

## شناسایی نواحی امیدبخش کانی‌سازی مس پورفیری در ناحیه چهارگنبد استان کرمان با استفاده از روش هوشمند یادگیری سریع

مریم قدیانلو<sup>۱</sup>، اندیشه علیمرادی<sup>۲</sup>، مهیار یوسفی<sup>۳\*</sup>

۱- دانشجوی کارشناسی ارشد، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین  
۲- استادیار، گروه مهندسی معدن، دانشکده فنی و مهندسی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین  
۳- دانشیار، گروه مهندسی معدن، دانشگاه ملایر، ملایر

(دریافت ۱۳۹۹/۰۶/۱۴، پذیرش ۱۳۹۹/۰۹/۱۲)

### چکیده

در مدلسازی پتانسیل‌های معدنی و شناسایی اهداف اکتشافی با استفاده از روش‌های هوش مصنوعی، نحوه استفاده از نمونه‌های آموزشی و انتخاب الگوریتم مناسب یک مساله مهم است، زیرا عدم استفاده از الگوریتم آموزش مناسب موجب بروز خطاهای سیستماتیک در مدل خروجی می‌شود. هدف از مطالعه حاضر، تهیه نقشه پتانسیل معدنی کانی‌سازی مس پورفیری در منطقه چهارگنبد استان کرمان با استفاده از شبکه عصبی مصنوعی است. در این راستا نقشه‌های شاهد وزن‌دار پیوسته برای معیارهای توده نفوذی، گسل، ژئوشیمی و آلتراسیون‌ها تولید و به عنوان ورودی شبکه عصبی انتخاب شدند. برای آموزش شبکه از ۱۶ نقطه شناخته شده دارای ذخیره و ۱۶ نقطه فاقد کانی‌سازی و همچنین از الگوریتم ماشین یادگیری سریع استفاده شد. در نهایت مدل پتانسیل معدنی تولید شده با استفاده از شبکه عصبی مصنوعی با نتایج مدلسازی با روش تلفیق میانگین هندسی، با استفاده از نمودار نرخ پیش‌بینی مساحت بهبودیافته، مورد مقایسه قرار گرفت و برای مدل‌های یاد شده، به ترتیب نرخ پیش‌بینی ۰/۳۴ و ۰/۲۷ به دست آمد. ارزیابی مدل‌ها اثبات کرد که اهداف شناسایی شده و مناطق دارای پتانسیل بالای کانی‌سازی مس، انطباق خوبی با اندیس‌ها و کانسارهای مس شناخته شده و همچنین با سایر شواهد اکتشافی دارند، بنابراین می‌توانند برای طراحی ادامه عملیات اکتشاف مورد توجه قرار گیرند.

### کلمات کلیدی

مدل مفهومی، وزن‌دهی پیوسته، تابع لجستیکی، چهارگنبد، شبکه عصبی مصنوعی.

## ۱- مقدمه

امروزه با گسترش شبکه‌های عصبی و پیشرفت موضوعات مربوط به آن، همواره تلاش شده است در زمینه‌های متنوع علمی مناسب‌ترین نوع شبکه عصبی برای حل مسایل به کار گرفته شود. در اکتشاف مواد معدنی نیز از روش شبکه عصبی مصنوعی استفاده شده و نتایج مطلوبی در جهت افزایش دقت و کاهش عدم قطعیت حاصل شده است [۲۰-۱۶]. در اکثر شبکه‌های عصبی، انتخاب تعداد لایه‌ها و تابع فعال‌سازی و همچنین کاهش زمان پردازش، از موارد چالش‌انگیز محسوب می‌شوند [۲۱]. بنابراین انتخاب شبکه‌های با قابلیت سرعت پردازش بالا و توابع فعال‌سازی متنوع و نیز تعداد لایه‌های کم یا تک لایه اهمیت پیدا می‌کند.

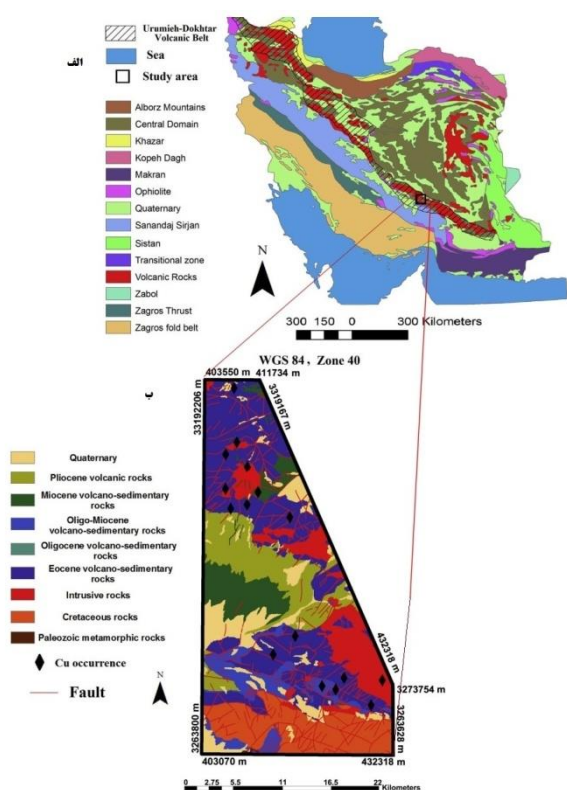
در سال ۲۰۰۶ ماشین یادگیری سریع (ELM) برای برطرف کردن نواقص پیشین توسعه داده شد و مشخص گردید که کارایی قابل توجهی نسبت به الگوریتم‌های دیگر دارد. به عنوان مثال هانگ و همکاران از سه الگوریتم SVM<sup>۳</sup>، BP<sup>۲</sup> و ELM در پردازش تصاویر ماهواره‌ای برای بررسی گیاهان و بیماری دیابت استفاده کردند و طبق نتایج به دست آمده اثبات گردید که الگوریتم ELM کارایی قابل توجهی نسبت به الگوریتم‌های دیگر دارد [۲۲]. ژینگ‌لو و همکاران جهت بررسی حوادث احتمالی معدن زغال‌سنگ در جریان تولید ماده معدنی، سه الگوریتم TMELM<sup>۴</sup>، OSELM<sup>۵</sup> و ELM را به کار گرفتند. نتایج حاصل، برتری الگوریتم ELM را نسبت به دو الگوریتم دیگر اثبات کرد [۲۳]. ژینجینگ‌وانگ و همکاران، داده‌های یک معدن زغال‌سنگ واقع در غرب چین را برای بررسی و تعیین مدل ضخامت کانسار، با استفاده از تحلیل مولفه اساسی (PCA)<sup>۶</sup> و الگوریتم ELM مورد بررسی قرار داده و مشاهده کردند که دقت الگوریتم ELM در تعمیم و آموزش بالا است [۲۴]. در این راستا هدف از مقاله حاضر ارزیابی کارایی الگوریتم آموزش ELM در مدلسازی پتانسیل معدنی و تلفیق داده‌ها و تعیین نواحی امیدبخش اکتشافی با استفاده از شبکه عصبی مصنوعی و مقایسه آن با روش تلفیق میانگین هندسی است. برای تشریح و ارزیابی بهتر روش‌های به کار رفته در این مقاله، از داده‌های اکتشافی مربوط به ذخایر مس پورفیری منطقه چهارگنبد استان کرمان استفاده شده است.

## ۲- محدوده مورد مطالعه و داده‌های مورد استفاده


منطقه مورد مطالعه بخش کوچکی از کمربند ماگمایی ارومیه- دختر است. که از شمال غرب تا جنوب شرق ایران

با توجه به اینکه بسیاری از ذخایر معدنی در سطح زمین، شواهد مستقیم قابل مشاهده‌ای از خود نشان نمی‌دهند، بنابراین شناسایی محل تجمع این ذخایر و کانی‌سازی‌ها از چالش‌های اکتشاف است. در این راستا با توجه به ویژگی‌های موجود در سطح و با بهره‌گیری از روش‌های اکتشافی مانند دورسنجی، ژئوشیمی و نظایر آن می‌توان وجود یا عدم وجود آنها را بررسی و نقشه پتانسیل معدنی مورد نظر را تهیه کرد. مدل‌های پتانسیل معدنی در هر مقیاسی، از ناحیه‌ای تا محلی، برای شناسایی مناطق هدف تهیه می‌شوند [۱]. این مدل‌ها با تحلیل، ترکیب و تلفیق شواهد به دست آمده از منابع مختلف از داده‌های فضایی، به تعیین و رتبه‌بندی نواحی امیدبخش، برای اکتشاف ذخایر کشف نشده، می‌پردازند. هدف از مدلسازی پتانسیل معدنی در مقیاس ناحیه‌ای، شناسایی مناطق امیدبخش، از میان ناحیه‌ای وسیع است تا بر روی این بخش انتخاب شده (به عنوان هدف)، در مقیاس محلی دوباره مدلسازی پتانسیل معدنی با هدف شناسایی و معرفی امیدبخش‌ترین مکان‌ها (با مساحت کوچکتر از مرحله قبل) انجام گیرد.

تاکنون مطالعات متعددی برای پی‌جویی و شناسایی ذخایر مس پورفیری با استفاده از توسعه و به کارگیری روش‌های مختلف اکتشافی و همچنین روش‌های متنوع وزن‌دهی تلفیق داده‌ها و مدلسازی انجام شده است [۸-۲]. روش‌های تولید لایه‌های شاهد وزن‌دار (تخصیص وزن به داده‌های اکتشافی و تولید نقشه‌های شاهد) برای استفاده در تلفیق داده‌ها و مدلسازی پتانسیل معدنی عمدتاً شامل چهار روش دانش‌محور، داده‌محور، ترکیبی و پیوسته (بر اساس تابع لجستیکی) است. روش دانش‌محور در شرایطی که در منطقه مورد مطالعه تعداد اندیس‌های شناخته شده کم باشد و یا هیچ اندیس شناخته شده‌ای وجود نداشته باشد استفاده می‌شود. در صورتی که در یک منطقه به اندازه کافی اندیس‌های شناخته شده وجود داشته باشد، از مدلسازی داده‌محور پتانسیل معدنی در تعیین مناطق هدف برای اکتشافات بعدی استفاده می‌شود [۹-۱۴]. در روش‌های پیوسته، موقعیت رخدادهای معدنی شناخته شده به عنوان نقاط آموزشی مورد استفاده قرار نمی‌گیرد و مقادیر عددی پیوسته داده‌های اکتشافی معرف کانی‌سازی (مانند فاصله از عوارض معرف کانی‌سازی) طبقه‌بندی نمی‌شوند یعنی گسسته‌سازی انجام نمی‌گیرد. در نتیجه این روش بر معایب وزن‌دهی جهت‌دار حاصل از روش‌های قبلی غلبه و عدم قطعیت را به خوبی مدل می‌کند [۱۵].



شکل ۱: الف) موقعیت منطقه مورد مطالعه در ایران و ب) نقشه زمین‌شناسی



شکل ۲: ساختار شبکه عصبی به صورت شماتیک [۲۸]

مصنوعی سه نوع لایه نورونی وجود دارد [۳۲]:

- ۱) لایه ورودی که وظیفه دریافت اطلاعات خامی که به شبکه تغذیه شده است، را دارد.
- ۲) لایه پنهان که عملکرد آن به وسیله ورودی‌ها و وزن اتصالات بین آنها تعیین می‌شود.
- ۳) لایه خروجی که عملکرد آن بسته به فعالیت واحد

گسترش دارد و حاصل فرورانش است [۲۵، ۲۶]. ماگماتیسم در قوس ماگمایی ارومیه دختر عمدتا در طول ائوسن اتفاق افتاده است، اما بعدا پس از گذشت زمانی در میوسن بالایی به پلیوکواترنر ادامه یافته است [۲۷]. منطقه مطالعاتی قسمتی از برگه ۱:۱۰۰.۰۰۰ چهارگنبد در استان کرمان است که در شکل ۱ نشان داده شده است.

همچنین با استفاده از داده‌ها و نقشه‌های زمین‌شناسی و ژئوشیمیایی موجود و تهیه شده به وسیله شرکت ملی صنایع مس ایران و سازمان زمین‌شناسی و اکتشافات معدنی کشور (با استفاده از تصاویر ASTER و ماهواره لندست ETM+)، در رابطه با منطقه چهارگنبد استان کرمان، ابتدا نقشه‌های شاهد پیوسته مربوط به نزدیکی به سنگ میزبان، چگالی گسل، نزدیکی به آلتراسیون‌ها و ژئوشیمیایی با استفاده از نرم‌افزار ArcGIS ساخته و سپس تلفیق خواهند شد.


### ۳- روش‌های تلفیق نقشه‌های شاهد

#### ۳-۱- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک سامانه پردازش اطلاعات است که با شبیه‌سازی و ساده‌سازی شبکه‌های عصبی بدن انسان به وجود آمده است (شکل ۲). قابلیت پردازش شبکه از نوع ارتباط بین واحدها و وزن‌های اتصال سرچشمه می‌گیرد که با استفاده از فرآیند یادگیری به دست می‌آید یا از قبل تعیین شده است [۲۸]. نورون کوچکترین واحد پردازش اطلاعات است. از اجتماع چند نورون که به طور موازی عمل می‌کنند یک لایه به وجود می‌آید. هر لایه وظیفه خاصی دارد و با ترکیب لایه‌ها، شبکه‌های عصبی مصنوعی به وجود می‌آید. با توجه به هدفی که شبکه عصبی مصنوعی برای آن طرح می‌شود، لایه‌های متعددی در نظر گرفته می‌شود [۲۹، ۳۰].

در شبکه عصبی مصنوعی خروجی نورون‌ها در وزن‌های متفاوت ضرب می‌شوند و به عنوان ورودی به نورون جدید می‌رسند. این ورودی‌ها پس از جمع شدن و گذشتن از تابعی به نام تابع انتقال از نورون خارج می‌شوند، بنابراین هر نورون مقدار زیادی ورودی و تنها یک خروجی دارد. اتصال تعداد زیادی از این نورون‌ها به یکدیگر می‌تواند یک شبکه عصبی مصنوعی را تشکیل دهد [۳۱].

یک شبکه عصبی مصنوعی شامل اجزای سازنده‌ای به نام لایه‌ها و وزن‌هاست. رفتار شبکه عصبی مصنوعی نیز وابسته به ارتباط بین اجزای آن است. در حالت کلی در شبکه عصبی



شکل ۳: ساختار کلی ELM

## ۳-۱-۱- الگوریتم آموزش EIM

از آنجا که سرعت شبکه‌های عصبی پس‌انتشار (BP) خیلی کمتر از حد مورد نیاز است، در دهه‌های اخیر این نقطه ضعف به یک چالش در کاربردهای عملی تبدیل شده است. دو دلیل عمده برای این سرعت کم وجود دارد: دلیل اول الگوریتم یادگیری کند بر پایه گرادیان، برای آموزش شبکه عصبی است و دلیل دوم تنظیم مکرر همه پارامترها در این نوع الگوریتم‌های یادگیری است [۲۲]. به همین دلیل در کاربردهای صنعتی و عملی، مدل‌های خطی اغلب به دلیل سرعت بالاتر در یادگیری، به شبکه‌های عصبی پس‌انتشار ترجیح داده می‌شوند. برای غلبه بر ساختار کند شبکه‌های پس‌انتشار، یک شبکه عصبی جدید به نام ELM معرفی شده است [۳۳]. این شبکه عصبی، تعمیم‌یافته شبکه‌های پس‌انتشار تک‌لایه است اما تفاوت اصلی آن با سایر شبکه‌ها، این است که برخلاف روش‌های یادگیری معمولی که قبل از تولید، نورون‌های مخفی باید آموزش ببینند؛ در شبکه عصبی ELM وزن‌های ورودی (وزن اتصالات بین متغیرهای ورودی و نورون‌های لایه پنهان) به طور تصادفی انتخاب می‌شوند و ELM می‌تواند قبل از به کارگیری داده‌های آموزشی، این پارامترها را تولید کند.

شبکه عصبی ELM تعمیم‌یافته SLFN است (شکل ۳). ساختار شبکه SLFN و ELM در قالب ریاضی به صورت روابط ۱ و ۲ تعریف می‌شود [۳۲]:

$$y = g(b_o + \sum_{j=1}^h w_{jo} v_j) \quad (1)$$

$$v_j = f_j \left( b_i + \sum_{i=1}^n a_i s_i x_i \right) \quad (2)$$

که در آن:

$h$  و  $n$ : تعداد متغیرهای ورودی و تعداد نورون‌های لایه

مخفی

$V_j$ : خروجی نورون‌های لایه مخفی

$f=1, \dots, n$ : متغیرهای ورودی

$a_i$ : وزن اتصالات بین متغیر ورودی  $i$  و نورون  $j$  در لایه

مخفی

$w_{jo}$ : وزن اتصالات بین نورون  $j$  در لایه مخفی و نورون

خروجی

$b_i$ : بایاس نورون در لایه مخفی

$b_o$ : بایاس نورون خروجی

$f_i$  و  $g$ : تابع فعال‌سازی نورون  $j$  در لایه مخفی و تابع

فعال‌سازی نورون خروجی

$s_i$ : یک متغیر دوتایی که در گزینش متغیرهای ورودی

برای طراحی SLFN به کار می‌رود. با استفاده از این متغیر دوتایی هر متغیر ورودی را می‌توان مورد بررسی قرار داد که آیا در ساخته شبکه وجود دارد یا خیر [۳۴].

شبکه SLFN تابع را در دو مرحله آموزش می‌دهد: ۱-

نگاشت مشخصه تصادفی و ۲- حل پارامترهای خطی. در مرحله اول به طور تصادفی لایه پنهان را مقداردهی اولیه می‌کند تا داده ورودی را به فضای ویژه نگاشت کند. این کار به وسیله برخی توابع نگاشت غیرخطی انجام می‌گیرد [۳۳].

مرحله نگاشت تصادفی، ELM را از بسیاری از الگوریتم‌های یادگیری موجود مانند SVM (که از توابع کرنل برای نگاشت مشخصه استفاده می‌کنند) یا Neural Network Deep (که از RBM یا AE برای آموزش مشخصه استفاده می‌کنند) مجزا می‌کند. توابع نگاشت غیرخطی در ELM ممکن است هر نوع تابع پیوسته غیرخطی باشد که در جدول ۱ آورده شده است.

تابع خروجی ELM جهت تعمیم SLFN به صورت رابطه

۳ است:

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} h_1(x_1) & \dots & h_L(x_1) \\ \vdots & \ddots & \vdots \\ h_1(x_N) & \dots & h_L(x_N) \end{bmatrix} \quad (6)$$

$$T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} = \begin{bmatrix} t_{11} & \dots & t_{1n} \\ \vdots & \ddots & \vdots \\ t_{N1} & \dots & t_{Nm} \end{bmatrix} \quad (7)$$

جواب بهینه برای  $\beta$  نیز به صورت رابطه ۸ است:

$$\beta = H^{-1}T \quad (8)$$

از نقطه نظر یادگیری و بهره‌وری، ماشین یادگیری سریع سه هدف حداقل دخالت انسانی، دقت یادگیری بالا و سرعت یادگیری بالا را دنبال می‌کند اما از آنجا که تابع فعال‌سازی نورون‌های خروجی خطی است (در شبکه عصبی ELM وزن‌های خروجی بر اساس وزن‌های ورودی تصادفی و بایاس‌های گره‌های مخفی محاسبه می‌شود)، ممکن است مجموعه‌ای از وزن‌های ورودی غیربهینه یا گره‌های مخفی غیرضروری وجود داشته باشد. به علاوه ELM نسبت به الگوریتم‌های یادگیری مرسوم (بر اساس تنظیم‌سازی)؛ گرایش به تعداد نورون‌های زیاد دارد. همچنین این شبکه‌ها در حضور مقادیر ورودی نامرتب و همبسته، با مشکلات بیش برآش مواجه می‌شوند.

### ۳-۲- میانگین هندسی

عملگر میانگین هندسی، یک تابع تصمیم‌گیری چند معیاره برای تلفیق نقشه‌های شاهد وزن‌دار در تولید مدل‌های پتانسیل معدنی است.

$$G_A(F_1, F_2, \dots, F_n) = \sqrt[n]{\prod_{i=1}^n F_i} = \sqrt[n]{F_1 F_2 \dots F_n} \quad (9)$$

میانگین هندسی به صورت ریشه  $n$ ام حاصلضرب مقادیر، تعریف می‌شود که در آن  $n$  تعداد مقادیر است. این رابطه برای هر سلول از منطقه مورد مطالعه است. که در آن:

$G_A$ : میانگین هندسی مجموعه داده‌های اکتشافی  
 $F_i$ : مقدار عددی وزنی نقشه شاهد نام در سلول مورد نظر  
 $n$ : تعداد نقشه‌های شاهد مورد استفاده است.

برای این منظور ارزش پیش‌بینی کانی‌سازی مس در هر سلول از منطقه مورد مطالعه با استفاده از رابطه میانگین هندسی، با توجه به نقشه‌های شاهد مورد استفاده، به صورت رابطه ۱۰ نوشته می‌شود [۱۶]:

جدول ۱: توابع نگاشت غیرخطی در شبکه ELM

Sigmoid function	$G(a, b, x) = \frac{1}{1 + \exp(-(a \cdot x + b))}$
Hyperbolic tangent function	$G(a, b, x) = \frac{1 - \exp(-(a \cdot x + b))}{1 + \exp(-(a \cdot x + b))}$
Gaussian Function	$G(a, b, x) = \exp(-b \ x - a\ )$
Multiquadric function	$G(a, b, x) = (\ x - a\  + b^2)^{1/2}$
Hard limit Function	$G(a, b, x) = \begin{cases} 1, & \text{if } a \cdot x + b \leq 0 \\ 0, & \text{otherwise} \end{cases}$
Gosin function/ fourier basis	$G(a, b, x) = \cos(a \cdot x + b)$

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = h(x)\beta \quad (3)$$

که در آن:

$$\beta = [\beta_1 \dots \beta_L]^T$$

و  $x$  گره خروجی

$$h(x) = [h_1(x), \dots, h_L(x)]$$

یادگیری فرین است.

$h_i$  نیز به صورت رابطه ۴ تعریف می‌شود:

$$h_i(x) = G(a_i, b_i, x), \quad a_i \in R^d, \quad b_i \in R \quad (4)$$

که در آن:

$G(a, b, x)$ : تابع پیوسته غیرخطی تکه‌ای<sup>۱</sup> است.

در شبکه عصبی ELM پارامترهای گره پنهان (یعنی  $a$  و  $b$ ) به صورت تصادفی و مستقل از داده آموزشی و بر اساس تابع توزیع احتمالی تولید می‌شوند. این ویژگی به ایجاد کارایی بیشتر در مقایسه با شبکه‌های عصبی قدیمی و سنتی منجر می‌شود. در مرحله دوم یادگیری،  $\beta$  یعنی وزن‌های بین لایه پنهان و لایه خروجی، با به حداقل رساندن خطای مربعاتی به دست می‌آید.

$$\beta \in R_{L \times m}^{\min} \|H\beta - T\|^2 \quad (5)$$

که در آن:

$H$ : ماتریس خروجی لایه پنهان

$T$ : ماتریس هدف داده آموزشی است.

داده‌های فضایی مختلف استنتاج شده است، حداقل و حداکثر مقادیر آنها یکسان نیستند و فضاهای آنها نیز متفاوت است. در این پژوهش، با استفاده از تابع لجستیک زیر به عنوان یک تبدیل غیرخطی [۳۳]، مقادیر مجموعه داده‌های مختلف شواهد اکتشافی به یک فضای مشابه تبدیل شده‌اند:

$$F_E = \frac{1}{1 + \exp[-s(E - i)]} \quad (11)$$

که در آن:

$F_E$ : مقدار عضویت فازی و امتیاز فازی اختصاص یافته

$s$ : شیب تابع لجستیک

$i$ : نقطه عطف تابع لجستیک

$E$ : مقدار عددی مربوط به شاهد فضایی که در دامنه

[۰، ۱] تبدیل می‌شود.

مقادیر  $i$  و  $s$ : به وسیله تحلیل گر به گونه‌ای تعریف می‌شوند

که امتیازات شواهد در محدوده فازی [۰، ۱] قرار گیرند.

#### ۴-۱-۱- نقشه شاهد توده نفوذی

ذخایر مس پورفیری در کمربند ارومیه- دختر به طور ژنتیکی و فضایی (موقعیت مکانی) با توده‌های نفوذی در ارتباطند [۳۷، ۳۶]. این ارتباط به این دلیل است که حاشیه توده‌های نفوذی شکسته و خرد شده بوده که امکان چرخش و حرکت سیالات گرمایی و در نتیجه تبادل گرما را فراهم می‌کند [۳۸-۴۰]. به همین دلیل در مناطق نزدیک به توده نفوذی و در مجاورت آنها، احتمال تشکیل ذخایر مس پورفیری بیشتر است [۴۲، ۴۱].

برای تولید نقشه شاهد وزن‌دار توده نفوذی در منطقه، از آنجایی که مجاورت توده‌های نفوذی، مطلوبیت بیشتری برای تشکیل کانی‌سازی مس پورفیری دارد [۴۴، ۴۳، ۴۱]، از عکس فاصله تا توده‌های نفوذی (شامل گرانودیوریت‌ها، گرانیت‌ها و کوارتز دیوریت‌ها) استفاده شد، سپس برای تولید نقشه وزن‌دار توده‌های نفوذی، از معادله ۱۱ برای انتقال مقادیر معکوس فاصله به فضای لجستیک (فضای وزن) استفاده شد (شکل ۴).

#### ۴-۱-۲- نقشه شاهد چگالی گسل

بررسی‌های ساختاری، نقش مهم نفوذپذیری سنگ‌ها در تشکیل ذخایر معدنی را نشان می‌دهند [۴۵]. در این راستا همچنین وجود واریختگی ساختاری عموماً به عنوان یک معیار

$$G_{Cu}(F_{HR}, F_{FD}, F_{GS}, F_{AI}, F_{ARG}) = \sqrt[5]{\prod_{i=1}^5 F_i} \quad (10)$$

$$= \sqrt[5]{F_{HR} F_{FD} F_{GS} F_{AI} F_{ARG}}$$

که در آن:

$F_{HR}$ : امتیاز فازی وزن‌دار مقادیر داده‌های اکتشافی متناظر

با نقشه شاهد فاصله از سنگ میزبان

$F_{FD}$ : امتیاز فازی وزن‌دار مقادیر داده‌های اکتشافی متناظر

با نقشه شاهد چگالی گسل

$F_{GS}$ : امتیاز فازی وزن‌دار مقادیر داده‌های اکتشافی متناظر

با نقشه شاهد اثر ژئوشیمیایی مرتبط با عناصر مس

$F_{ARG}$ : امتیاز فازی وزن‌دار مقادیر داده‌های اکتشافی

متناظر با نقشه شاهد آلتراسیون آرژیلیک

$F_{AI}$ : امتیاز فازی وزن‌دار مقادیر داده‌های اکتشافی متناظر

با نقشه شاهد آلتراسیون اکسید آهن است.

#### ۴- نتایج

##### ۴-۱- تولید لایه‌های شاهد وزن‌دار

در مدل‌سازی پتانسیل معدنی برای یک نوع ذخیره مورد پی‌جویی، در ابتدا همه ویژگی‌های کنسارهای تیپ ماده معدنی مورد جستجو، شناسایی و جمع‌آوری می‌شوند. در این مرحله می‌توان مدل مفهومی ناحیه‌ای را با توجه به مطالعات عمومی ذخایر تیپ ماده معدنی مورد پی‌جویی که در سراسر جهان وجود دارند، استنتاج کرد، زیرا یک مدل مفهومی خوب بهترین ابزار برای شناخت معیارهای اکتشافی و استخراج الگوهای پیشگوی ماده معدنی مورد نظر است. برای تهیه مدل پتانسیل معدنی یک ذخیره معین از نوع مورد جستجو در یک منطقه مشخص، مجموعه داده‌های اکتشافی مورد استفاده، بر اساس مدل مفهومی آن نوع ذخیره است، سپس بر اساس داده‌ها، نقشه‌های شاهد تولید و وزن‌دار شده و در نهایت برای شناسایی مناطق هدف تلفیق می‌شوند.

برای ساخت مدل مفهومی ناحیه‌ای ذخایر مس پورفیری در منطقه چهارگنبد، معیارهای اکتشافی زمین‌شناسی، ژئوشیمیایی و سنجش از دور مورد استفاده قرار گرفتند و پنج نقشه (لایه) شاهد اکتشافی شامل سنگ میزبان، چگالی گسل، اثر ژئوشیمیایی، آلتراسیون اکسید آهن و آلتراسیون آرژیلیک برای جستجوی کانی‌سازی مس در منطقه با استفاده از روش فازی پیوسته تولید شدند. از آنجا که این مقادیر از مجموعه

یک تیپ ماده معدنی مشخص است که در این راستا دلایل منطقی متعددی ارائه شده است، بنابراین با توجه به اینکه مواد معدنی همیشه در سطح زمین رخمون ندارند و همین طور به دلیل گسترش کم محدوده کانی‌سازی فن سنجش از دور می‌تواند در بیشتر مواقع در پی‌جویی و اکتشاف ذخایر معدنی و کوچک کردن محدوده مورد مطالعه مفید واقع شود. شناسایی و تشخیص دگرسانی‌ها به روش دورسنجی نیز یکی از ابزارهای کارآمد در اکتشاف بعضی از منابع معدنی است و به کارگیری آن در ذخایری با هاله‌های وسیع و شاخص، بسیار اثربخش بوده است. از شاخصه‌های مهم کانسارهای گرمابی تشکیل هاله‌های دگرسانی است [۴۷].

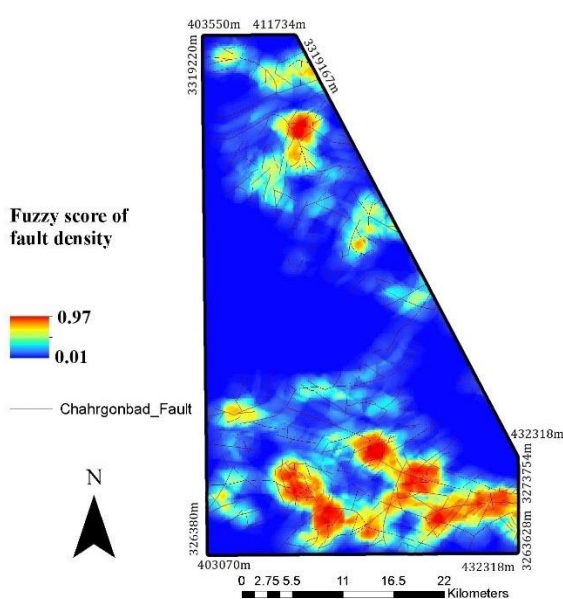
وجود دگرسانی‌هایی مانند پتاسیک، پروپیلیتیک، آرژیلیک و اکسید آهن (گوسان)، از شواهدی است که امکان حضور ذخایر مس پورفیری را تقویت می‌کند و ممکن است در فواصل چندین کیلومتر از مرکز کانی‌سازی گسترش داشته باشند [۳۸-۴۰]. در این راستا، آلتراسیون‌های آرژیلیک و اکسید آهن معمولاً در سطح و اطراف ذخایر مس پورفیری گسترش دارند [۴۸، ۴۹]. دگرسانی سوپرژن و تغییرات آب و هوایی سنگ‌های سولفیددار به طور کلی به شکل‌گیری اکسید آهن منجر می‌شوند و مناطق اکسید آهن اغلب با مناطق دگرسانی هیدروترمال همراه‌اند [۴۸، ۵۰، ۵۱] که نشان‌دهنده مناطق مطلوب برای وجود ذخایر مس پورفیری است. اگرچه سایر دگرسانی‌های مرتبط با ذخایر

مهم برای حضور برخی ذخایر محسوب می‌شود.

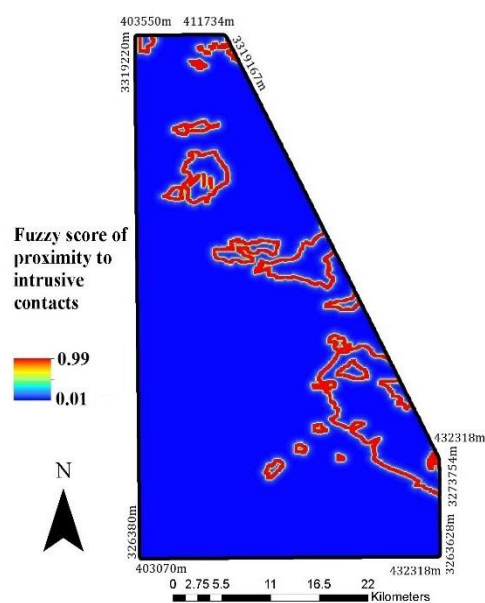
گسل‌ها، عبور ماگماها و گردش سیالات هیدروترمال را تسهیل می‌کنند [۳۹] و به طور کلی پذیرفته شده است که ناحیه‌های خرد شده و دارای شکستگی به عنوان کانال‌های اصلی عبور سیالات هیدروترمال عمل می‌کنند [۴۵]. گسل‌ها و شکستگی‌ها در شکل‌گیری بسیاری از ذخایر معدنی نقش دارند و بنابراین حضور چنین ویژگی‌های زمین‌شناسی نشان‌دهنده افزایش نفوذپذیری ساختاری سنگ‌ها در زیر زمین است [۴۶]. بنابراین مناطق با چگالی گسل زیاد و دارای شکستگی، قابلیت انتقال و چرخش محلول‌های کانه‌دار را دارند. در این مقاله، از چگالی گسل (FD)<sup>۱</sup> به عنوان یک لایه شاهد کنترل‌کننده ساختاری تشکیل ذخایر مس پورفیری در منطقه مورد مطالعه استفاده شده است. برای تولید نقشه چگالی گسل، مجموع طول کل گسل‌ها در هر پیکسل از منطقه مورد مطالعه (یعنی تراکم یا چگالی گسل) محاسبه شد، سپس به این دلیل که مقادیر چگالی گسل دامنه مشخصی ندارند خارج از فضای لجستیک‌اند، معادله ۱۱ بر روی مجموعه داده‌های چگالی گسل اعمال شد (شکل ۵).

#### ۴-۱-۳- نقشه‌های شاهد آلتراسیون (اکسید آهن و آرژیلیک)

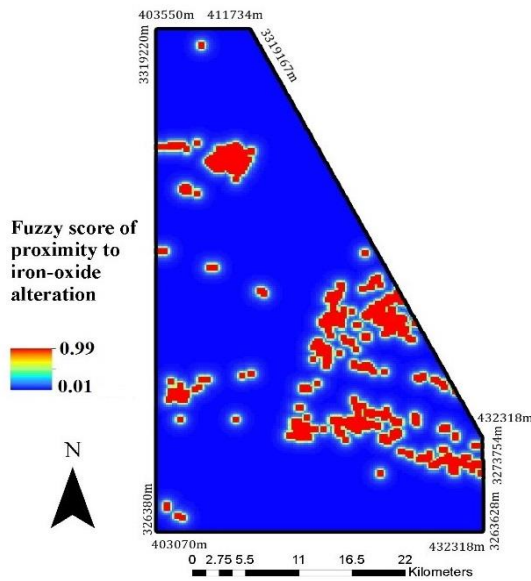
یکی از ایده‌های کلیدی فنون سنجش از دور در زمین‌شناسی اکتشافی، در نمایش سنگ‌ها، کانی‌ها و ساختارهای مرتبط با



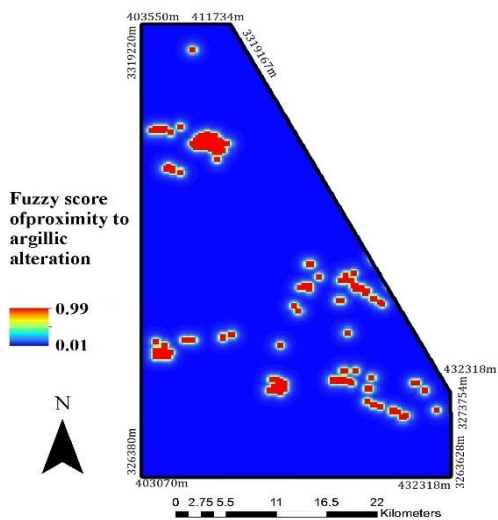
شکل ۵: نقشه شاهد چگالی گسل



شکل ۴: نقشه شاهد توده نفوذی



شکل ۶: نقشه شاهد آلتراسیون اکسید آهن



شکل ۷: نقشه شاهد آلتراسیون آرژیلیک

عنصری از انواع کانسارهای معدنی به دنبال داده‌های رسوبات رودخانه‌ای توسعه داده‌اند. نتایج SFA اجازه شناسایی بهبود یافته آنومالی‌های ژئوشیمیایی قابل توجهی از نوع کانسار را می‌دهد. در SFA، عناصر غیرشاخص و پر سر و صدا به تدریج شناسایی شده و از تجزیه و تحلیل حذف می‌شوند تا نشانه چند عنصری قابل قبول به دست آید.

در این مقاله، از روش SFA برای شناسایی آنومالی‌های چند عنصری معرف ذخایر مس پورفیری بر روی داده‌های

مس پورفیری نیز قابل استفاده‌اند ولی در این مطالعه با توجه به اینکه دو دگرسانی یاد شده در سطح گسترش بیشتری دارند (مثلا در مقایسه با دگرسانی پتاسیک)، به ویژه در مقیاس منطقه‌ای می‌توانند موجب کوچکتر شدن دقیق‌تر منطقه مورد مطالعه شوند. در این حالت در مراحل بعدی اکتشاف می‌توان گسترش سایر دگرسانی‌ها را بیشتر بررسی کرد.

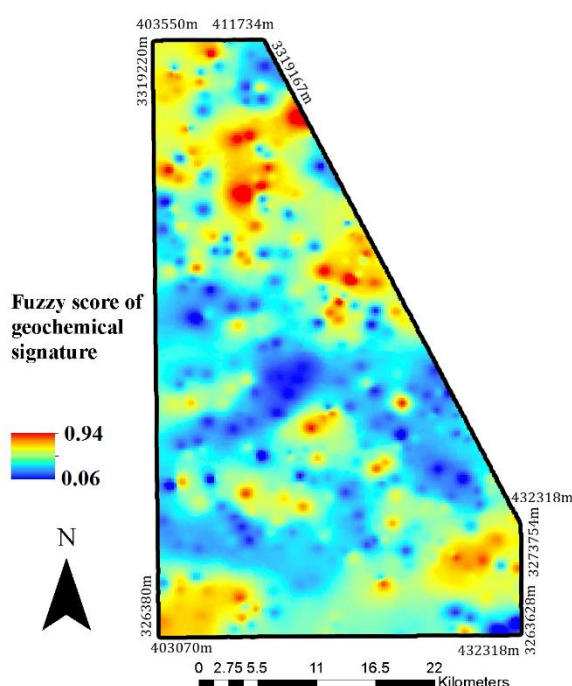
در این مقاله از نقشه‌های دگرسانی آرژیلیک و اکسید آهن (Jarosite, Hematite, Goethite)، به دست آمده از پردازش تصاویر ASTER و ماهواره لندست ETM+، برای تولید لایه‌های وزن دار آلتراسیون‌ها استفاده شده است که به طور گسترده‌ای برای مطالعه و اکتشاف ذخایر مس پورفیری در ایران مورد استفاده قرار گرفته است [۴۴، ۴۸، ۴۹، ۵۰، ۵۱]. به این منظور ابتدا نقشه‌های فاصله از آلتراسیون‌های آرژیلیک و اکسید آهن تولید شدند. از آنجا که نزدیکی به آلتراسیون، نشان‌دهنده مطلوبیت بیشتر برای کانی‌سازی مس پورفیری است، از عکس فاصله تا آلتراسیون برای تولید نقشه شاهد و از رابطه ۱۱ برای انتقال مقادیر عکس فاصله به فضای لجستیک استفاده شد (شکل‌های ۶ و ۷).

#### ۴-۱-۴ اثر ژئوشیمیایی چند عنصری معرف

بررسی‌های ژئوشیمیایی را می‌توان در مراحل مختلف اکتشاف منابع معدنی از ناحیه‌ای تا محلی به کار بست. اساس اکتشافات ژئوشیمیایی، جستجو و ردیابی مناطقی است که در آنها غلظت یک یا چند عنصر معین، بیش از حد معمول است. به عبارت دیگر، به کمک اکتشافات ژئوشیمیایی، مناطقی که دارای این قبیل ناهنجاری‌ها هستند، مشخص می‌شود. مشکل اساسی در شناسایی ناهنجاری‌ها در بررسی‌های ژئوشیمیایی اکتشاف مواد معدنی، تعیین و استنتاج اثرهای چند عنصری معرف کانی‌سازی مورد جستجو است [۵۲]. در این راستا، تجزیه و تحلیل فاکتوری به عنوان یکی از روش‌های تحلیل چند متغیره به طور گسترده‌ای برای تفسیر داده‌های ژئوشیمیایی رسوبات آبراهه‌ای مورد استفاده قرار گرفته است. تجزیه و تحلیل فاکتوری می‌تواند ترکیبات چند عنصری را از بین مجموعه داده‌ها آشکار کند که می‌توانند به عنوان اثرهای ژئوشیمیایی معرف کانی‌سازی تیپ مورد جستجو، استفاده شوند.

اخیرا یوسفی و همکاران [۵۱، ۵۳] تجزیه و تحلیل فاکتوری مرحله‌ای (SFA) را برای استخراج کارآمد آنومالی‌های چند





شکل ۸: نقشه شاهد اثر ژئوشیمیایی چند عنصری معرف

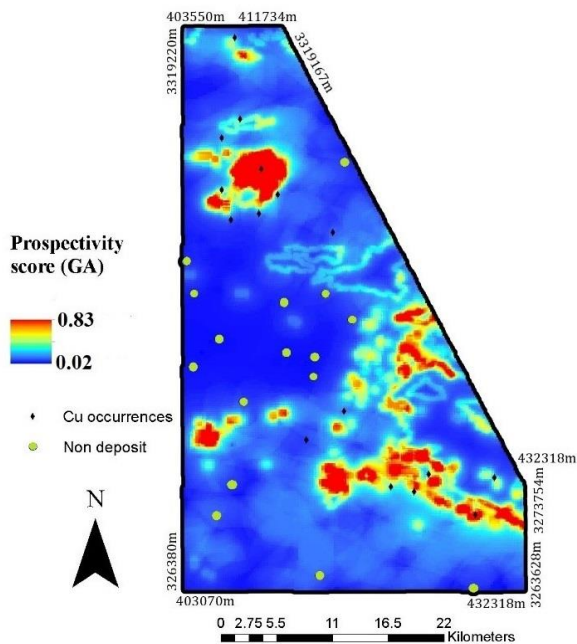
جدول ۲: ماتریس مولفه‌های چرخش یافته تجزیه و تحلیل فاکتوری (اعداد پررنگ نشان‌دهنده عناصر انتخاب شده بر اساس حد آستانه ۰٫۶ است.)

عنصر	مؤلفه		
	F1	F2	F3
Zn	۰٫۶۱۲	۰٫۳۱۳	۰٫۳۷۶
Pb	۰٫۰۶۸	۰٫۰۶۷	۰٫۲۵۳
Ag	۰٫۸۰۶	۰٫۱۰۷	۰٫۵۵
Cu	۰٫۷۰۵	۰٫۳۴۵	۰٫۰۱۵
Mo	۰٫۰۰۸	۰٫۱۱۳	-۰٫۷۳
Cr	۰٫۲۰۸	۰٫۶۱۹	۰٫۲۰۳
Ni	۰٫۰۸	۰٫۷۹۸	-۰٫۰۷۳
Co	۰٫۱۵۱	۰٫۸۶۴	-۰٫۰۴۱
Ba	۰٫۷۲۸	۰٫۰۲۲	۰٫۳۳۳
مقدار ویژه	۲٫۹۵	۱٫۲۸	۱٫۱
واریانس (۵)	۳۲٫۸۳	۱۴٫۲	۱۲٫۲۹
واریانس تجمعی (%)	۳۲٫۸۳	۴۷٫۰۳	۵۹٫۳۲

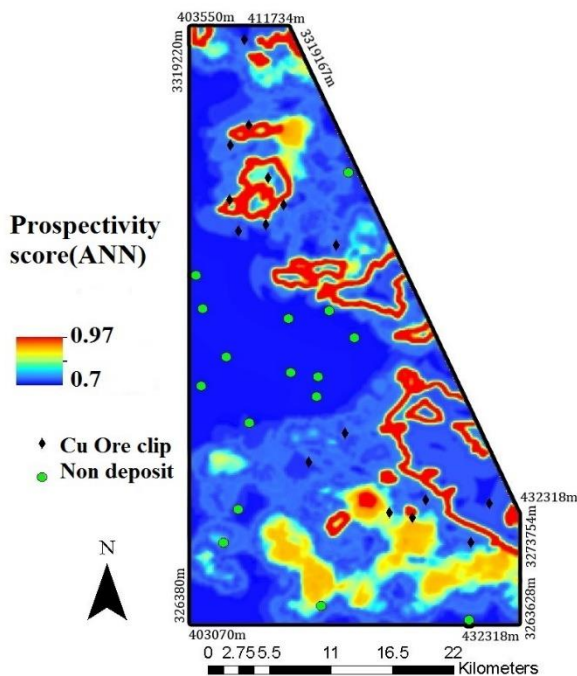
ژئوشیمیایی رسوبات آبراهه‌ای استفاده شده است. داده‌های ژئوشیمیایی، داده‌های ترکیبی (سیستم بسته) هستند [۵۵]. در این راستا، چندین محقق تبدیل ایزومتریک لگاریتمی (ilr) را به عنوان روش مناسب برای باز کردن داده‌های ترکیبی [۵۶] و مفید بودن آن برای تجزیه و تحلیل آماری داده‌های ژئوشیمیایی رسوبات رودخانه‌ای نشان داده‌اند [۵۷]. بنابراین پس از تبدیل ایزومتریک لگاریتمی، از داده‌های غلظت عناصر (Au, Cu, Mo, Zn, Pb, As, Sb, Ni, Cr و Co) مربوط به تعداد ۸۴۶ نمونه رسوب آبراهه‌ای (۸۰- مش برابر > ۱۷۷ میکرومتر) استفاده شده است. این داده‌ها به وسیله سازمان زمین‌شناسی و اکتشافات معدنی کشور برداشت و آنالیز شده است. در اجرای روش SFA از تحلیل مولفه‌های اصلی (PCA) کلاسیک برای استخراج فاکتورها و همچنین از روش واریماکس برای چرخش آنها استفاده شده است [۵۸]. در نهایت از فاکتورهایی با مقادیر ویژه بیشتر از ۱ برای تفسیر استفاده شده است (جدول ۱). بر اساس این جدول، فاکتور ۱ (F1) با همراهی عناصر Cu-Pb-Zn-Ba بهترین فاکتوری است که نشان‌دهنده اثر ژئوشیمیایی معرف چند عنصری کانی‌سازی مس پورفیری در منطقه مورد مطالعه است، زیرا عناصر مشارکت‌کننده در این فاکتور، از عناصر مهم معرف و ردیاب ذخایر مس پورفیری اند [۳۱] که مقدار ویژه (۲٫۹۵) و واریانس (۳۲٫۸۳) بالاتری را نسبت به سایر فاکتورها به دست داده است. مقادیر امتیازات فاکتوری (Cu-Pb-Zn-Ba) F1 بدون دامنه‌اند، بنابراین مانند دیگر لایه‌های شاهد از تابع لجستیک رابطه ۱۱ برای انتقال آنها به فضای وزن استفاده شد.

مقادیر امتیازات فاکتوری تبدیل شده با استفاده از تابع لجستیک، شاخص احتمالی کانی‌سازی ژئوشیمیایی (GMPI) [۵۴، ۵۵] و در واقع یک اثر چند عنصری ژئوشیمیایی معرف کانی‌سازی است [۵۴، ۵۵]. GMPI وزنی است که اهمیت نسبی نمونه‌های ژئوشیمی را برای جستجوی ماده معدنی مورد نظر نشان می‌دهد [۵۹]. یوسفی و همکاران نشان داده‌اند که یک نقشه GMPI، یک لایه شاهد ژئوشیمیایی بهبود یافته است. به همین منظور، در این مطالعه، داده‌های نقطه‌ای مقادیر GMPI، با استفاده از روش معکوس فاصله (IDW) [۶۰]، درون‌یابی و به نقشه تبدیل شدند (شکل ۸) [۶۰].

نقشه‌های شاهد وزن‌دار باید ترکیب شوند تا شواهد قوی‌تری برای اکتشاف مواد معدنی تولید شود [۶۱، ۶۲]. از آنجایی که در محیط‌های مختلف زمین‌شناسی و مناطق مختلف اکتشافی به دلیل وجود پیچیدگی‌های زمین‌شناسی، نتایج روش‌های



شکل ۹: مدل پتانسیل معدنی تولید شده با استفاده از میانگین هندسی



شکل ۱۰: مدل پتانسیل معدنی تولید شده با استفاده از شبکه عصبی مصنوعی

مختلف تلفیق یکسان نخواهد بود، لازم است در هر منطقه دو یا چند مدل پتانسیل مختلف، تولید و نتایج با هم مقایسه شوند تا بهترین مدل برای اکتشافات بعدی انتخاب شود.

برای این منظور، بر اساس روش وزن دهی به لایه های شاهد و همچنین روش مدلسازی، از روش ها و توابع ریاضی متعددی می توان استفاده کرد. در این تحقیق نقشه های شاهد پیوسته با استفاده از روش میانگین هندسی (شکل ۹) و شبکه عصبی مصنوعی (با استفاده از الگوریتم ماشین یادگیری سریع، نشان داده شده در شکل ۱۰) برای تولید مدل پتانسیل معدنی ذخایر مس پورفیری در منطقه چهارگنبد با یکدیگر ترکیب شده اند.


برای تلفیق نقشه ها با استفاده از روش شبکه عصبی مصنوعی، در ابتدا شبکه باید مورد آموزش قرار گیرد. برای آموزش شبکه ELM از ۸۰٪ داده ها به عنوان داده آموزشی و ۲۰٪ به عنوان داده های ارزیابی و تست استفاده شده است. در این شبکه نورون های ورودی به شبکه اعمال شده و با ضرب در W وزن دار می شوند. پس از جمع نتایج بردار، حاصل جمع با مقدار بایاس جمع می شود. حاصل عملیات جمع شده به تابع انتقال که در اینجا hardlim است؛ به عنوان ورودی اعمال می شود. عملکرد این تابع به اینصورت است که ورودی های صفر یا بزرگتر از صفر را ۱ و در غیر اینصورت صفر را به عنوان خروجی باز می گرداند. علت انتخاب تابع انتقال پله ای hardlim این است که اطلاعات ورودی برای آموزش شبکه عصبی مصنوعی ELM در مطالعه حاضر، نقاطی با تابع هدف صفر و ۱ هستند. آموزش شبکه نیز نباید به صورتی باشد که شبکه دچار حالت آموزش بیش از حد آموزش (برازش بیش از حد بر داده های آموزش<sup>۱۴</sup>) شود.

در ارزیابی و تعمیم شبکه ELM یکی از مهم ترین عوامل، تعمیم نوع تابع فعال سازی و تعداد گره های پنهان است [۶۳]. لازم به ذکر است با توجه به تک لایه بودن این نوع شبکه تنظیم درست تعداد گره های پنهان امر مهمی است. با توجه به انتظارات گوناگون از جواب شبکه، تعداد گره های پنهان در برخی موارد با افزایش و یا کاهش، تغییر قابل توجهی پیدا نمی کند. در این بررسی از تعداد گره ها و نورون های لایه پنهان مختلفی استفاده شد. تعداد نورون مخفی استفاده شده ۱۳۵۰ نورون است که این تعداد کمک قابل توجهی به آموزش و تعمیم شبکه می کند. زمان سریع پردازش و مقداردهی لایه با توجه به تک لایه بودن الگوریتم به ساده بودن و دقت شبکه افزوده است. زمان آموزش شبکه<sup>۱۵</sup>، ۰٫۲۶۵۶ ثانیه و زمان آزمایش شبکه<sup>۱۶</sup> صفر ثانیه است. دقت آموزش شبکه<sup>۱۷</sup>  $1.5575 \times 10^{-14}$  و دقت آزمایش شبکه<sup>۱۸</sup>  $2.2523 \times 10^{-14}$  است.

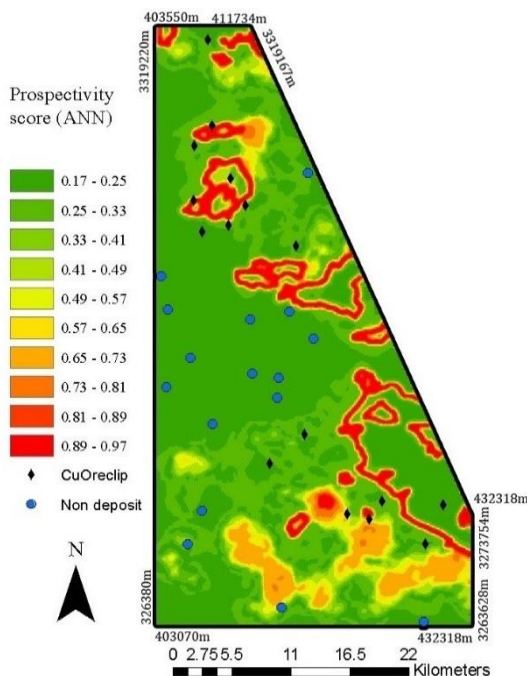
در گام آخر و برای تهیه نقشه نهایی پتانسیل مس پورفیری در منطقه، نقشه‌های شاهد نزدیکی به توده نفوذی، اثرات ژئوشیمیایی، آلتراسیون‌ها و گسل‌ها، لایه‌های ورودی شبکه عصبی مصنوعی را تشکیل دادند که با استفاده از نرم‌افزار ArcGIS و وزن‌دار کردن نقشه‌ها، وزن‌هایی به صورت جداگانه برای هر یک از نقشه‌های شاهد در نظر گرفته شد. به اینصورت که به تمام نقشه‌های شاهد عددی بین صفر تا ۱ با توجه وزن‌هایشان اختصاص یافت. شبکه طراحی شده به صورت هوشمند رابطه‌ای را که در قسمت آموزش شبکه پیدا کرده بود، به داده‌های وزن‌دار نهایی اعمال کرده و نقشه نهایی تلفیق شده را به صورت وزن تولید کرد. در این خصوص با مقایسه نقشه نهایی تولید شده و نقشه‌های شاهد و زمین‌شناسی منطقه، مشخص می‌شود که شبکه استفاده شده کارایی بالایی در تلفیق نقشه‌ها داشته و می‌توان برای اکتشافات ناحیه‌ای و دقیق‌تر از آن استفاده کرد.

#### ۵- ارزیابی مدل‌ها

در مدل‌سازی پتانسیل معدنی، وزن اختصاص‌یافته به یک شاهد فضایی معرف رابطه بین شاهد فضایی و کانی‌سازی تیپ ذخیره مورد هدف است، 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 مقاله نیز برای ارزیابی قابلیت پیش‌بینی مدل تولید شده از ۱۶ موقعیت دارای ذخیره و ۱۶ موقعیت فاقد ذخیره مس پورفیری در منطقه مورد مطالعه استفاده شده است. از موقعیت‌های دارای ذخیره و فاقد ذخیره صرفاً برای ارزیابی مدل استفاده شده و در تخصیص وزن و تولید مدل پتانسیل معدنی تاثیری نداشته‌اند. ارزیابی اهمیت نسبی نقشه‌های شاهد استخراج شده از داده‌های مکانی، بسیار مشکل و زمان‌بر بوده و اختصاص وزن به نقشه‌ها معمولاً شامل یک روند آزمایشی و همراه با خطا است. نمودار نرخ پیش‌بینی - مساحت  $^{1}P-A$  یک روش ارزیابی مبتنی بر داده است و از نظر کارشناس و متخصص برای ارزیابی استفاده نمی‌کند. در نمودار نرخ پیش‌بینی - مساحت، دو منحنی وجود دارد که در مقابل کلاس‌های مختلف مدل پتانسیل معدنی رسم می‌شوند. اولین منحنی مربوط به نرخ پیش‌بینی اندیس‌های شناخته شده 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 [۶۴]. در این نمودار،



شکل ۱۱: نقشه کلاسه‌بندی شده مدل تولید شده با استفاده از میانگین هندسی



شکل ۱۲: نقشه کلاسه‌بندی شده مدل تولید شده با استفاده از شبکه عصبی مصنوعی

با توجه به اینکه برای رسم نمودار نرخ پیش‌بینی - مساحت به طبقه‌بندی مدل پتانسیل معدنی نیاز است، از روش طبقه‌بندی فواصل مساوی<sup>۲۰</sup> برای تعیین حد آستانه‌ای کلاس‌های مختلف استفاده شد. این روش معمولاً برای متغیرهای عددی که در دامنه‌های یکسانی‌اند، استفاده می‌شود. این روش کل دامنه اعداد از کوچکترین تا بزرگترین را به فواصل مساوی تعیین شده به وسیله کاربر تقسیم می‌کند. در نهایت با توجه به مدل پتانسیل معدنی طبقه‌بندی شده (شکل‌های ۱۱ و ۱۲)، تعداد اندیس‌های ماده معدنی پیش‌بینی شده در هر کلاس و مساحت متناظر با هر کلاس، نمودار نرخ پیش‌بینی - مساحت بهبودیافته برای هر دو مدل شبکه عصبی و میانگین هندسی رسم شده است (شکل‌های ۱۳ و ۱۴). همان‌طور که مشاهده می‌شود تفاضل دو منحنی در روش تولید شده با استفاده از شبکه عصبی مصنوعی بیشتر است، بنابراین این مدل کارآیی بیشتری داشته و در هدایت عملیات اکتشافی در منطقه چهارگنبد استفاده می‌شود.


#### ۶- بحث

ارایه یک روش مناسب و راه‌حلی که بتواند پارامترهایی مانند عدم قطعیت، خطا و نرخ موفقیت اکتشاف را ارتقا دهد همواره مورد نیاز و قابل توجه است [۷۵-۷۲]. از آنجایی که در کلیه روش‌های داده‌محور، دانش‌محور و ترکیبی، مقادیر عددی داده‌های اکتشافی ابتدا به تعدادی کلاس با فواصل دلخواه طبقه‌بندی می‌شوند و سپس به مقادیر داده‌های اکتشافی در هر کلاس با توجه به روش مورد استفاده وزن یکسانی اختصاص می‌یابد، بدیهی است که خروجی مدل‌سازی پتانسیل معدنی

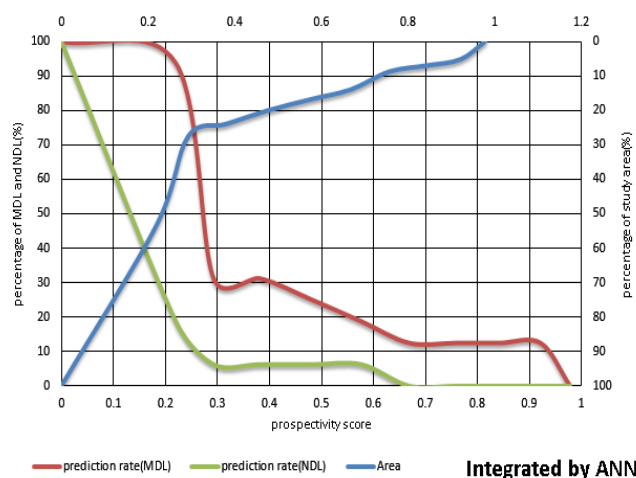
نقطه تقاطع دو منحنی نرخ پیش‌بینی و مساحت، معیاری برای ارزیابی مدل پتانسیل معدنی است و هرچه تقاطع دو منحنی بالاتر باشد، مدل کارآیی بیشتری دارد، زیرا اندیس‌های شناخته شده در سطوح کوچکتری از منطقه مورد مطالعه قرار گرفته و در نتیجه احتمال رخداد معدنی در این سطوح بالاتر است.

در ارزیابی لایه‌های شاهد فضایی و مدل‌های ساخته شده، موضوع دیگری در رابطه با موقعیت‌های فاقد ذخیره وجود دارد [۶۸-۶۵]. بر اساس این نظر، مناطق هدف تولید شده با روش‌های مدل‌سازی پتانسیل معدنی باید با موقعیت‌های فاقد ذخیره که در آن ذخایر معدنی به دلیل وجود شرایط زمین‌شناسی نامناسب و عدم وجود شواهد اکتشاف وجود ندارد، کمتر همخوانی داشته باشند [۶۹، ۶۳، ۴۶، ۷۰].

برای جلوگیری از کاستی‌های یاد شده در نمودار P-A، این نمودار با افزودن منحنی پیش‌بینی نرخ مکان‌های فاقد ذخیره، بهبود داده شده است، بنابراین در نمودار بهبودیافته سه منحنی نرخ پیش‌بینی اندیس‌های ماده معدنی متناظر با کلاس‌ها و طبقه‌بندی پتانسیل معدنی، منحنی درصد مساحت تحت پوشش متناظر با کلاس‌ها و طبقه‌بندی پتانسیل معدنی و منحنی نرخ پیش‌بینی اندیس‌های فاقد ماده معدنی متناظر با کلاس‌ها و طبقه‌بندی پتانسیل معدنی وجود دارد. در نمودار P-A بهبودیافته، دو نقطه تقاطع شامل تقاطع منحنی مساحت و نرخ پیش‌بینی مواد معدنی (۱) و تقاطع منحنی مساحت و نرخ پیش‌بینی نقاط فاقد ماده معدنی (۲) وجود دارد. هرچه تفاضل نقطه تقاطع اول و دوم بیشتر باشد (تقاطع اول بالاتر و تقاطع دوم پایین‌تر) مدل کارآیی بیشتری خواهد داشت [۷۱].



شکل ۱۳: نمودار نرخ پیش‌بینی - مساحت بهبودیافته برای مدل تولید شده با استفاده از میانگین هندسی



شکل ۱۴: نمودار نرخ پیش‌بینی - مساحت بهبود یافته برای مدل تولید شده با استفاده از شبکه عصبی

## ۷- نتیجه‌گیری

با توجه به کلیه مطالعات انجام گرفته در مقاله حاضر نتایج را می‌توان به صورت زیر بیان کرد:

- الگوریتم یادگیری سریع می‌تواند به خوبی در شبکه‌های عصبی مصنوعی برای آموزش شبکه مورد استفاده قرار گیرد و موجب افزایش نرخ موفقیت اکتشاف در مدل‌های پتانسیل معدنی گردد. لازم به ذکر است الگوریتم ELM دارای توابع فعال‌سازی متنوع، قدرت بالای تحلیل داده و زمان سریع پردازش است. همچنین دقت این الگوریتم در تعمیم و آموزش بسیار بالا است.

- در خصوص داده‌های مورد استفاده در مطالعه حاضر، هر دو روش تلفیق شبکه عصبی مصنوعی داده‌محور و میانگین هندسی (بدون استفاده از نقاط آموزشی) عملکرد قابل قبولی دارند، اما با توجه به استفاده از نقاط آموزشی، شبکه عصبی مصنوعی، مقدار کارایی کلی بهتری را ارائه داده است، بنابراین مدل تولید شده با این روش کارایی بیشتری دارد و اهداف تعیین شده می‌تواند برای هدایت اکتشافات بعدی ذخایر مس پورفیری در منطقه چهارگنبد مورد استفاده قرار گیرد.

- لازم است اهداف اکتشافی شناسایی شده در مطالعه حاضر، برای ادامه عملیات اکتشافی سیستماتیک در مقیاس بزرگتر (به عنوان مثال ۱:۲۵۰۰۰) مورد طراحی و برنامه‌ریزی قرار گیرد.

تحت تاثیر تعداد و دامنه کلاس‌های انتخابی قرار گرفته و اهمیت نسبی داده‌های اکتشافی در هر کلاس از نقشه‌های شاهد سنجیده نمی‌شود، در نتیجه چنین نقشه‌هایی نمی‌توانند عدم قطعیت را به خوبی مدل کنند. به همین دلیل استفاده از روش‌های پیوسته پیشنهاد می‌گردد که در آن لایه‌های شاهد وزن‌دار با استفاده از توابع لجستیکی و بدون استفاده از قضاوت شخصی تولید می‌شوند. در نتیجه، این روش بر وزن‌دهی جهت‌دار (خطای سیستماتیک و تصادفی ناشی از روش‌های داده‌محور و دانش‌محور) غلبه کرده و می‌تواند عدم قطعیت را به خوبی مدل کند. به همین منظور در این پژوهش از تابع غیرخطی لجستیکی برای تولید نقشه‌های شاهد پیوسته برای مدلسازی پتانسیل معدنی مس پورفیری در منطقه چهارگنبد استفاده شده است. مقایسه نتایج تلفیق لایه‌های وزن‌دار با دو روش ترکیب متفاوت میانگین هندسی (بدون استفاده از نمونه‌های آموزشی) و روش شبکه عصبی مصنوعی ELM (با استفاده از نمونه‌های آموزشی) اثبات کرد که مدل پتانسیل تولید شده با استفاده از روش داده‌محور شبکه عصبی با داشتن مقدار کارایی کلی  $(O_e)$  برابر ۰٫۳۴ بهتر از مدل پتانسیل تولید شده با استفاده از روش میانگین هندسی با مقدار کارایی کلی  $(O_e)$  برابر ۰٫۲۷ است. البته لازم به تاکید است که روش میانگین هندسی نیاز به داده‌های آموزشی نداشته و می‌تواند در مناطق فاقد اندیس شناخته شده به خوبی عمل کند.

## ۸- سپاس‌گزاری

مقاله حاضر بخشی از پایان‌نامه کارشناسی ارشد دانشگاه بین‌المللی امام خمینی (ره) است که نویسندگان از حمایت‌های آنان تشکر می‌کنند. همچنین از داوران محترم که با نظرات خود موجب ارتقای سطح مقاله شدند نهایت سپاسگزاری به عمل می‌آید. از شرکت ملی صنایع مس ایران و سازمان زمین‌شناسی و اکتشافات معدنی کشور جهت در اختیار قرار دادن داده‌ها قدردانی می‌شود.

## ۹- مراجع

- Methods in the Geoscientists, Pergamon, Oxford, 13: 398.
- [10] Porwal, A., Carranza, E. J. M., and Hale, M. (2004). "A hybrid neuro-fuzzy model for mineral potential mapping". *Mathematical Geology*, 36: 803-826.
- [11] Carranza, E. J. M. (2008). "Geochemical anomaly and mineral prospectivity mapping in GIS". Elsevier, 11: 365.
- [12] Porwal, A., and Kreuzer, O. P. (2010). "Introduction to the Special Issue: Mineral prospectivity analysis and quantitative resource estimation". *Ore Geology Reviews* 38: 121-127.
- [13] Kreuzer, O. P., Miller, A. V., Peters, K. J., Payne, C., Wildman, C., Partington, G. A., Puccioni, E., McMahon, M. E., and Etheridge, M. A. (2015). "Comparing prospectivity modelling results and past exploration data: A case study of porphyry Cu-Au mineral systems in the Macquarie Arc, Lachlan Fold Belt, New South Wales". *Ore Geology Reviews*, 71: 516-544.
- [14] Yousefi, M., and Nykänen, V. (2017). "Introduction to the special issue: GIS-based mineral potential targeting". *Journal of African Earth Sciences*, 12: 1-4.
- [15] Yousefi, M., and Nykänen, V. (2016). "Data-driven logistic-based weighting of geochemical and geological evidence layers in mineral prospectivity mapping". *Journal of Geochemical Exploration*, 164: 94-106.
- [۱۶] شهبایی فر، م.؛ ۱۳۸۳؛ "تخمین ذخیره کانسار با تکنیک شبکه عصبی مصنوعی". کنفرانس مهندسی معدن ایران، ۱۲ تا ۱۴ بهمن، دانشگاه تربیت مدرس، ایران.
- [۱۷] طهماسبی، پ.، هزارخانی، ا.؛ ۱۳۸۸؛ "ارائه روشی برای بهینه سازی شبکه عصبی برای برآورد عیار با استفاده از اطلاعات سیستم مس پورفیری سوناجیل-اهر". فصل‌نامه علوم زمین، سال بیست و یکم، شماره ۸۱، ص ۳۱-۳۶.
- [۱۸] طهماسبی، پ.، هزارخانی، ا.؛ ۱۳۹۰؛ "استفاده از شبکه های عصبی-فازی-ژنتیکی به منظور تخمین عیار در کانسار مس پرفیری دره زار-کرمان". نشریه مهندسی معدن ایران، دوره ششم، شماره ۱۲، ص ۱-۹.
- [۱۹] درویشی، م.، شیوا، ج.؛ ۱۳۹۰؛ "تخمین عیار مس در اکتشافات ژئوشیمیائی رسوبات رودخانه ای توسط روش شبکه عصبی پرسپترون چند لایه در منطقه غرب تالش-گیلان". اولین همایش ملی مس، تهران.
- [۲۰] مجدی فر، س.، کمالی، غ.؛ ۱۳۹۲؛ "تخمین عیار آهن در آنومالی تپه قرمز معدن سنگ آهن سنگان با استفاده از سه الگوریتم فازی عصبی تطبیقی". نشریه روش های تحلیلی و عددی در مهندسی معدن، شماره ۵، ص ۱-۱۰.
- [1] Hronsky, J. M. A., and Groves, D. I. (2008). "Science of targeting: definition, strategies, targeting and performance measurement". *Australian Journal of Earth Sciences*, 55(1): 3-12.
- [2] Davis, W. E., Jackson, W. H., and Richter, D. H. (1957). "Gravity prospecting for chromite deposits in Camaguey province, Cuba". *Geophysics*, 22: 848-869.
- [3] Bhattacharya, B. B., Mallick, K., and Roy, A. (1969). "Gravity prospecting for chromite at Sukinda and Sukrangi, Cuttack District, Orissa (India)". *Geoexploration*, 7: 201-240.
- [4] Bayrak, M. (2002). "Exploration of chrome ore in Southwestern Turkey by VLF-EM". *Journal of the Balkan Geophysical Society*, 5: 35-46.
- [5] Mohanty, W. K., Mandal, A., Sharma, S. P., Gupta, S., and Misra, S. (2011). "Integrated geological and geophysical studies for delineation of chromite deposits: A case study from Tangarparha, Orissa". *Geophysics*, 76: 173-185.
- [6] Rajendran, S., Al-Khribash, S., Pracejus, B., Nasir, S., Al-Abri, A. H., Kusky, T. M., and Ghulam, A. (2012). "ASTER detection of chromite bearing mineralized zones in Semail Ophiolite Massifs of the northern Oman Mountains: Exploration strategy". *Ore Geology Reviews*, 44: 121-135.
- [7] Pournamdari, M., and Hashim, M. (2014). "Detection of chromite bearing mineralized zones in Abdasht ophiolite complex using ASTER and ETM+ remote sensing data". *Arabian Journal of Geosciences*, 7: 1973-1983.
- [8] Aşçi, M., and Bayat, C. (2015). "Chrome mine exploration by microgravity method in Fenk plateau, Osmaniye, Turkey". In EGU General Assembly Conference Abstracts, pp. 17.
- [9] Bonham-Carter, G. F. (1994). "Geographic information systems for geoscientists modeling with GIS". *Computer*

- toolbox for use with MATLAB". The Math Works Incorporated, USA, pp. 840.
- [33] Huang, G. B., Yu Zhu, Q., and Siew, Ch. Kh. (2006). "Extreme Learning Machine: Theory and Applications". Neurocomputing, 70: 489-501.
- [34] Haupt, R. L., and Haupt, S. E. (2004). "Practical Genetic Algorithms". 2nd edn with CD-ROM. John Wiley & Sons, New York, NY.
- [35] Yousefi, M., and Carranza, E. J. M. (2016). "Data-driven index overlay and Boolean logic mineral prospectivity modeling in Greenfields exploration". Natural Resources Research, 25: 3-18.
- [36] Hezarkhani, A. (2006). "Petrology of the intrusive rocks within the Sungun porphyry copper deposit, Azerbaijan, Iran". Journal of Asian Earth Sciences, 27: 326-340.
- [37] Boomeri, M., Nakashima, K., and Lentz, D. R. (2009). "The Miduk porphyry Cu deposit, Kerman, Iran: a geochemical analysis of the potassic zone including halogen element systematics related to Cu mineralization processes". Journal of Geochemical Exploration, 103: 17-29.
- [38] Sillitoe, R. H. (1972). "A plate tectonic model for the origin of porphyry copper deposits". Economic Geology, 67: 184-197.
- [39] Sillitoe, R. H. (1997). "Characteristics and controls of the largest porphyry copper-gold and epithermal gold deposits in the circum-Pacific region". Australian Journal of Earth Sciences, 44: 373-388.
- [40] Sillitoe, R. H. (2010). "Porphyry copper systems". Economic Geology, 105: 3-41.
- [41] Tangestani, M. H., and Moore, F. (2001). "Comparison of three principal component analysis techniques to porphyry copper alteration mapping. A case study, Meiduk area, Kerman, Iran". Canadian Journal of Remote Sensing, 27: 176-182.
- [42] Carranza, E. J. M., and Hale, M. (2002a). "Where are porphyry copper deposits spatially localized? A case study in Benguet province, Philippines". Natural Resources Research, 11: 45-59.
- [43] Peytcheva, I., Quadt, A.V., Neubauer, F., Frank, M., Nedialkov, R., Heinrich, C., and Strashimirov, S. (2009). "U-Pb dating, Hf-isotope characteristics and trace REE patterns of zircons from Medet porphyry copper deposit, Bulgaria: implications for timing, duration and sources of ore-bearing magmatism". Mineral petroleum, 96: 19-41.
- [44] Pazand, K., Hezarkhani, A., Ataei, M., and Ghanbari, [21] کریمی، الف؛ ۱۳۹۵؛ "تعیین نشانگرهای ژئوفیزیکی IP/RS مرتبط با مقادیر عیار و تخمین عیار در معدن طلای زرشوران با استفاده از تکنیک شبکه عصبی مصنوعی". پایان نامه کارشناسی ارشد، دانشکده فنی و مهندسی، دانشگاه بین المللی امام خمینی (ره).
- [22] Huang, G., Huang, G. B, Song, S., and You, K. (2015). "Trends in Extreme Learning Machines: A Review". Neural Networks, 61: 32-48.
- [23] Luo, X., Yang, X., Chang, X., and Zhang, Ch. (2015). "Prediction of Hidden Dangers in Mine Production Using Timeliness Managing Extreme Learning Machine for Cloud Services". IEEE Computer Society, 10: 1109.
- [24] Wang, X., Lib, Y., Chenc, T., Yana, Q., and Ma, L. (2017). "Quantitative thickness prediction of tectonically deformed coal using Extreme Learning Machine and Principal Component Analysis: a case study". Computers and Geosciences, 101: 38-47.
- [25] یوسفی، م.، خالوکاکایی، ر.؛ ۱۳۸۳؛ "مدل‌سازی پتانسیل معدنی طلا و فلزات پایه در ناحیه ماهنشان با استفاده از سیستم اطلاعات جغرافیایی". کنفرانس مهندسی معدن ایران، ص ۱۷-۱.
- [26] Berberian, F., Muir, I. D., Pankhurst, R. J., and Berberian, M. (1982). "Late cretaceous and early miocene andean-type plutonic activity in northern Makran and central". Journal of the Geological Society, 139(5): 605-614.
- [27] Afzal, P., Eskandarnejad Tehrani, M., Ghaderi, M., and Hosseini, M. R. (2016). "Delineation of supergene enrichment, hypogene and oxidation zones utilizing staged factor analysis and fractal modeling in Takht-e-Gonbad porphyry deposit, SE Iran". Journal of Geochemical Exploration, 161: 119-127.
- [28] Monjezi, M., and Dehghani, H. (2008). "Evaluation of effect of blasting pattern parameters on back break using neural networks". International Journal of Rock Mechanics and Mining Sciences, 45(8): 1446-1453.
- [29] Acharya, C., Mohanty, S., Sukla, L., and Misra, V. (2006). "Prediction of sulphur removal with Acidithiobacillus sp. using artificial neural networks". Ecological Modelling, 190(1): 223- 230.
- [30] Yasrebi, A. B., Hezarkhani, A., Afzal, P., Karami, R., Eskandarnejad Tehrani, M., and Borumandnia, A. (2020). "Application of an ordinary kriging-artificial neural network for elemental distribution in Kahang porphyry deposit, Central Iran". Arabian Journal of Geosciences, 13(15): 1-14.
- [31] Hagan, M. T., Demuth, H. B., and Beale, M. H. (2002). "Neural network design. Campus Publishing Service". University of Colorado Bookstore, USA, pp. 736.
- [32] Demuth, H., and Beale, M. (2002). "Neural network

- J. M. (2014). "Application of staged factor analysis and logistic function to create a fuzzy stream sediment geochemical evidence layer for mineral prospectivity mapping, *Geochemistry: Exploration*". *Geochemistry: Exploration, Environment, Analysis*, 14(1): 45-58.
- [56] Filzmoser, P., Hron, K., and Reimann, C. (2009). "Univariate statistical analysis of environmental (compositional) data: problems and possibilities". *Science of the Total Environment*, 407: 6100-6108. *Environment, Analysis*, 14: p45-58.
- [57] Egozcue, J. J., Pawlowsky-Glahn, V., Mateu-Figueras, G., and Barcelo-Vidal, C. (2003). "Isometric logratio transformations for compositional data analysis". *Mathematical Geology*, 35: 279-300.
- [58] Carranza, E. J. M. (2011). "Analysis and mapping of geochemical anomalies using logratio transform stream sediment data with censored values". *Journal of Geochemical Exploration*, 110: 167-185.
- [59] Kaiser, H. F. (1958). "The varimax criteria for analytical rotation in factor analysis". *Psychometrika*, 23: 187-200.
- [60] Afzal, P., Yousefi, M., Mirzaie, M., Ghadiri-Sufi, E., Ghasemzadeh, S., and Daneshvar Saein, L. (2019). "Delineation of podiform-type chromite mineralization using geochemical mineralization prospectivity index and staged factor analysis in Balvard area (SE Iran)". *Journal of Mining and Environment*, 10(3): 705-715.
- [61] Zuo, R. (2011). "Identifying geochemical anomalies associated with Cu and Pb-Zn skarn mineralization using principal component analysis and spectrumearea fractal modeling in the Gangdese Belt, Tibet (China)". *Journal of Geochemical Exploration*, 111: 13-22.
- [62] Bonham-Carter, G. F. (1994). "Geographic Information Systems for Geoscientists: Modelling with GIS". Pergamon, Oxford.
- [63] Carranza, E. J. M. (2008). "Geochemical anomaly and Mineral Prospectivity Mapping in GIS, *Handbook of Exploration and Environmental Geochemistry*". Vol. 11, Elsevier, Amsterdam.
- [64] Brown, W. M., Gedeon, T. D., and Groves, D. I. (2003). "Use of noise to augment training data: a neural network method of mineral potential mapping in regions of limited known deposit examples". *Natural Resources Research*, 12(3), 141-152.
- [65] Yousefi, M., and Carranza, E. J. M. (2015). "Prediction-area (P-A) plot and C-A fractal analysis to classify and evaluate evidential maps for mineral prospectivity modeling". *Computers & Geosciences*, 79: 69-81.
- [66] Nyka'nen, V. (2008). "Radial basis functional link nets
- Y. (2011). "Combining AHP with GIS for predictive Cu porphyry potential mapping: a case study in Ahar area (NW, Iran)". *Natural Resources Research*, 20: 251-262.
- [45] Pirajno, F. (2010). "Intracontinental strike-slip faults, associated magmatism, mineral systems and mantle dynamics: examples from NW China and Altay-Sayan (Siberia)". *Journal of Geodynamics*, 50: 325-346.
- [46] Carranza, E. J. M. (2004). "Weights of evidence modeling of mineral potential: a case study using small number of prospects, Abra, Philippines". *Natural Resources Research*, 13: 173-187.
- [47] Carranza, E. J. M. (2008). "Geochemical anomaly and Mineral Prospectivity Mapping in GIS". *Handbook of Exploration and Environmental Geochemistry*, vol. 11, Elsevier, Amsterdam, pp. 368.
- [48] Fakhari, S., Jafarira, A., Afzal, P., and Lotfi, M. (2019). "Delineation of hydrothermal alteration zones for porphyry systems utilizing ASTER data in Jebal-Barez area, SE Iran". *Iranian Journal of Earth Sciences*, 11(1): 80-92.
- [49] Gholami, R., Moradzadeh, A., and Yousefi, M. (2012). "Assessing the performance of independent component analysis in remote sensing data processing". *Journal of Indian Society of Remote Sensing*, 40: 577-588.
- [50] Ranjbar, H., Masoumi, F., and Carranza, E. J. M. (2011). "Evaluation of geophysics and spaceborne multispectral data for alteration mapping in Sar Chesmeh mining area". *International Journal of Remote Sensing*, 32: 3309-3327.
- [51] Tangestani, M. H., and Moore, F. (2002). "Porphyry copper alteration mapping in the Meiduk area, Iran". *International Journal of Remote Sensing*, 23: 4815-4825.
- [52] Beiranvand Pour, A., and Hashim, M. (2011). "Identification of hydrothermal alteration minerals for exploring of porphyry copper deposit using ASTER data, SE Iran". *Journal of Asian Earth Sciences*, 42: 1309-1323.
- [53] Carranza, E. J. M., and Hale, M. (1997). "A catchment basin approach to the analysis of geochemical-geological data from Albay province, Philippines". *Journal of Geochemical Exploration*, 60: 157-171.
- [54] Yousefi, M., Kamkar-Rouhani, A., and Carranza, E. J. M. (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". *Journal of Geochemical Exploration*, 115: 24-35.
- [55] Yousefi, M., Kamkar-Rouhani, A., and Carranza, E.



72-79.

[75] Yousefi, M., and Carranza, E. J. M. (2017). "Union score and fuzzy logic mineral prospectivity mapping using discretized and continuous spatial evidence values". *Journal of African Earth Sciences*, 128: 47-60.

used as a prospectivity mapping tool for orogenic gold deposits within the Central Lapland Greenstone Belt Northern Fennoscandian Shield". *Natural Resources Research*, 17: 29-48.

[67] Nykänen, V., Lahti, I., Niiranen, T., and Korhonen, K. (2015). "Receiver operating characteristics (ROC) as validation tool for prospectivity models—A magmatic Ni–Cu case study from the Central Lapland Greenstone Belt, Northern Finland". *Ore Geology Reviews*, 71: 853-860.

[68] Chen, Y. (2015). "Mineral potential mapping with a restricted Boltzmann machine". *Ore Geology Reviews*, 71: 749-760.

[69] Zuo, R. (2018). "Selection of an elemental association related to mineralization using spatial analysis". *Journal of Geochemical Exploration*, 184: 150-157.

[70] Chen, Y., and Wu, W. (2016). "Mapping mineral prospectivity using an extreme learning machine regression". *Ore Geology Reviews*, 80: 200-213.

[71] Roshanravan, B., Aghajani, H., Yousefi, M., and Kreuzer, O. (2018). "An improved Prediction-Area plot for prospectivity analysis of mineral deposit". *Natural Resources Research*, 28: 1089-1105.

[72] Yousefi, M., Kreuzer, O. P., Nykänen, V., and Hronsky, J. M. A. (2019). "Exploration information systems—a proposal for the future use of GIS in mineral exploration targeting". *Geology Reviews*, 111: 103005.

[73] Yousefi, M., and Carranza, E. J. M. (2015). "Fuzzification of continuous-value spatial evidence for mineral prospectivity mapping". *Computers & Geosciences*, 74: 97-109.

[74] Yousefi, M., and Carranza, E. J. M. (2015). "Geometric average of spatial evidence data layers: A GIS-based multi-criteria decision-making approach to mineral prospectivity mapping". *Computers & Geosciences*, 83:

<sup>1</sup> Extreme learning machine

<sup>2</sup> Back propagation

<sup>3</sup> Support vector machines

<sup>4</sup> Timeliness managing extreme learning machine

<sup>5</sup> On-line sequential extreme learning machine

<sup>6</sup> Principal component analysis

<sup>7</sup> Single hidden layer feedforward neural network

<sup>8</sup> Nonlinear Piecewise Continuous Function

<sup>9</sup> Fault density

<sup>10</sup> Staged-factor analysis

<sup>11</sup> Isometric logarithmic reformation

<sup>12</sup> Geochemical mineralization probability index

<sup>13</sup> Inverse distance weighting

<sup>14</sup> Overtrain

<sup>15</sup> Training time

<sup>16</sup> Testing time

<sup>17</sup> Training accuracy

<sup>18</sup> Testing accuracy

<sup>19</sup> Prediction-Area

<sup>20</sup> Equal Interval

<sup>21</sup> Overall efficiency



## Recognizing Porphyry Copper Mineralization Targets in Chahar-Gonbad Area of Kerman Province Using Extreme Learning Intelligent Method

Ghadiyanloo M.<sup>1</sup>, Alimoradi A.<sup>2</sup>, Yousefi M.<sup>3\*</sup>

1- M.Sc Student, Dept. of Mining Engineering, Faculty of Technical & Engineering, Imam Khomeini International University, Qazvin, Iran

mm.ghadiyanloo@gmail.com

2- Assistant professor, Dept. of Mining Engineering, Faculty of Technical & Engineering, Imam Khomeini International University, Qazvin, Iran

alimoradi@eng.ikiu.ac.ir

3- Associate Professor, Dept. of Mining Engineering, Malayer University, Malayer, Iran

m.yousefi.eng@gmail.com

(Received: 04 Sep. 2020, Accepted: 02 Dec. 2020)

**Abstract:** Selection of training sites is an important and critical undertaking in the modeling procedure of mineral exploration targets using artificial intelligence approaches. This is because application of improper training algorithms results in exploration targeting models that carry bias and uncertainty. The present study aims to model exploration targets of porphyry copper mineralization in Chahar-Gonbad area, Kerman province, Iran, using artificial neural networks. In this regard, continuous weighted evidence maps of exploration criteria including proximity to intrusive contacts, fault density, multi-element geochemical signature and proximity to iron-oxide and argillic alterations were generated and applied as inputs to the neural network. Subsequently, 16 points with known mineral deposits and 16 points without mineralization were used to train the neural network through extreme learning algorithm. The ensuing exploration targeting model was compared with a model obtained by using geometric average integration method through prediction-area plot. The overall efficiency of the models are 0.34 and 0.27, respectively. Evaluation of the models demonstrated that the areas with high copper mineralization potential, marked as exploration targets, are in good conformity with known copper occurrences as well as with geological indicator features. Thus, the targets can be planned for further exploration programs.

**Keywords:** Continuous weighting method, Logistic function, Chahar-Gonbad area, Artificial neural networks, Exploration targets.

### INTRODUCTION

Mineral potential models are generated at any exploration scale, from regional to local, to delineate mineral exploration targets [1]. Many mineral deposits are hidden and buried, and so, do not show direct visible evidence. Thus, discovering ore deposition sites has been always an exploration challenge [2,3]. In



this regard, according to the presence of geological indicator features and spatial proxies of mineralization such as alterations, geochemical anomalies, and structural features, the possible occurring of mineralization events are investigated through mineral prospectivity analysis [4-6].

General methods of generating weighted evidence layers for use in mineral exploration targeting are categorised into knowledge-driven, data-driven, hybrid and logistic-based continuous approaches [1-3,7]. The knowledge-driven methods are used in areas where there are no or a few number of known deposits [8]. If there are sufficiently known deposits in an area, data-driven modelling methods can be used to determine exploration targets [2,3,7,8]. In continuous weighting methods, the spatial positions of mineralization events, or so called as training points, are not used in the modelling procedure [8]. Furthermore, the exploration spatial data, representing mineralization, are not discretised using arbitrary intervals. As a result, this method overcomes the bias and uncertainty in the weighting procedures [9].

Extreme Learning Machine (ELM) was developed to address previous shortcomings of supervised methods and was found to be significantly more efficient than other algorithms. Huang et al. used three algorithms, including Back Propagation (BP), Support Vector Machine (SVM), and ELM, to process satellite imagery to study plants and diabetes, and the results showed that the ELM algorithm is significantly more efficient than others [10]. Luo et al. used Timeliness Managing Extreme Learning Machine (TMELM), On-line Sequential Extreme Learning Machine (OSELM) and, ELM algorithms to investigate possible coal mine accidents during mineral production [11]. The results proved the superiority of ELM algorithm over two other algorithms. Wang et al. examined the data of a coal mine located in western China, using Principal Component Analysis (PCA) and the ELM algorithm, to investigate and determine the model of deposit thickness, and observed that the accuracy of the ELM algorithm is high in generalization and education [12].

Following the above-mentioned researches, this paper aims to evaluate the efficiency of ELM training algorithm in prospectivity analysis and data integration for exploration targeting through artificial neural network and to compare its effectiveness with geometric average integration method [6].

## METHODS

In this research, a nonlinear logistic function was applied to generate continuously-weighted evidence maps for modelling exploration targets. For this five weighted layers including proximity to host rock, fault density, geochemical signature, and proximity to Iron oxide and argillic alterations were generated. The weighted maps were then integrated with two different methods, geometric average (without using training samples) [5] and artificial neural network (using training samples) [10]. Finally the models were compared by prediction-area plot [8]. In order to better illustrate and evaluate the methods used in this paper, exploration data of porphyry copper deposits in Chahar-Gonbad region of Kerman province, Iran, were applied (Figure1).

## FINDINGS AND ARGUMENT

Continuous weighting methods, unlike the existing conventional data-driven, knowledge-driven and hybrid approaches, do not require classification and then weight allocation to the classes of spatial data [1]. Thus, by using the continuous weighting methods, the drawbacks of the conventional methods are modulated. In the continuous weighting method, fuzzy weights are assigned to the continuous exploration values using logistic functions [5]. Figure 2 shows the continuous weighted maps in this study. In this method, the known deposit locations and expert's opinion are not used for weighting [4]. After generation of the continuously-weighted evidence layers, they were integrated by geometric average function (Figure 3A) and neural network method (Figure 4A). The exploration targeting models were then classified for prioritization of the area for further exploration programs (Figures 3B and 4B) [13].

To assess the ability of the two models generated, in terms of predicting undiscovered mineralization, location of 16 known mineral deposits and 16 non-deposit locations (without mineralization) were applied two make the prediction-area plots (Figure 5) [5,14]. In this plot, there are three curves, namely the curve of (1) the prediction rate of mineral deposit corresponding to the prospectivity classes (MDL), (2) the percentage of the areas occupied by the corresponding classes of mineral prospectivity (Area), and (3) the prediction rate of non-deposit locations corresponding to the prospectivity classes (NDL) [5,14]. The

comparison demonstrated that the potential model produced with the use of neural network data-driven method with an overall efficiency of 0.34 is better than the potential model produced using the geometric average method with an overall efficiency of 0.27. It should be emphasized that the geometric average method does not require training data and can work well in areas without known mineral deposits.


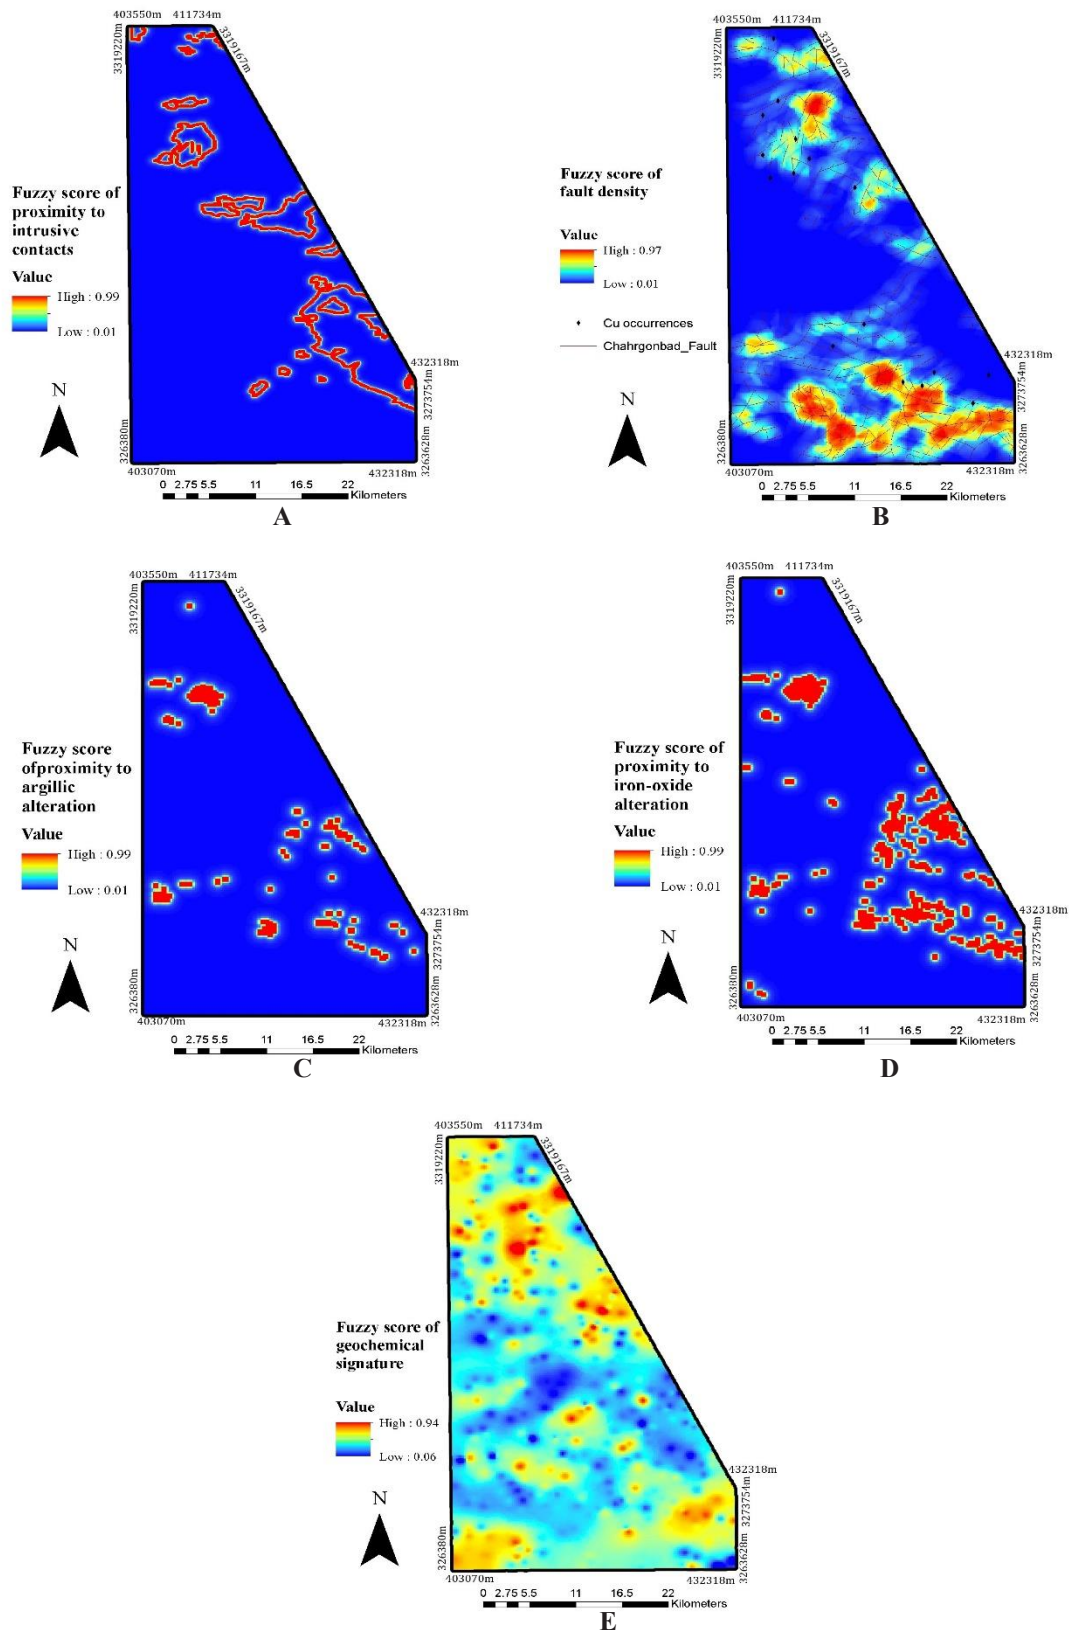


Figure 1. A: Location of the study area in Iran and B: its simplified geological map



**Figure 2.** Continuously-weighted evidence layer of **A:** proximity to intrusive rocks, **B:** fault density, **C:** proximity to argillic alteration, **D:** proximity to iron-oxide alteration, and **E:** multi element geochemical signature

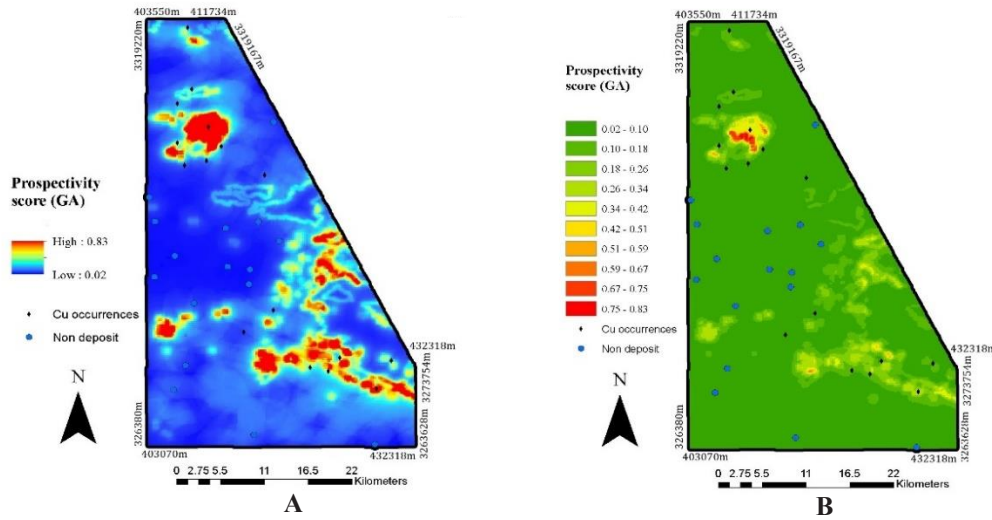


Figure 3. A: Geometric average exploration targeting model and B: model of the ensuing classified targets

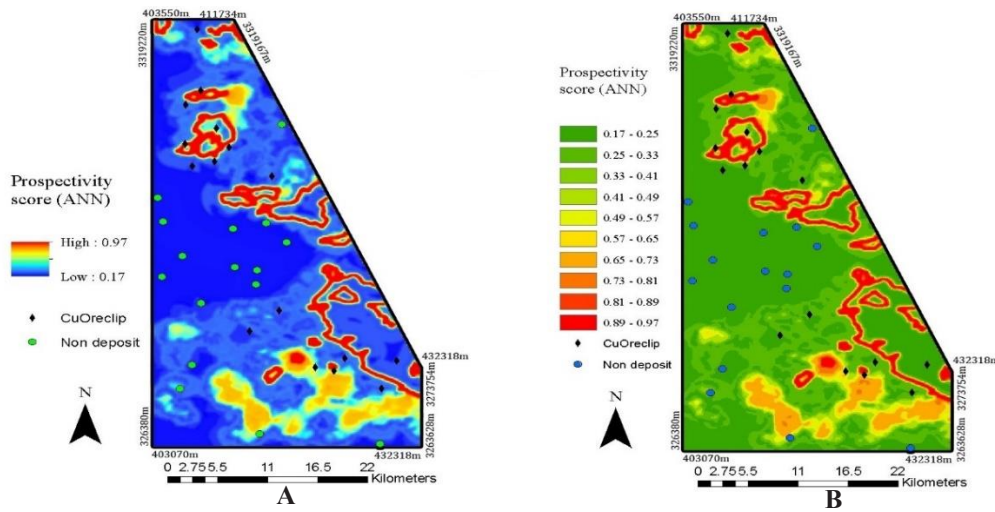


Figure 4. A: Artificial neural network exploration targeting model and B: model of the ensuing classified targets

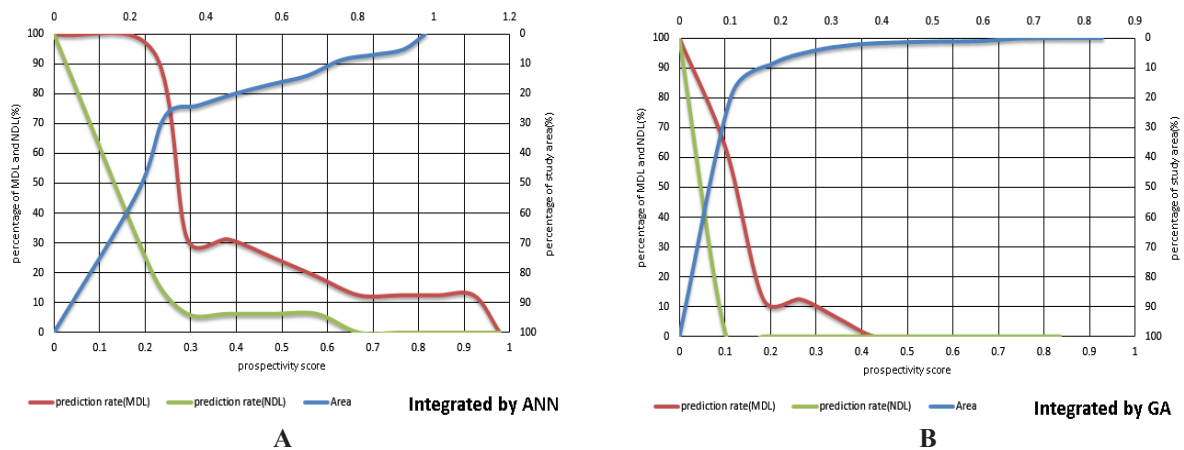


Figure 5. Prediction-area plot for exploration targeting model using A: the geometric average and B: artificial neural network methods

## CONCLUSIONS

Findings of this paper can be remarked as below:

- Extreme learning machine can efficiently be used to train artificial neural networks for the purpose of increasing the exploration success of targeting models. That is due to the various activation functions, strong ability in data analysis, high accuracy in generalization and training, and fast processing time of the ELM algorithm.
- It is suggested to design further exploration programs by focusing on the targets generated in the present study in order to vectoring towards undiscovered mineral deposit sites.

## ACKNOWLEDGMENT

The authors thank geological Survey of Iran (GSI) for supplying necessary data to do this research work. We would also like to thank the respected reviewers who their comments helped us to improve this paper. The National Iranian Copper Industries Company is appreciated for providing some of the data.

## REFERENCES

- [1] Yousefi, M., Kreuzer, O. P., Nykänen, V., and Hronsky, J. M. A. (2019). "Exploration information systems—a proposal for the future use of GIS in mineral exploration targeting". *Geology Reviews*, 111: 103005.
- [2] Bonham-Carter, G. F. (1994). "Geographic Information Systems for Geoscientists: Modelling with GIS". Pergamon, Oxford.
- [3] Carranza, E. J. M. (2008). "Geochemical anomaly and Mineral Prospectivity Mapping in GIS, Handbook of Exploration and Environmental Geochemistry". Vol. 11, Elsevier, Amsterdam.
- [4] Yousefi, M., and Carranza, E. J. M. (2015). "Fuzzification of continuous-value spatial evidence for mineral prospectivity mapping". *Computers & Geosciences*, 74: 97-109.
- [5] Yousefi, M., and Carranza, E. J. M. (2015). "Prediction-area (P-A) plot and C-A fractal analysis to classify and evaluate evidential maps for mineral prospectivity modeling". *Computers & Geosciences*, 79: 69-81.
- [6] Yousefi, M., and Carranza, E. J. M. (2015). "Geometric average of spatial evidence data layers: A GIS-based multi-criteria decision-making approach to mineral prospectivity mapping". *Computers & Geosciences*, 83: 72-79.
- [7] Yousefi, M., and Carranza, E. J. M. (2016). "Data-driven index overlay and Boolean logic mineral prospectivity modeling in Greenfields exploration". *Natural Resources Research*, 25: 3-18.
- [8] Yousefi, M., and Carranza, E. J. M. (2017). "Union score and fuzzy logic mineral prospectivity mapping using discretized and continuous spatial evidence values". *Journal of African Earth Sciences*, 128: 47-60.
- [9] Yousefi, M., and Nykänen, V. (2016). "Data-driven logistic-based weighting of geochemical and geological evidence layers in mineral prospectivity mapping". *Journal of Geochemical Exploration*, 164: 94-106.
- [10] Huang, G., Huang, G. B., Song, S., and You, K. (2015). "Trends in Extreme Learning Machines: A Review". *Neural Networks*, 61: 32-48.
- [11] Luo, X., Yang, X., Chang, X., and Zhang, Ch. (2015). "Prediction of Hidden Dangers in Mine Production Using Timeliness Managing Extreme Learning Machine for Cloud Services". *IEEE Computer Society*, 10: 1109.
- [12] Wang, X., Lib, Y., Chenc, T., Yana, Q., and Ma, L. (2017). "Quantitative thickness prediction of tectonically deformed coal using Extreme Learning Machine and Principal Component Analysis: a case study". *Computers and Geosciences*, 101: 38-47.
- [13] Carranza, E. J. M. (2008). "Geochemical anomaly and mineral prospectivity mapping in GIS". Elsevier, 11: 365.
- [14] Roshanravan, B., Aghajani, H., Yousefi, M., and Kreuzer, O. (2018). "An improved Prediction-Area plot for prospectivity analysis of mineral deposit". *Natural Resources Research*, 28: 1089-1105.