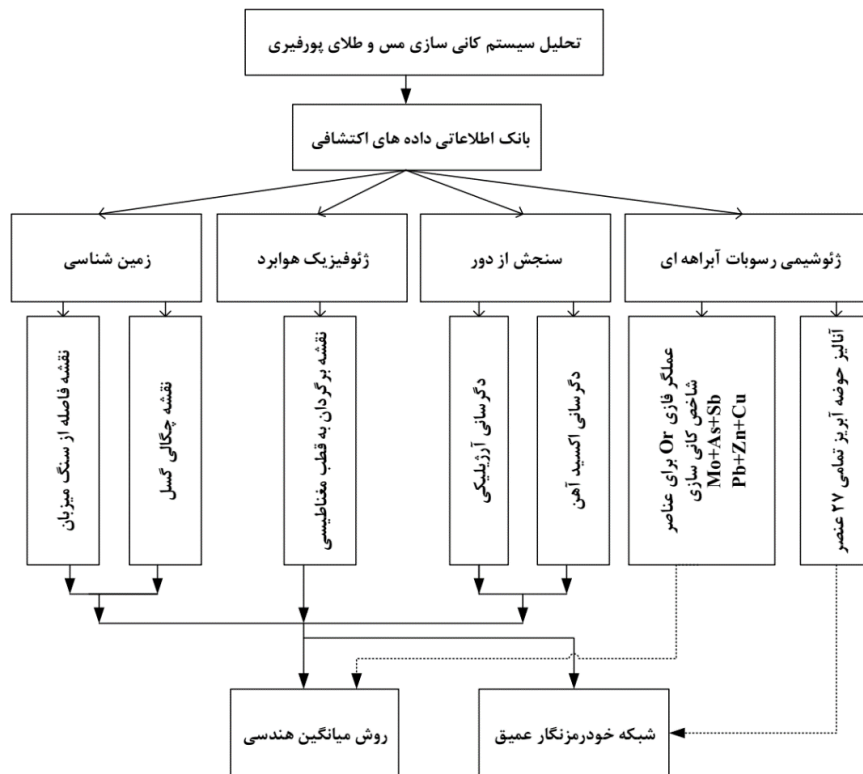
ذخایر پورفیری مهم‌ترین منابع معدنی برای عناصر مس، مولیبدن و همچنین مقدار قابل توجهی از طلا، نقره و دیگر فلزات است. کانی‌زایی در سیستم‌های پورفیری به صورت رگه‌ها و رگچه‌های استوک‌ورک، برش‌های هیدروترمال و جایگزینی در سنگ دیواره و در عمق ۱ تا ۶ کیلومتری از سطح زمین تشکیل می‌شود [۴۱]. کانسارهای مس پورفیری همراه سنگ‌های مونزونیتی، دیوریتی و گرانودیوریتی کالک آلکالن کشف می‌شوند. اصطلاح پورفیری از بافت پورفیری سنگ‌های همراه، بافت استوک‌ورک و پراکنده ذخیره گرفته شده است [۴۲]. این کانسارها در کمربند تکتونیکی زون فرورانش حاشیه قاره‌ها و جزایر قوسی کشف شده‌اند. کانسارهای پورفیری اغلب بر اساس عناصر اقتصادی‌شان طبقه‌بندی می‌شوند و شامل دو زیرمجموعه اصلی مس-طلا و مس-مولیبدن پورفیری

استر) و ژئوفیزیک هوابرد به منظور مدلسازی پتانسیل معدنی استفاده شده است. داده‌های زمین‌شناسی برگرفته از نقشه ۱:۱۰۰۰۰۰ زمین‌شناسی دهسلم و شامل واحدهای ولکانیک نفوذی، گسل‌ها و اندیس‌های شناخته شده مس و طلای پورفیری در منطقه مورد بررسی است (شکل ۱). داده‌های ژئوشیمی، شامل آنالیز ۲۷ عنصری ICP برای ۸۴۳ نمونه رسوبات آبراهه‌ای است که با چگالی یک نمونه به ازای هر ۴ کیلومتر مربع و داده‌های ژئوفیزیک هوابرد شامل مقادیر برگردان به قطب مغناطیسی (RTP^{۲۱})، توسط سازمان زمین‌شناسی ایران برداشت و آنالیز شده است. در شکل ۴، روند مدلسازی پتانسیل مس و طلای پورفیری با استفاده از روش‌های خودرمنگار عمیق و روش پیوسته میانگین هندسی ارائه شده است. متغیرهای زیر به عنوان لایه‌های شاهد ورودی جهت مدلسازی بر اساس مطالعات زمین‌شناسی قبلی و مدل سیستم کانی‌سازی برای تشکیل ذخایر مس و طلای پورفیری انتخاب شده‌اند.

در محیط تشکیل کانسارهای پورفیری اغلب در عمق کمتر از یک کیلومتری سطح زمین در اثر جریان جانبی سیالات اسیدی از طریق افق‌های متخلخل، زون‌های گسترده‌ای از دگرسانی رسی که به عنوان لیتوکپ نامیده می‌شوند، صورت می‌گیرد. لیتوکپ‌ها اغلب غنی از اکسیدهای آهن، دارای هسته‌ای از دگرسانی‌های سیلیسی و آرژیلیک پیشرفته هستند که در اطراف با آرژیلیک پیشرفته، آرژیلیک و پروپلیتیک احاطه می‌شوند [۴۳، ۴۶]. کانی‌زایی‌های اپی‌ترمال سولفیداسیون بالا ممکن است در نواحی کپ سیلیسی در بالای کانسارهای پورفیری رخ دهد. بیشترین تمرکز کانی‌سازی اقتصادی در کانسارهای مس پورفیری در زون پتاسیک و در حاشیه آن و مرز با زون دگرسانی فیلیک است [۴۲، ۴۷، ۴۸].

۵- داده‌های اکتشافی و استنتاج معیارهای اکتشافی

در این پژوهش، از مجموعه داده‌های زمین‌شناسی، ژئوشیمی رسوبات آبراهه‌ای، سنجش از دور (تصاویر سنجد)



شکل ۴: فرآیند مدلسازی پتانسیل مس و طلای پورفیری در محدوده مورد مطالعه

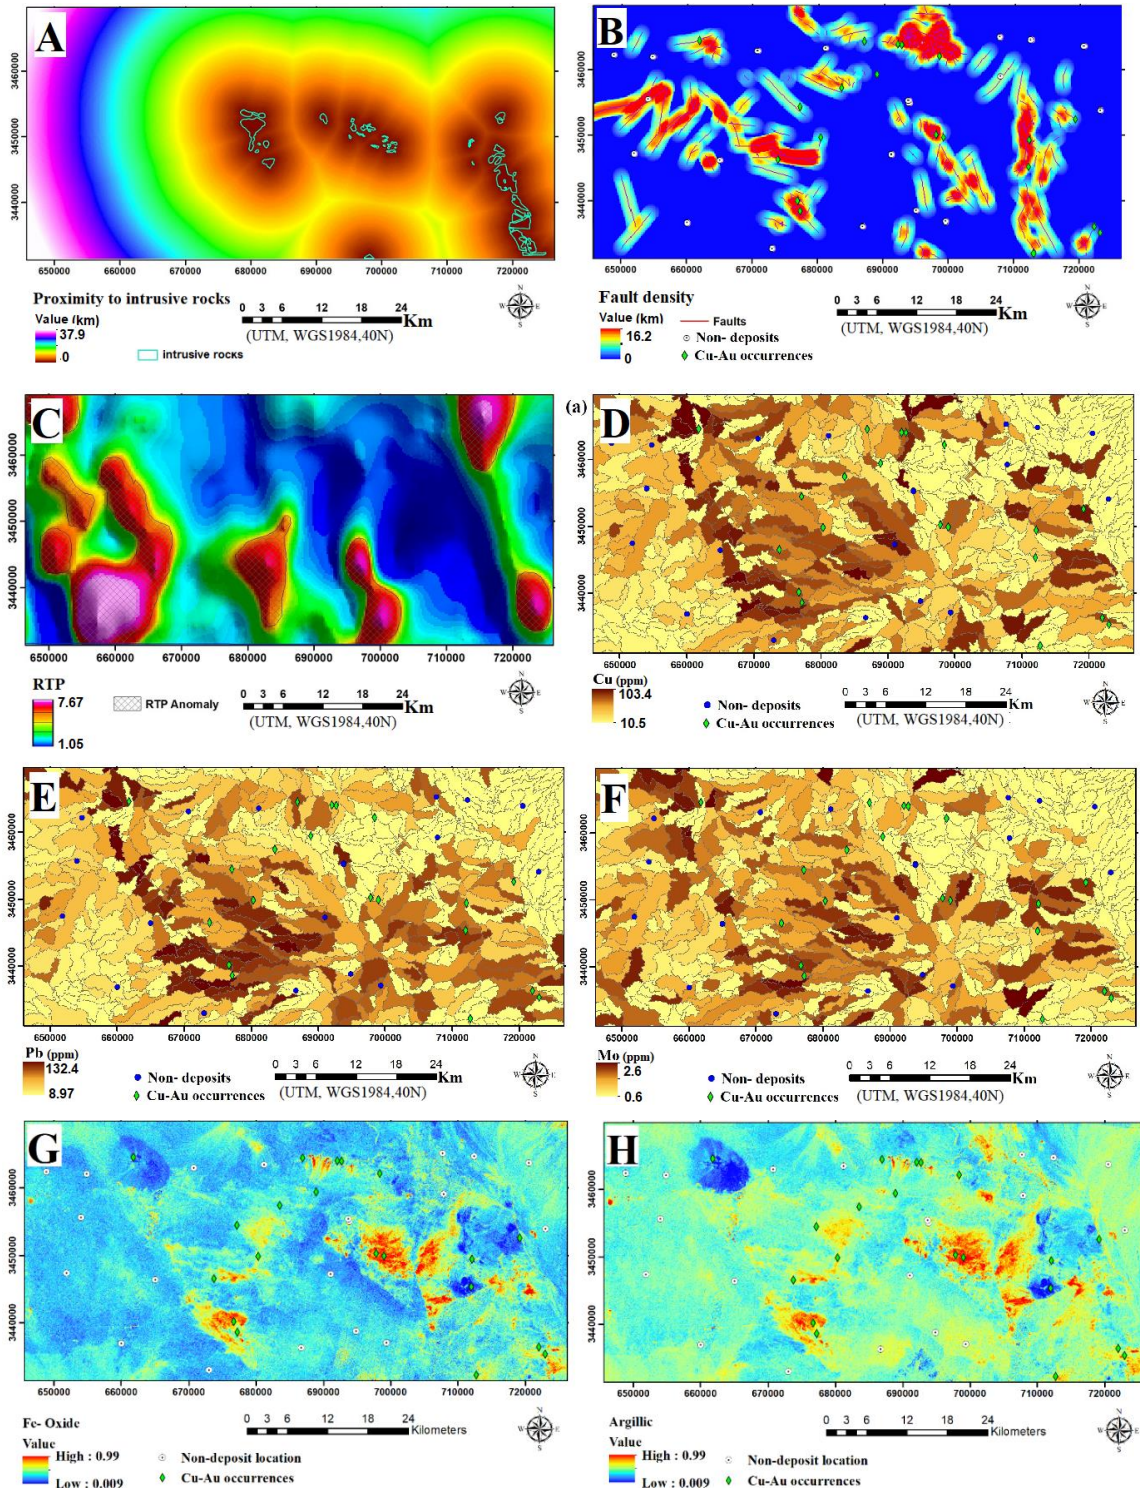
گرانودیوریت و گرانودیوریت با سن ائوسن تا الیگوسن و واحدهای ولکانیک ترشیاری با ترکیب ریولیت، به عنوان منشا اصلی مرتبط با کانی‌سازی پورفیری در منطقه دهسلم

۵-۱- واحدهای ولکانیک و نفوذی اسیدی

بر اساس مطالعات انجام شده واحدهای نفوذی نیمه‌عمیق اسیدی با ترکیب مونزونیت، دیوریت، دیوریت-

این مطالعه نزدیکی به این واحدها به عنوان معیاری مناسب جهت مدلسازی کانی‌سازی پورفیری در نظر گرفته شده است (شکل ۵-۸).

معرفی شده‌اند [۳۲، ۳۴، ۳۵]. واحدهای نفوذی، منشا ایجاد حرارت و سیالات کانه‌دار جهت تشکیل و واحدهای ولکانیک محیطی مناسب برای ته‌نشست و میزبانی ذخایر پورفیری در منطقه مورد مطالعه هستند [۳۱]. بنابراین در



شکل ۵: لایه‌های شاهد اکتشافی جهت مدلسازی پتانسیل مس - طلای پورفیری در منطقه مورد مطالعه، (A) لایه فاصله از واحدهای ولکانیک نفوذی، (B) لایه چگالی گسل‌ها، (C) لایه فاصله از آنومالی برگردان به قطب مغناطیسی، (D) نقشه پراکندگی ژئوشیمیایی حوضه آبریز برای عنصر مس، (E) نقشه پراکندگی ژئوشیمیایی حوضه آبریز برای عنصر سرب، (F) نقشه پراکندگی ژئوشیمیایی حوضه آبریز برای عنصر مولیبدن، (G) آلتراسیون اکسید آهن و (H) آلتراسیون آرژیلیک

۵-۲- گسل‌ها

عناصر مس، سرب و مولیبدن در شکل D-۵ تا F-۵ نشان داده شده است.

۵-۴- آنومالی ژئوفیزیک هوابرد

در سیستم کانی‌سازی مس-طلای پورفیری، زون پتاسیک اولیه بر اثر عملکرد سیالات هیدروترمال، غنی از مگنتیت است [۵۶]. بنابراین داده‌های مغناطیس هوابرد ابزاری مناسب جهت شناسایی زون پتاسیک حاوی کانی‌سازی در سیستم‌های پورفیری هستند [۴۹، ۵۷]. در این پژوهش، از نقشه برگردان به قطب مغناطیسی، به منظور ردیابی کانی‌سازی پورفیری استفاده شده است (شکل ۵-۳). نقشه RTP، ابزاری مناسب برای حذف اثرات گرایش میدان مغناطیسی زمین است. در این تکنیک، با حذف طبیعت دو قطبی انحنای مغناطیسی، آنومالی‌های مغناطیسی به طور مستقیم با اجسام مغناطیسی زیر سطحی همخوانی پیدا می‌کند [۵۸، ۵۹].

۵-۵- دگرسانی‌های گرمایی

استفاده از داده‌های سنجنده‌های چندطیفی و ابرطیفی به منظور شناسایی کانی‌های زون‌های دگرسانی هیدروترمالی، به عنوان ابزاری مناسب برای اکتشاف کانسارهای مس و طلای پورفیری و طلای اپی‌ترمال معرفی شده است [۵۰]. کانسارهای مس پورفیری از فرآیندهای هیدروترمالی به وجود می‌آیند که باعث تغییر ترکیبات شیمیایی و کانی‌شناسی در سنگ‌های میزبان (درب‌گیرنده) می‌شوند. کانی‌های شاخص دگرسانی‌ها دارای ویژگی‌های جذب طیفی مشخصی در محدوده‌های طیفی مختلف هستند [۶۰]. این کانسارها دارای هسته‌ای از جنس کوارتز و کانی‌های پتاسیم‌دار بوده و در اطراف این هسته چندین زون دگرسانی وجود دارد که عموماً دارای کانی‌هایی با عامل هیدروکسیل و کانی‌های رسی هستند. فرآیندهای سوپرژن باعث تولید یک زون اکسیدی بر روی کانسارهای مس پورفیری می‌شود که این زون دارای کانی‌های هیدروکسیل/اکسید آهن (عموماً در سنگ‌های دگرسان شده به رنگ زرد و قرمز دیده می‌شوند) با گستردگی زیاد است که به عنوان زون گوسان شناخته می‌شود [۴۳]. بارزسازی دگرسانی‌ها خصوصاً بررسی و بارزسازی دگرسانی‌های آرژیلیک و اکسید آهن در مقیاس ناحیه‌ای، به منظور اکتشاف کانسارهای مس پورفیری از اهمیت

گسل‌ها و شکستگی‌های با روند شمالی- جنوبی تا شمال‌غربی- جنوب‌شرقی در منطقه دهسلم به عنوان عامل اصلی مسیر انتقال سیال‌های ماگمایی- هیدروترمال موثر در کانی‌سازی پورفیری معرفی شده‌اند [۳۳]. بنابراین در این مطالعه، نقشه چگالی گسل‌های منطقه به عنوان معیاری مطلوب جهت مدلسازی پتانسیل معدنی در نظر گرفته شده است (شکل ۵-۲).

۵-۳- آنومالی‌های ژئوشیمیایی

آنومالی‌های ژئوشیمیایی، مرتبط با نواحی کانی‌سازی و دگرسانی‌های هیدروترمال در کانی‌سازی پورفیری هستند [۴۶]. در این نوع کانی‌سازی فرآیندهای ژئوشیمیایی پیچیده، شامل برهم‌کنش سیال‌های گرمایی با سنگ‌های منشا و میزبان کانی‌سازی، منجر به ایجاد الگوهای ژئوشیمیایی پیچیده‌ای می‌شود [۴۳]. در بسیاری از مطالعات صورت گرفته عناصر مس، طلا، مولیبدن، سرب، آرسنیک، نقره، سرب و آنتیموان به عنوان عناصر شاخص مرتبط با این کانی‌سازی معرفی شده است [۴۱، ۴۹، ۴۹]. با توجه به پیچیدگی روابط حاکم بر الگوهای ژئوشیمیایی در این تیپ کانساری، روابط و روش‌های مختلفی جهت به کارگیری و شدت‌بخشی ژئوشیمیایی برای مدلسازی اکتشافی پیشنهاد شده است [۵۰-۵۲]. بدین منظور داده‌های ژئوشیمیایی، پس از انجام تصحیحات و پیش‌پردازش‌های اولیه شامل جایگزینی مقادیر سنسورد و خارج از ردیف با توجه به خاصیت ترکیبی بودن ذاتی داده‌های بسته ژئوشیمی [۵۳]، توسط روش آنالیز حوضه آبریز [۵۴] برای تمامی ۲۷ عنصر، به نقشه درآمده و در مدلسازی استفاده شده است. بدین منظور برای شدت بخشی به لایه ژئوشیمیایی عناصر شاخص مرتبط با کانی‌سازی مس و طلای پورفیری، مجموعه عناصر مولیبدن، آرسنیک، آنتیموان و سرب، روی، مس پس از تلفیق توسط عملگر فازی "Or" به عنوان لایه شاهد ورودی در مدلسازی به روش میانگین هندسی مورد استفاده قرار گرفته است [۵۱، ۵۵]. در مورد روش خودرمنگار عمیق، نقشه پراکندگی غلظت تمامی ۲۷ عنصر در فرآیند مدلسازی وارد شده است. نقشه پراکندگی

عملگر میانگین هندسی، یک تابع تصمیم‌گیری چندمعیاره است که به منظور تلفیق نقشه‌های شاهد وزن‌دار برای ایجاد مدل پتانسیل معدنی مورد استفاده قرار می‌گیرد (رابطه ۶):

$$G_A(F_1, F_1, \dots, F_n) = \sqrt[n]{\prod_{i=1}^n F_i} \quad (6)$$

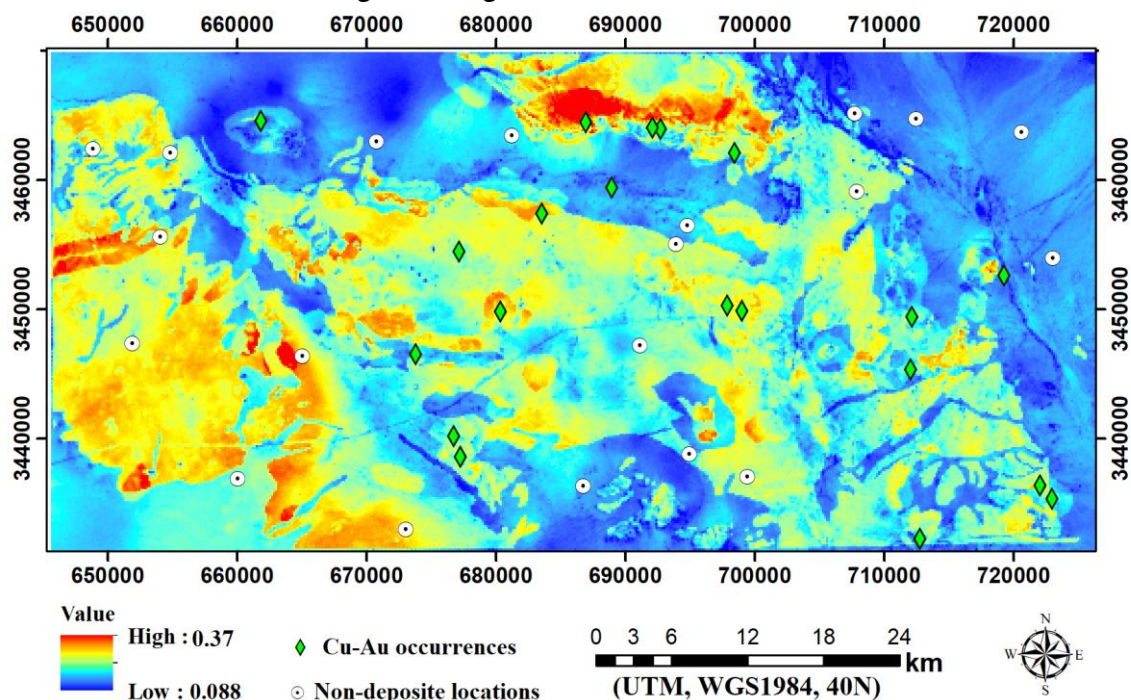
میانگین هندسی به صورت ریشه n ام حاصل‌ضرب مقادیر، تعریف شده که n تعداد مقادیر است. این رابطه برای هر سلول از منطقه مورد مطالعه محاسبه می‌شود که در آن GA میانگین هندسی مجموعه داده‌های اکتشافی، F_i مقدار عددی وزنی نقشه شاهد n ام در سلول مورد نظر و n تعداد نقشه‌های شاهد است [۶۶]. در این پژوهش، میانگین هندسی کانی‌سازی مس و طلا ی پورفیری در هر سلول از منطقه مورد مطالعه با توجه به نقشه‌های شاهد مورد استفاده (شکل ۴)، برای هر پیکسل در منطقه مورد مطالعه، محاسبه شد و این مقادیر به منظور تولید مدل پتانسیل معدنی کانی‌سازی مس و طلا ی پورفیری به نقشه تبدیل شدند (شکل ۶).

ویژه‌های برخوردار است [۶۱، ۶۲]. در این پژوهش، دگرسانی‌های آرژیلیک با به کارگیری روش‌های کمترین زاویه طیفی (SAM^{22}) [۶۰] و اکسید آهن با استفاده از روش نسبت بانندی چهار به دو [۶۳] (۴/۲) بر روی تصاویر سنجنده استر بارزسازی شده است (شکل ۵-G و ۵-H).

۶- نتایج

به منظور مدلسازی پتانسیل معدنی تمامی ۳۰ لایه شاهد ورودی، شامل دو لایه زمین‌شناسی (سنگ میزبان و چگالی گسل‌ها)، یک لایه ژئوفیزیک (نقشه RTP) و ۲۷ متغیر ژئوشیمیایی، پس از رستری شدن با ابعاد 100×100 متر [۶۴]، برای تشخیص آنومالی‌های مربوط به کانی‌سازی با به کارگیری تابع لجیستیکی وزن‌دار شدند [۶۵] و به عنوان لایه‌های ورودی جهت مدلسازی پتانسیل مس و طلا ی پورفیری ترکیب شدند.

۶-۱- مدلسازی به روش میانگین هندسی




شکل ۶: مدل پتانسیل مس و طلا ی پورفیری تولید شده با روش میانگین هندسی پیوسته

ژئوشیمی رسوب آبراهه، لایه‌های فاصله از سنگ میزبان و چگالی گسل، نقشه‌های دگرسانی آرژیلیک و اکسید آهن و نقشه برگردان به قطب مغناطیسی (شکل ۲)، استفاده شد. در این پژوهش، DAN با چهار CRBM انباشته شد و

۶-۲- مدلسازی به روش الگوریتم خودرمنگار عمیق


برای مدلسازی پتانسیل معدنی مس و طلا ی پورفیری از تمامی داده‌های اکتشافی موجود شامل آنالیز ۲۷ عنصر

مقارن DAN، یک شبکه خودرزم نگار ۱۲۸-۶۴-۳۲-۳۲-۱۶-۳۲-۶۴-۳۲-۱۶-۳۲-۶۴-۳۲-۱۶ ساخته شد. میانگین خطای بازسازی در دوره آموزشی 250^{33} به میزان کمینه خود رسیده و پایدار می‌ماند (شکل ۷-B)، در نتیجه برای ایجاد یک مدل پایدار به درستی آموزش دیده، تعداد تکرارها بر روی ۲۵۰ و سایر پارامترهای مدل، بر اساس نظر کارشناس تنظیم شد. مدل پتانسل معدنی تولیدشده توسط روش DAN در شکل ۸ آورده شده است.

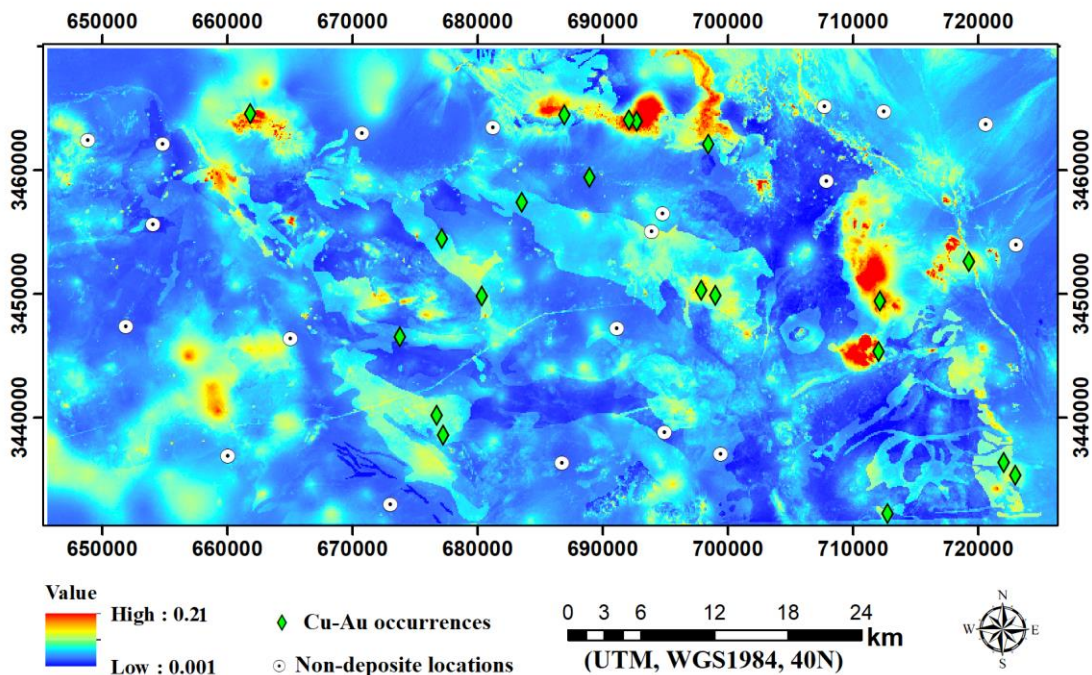


اندازه لایه‌های مختلف، با افزایش شاخص تعداد واحدهای پنهان انجام شد. نتایج تایید می‌کند که خطای بازسازی در تعداد واحد پنهان معادل ۲۰۰ تثبیت و در شبکه خودرزم‌نگار با ساختار ۱۲۸-۶۴-۳۲-۱۶-۳۲-۶۴-۳۲-۱۶-۳۲-۶۴-۳۲-۱۶ به مقدار کمینه رسیده است (شکل ۷-A).

برای مدل‌سازی پتانسیل معدنی، DAN شامل چهار لایه CRBM انباشته شده و واحدهای پنهان مربوطه به لایه‌های مخفی ۱۲۸-۶۴-۳۲-۱۶ است. با توجه به ویژگی



شکل ۷: (A) خطای بازسازی برای کاهش معماری، به عنوان تابعی از تعداد کل واحدهای پنهان، (B) میانگین خطای بازسازی با دوره‌های آموزشی متفاوت



شکل ۸: مدل پتانسل مس و طلا ی پورفیری تولیدشده با روش خودرزم‌نگار عمیق


باشد [۶۷]. بنابراین می‌توان از موقعیت اندیس‌های شناخته شده و همچنین موقعیت‌های فاقد ذخیره در منطقه مورد مطالعه برای ارزیابی مدل‌های پتانسیل معدنی استفاده کرد. در این پژوهش، جهت ارزیابی عملکرد مدل‌های تولید شده

۳-۶- ارزیابی و مقایسه مدل‌های پتانسیل تولید شده


مناطق معرفی شده در خروجی یک مدل پتانسیل معدنی باید بیشترین همبستگی را با اندیس‌های شناخته شده و کمترین ارتباط را با نواحی فاقد کانی‌سازی داشته

نقطه تقاطع منحنی‌ها از یکدیگر بیشتر باشد، نشان دهنده عملکرد بهتر مدل در پیش‌بینی نواحی معدنی و نقاط فاقد ذخیره است [۶۸].

در این پژوهش، از روش فرکتالی عیار- مساحت برای تعیین حد آستانه‌ای جوامع مختلف استفاده شد. با توجه به مدل‌های پتانسیل معدنی طبقه‌بندی شده، تعداد اندیس‌های پیش‌بینی شده در هر کلاس، تعداد نقاط فاقد ذخیره پیش‌بینی شده در هر کلاس و مساحت متناظر کلاس‌ها، نمودارهای آهنگ پیش‌بینی- مساحت رسم شده است (شکل ۹). فاصله دو نقطه تقاطع منحنی‌ها در این نمودار برای مدل‌های تولیدشده به روش خودرمننگار عمیق و میانگین هندسی مقدار 0.27 و 0.29 محاسبه شده است.



از روش نمودار نرخ پیش‌بینی- مساحت بهبود یافته، با استفاده از موقعیت 20 اندیس معدنی و موقعیت 20 نقطه فاقد ذخیره مس و طلای پورفیری در منطقه مورد مطالعه، استفاده شده است [۶۸، ۶۹]. این نمودار سه منحنی دارد که در مقابل کلاس‌های مختلف مدل پتانسیل معدنی رسم می‌شوند. اولین منحنی مربوط به آهنگ پیش‌بینی اندیس‌های شناخته شده متناظر با کلاس‌های مدل پتانسیل معدنی، منحنی دوم مرتبط به آهنگ پیش‌بینی نواحی فاقد کانی‌سازی مرتبط متناظر با کلاس‌های مدل پتانسیل معدنی و منحنی دیگر مساحت تحت پوشش هر کلاس از مدل پتانسیل معدنی نسبت به کل مساحت منطقه مورد مطالعه است. در این نمودار هرچه فاصله دو




شکل ۹: نمودار نرخ پیش‌بینی- مساحت برای مدل‌های پتانسیل تولیدشده به روش: (الف) شبکه خودرمننگار عمیق و (ب) میانگین هندسی


هندسی

دو مدل پتانسیل تولیدشده، به ترتیب در شکل‌های ۱۱ و ۱۲ نشان داده شده است که در آنها اهداف اکتشافی به خوبی قابل تشخیص است. بر این اساس، اهداف اکتشافی جدیدی در قسمت‌های شرق، شمال، غرب و جنوب غربی محدوده اکتشافی با اهمیت تشخیص داده شده است که برای بررسی وجود کانی‌سازی، نیاز به بررسی‌های میدانی زمین‌شناسی است. مشاهده آثاری از کانی‌سازی مس در اهداف شناسایی شده در قسمت شرقی منطقه مورد بررسی (شکل ۱۳)، نشان دهنده کارایی مدل تولید شده توسط روش خودرمننگار عمیق در شناسایی اهداف اکتشافی کانی‌سازی مس و طلای پورفیری در منطقه مورد مطالعه دارد. موقعیت منطقه مورد بررسی، در شکل‌های ۱۱ و ۱۲ با علامت ستاره مشخص شده است.

بر اساس مدل نهایی پتانسیل اکتشافی تولیدشده با به کارگیری الگوریتم DAN (شکل ۸)، نواحی با مقادیر بالای خطای بازسازی نشان دهنده نواحی آنومالی برای کانی‌سازی احتمالی مس و طلای پورفیری در منطقه دهسلم است. بر اساس مقایسه میزان خطای بازسازی مدل شده در نواحی شناخته شده معدنی در منطقه مورد مطالعه (شکل ۱۰)، مقادیر بیش از 0.3 می‌تواند به عنوان نواحی اهداف اکتشافی برای برنامه‌ریزی مطالعات تفصیلی اکتشاف مورد توجه قرار گیرد. این نتیجه مطابق با مرز ناهنجاری شناسایی شده با روش فرکتالی است. بر اساس روش فرکتال عیار- مساحت، مرز جدایش آنومالی برای روش میانگین هندسی 0.242 و برای مدل خودرمننگار عمیق برابر 0.34 محاسبه شده است. نقشه‌های دو کلاسه شده بر اساس مرز آستانه شناسایی شده توسط روش فرکتالی برای



شکل ۱۰: هیستوگرام مقادیر خطای بازسازی مدل شده در محدوده اکتشافی و در نواحی شناخته شده معدنی در منطقه دهسلم

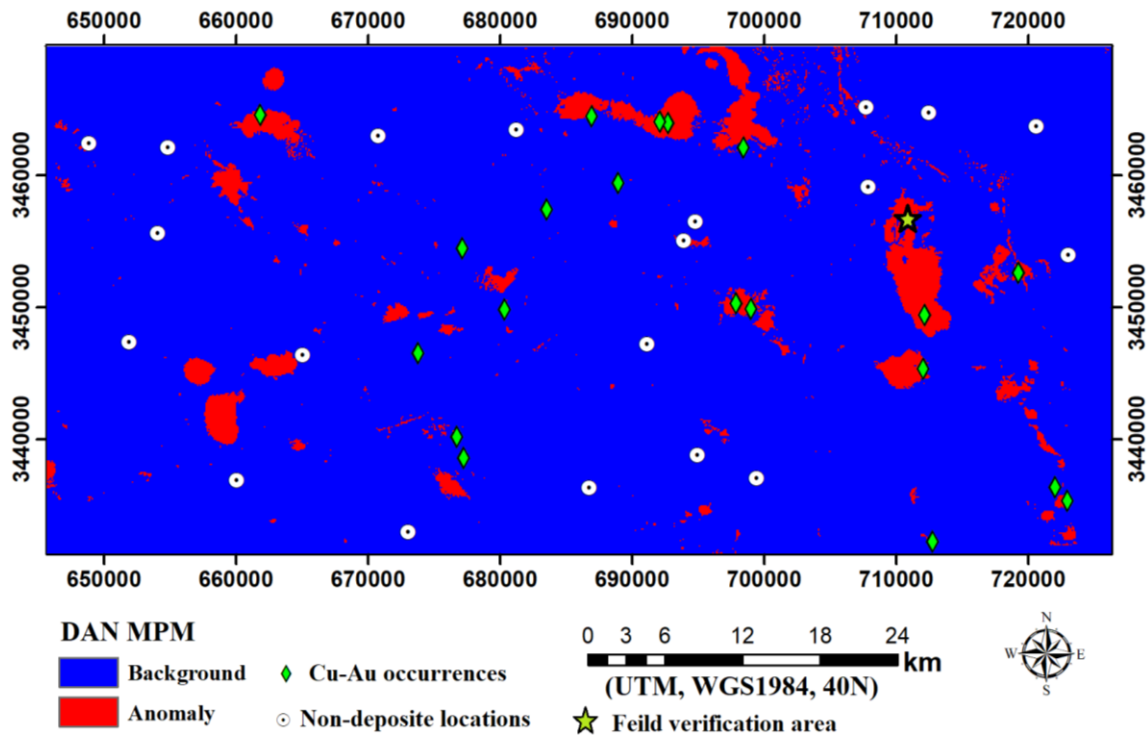


شکل ۱۱: نمایش دو کلاسی اهداف اکتشافی مس طلای پورفیری بر اساس روش فرکتال عبار - مساحت در مدل میانگین هندسی

۷- بحث و نتیجه‌گیری

می‌دهد که پیچیدگی حاکم بر داده‌های ورودی اکتشافی، تنها بر اساس آنالیز ساختار پنهان حاکم بر مجموعه داده‌ها، آشکار شود [۱۳]. این مفهوم حاکم بر روش‌های تحلیلی داده‌های حجیم، می‌تواند در مدل‌سازی اکتشافی برای بررسی و یافتن ارتباط بین شاخصه‌های پیچیده زمین‌شناسی با حضور و یا عدم حضور کانی‌سازی و نیز تلفیق داده‌های با منشاهای متفاوت اکتشافی استفاده شود.

در مدل‌سازی پتانسیل معدنی، مبحث تحلیل داده‌های حجیم می‌تواند به عنوان ابزاری نوین جهت شناسایی اهداف اکتشافی به کار گرفته شود. ایده اصلی به کارگیری این روش‌ها در مدل‌سازی، استفاده از تمامی داده‌های اکتشافی موجود، به جای انتخاب یک زیر مجموعه از داده‌های اکتشافی است. این تکنیک مبتنی بر علم داده است و اجازه



شکل ۱۲: نمایش دو کلاسی اهداف اکتشافی مس طلای یورفیری بر اساس روش فرکتال عیار- مساحت در مدل خودرمنگار عمیق



شکل ۱۳: آثاری از کانی‌سازی مس در نواحی اکتشافی شناسایی شده در قسمت شرقی محدوده مورد مطالعه (موقعیت منطقه مورد بررسی در شکل ۱۱ و ۱۲ با علامت ستاره مشخص شده است)

یا همان k-means است. بنابراین اشکال عمده این شبکه‌ها در جایی که حجم بالایی از داده‌ها مورد پردازش قرار گیرد، وجود بعضی الگوهای پیچیده در خروجی شبکه است که امکان تفسیر نتایج را دشوار می‌کند [۷۴]. از دیگر سو، در روش‌های نظارت شده یادگیری ماشین به دلیل استفاده از اندیس‌های معدنی شناخته شده در مدلسازی پتانسیل معدنی، نتایج حاصل همواره با یک خطای سیستماتیک همراه است [۷۵]. در مقایسه با روش‌های کلاسیک شبکه‌های عصبی، نگاشت‌های SOM و روش‌های نظارت

به طور کلی شبکه‌های عصبی چند لایه کلاسیک، در مرحله یادگیری اولیه به درستی آموزش نمی‌بینند، این امر به دلیل آن است که روش استاندارد گرادبان نزولی^{۲۴} که به صورت تصادفی در مرحله آموزش به کار گرفته می‌شود، در شبکه‌های عصبی چند لایه عملکرد ضعیفی دارد [۷۰-۷۲]. شبکه‌های عصبی نگاشت‌های نقشه‌های خودسازمانده (SOM^{۲۵})، نمونه‌های تحت آموزش را در یک فضای کم بعد و تفکیک شده، نمایش می‌دهد [۷۳]. الگوریتم آموزش در این شبکه‌ها با به کارگیری الگوریتم کمی‌سازی بردار^{۲۶}

مساحت منطقه مورد مطالعه (شکل ۹-ب) و در روش خودرمنگار عمیق ۷۸/۶۱ درصد ذخایر معدنی در ۲۱/۳۹ درصد از مساحت منطقه مورد مطالعه (شکل ۹-الف)، پیش‌بینی شده‌اند. در نمودار نرخ پیش‌بینی-مساحت بهبود یافته برای هر مدل پتانسیل، نرخ پیش‌بینی اندیس‌ها و نرخ پیش‌بینی نقاط فاقد اندیس محاسبه می‌شود و جهت بررسی عملکرد نهایی هر مدل، دو عدد فوق از هم کسر شده تا عملکرد نهایی برای هر مدل محاسبه شود. در پژوهش حاضر، عملکرد محاسبه‌شده برای دو روش میانگین هندسی و شبکه خودرمنگار عمیق به ترتیب برابر ۰/۲۷ و ۰/۲۹ محاسبه‌شده است. با توجه به آنکه اختلاف عملکرد مدل‌ها در حد ۰/۰۲، در سطح معنی‌داری اختلاف نشان نداده است [۶۸، ۶۹]، مؤید آن است که دو مدل عملکرد تقریباً مشابهی در مدلسازی پتانسیل مس و طلای پورفیری داشته‌اند، که یکی از دلایل این امر می‌تواند استفاده از لایه‌های وزن‌دار پیوسته در فرآیند مدلسازی توسط روش خودرمنگار عمیق باشد. توجه به این نکته نیز ضروری هست، که روش میانگین هندسی در مقایسه با روش خودرمنگار به کار گرفته شده در این پژوهش، پیچیدگی محاسباتی کمتری را شامل می‌شود.

روش ترکیبی تجزیه و تحلیل داده‌های حجیم و الگوریتم‌های یادگیری عمیق، یک ابزار جدید و قدرتمند برای شناسایی ناهنجاری‌های زمین‌شناسی و ادغام مجموعه داده‌های چندلایه علوم زمین است. مطالعه موردی مدلسازی اکتشافی برای کانی‌سازی مس و طلای پورفیری، در ناحیه دهسلم، شرق ایران، نشان‌دهنده اثربخشی این روش ترکیبی در مدلسازی پتانسیل معدنی است. با این حال، مطالعات زمین‌شناسی و بررسی مدل‌های کانی‌سازی، جهت شناسایی عوامل موثر در تشکیل و مدلسازی ذخیره مورد جستجو همچنان ضروری است. سوالاتی در مورد نحوه انتخاب داده‌های اکتشافی مربوطه و ترکیب آنها در مجموعه داده‌های موجود برای مدلسازی پتانسیل معدنی با استفاده از روش‌های مبتنی بر تحلیل داده‌های حجیم و الگوریتم‌های یادگیری عمیق، نیاز به بررسی‌های بیشتر در مناطق مختلف اکتشافی با تیپ داده‌های ورودی مختلف دارد.

شده مدلسازی پتانسیل معدنی، روش‌های یادگیری عمیق در مرحله یادگیری، از رویه‌های آموزشی متفاوتی نظیر راهبردهای پیش‌آموزش و تنظیم دقیق بدون نظارت^{۲۷} استفاده می‌کنند. نتیجه این امر، استخراج ویژگی‌های سطح بالا از شاخصه‌های پیچیده ورودی را فراهم کند و آن را به یک ابزار قدرتمند برای تجزیه و تحلیل داده‌های حجیم بدل می‌نماید [۷۰، ۷۶]. این مزایا نشان می‌دهد که روش‌های یادگیری عمیق می‌تواند به طور موثر برای شناسایی ناهنجاری‌ها و الگوهای زمین‌شناسی، معرفی و به کار گرفته شود.

توانایی شناسایی الگوهای فضایی مخفی حاکم بر ساختار پیچیده شاخصه‌های ورودی، که برای روش‌های کلاسیک مدلسازی پتانسیل معدنی با محدودیت همراه است و استفاده از مجموعه داده‌های اکتشافی به منظور کشف ارتباطات بین ویژگی‌های زمین‌شناسی و ذخایر معدنی به جای استفاده از نظر کارشناسی، از مزایای تجزیه و تحلیل داده‌های حجیم و الگوریتم‌های یادگیری عمیق در مدلسازی پتانسیل معدنی است. با این حال، مقیاس و تعداد متغیرهایی که برای مدلسازی پتانسیل معدنی از طریق تجزیه و تحلیل داده‌های حجیم و الگوریتم‌های یادگیری عمیق مورد نیاز است، می‌تواند به مسئله بعد داده، پیچیدگی محاسبات و اضافه کاری جهت پیش‌پردازش داده‌ها منجر شود. علاوه بر این، تفسیر نتایج حاصل از به‌کارگیری این الگوریتم‌ها از دیدگاه زمین‌شناسی، به دلیل عدم شفافیت در نحوه محاسبه الگوریتم شبکه‌های عمیق به خصوص در محاسبات مربوط به لایه‌های پنهان، با محدودیت‌هایی همراه است. این امر ممکن است سبب عدم اعتماد زمین‌شناسان و مهندسان اکتشاف نسبت به خروجی مدل‌های تولیدشده گردد. بنابراین تلاش‌های قابل‌توجهی برای ایجاد یک مدل یادگیری عمیق با ساختار قابل دسترس و شفاف، برای پر کردن شکاف ارتباط بین زمین‌شناسان و داده‌پردازان، نیاز است.

در این پژوهش، نتایج حاصل از مدلسازی پتانسیل مس و طلای پورفیری با به‌کارگیری روش یادگیری خودرمنگار عمیق و میانگین هندسی، توسط نمودار نرخ پیش‌بینی-مساحت بهبودیافته، ارزیابی شد. بر این اساس، مدل پتانسیل معدنی تولید شده با استفاده از روش میانگین هندسی، ۷۲/۱۵ درصد ذخایر معدنی در ۲۷/۸۵ درصد از

۸- سپاسگزاری

نویسندگان از سازمان زمین‌شناسی ایران جهت در اختیار گذاشتن داده‌های اکتشافی قدردانی می‌نمایند. از سازمان صنعت، معدن و تجارت استان خراسان جنوبی و شرکت‌های اکتشافی مهندسی چکاد کاوش و پویندگان سامان شرق، جهت فراهم آوردن امکانات بازدید بررسی‌های صحرایی تشکر می‌گردد.

مراجع

- [9] M. Deng and L. Di, 2009, "Building an online learning and research environment to enhance use of geospatial data," ...*Journal Spat. Data Infrastructures Res.*, doi: 10.2902/1725-0463.2009.04.art4.
- [10] A. Gore, 1998, "The Digital Earth: Understanding our planet in the 21st Century," Open GIS Consortium.
- [11] R. Zuo and Y. Xiong, 2018, "Big Data Analytics of Identifying Geochemical Anomalies Supported by Machine Learning Methods," *Nat. Resour. Res.*, doi: 10.1007/s11053-017-9357-0.
- [12] C. Wang, X. Ma, J. Chen, and J. Chen, 2018, "Information extraction and knowledge graph construction from geoscience literature," *Comput. Geosci.*, doi: 10.1016/j.cageo.2017.12.007.
- [13] V. Mayer-Schönberger and K. Cukier, 2013, *Big Data: A Revolution That Will Transform How We Live, Work, and Think*.
- [14] X.-X. Liu, Y.-C. Chen, D.-H. Wang, F. Huang, and Z. Zhao, 2016, "The metallogenic geomorphic condition analysis of the ion-absorbing type rare earths ore in the Eastern Nanling region based on DEM data," *Acta Geosci. Sin.*, doi: 10.3975/cagsb.2016.02.05.
- [15] J. M. Luo et al., 2017, "Application of integrated geophysical and geochemical data processing to metallogenic target zone quantitative prediction and optimization," *Bull. Mineral. Petrol. Geochemistry*, vol. 36, no. 6, pp. 886–891.
- [16] M. Chen, S. Mao, and Y. Liu, 2014, "Big data: A survey," in *Mobile Networks and Applications*, doi: 10.1007/s11036-013-0489-0.
- [17] A. Porwal, E. J. M. Carranza, and M. Hale, 2003, "Artificial neural networks for mineral-potential mapping: a case study from Aravalli Province, Western India," *Nat. Resour. Res.*, vol. 12, no. 3, pp. 155–171.
- [18] D. Harris and G. Pan, 1999, "Mineral favorability mapping: a comparison of artificial neural networks, logistic regression, and discriminant analysis," *Nat. Resour. Res.*, vol. 8, no. 2, pp. 93–109.
- [19] H.-J. Oh and S. Lee, 2010, "Application of artificial neural network for gold-silver deposits potential mapping: a case study of Korea," *Nat. Resour. Res.*, vol. 19, no. 2, pp. 103–124.
- [20] M. Abedi, G.-H. Norouzi, and A. Bahroudi, 2012, "Support vector machine for multi-classification of mineral prospectivity areas," *Comput. Geosci.*, vol. 46, pp. 272–283.
- [1] G. F. Bonham-Carter, 1994, "Geographic information systems for geoscientists-modeling with GIS," *Comput. methods Geosci.*, vol. 13, p. 398.
- [2] V. F. Rodriguez-Galiano, M. Chica-Olmo, and M. Chica-Rivas, 2014, "Predictive modelling of gold potential with the integration of multisource information based on random forest: a case study on the Rodalquilar area, Southern Spain," *Int. J. Geogr. Inf. Sci.*, vol. 28, no. 7, pp. 1336–1354.
- [3] E. J. M. Carranza and A. G. Laborte, 2015, "Random forest predictive modeling of mineral prospectivity with small number of prospects and data with missing values in Abra (Philippines)," *Comput. Geosci.*, vol. 74, pp. 60–70.
- [4] Y. Gao, Z. Zhang, Y. Xiong, and R. Zuo, 2016, "Mapping mineral prospectivity for Cu polymetallic mineralization in southwest Fujian Province, China," *Ore Geol. Rev.*, vol. 75, pp. 16–28.
- [5] H. Hu, Y. Wen, T. S. Chua, and X. Li, 2014, "Toward scalable systems for big data analytics: A technology tutorial," *IEEE Access*, doi: 10.1109/ACCESS.2014.2332453.
- [6] H. Moeini and F. M. Torab, 2017, "Comparing compositional multivariate outliers with autoencoder networks in anomaly detection at Hamich exploration area, east of Iran," *J. Geochemical Explor.*, doi: 10.1016/j.gexplo.2017.05.008.
- [7] Y. Xiong, R. Zuo, and E. J. M. Carranza, 2018, "Mapping mineral prospectivity through big data analytics and a deep learning algorithm," *Ore Geol. Rev.*, doi: 10.1016/j.oregeorev.2018.10.006.
- [8] M. F. Goodchild, 2008, "The use cases of digital earth," *Int. J. Digit. Earth*, doi: 10.1080/17538940701782528.

- [33] R. M. Beydokhti, M. H. Karimpour, and S. A. Mazaheri, 2014, "Studies of remote sensing, geology, alteration, mineralization and geochemistry of Balazard copper-gold prospecting area, west of Nehbandan," *Iran. J. Crystallogr. Mineral.*, vol. 23, no. 3, pp. 459–470.
- [34] R. M. Beydokhti, M. H. Karimpour, S. A. Mazaheri, J. F. Santos, and U. Klötzli, 2015, "U–Pb zircon geochronology, Sr–Nd geochemistry, petrogenesis and tectonic setting of Mahoor granitoid rocks (Lut Block, Eastern Iran)," *J. Asian Earth Sci.*, vol. 111, pp. 192–205.
- [35] A. M. Shafaroudi, M. H. Karimpour, and C. R. Stern, 2015, "The Khopik porphyry copper prospect, Lut Block, Eastern Iran: geology, alteration and mineralization, fluid inclusion, and oxygen isotope studies," *Ore Geol. Rev.*, vol. 65, pp. 522–544.
- [36] M. A. Akrami and N. Naderi Mighan, 2005, Geological map of Dehsalm(1:100,000). Geological Survey of Iran.
- [37] G. E. Hinton, S. Osindero, and Y.-W. Teh, 2006, "A fast learning algorithm for deep belief nets," *Neural Comput.*, vol. 18, no. 7, pp. 1527–1554.
- [38] Y. Xiong and R. Zuo, 2018, "GIS-based rare events logistic regression for mineral prospectivity mapping," *Comput. Geosci.*, doi: 10.1016/j.cageo.2017.10.005.
- [39] G. E. Hinton, 2002, "Training products of experts by minimizing contrastive divergence," *Neural Comput.*, doi: 10.1162/089976602760128018.
- [40] G. Hinton, 2010, "A Practical Guide to Training Restricted Boltzmann Machines A Practical Guide to Training Restricted Boltzmann Machines," *Computer (Long. Beach. Calif.)*, doi: 10.1007/978-3-642-35289-8_32.
- [41] E. J. M. Carranza and M. Hale, 2002, "Where are porphyry copper deposits spatially localized? A case study in Benguet province, Philippines," *Nat. Resour. Res.*, vol. 11, no. 1, pp. 45–59.
- [42] A. C. Philip, 2005, "Magmatic processes in the development of porphyry-type ore systems," *Econ. Geol.*, vol. 100, pp. 25–38.
- [43] R. H. Sillitoe, 2010, "Porphyry copper systems," *Econ. Geol.*, vol. 105, no. 1, pp. 3–41.
- [44] B. R. Berger, R. A. Ayuso, J. C. Wynn, and R. R. Seal, 2008, "Preliminary model of porphyry copper deposits," *US Geol. Surv. open-file Rep.*, vol. 1321, p. 55.
- [21] M. Shabankareh and A. Hezarkhani, 2017, "Application of support vector machines for copper potential mapping in Kerman region, Iran," *J. African Earth Sci.*, vol. 128, pp. 116–126.
- [22] S. Hariharan, S. Tirodkar, A. Porwal, A. Bhattacharya, and A. Joly, 2017, "Random forest-based prospectivity modelling of greenfield terrains using sparse deposit data: An example from the Tanami Region, Western Australia," *Nat. Resour. Res.*, vol. 26, no. 4, pp. 489–507.
- [23] G. LeCun, Y. Bengio, Y. Hinton, 2015, "Deep learning. nature 521 (7553): 436," *Nat.* 521 (7553), 436–444., doi: 10.1038/nature14539.
- [24] Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, 2014, "Deep learning-based classification of hyperspectral data," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, doi: 10.1109/JSTARS.2014.2329330.
- [25] L. Zhang, L. Zhang, and B. Du, 2016, "Deep learning for remote sensing data: A technical tutorial on the state of the art," *IEEE Geosci. Remote Sens. Mag.*, doi: 10.1109/MGRS.2016.2540798.
- [26] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, 2017, "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," *IEEE Geosci. Remote Sens. Lett.*, doi: 10.1109/LGRS.2017.2681128.
- [27] A. P. Valentine and J. Trampert, 2012, "Data space reduction, quality assessment and searching of seismograms: Autoencoder networks for waveform data," *Geophys. J. Int.*, doi: 10.1111/j.1365-246X.2012.05429.x.
- [28] Z. E. Ross, M. A. Meier, and E. Hauksson, 2018, "P Wave Arrival Picking and First-Motion Polarity Determination With Deep Learning," *J. Geophys. Res. Solid Earth*, doi: 10.1029/2017JB015251.
- [29] Y. Chen, 2015, "Mineral potential mapping with a restricted Boltzmann machine," *Ore Geol. Rev.*, vol. 71, pp. 749–760.
- [30] Y. Chen and W. Wu, 2018, "Isolation Forest as an Alternative Data-Driven Mineral Prospectivity Mapping Method with a Higher Data-Processing Efficiency," *Nat. Resour. Res.*, pp. 1–16.
- [31] M. Karimpour and others, 2011, "Review of age, Rb–Sr geochemistry and petrogenesis of Jurassic to Quaternary igneous rocks in Lut Block, Eastern Iran," *Geopersia*, vol. 1, no. 1, pp. 19–54.
- [32] A. M. Shafaroudi and M. H. Karimpour, 2013, "Hydrothermal alteration mapping in northern Khur, Iran, using ASTER image processing: a new insight to the type of copper mineralization," *Acta Geol. Sin. Ed.*, vol. 87, no. 3, pp. 830–842.

- [57] H. H. Asadi, A. Porwal, M. Fatehi, S. Kianpouryan, and Y.-J. Lu, 2015, "Exploration feature selection applied to hybrid data integration modeling: Targeting copper-gold potential in central Iran," *Ore Geol. Rev.*, vol. 71, pp. 819–838,.
- [58] A. H. Ansari and K. Alamdar, 2009, "Reduction to the pole of magnetic anomalies using analytic signal," *World Appl. Sci. J.*, vol. 7, no. 4, pp. 405–409,.
- [59] A. R. Bansal, G. Gabriel, V. P. Dimri, and C. M. Krawczyk, 2011, "Estimation of depth to the bottom of magnetic sources by a modified centroid method for fractal distribution of sources: An application to aeromagnetic data in Germany," *Geophysics*, vol. 76, no. 3, pp. L11–L22,.
- [60] M. H. Zadeh, M. H. Tangestani, F. V. Roldan, and I. Yusta, 2014, "Sub-pixel mineral mapping of a porphyry copper belt using EO-1 Hyperion data," *Adv. Sp. Res.*, vol. 53, no. 3, pp. 440–451,.
- [61] M. Yousefi and E. J. M. Carranza, 2017, "Union score and fuzzy logic mineral prospectivity mapping using discretized and continuous spatial evidence values," *J. African Earth Sci.*, vol. 128, pp. 47–60,.
- [62] H. Ranjbar, F. Masoumi, and E. J. M. Carranza, 2011, "Evaluation of geophysics and spaceborne multispectral data for alteration mapping in the Sar Cheshmeh mining area, Iran," *Int. J. Remote Sens.*, doi: 10.1080/01431161003745665.
- [63] J. R. Gozzard, 2006, Image processing of ASTER multispectral data. Geological Survey of WA,.
- [64] T. Hengl, 2006, "Finding the right pixel size," *Comput. Geosci.*, vol. 32, no. 9, pp. 1283–1298,.
- [65] M. Yousefi and E. J. M. Carranza, 2015, "Fuzzification of continuous-value spatial evidence for mineral prospectivity mapping," *Comput. Geosci.*, vol. 74, pp. 97–109,.
- [66] M. Yousefi and E. J. M. Carranza, 2015, "Geometric average of spatial evidence data layers: A GIS-based multi-criteria decision-making approach to mineral prospectivity mapping," *Comput. Geosci.*, doi: 10.1016/j.cageo.2015.07.006.
- [67] A. Porwal, E. J. M. Carranza, and M. Hale, 2006, "Bayesian network classifiers for mineral potential mapping," *Comput. Geosci.*, vol. 32, no. 1, pp. 1–16,.
- [68] B. Roshanravan, H. Aghajani, M. Yousefi, and O. Kreuzer, 2019, "An Improved Prediction-Area Plot for Prospectivity Analysis of Mineral Deposits," *Nat. Resour. Res.*, doi: 10.1007/s11053-018-9439-7.
- [45] D. R. Cooke, P. Hollings, and J. L. Walshe, 2005, "Giant porphyry deposits: characteristics, distribution, and tectonic controls," *Econ. Geol.*, vol. 100, no. 5, pp. 801–818,.
- [46] R. H. Sillitoe, 1972, "A plate tectonic model for the origin of porphyry copper deposits," *Econ. Geol.*, vol. 67, no. 2, pp. 184–197,.
- [47] R. H. Sillitoe, 2000, "Gold-rich porphyry deposits: descriptive and genetic models and their role in exploration and discovery," *Rev. Econ. Geol.*, vol. 13, pp. 315–345,.
- [48] E.-J. Holden, S. C. Fu, P. Kovesi, M. Dentith, B. Bourne, and M. Hope, 2011, "Automatic identification of responses from porphyry intrusive systems within magnetic data using image analysis," *J. Appl. Geophys.*, vol. 74, no. 4, pp. 255–262,.
- [49] Z. Hou, H. Zhang, X. Pan, and Z. Yang, 2011, "Porphyry Cu (–Mo–Au) deposits related to melting of thickened mafic lower crust: examples from the eastern Tethyan metallogenic domain," *Ore Geol. Rev.*, vol. 39, no. 1–2, pp. 21–45,.
- [50] M. Parsa, A. Maghsoudi, M. Yousefi, and M. Sadeghi, 2016, "Prospectivity modeling of porphyry-Cu deposits by identification and integration of efficient mono-elemental geochemical signatures," *J. African Earth Sci.*, vol. 114, pp. 228–241,.
- [51] B. Roshanravan, H. Aghajani, M. Yousefi, and O. Kreuzer, 2019, "Particle Swarm Optimization Algorithm for Neuro-Fuzzy Prospectivity Analysis Using Continuously Weighted Spatial Exploration Data," *Nat. Resour. Res.*, pp. 1–17,.
- [52] M. Yousefi and E. J. M. Carranza, 2016, "Data-driven index overlay and Boolean logic mineral prospectivity modeling in greenfields exploration," *Nat. Resour. Res.*, vol. 25, no. 1, pp. 3–18,.
- [53] V. Pawlowsky-Glahn and A. Buccianti, 2011, Compositional data analysis: Theory and applications. John Wiley & Sons,.
- [54] E. J. M. Carranza, 2008, Geochemical anomaly and mineral prospectivity mapping in GIS, vol. 11. Elsevier,.
- [55] M. Yousefi, A. Kamkar-Rouhani, and E. J. M. Carranza, 2012, "Geochemical mineralization probability index (GMPI): a new approach to generate enhanced stream sediment geochemical evidential map for increasing probability of success in mineral potential mapping," *J. Geochemical Explor.*, vol. 115, pp. 24–35,.
- [56] D. A. Clark, 2014, "Magnetic effects of hydrothermal alteration in porphyry copper and iron-oxide copper-gold systems: a review," *Tectonophysics*, vol. 624, pp. 46–65,.

[69] M. Yousefi and E. J. M. Carranza, 2015, "Prediction-area (P-A) plot and C-A fractal analysis to classify and evaluate evidential maps for mineral prospectivity modeling," *Comput. Geosci.*, vol. 79, pp. 69–81,.

[70] X. Glorot and Y. Bengio, 2010, "Understanding the difficulty of training deep feedforward neural networks," in *Proceedings of the 13th International Conference On Artificial Intelligence and Statistics*,.

[71] H. Larochelle, Y. Bengio, J. Louradour, and P. Lamblin, 2009, "Exploring Strategies for Training Deep Neural Networks," *J. Mach. Learn. Res.*,.

[72] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, 1986, "Learning representations by back-propagating errors," *Nature*, doi: 10.1038/323533a0.

[73] L. Li and Y. Wang, 2014, "What drives the aerosol distribution in Guangdong - The most developed province in Southern China?," *Sci. Rep.*, doi: 10.1038/srep05972.

[74] J. Vesanto, 1999, "SOM-based data visualization methods," *Intell. Data Anal.*, doi: 10.3233/IDA-1999-3203.

[75] A. Joly, A. Porwal, and T. C. McCuaig, 2012, "Exploration targeting for orogenic gold deposits in the Granites-Tanami Orogen: Mineral system analysis, targeting model and prospectivity analysis," *Ore Geol. Rev.*, doi: 10.1016/j.oregeorev.2012.05.004.

[76] M. M. Najafabadi, F. Villanustre, T. M. Khoshgoftaar, N. Seliya, R. Wald, and E. Muharemagic, 2015, "Deep learning applications and challenges in big data analytics," *J. Big Data*, doi: 10.1186/s40537-014-0007-7.

¹ Mineral potential Mapping

² Big data

³ Digital elevation model

⁴ Unsupervised

⁵ Deep auto-encoder network

⁶ Generative

⁷ Probabilistic

⁸ Stacks

⁹ Restricted Boltzmann machines

¹⁰ Encode

¹¹ Reconstruct

¹² Small sample sizes

¹³ Singularity

¹⁴ Continuous Restricted Boltzmann machines

¹⁵ Back-propagation

¹⁶ Stochastic neural networks

¹⁷ Minimizing contrastive divergence

¹⁸ Learning rate

¹⁹ One-step reconstructed states

²⁰ Gradient descent technique

²¹ Reduction to pole

²² Spectral Angel Mapper

²³ Epochs

²⁴ Standard gradient decent

²⁵ Self-Organizing Maps

²⁶ Vector Quantization

²⁷ Unsupervised pre-training and fine-tuning