

مدل‌سازی توزیع کانه‌زایی در عمق کانسار با استفاده از داده‌های سطحی در نواحی فاقد حفاری در محدوده اکتشافی کال کافی، استان اصفهان

سعید اسماعیل اوغلی؛ بهنام تقوی

چکیده

پیش‌بینی نواحی امیدبخش کانه‌زایی زیرسطحی و تعیین اولویت‌های عملیاتی جهت مطالعات تفصیلی، اهدافی کلیدی در مهندسی اکتشاف مواد معدنی هستند. سیستم متالوژنیک کال کافی در شمال شرق استان اصفهان و در محدوده شرقی بخش انارک، از توابع شهرستان نائین واقع شده است. در این محدوده، فرآیندهای هیدروترمال کانه‌ساز منجر به پیدایش کانه‌زایی طلای پلی‌متال در تیپ‌های رگه‌ای شده است. علی‌رغم این که بخش‌هایی از منطقه مطالعاتی تحت حفاری قرار گرفته‌اند، اما سایر نواحی همچنان نیازمند مطالعات تفصیلی جهت طراحی اکتشافات عمیق هستند. لذا این پژوهش با هدف استفاده از داده‌های اکتشافی سطح زمین برای مدل‌سازی الگوی کانه‌زایی زیرسطحی در نواحی فاقد حفاری اجرا شده است. راهکار پیشنهاد شده برای حل این مسئله، استفاده از تکنولوژی‌های نوین پردازش داده برای آموزش شبکه‌های هوش مصنوعی به منظور بازشناسی الگوی کانه‌زایی زیرسطحی است. در این رویکرد، با تولید داده‌های آموزشی در نقاط حفاری و با استفاده از مدل‌های هوش مصنوعی، ارتباطات آماری خطی یا غیرخطی میان داده‌های عمق (عبارهای طلای ثبت شده در حفاری‌ها) و سطح زمین (اطلاعات اکتشافی پیشگوی کانه‌زایی) استخراج شده و توابع طبقه‌بندی حاصل به داده‌های اکتشافی در مناطق فاقد حفاری اعمال می‌شوند تا الگوهای کانه‌زایی طلا در نواحی عمیق محدوده مطالعاتی حاصل شوند. نقشه‌های پتانسیل کانه‌زایی حاصل از مدل‌های یادگیری مختلف با یکدیگر تلفیق شده و الگوی اکتشافی نهایی را جهت تعریف اهداف اکتشافی جدید تولید می‌کنند. مدل‌سازی توزیع فضایی احتمالات کانه‌زایی و عدم قطعیت‌های وابسته به آن توانسته است بینش کاربردی کارآمدی جهت مدیریت و طراحی بهینه اکتشافات آتی در محدوده کال کافی به ارمغان آورد.

کلید واژه‌ها: اکتشاف معدن، کانه‌زایی، هوش مصنوعی، حفاری، کال کافی.

Modeling deep mineralization using surface exploration data of undrilled regions in Kal-e-Kafi prospect area, Isfahan Province

Abstract

Prediction of prospective subsurface mineralization areas and determining operational priorities for detailed studies are key goals in mineral exploration engineering. Kal-e-Kafi metallogenic system is located in the north-east of Isfahan province and in the eastern border of Anark district, Naein city. In this region, hydrothermal ore-forming processes have led to the emergence of polymetallic gold mineralization in vein types. Although parts of the study area have been drilled, other areas still need detailed studies to design deep explorations. Therefore, this research has been carried out with the aim of using exploration data of the earth's surface to model the pattern of subsurface mineralization in areas without drilling. The proposed solution to solve this is to use new data processing technologies to train artificial intelligence models in order to recognize subsurface mineralization patterns. In this approach, by producing training data in drilling points and using artificial intelligence models, linear or non-linear statistical relationships between depth data (gold grades recorded in drilling) and surface data (predictive exploration information) are extracted and the resulting classification functions are applied to exploration data in undrilled areas in order to obtain patterns of gold mineralization in the deep areas of the study area. Mineralization potential maps obtained from different models are combined with each other and produce the final exploration model to define new exploration targets. Spatial distribution modeling of mineralization probabilities and uncertainties related to it has been able to bring efficient practical insight for the management and optimal design of future discoveries within the Kal-e-Kafi prospect area.

Keywords: Mineral exploration, Mineralization, Artificial intelligence, Drilling, Kal-e-Kafi.

۱. مقدمه

داده‌های زیرسطحی) کشف گردد. در گام نهایی، توابع آموزش دیده به سلول‌های فاقد برچسب در شبکه سطح اعمال می‌شوند تا بر اساس ویژگی‌های پیشگوی معین در آن‌ها، کلاس کان‌زایی زیرسطحی تعیین شده و نقشه پتانسیل کان‌زایی در عمق منطقه مدل‌سازی گردد.

در این تحقیق، الگوریتم‌های یادگیری متنوعی برای بازشناسی الگوی کان‌زایی مورد مطالعه قرار گرفته‌اند. تکنیک‌های SVM، LR و RF روش‌های قدرتمند هوش مصنوعی هستند که می‌توانند قابلیت‌های مناسبی جهت پیشگویی پتانسیل کان‌زایی زیرسطحی در منطقه معدنی کال کافی داشته باشند. علاوه بر مدل‌های هوش مصنوعی، در این پژوهش از یک رویکرد یادگیری عمیق تحت عنوان شبکه عصبی عمیق تماماً متصل (FCDNN) نیز برای برآورد نواحی امیدبخش کان‌زایی زیرسطحی در منطقه معدنی کال کافی استفاده می‌شود. مدل‌های یادگیری عمیق از توانایی بالاتری جهت پردازش و بازشناسی الگوهای اکتشافی پیچیده و غیرایستا در سیستم‌های زمین‌شناسی غیرخطی برخوردار هستند.

بررسی صحت عملکرد نقشه‌های پتانسیل کان‌زایی حاصل از مدل‌های مختلف و تولید الگوی اکتشافی بهینه، گام نهایی این پژوهش است. میزان صحت و کارایی عملکرد مدل‌های مختلف می‌تواند با استفاده از ماتریس‌های اختلاط [۱۱] مورد مطالعه قرار گیرد. هر نقشه پتانسیل کان‌زایی بسته به میزان کارایی آن، درجه‌ای از صحت (بر حسب درصد) را به واسطه محاسبه ماتریس اختلاط مربوطه دریافت می‌کند. حال بر اساس میزان صحت الگوهای کان‌زایی به دست آمده از مدل‌های یادگیری مختلف، بایستی یک نقشه پتانسیل کان‌زایی واحد تولید شود، به نحوی که تمام نقشه‌های پتانسیل معدنی حاصل از مدل‌های مختلف را نمایندگی کند. همچنین، عدم قطعیت وابسته به الگوی اکتشافی تلفیقی نیز به منظور احتساب ریسک تصمیم‌گیری‌های فنی-اقتصادی در مدیریت پروژه اکتشافی بایستی محاسبه شده و مد نظر قرار گیرد. لذا به منظور برآورده نمودن این موارد، از رویکرد متوسط‌گیری وزن‌دار [۱۲] برای مدل‌سازی الگوی اکتشافی تلفیقی و عدم قطعیت‌های وابسته به آن استفاده شده است. در نهایت، الگوی اکتشافی نهایی از ترکیب الگوی اکتشافی تلفیقی و مدل عدم قطعیت ساخته شده و به عنوان مبنایی جهت طراحی اکتشافات تفصیلی در ناحیه معدنی کال کافی پیشنهاد شده است.

۲. روش‌های هوش مصنوعی

۲-۱. ماشین بردار پشتیبان (SVM)

تکنیک SVM [۲] یکی از روش‌های یادگیری نظارت شده

کشف دانش درباره کان‌زایی زیرسطحی از روی اطلاعات اکتشافی سطح زمین همواره یکی از اهداف جذاب در مهندسی اکتشاف مواد معدنی بوده است. از آنجایی که حفاری سیستماتیک پرهزینه است، پردازش داده‌های اکتشافی سطح به منظور ثبت الگوهای معنی‌داری که به طور کارآمدی توزیع فضایی کان‌زایی زیرسطحی را جهت هدایت اکتشافات تفصیلی منعکس کنند، حائز اهمیت است. بدین منظور، از اوایل دهه‌ی ۲۰۱۰، روش‌های هوش مصنوعی برای تخمین کلاس‌های کان‌زایی عمق از روی داده‌های اکتشافی سطح توسعه داده شده‌اند. روش‌های یادگیری نظارت شده مانند رگرسیون لجستیک (LR) [۱]، ماشین بردار پشتیبان (SVM) [۲]، شبکه عصبی مصنوعی [۳] و جنگل تصادفی (RF) [۴] از جمله الگوریتم‌های متداولی بوده‌اند که از طریق برقراری یک ارتباط آماری میان داده‌های سطحی و عمقی برچسب‌دار، برای بازشناسی الگوی کان‌زایی زیرسطحی استفاده شده‌اند [۵]-[۹]. مهندسی اکتشاف مواد معدنی با کمک این مدل‌ها و با استفاده از داده‌های آموزشی حاصل از حفاری یا ترانشه‌زنی، اغلب یک تابع طبقه‌بندی (کلاسیفایر) طراحی می‌کنند. سپس با اعمال تابع حاصل به اطلاعات اکتشافی سطح زمین، نمونه‌ها یا سلول‌های فاقد برچسب به یکی از کلاس‌های کان‌زایی یا عدم کان‌زایی تخصیص می‌یابند [۵]، [۱۰].

محدوده اکتشافی کال کافی بیان‌کننده یک سیستم معدنی طلا، واقع در استان اصفهان و شهرستان انارک است. عملیات اکتشاف تفصیلی شامل حفاری‌های عمیق (گمانه) و کم‌عمق (ترانشه) در بخشی از رگه اصلی طلا‌دار اجرا شده است. با این حال، منطقه نیازمند حفاری‌های شناسایی بیش‌تر جهت تعیین مرزهای کان‌زایی اقتصادی در زیر سطح و توجیه فاز آتی عملیات حفاری است. لذا در این مطالعه، با استفاده از تکنیک‌های نوین هوش مصنوعی اقدام به مدل‌سازی توزیع فضایی کان‌زایی طلا در نواحی زیرسطحی محدوده کال کافی شده است. در رویکرد پیشنهادی، ابتدا ویژگی‌های پیشگوی کان‌زایی از مجموعه داده‌های اکتشافی سطح زمین (حول سلول‌های شبکه سطحی) استخراج می‌شوند. سپس، سلول‌های دربرگیرنده حفاری به عنوان نقاط آموزشی در نظر گرفته شده و بر اساس داده‌های عیارسنجی در طول گمانه‌ها و ترانشه‌ها، به صورت کلاس‌های کان‌زایی (مثبت) و عدم کان‌زایی (منفی) برچسب‌دار می‌شوند. حال، روش‌های هوش مصنوعی به نحوی آموزش داده می‌شوند تا در قالب توابع طبقه‌بندی، ارتباطات آماری خطی یا غیرخطی میان ویژگی‌های اکتشافی پیشگوی کان‌زایی (در سطح زمین) و برچسب‌های اختصاص داده شده به سلول‌های آموزشی (بر اساس

که با یکدیگر تلفیق می شوند [۲۳]-[۲۷]. این فرآیند موجب می شود که واریانس (عدم قطعیت) پیش بینی ها کاهش یابد و نیز نتایج حاصل کم تر تحت تأثیر مقادیر پرت موجود در مجموعه داده آموزشی قرار گیرند [۴]، [۲۸]. از این رو در زمینه کاربردها برای اکتشاف مواد معدنی، تکنیک RF با موفقیت برای بازشناسی الگوهای پیچیده کانه زایی از ویژگی های اکتشافی به کار رفته است [۲۹]-[۳۴].

۲-۴. شبکه عصبی عمیق تماماً متصل (FCDNN)

مدل FCDNN یک شبکه یادگیری عمیق است که خروجی های آن ترکیباتی خطی از توابع شعاعی پایه ورودی و پارامترهای نورون هستند. معماری FCDNN توانایی شناسایی الگوهای پیچیده تر و سرعت یادگیری بالاتری نسبت به اغلب معماری های سطحی موجود در مدل های هوش مصنوعی دارد [۳۵]، [۳۶]. معماری FCDNN ادغامی از لایه های کاملاً متصل است. نورون ها واحدهای سازنده بنیادین شبکه های عصبی هستند که شامل یک ورودی، وزن های خطی و بایاس ها، توابع فعال سازی و خروجی ها می باشند [۳۷]. هر نورون (گره) در هر لایه تماماً متصل به تمامی گره های لایه پیش از خود متصل می شود تا ترکیب شدن ویژگی های استخراج شده از خط مقدم شبکه را تسهیل کند. مدل FCDNN از طریق مجموعه داده آموزشی، بین ورودی ها و خروجی ها ارتباط برقرار می کند. طی آموزش شبکه، وزن های داخلی که بر روی ورودی های هر گره اعمال می شوند، تغییر می کنند تا به شرایط بهینه برسند [۳۷].

حوزه کاربردی مدل های FCDNN بسیار گسترده است و از کاربردهای طبقه بندی و رگرسیون تا کاربردهایی چون درون یابی، شناسایی آنومالی و غیره را شامل می شود [۳۸]، [۳۹]. برای حل هر مسئله ای در این حوزه ها، مدل FCDNN سه مرحله متوالی را طی می کند [۴۰]: آموزش، آزمایش و اعمال. مرحله آموزش، فرآیندی است که طی آن شبکه می آموزد تا الگوهای مختلف موجود در مجموعه داده های آموزشی ورودی را شناسایی کند. مرحله آزمایش، فرآیند ارزیابی عملکرد شبکه در ارائه نتایج قابل قبول در قبال ورودی هایی (مجموعه داده آزمایشی) است که پیش تر در مجموعه داده آموزشی نبوده اند. در نهایت، استفاده از شبکه آموزش دیده جهت انجام وظیفه ای که برای آن طراحی شده است را اعمال می گویند.

۳. منطقه مطالعاتی

سیستم معدنی کال کافی در شمال شرق استان اصفهان و در محدوده بخش انارک از توابع شهرستان نائین قرار دارد. از نظر تقسیم بندی های متداول پهنه های زمین شناسی ایران، این ناحیه


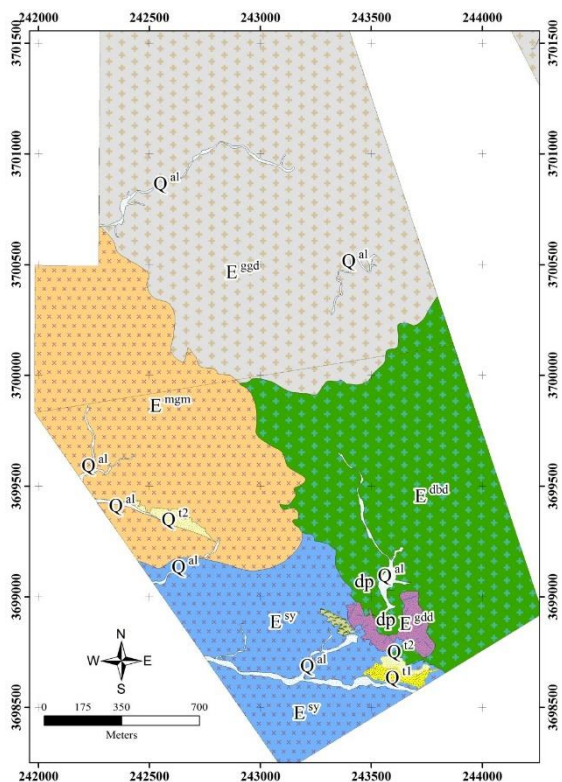
است که برای طبقه بندی خطی و غیرخطی و نیز رگرسیون چندبعدي به کار می رود [۱۳]. هدف کلی طبقه بندی SVM، یافتن ابرصفحه ای است که بتواند به شکل مناسبی داده های دوکلاسه یا چندکلاسه را از یکدیگر تفکیک کند. به منظور این که مدل هوش مصنوعی توانایی طبقه بندی داده هایی با پیچیدگی بالا را نیز داشته باشد، داده ها به وسیله یک تبدیل کرنل به فضایی با ابعاد بالاتر منتقل می شوند. در این راستا، از توابع کرنل مختلفی از جمله توابع خطی، چندجمله ای، سیگموید و شعاعی پایه (RBF) می توان استفاده نمود. در زمینه کاربردها برای اکتشاف مواد معدنی، تکنیک SVM با موفقیت برای بازشناسی الگوهای پیچیده کانه زایی از ویژگی های اکتشافی چندمنبعی به کار رفته است [۱۴]-[۱۶].

۲-۲. رگرسیون لجستیک (LR)

طی دهه های گذشته، مدل های رگرسیون مختلفی در زمینه ارزیابی منابع معدنی مورد استفاده قرار گرفته اند که در میان آن ها، مدل LR بر اساس توزیع لجستیک، ابزاری قدرتمند برای آنالیز کمی متغیر وابسته باینری و شناسایی ضرایب تأثیر آن است. همچون SVM، این روش نیز شامل رویکردی داده محور جهت طبقه بندی الگوها بر اساس فضای ویژگی چندبعدي است. مدل LR از طریق اجرای تکنیک های بیشترین درستنمایی سعی در تولید یک تابع طبقه بندی بهینه دارد [۱]، [۱۷]. این تکنیک یک مدل کارآمد برای آنالیز کمی متغیر پاسخ بر اساس سهم ویژگی ها یا متغیرهای پیشگوی مستقل است. در مدل LR، لگاریتم بخت های متغیر پاسخ به صورت یک ترکیب خطی از متغیرهای پیشگو مدل سازی می شود [۱۸]. تابع LR بر اساس یک مدل احتمال غیرخطی است و از این لحاظ، در زمینه حل مسائل یادگیری مختلف از قبیل بازشناسی الگوهای کانه زایی، مزیت هایی نسبت به مدل های خطی دارد [۱۹]-[۲۲].

۳-۲. جنگل تصادفی (RF)

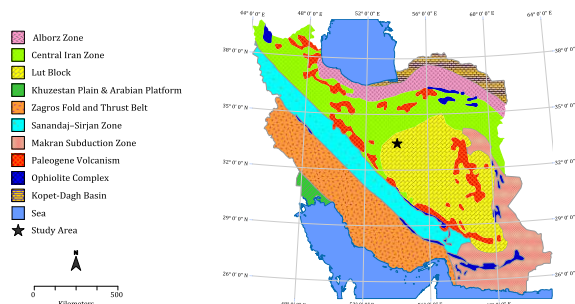
تکنیک RF [۴] یکی از مدل های یادگیری مبتنی بر قواعد انجمنی است که امروزه به عنوان یکی از موفق ترین روش ها در حوزه داده کاوی آماری و بازشناسی الگو مطرح شده است. در این روش، یک انجمن (اجتماع) از درخت ها (پیش بینی ها) سازمان دهی می شود و یک پروسه رأی گیری اجرا می شود تا کلاسی که مد نظر جمهور درخت ها است به هر نمونه در نقشه پیش بینی نهایی اختصاص داده شود. نکته اساسی کلاسیفایرهای مبتنی بر قواعد انجمنی از قبیل مدل RF آن است که پروسه یادگیری آن ها نه تنها بر اساس یک پیش بینی (درخت تصمیم) خاص، بلکه بر مبنای چندین پیش بینی مختلف صورت می پذیرد



شکل (۲). نقشه زمین‌شناسی مقیاس ۱:۱۰۰۰ محدوده معدنی کال-کافی.

کانه‌زایی رگه‌ای پلی‌متال در محدوده کال کافی با نفوذی‌ها مرتبط می‌باشد و از نظر ساختمانی اغلب با گسل‌های اصلی ناحیه وابستگی نزدیک دارد و در موارد متعددی، بخشی از کانسار درون این گسل‌ها تشکیل شده است. از لحاظ تیپ کان‌زایی طلا، درجه نخست متعلق به رگه‌های سیلیسی و اکسید آهن می‌باشد که در اغلب موارد، کانی‌های پیریت، کالکوپیریت، مالاکیت و آزوریت نیز در رگه سیلیسی مشاهده می‌شوند. فلز طلا در درجه بعدی به

در زون ساختاری ایران مرکزی واقع شده است و تابع شرایط ژئودینامیکی و متالوژنی آن می‌باشد (شکل ۱). زون ایران مرکزی یکی از واحدهای اصلی ساختاری ایران است که به شکل مثلث در مرکز ایران واقع شده است و یکی از پیچیده‌ترین سازندهای ژئوتکتونیک آن محسوب می‌شود.



شکل (۱). نقشه پهنه‌های ساختاری ایران و موقعیت منطقه مطالعاتی در زون ایران مرکزی.

آن‌گونه که از نقشه زمین‌شناسی مقیاس ۱:۱۰۰۰ منطقه مطالعاتی مشاهده می‌شود، واحدهای سنگی گرانیت تا گرانودیوریت، دیوریت، مونزوگرانیت تا مونزونیت، سینیت، مونزوگرانیت تا مونزونیت، دایک‌های آپلیتی و رسوبات رودخانه‌ای کواترنری به ترتیب بیش‌ترین تظاهر را در سیستم متالوژنیک کال کافی دارند (شکل ۲). کانی‌های موجود در واحد گرانیت تا گرانودیوریت شامل کوارتز، پلاژیوکلاز و آمفیبول هستند، در حالی که کانی‌های غالب در واحد مونزونیتی عمدتاً از نوع فلدسپار آلکالن و پیروکسن هستند. واحدهای سنگی سینیتی در منطقه نیز عمدتاً با مجموعه کانی‌های پلاژیوکلاز و کوارتز شناخته می‌شوند. همچنین، بیوتیت، آمفیبول و پیروکسن، سازندهای اصلی واحدهای سنگی دیوریتی می‌باشند. آلتراسیون‌های رخمون‌دار در منطقه نیز شامل زون‌های سیلیسی، آرژلیک، اکسید آهن و کلریتی هستند.

در نتیجه فشارهای وارد شده از صفحات تکتونیک به منطقه، از سه جهت، شامل فشارش صفحات عربستان از سمت جنوب شرق، هندوستان از سمت شرق، و مکران به سمت اوراسیا باعث شده است که دسته‌های مختلفی از گسل‌های اصلی در جهات مختلف جغرافیایی در محدوده کال کافی شکل گیرند. در این بین، گسل‌های با روند NW-SE که با گسترش فراوانی در منطقه همراه هستند، نقش مؤثری در کان‌زایی پلی‌متالیک کال-کافی ایفا نموده‌اند، به طوری که با ایجاد معبری برای عبور سیالات هیدروترمال و همچنین نهشته شدن آن‌ها در فضاها به وجود آمده و تشکیل رگه‌ها در این محیط، به عنوان کنترل‌کننده‌های مهم فرآیندهای کان‌ساز در منطقه مطالعاتی عمل نموده‌اند.

آنالیز فاکتور و آنالیز خوشه‌ای سلسله‌مراتبی روش‌های چندمتغیره پایه برای شناسایی ویژگی‌های ژئوشیمیایی کارآمد جهت بازشناسی الگوی کانه‌زایی در مناطق مطالعاتی هستند [۴۴]–[۴۷]. به منظور کمینه‌سازی عدم قطعیت‌های محاسباتی در انتخاب متغیرهای اکتشافی کارآمد برای پیش‌بینی الگوی کانه‌زایی زیرسطحی، نتایج حاصل از اعمال این روش‌ها بر روی ۱۴۴ نمونه ژئوشیمیایی سنگی در محدوده معدنی کال کافی جمع شده‌اند. همچنین نتایج حاصل از آنالیز همبستگی آماری و آنالیز همبستگی فضایی نیز در این بخش مد نظر قرار گرفته‌اند. بر اساس نتایج این آنالیزها، داده‌های مربوط به مجموعه عناصر کارآمد جهت بازشناسی الگوی کانه‌زایی زیرسطحی در محدوده معدنی کال کافی انتخاب شده‌اند. به منظور رعایت اختصار در حجم مقاله، نقشه توزیع فضایی داده‌های Au که با استفاده از روش کریجینگ در شبکه رستری با 639×349 گره (ابعاد سلول $5 \text{ m} \times 5 \text{ m}$) درونیایی شده‌اند، در شکل (۳-الف) نمایش داده شده است. در این شکل، رنگ‌بندی گرم معرف نواحی ازدیاد غلظت طلا و رنگ‌بندی سرد معرف نواحی با مقادیر پایین از غلظت‌های طلا می‌باشند. خط‌چین رسم شده منطقه را به دو قسمت شمالی (کادر امین ۱) و جنوبی (کادر امین ۲) تقسیم می‌کند. همچنین، ناحیه حفاری شده به صورت یک چندضلعی در بخش شمال غرب محدوده نشان داده شده است.

۴-۱-۲. ویژگی شاهد متالورژیکی

رگه‌های سیلیسی و اکسید آهن، مهم‌ترین میزبان و خاستگاه متالورژیک طلا در محدوده معدنی کال کافی می‌باشند. بنابراین به منظور احتساب چنین فاکتورهای متالورژیکی، نیاز است که میزان مجاورت فضایی (عکس فاصله اقلیدوسی) هر سلول در شبکه سطحی به نزدیک‌ترین برونزد رگه در منطقه مطالعاتی محاسبه شود. شبکه رستری سطحی با 639×349 گره (ابعاد سلول $5 \text{ m} \times 5 \text{ m}$) طراحی گردیده است. بدین ترتیب، مقدار مجاورت هر سلول شبکه سطحی به رخنمون رگه‌های سیلیسی کانه‌دار در محدوده کال کافی محاسبه شده و در بازه‌ی [0,1] استانداردسازی شده است. توزیع فضایی ویژگی متالورژیک استخراج شده جهت پیش‌بینی الگوی کانه‌زایی در منطقه مطالعاتی در شکل (۳-ب) نمایش داده شده است. همان‌گونه که در این شکل مشاهده می‌شود، مناطق آنومالی نقشه مجاورت رگه عمدتاً در اطراف رگه‌های سیلیسی و اکسید آهن کانه‌دار تمرکز یافته‌اند.

۴-۱-۳. ویژگی‌های شاهد ساختاری

سیستم‌های شکستگی و گسلس ایجاد شده تحت تنش‌های

صورت همراهی با رگه‌ها و رگچه‌های اکسیدی و سولفیدی دیده می‌شود. در حقیقت می‌توان این رگه‌ها را در ارتباط با یک سیستم پورفیری نیز در نظر گرفت، به طوری که خاستگاه آن‌ها سیالات هیدروترمال نشأت گرفته از توده ساب‌ولکانیک پورفیری بوده که عناصر خود را در فضاهای خالی ناشی از گسل‌ها، درزه‌ها و شکستگی‌ها بر جای گذاشته‌اند.

در منطقه کال کافی، کانه‌زایی اسکارن نیز مشاهده شده است. تشکیل این تیپ از کانه‌زایی ماحصل نفوذ توده نفوذی کال کافی در واحدهای دگرگونی انارک و حضور میان لایه‌های آهکی در سیستم‌ها می‌باشد. بر طبق مطالعات صورت گرفته، روابط بافتی نشان دهنده تکامل پنج مرحله‌ای این اسکارن‌ها می‌باشند. در مرحله اول و همزمان با جای‌گیری توده نفوذی، کانی‌های دمابالا همچون کلینوپیروکسن، والستونیت و گارنت تشکیل شده‌اند. در مرحله بعد با افت تدریجی دما، گارنت جانشین کلینوپیروکسن شده است. در گام آخر از مرحله پیش رونده تکامل اسکارن، بخش عمده کانه‌زایی رخ داده است و به تدریج با سرد شدن توده و هجوم سیالات گرمایی تأخیری از توده و به حرکت درآمدن آب‌های سازندی، مرحله دگرسانی بازگشتی آغاز شده است. در این مرحله، بخش عمده کانی‌های کالک سیلیکاته آتره شده و عمده تهنشست سولفیدها رخ داده است. در مرحله آخر و با ادامه جریان سیالات گرمایی به درون این سنگ‌ها و از طرفی افزایش فشار بخشی در محیط، رگه‌های نابارور کلسیتی، کوارتزی و ارتوکلازی کانی‌های اسکارن را تحت تأثیر قرار داده‌اند.

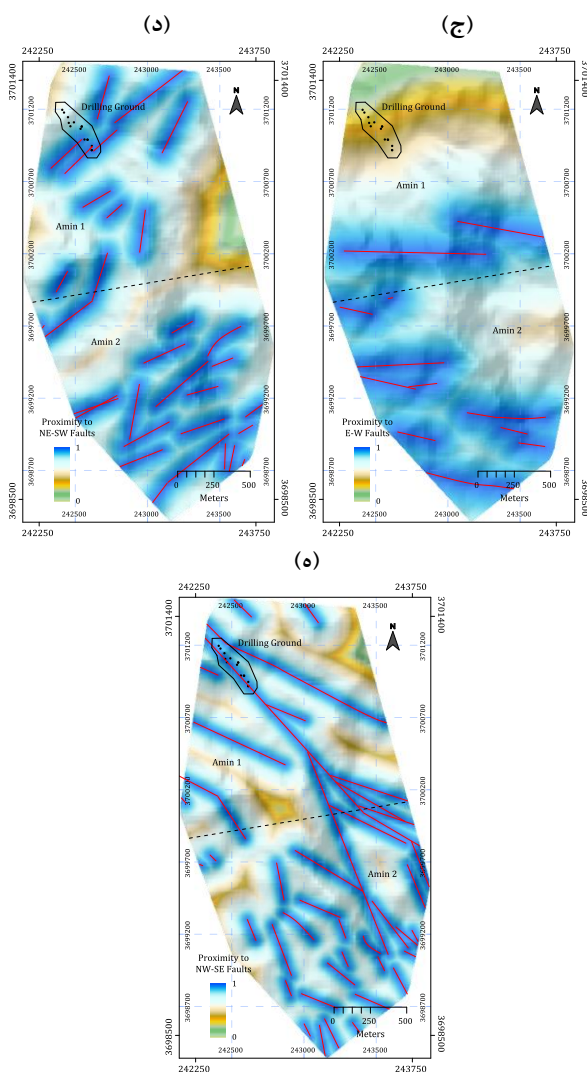
۴. نتایج و بحث

۴-۱-۱. تولید ویژگی‌های اکتشافی پیشگوی کانه‌زایی

به منظور تولید لایه‌های شاهد اکتشافی (ویژگی‌های اکتشافی پیشگوی کانه‌زایی) در سیستم معدنی کال کافی، از داده‌ها و اطلاعات مختلف زمین‌شناسی، ساختاری، متالورژیک و ژئوشیمیایی استفاده شده است.

۴-۱-۲. ویژگی‌های شاهد ژئوشیمیایی

یکی از مهم‌ترین لایه‌های اطلاعات اکتشافی که وزن بالا و سهم به‌سزایی در پیش‌بینی کمی الگوهای کانه‌زایی دارد، مجموعه داده‌های ژئوشیمیایی چندعنصری سطح زمین است که اغلب از آنالیز نمونه‌های خاک، رسوبات آبراه‌های و لیتوژئوشیمیایی حاصل می‌گردد [۴۱]–[۴۳]. محققان علوم زمین برای درک و شبیه‌سازی مکانیزم‌های دینامیکی فرآیندهای کانه‌ساز فعال در پوسته‌ی زمین نیاز مبرم به چنین داده‌هایی دارند [۴۳].



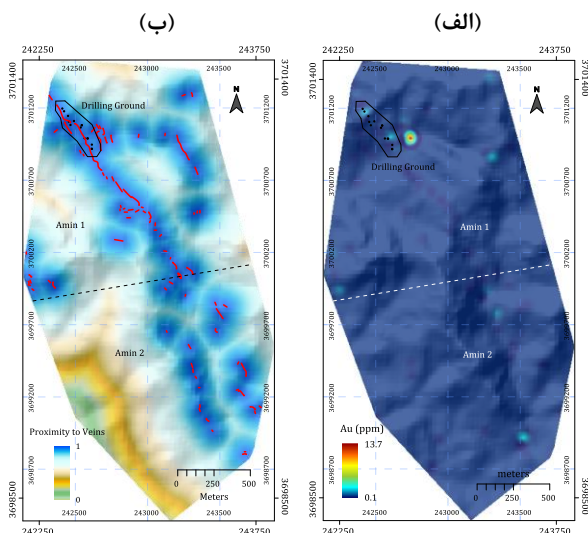
شکل (۳). نقشه‌های توزیع فضایی تعدادی از ویژگی‌های اکتشافی پیشگوی کانه‌زایی در محدوده معدنی کال کافی: (الف) غلظت‌های Au، (ب) ویژگی متالورژیک (مجاورت به رگه‌های سیلیسی و اکسید آهن)، (ج) ویژگی ساختاری (مجاورت به گسل‌های E-W)، (د) ویژگی ساختاری (مجاورت به گسل‌های NE-SW) و (ه) ویژگی ساختاری (مجاورت به گسل‌های NW-SE).

با توجه به این مسئله که تمامی گمانه‌های اکتشافی موجود در منطقه معدنی کال کافی به صورت مایل حفر شده‌اند، پروجکشن (تصویر سطحی) عیار مغزه‌ها در مسیر حفر گمانه‌های اکتشافی در سطح زمین مدل‌سازی شده و سلول‌هایی که در زیر سطح آن‌ها، مغزه‌هایی با عیار $Au \geq 0.5$ g/ton حضور داشتند به عنوان سلول‌های حاوی کانه‌زایی زیرسطحی (سلول‌های مثبت) برچسب زده شده‌اند. همچنین، با مدل‌سازی عیارهای Au در نمونه‌های سنگی برداشت شده در مسیر حفر ترانسه‌های اکتشافی، سلول‌هایی که در آن‌ها نمونه‌های سنگی با عیارهای $Au \geq 0.5$ g/ton شناسایی شده بودند به عنوان سلول‌های حاوی کانه‌زایی زیرسطحی (سلول‌های مثبت) برچسب زده شدند.

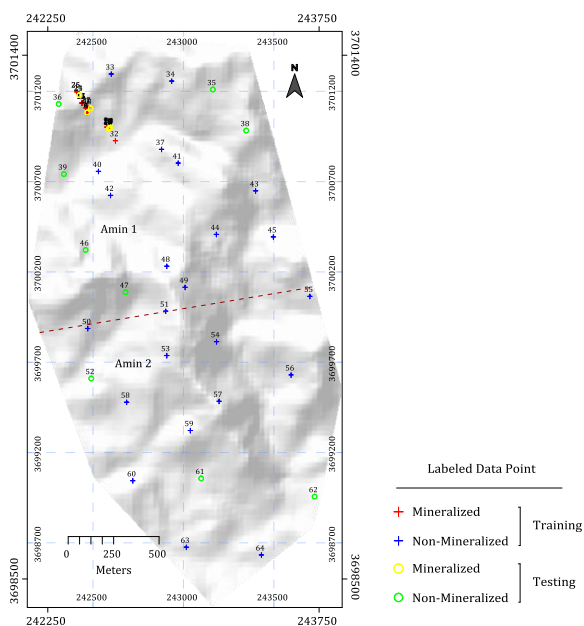
دینامیکی ناشی از تکتونیک فعال منطقه، عموماً معیار مساعدی جهت گردش سیالات هیدروترومال و تجمع کانه‌های فلزی مهیا می‌کنند [۴۸]. از نظر ساختمانی، کانه‌زایی رگه‌ای در منطقه مطالعاتی اغلب با گسل‌های اصلی ناحیه وابستگی نزدیک دارند و در موارد متعددی، بخشی از کانسار درون این گسل‌ها تشکیل شده است. بنابراین به منظور احتساب چنین فاکتورهای ساختاری، نیاز است که میزان مجاورت فضایی (عکس فاصله اقلیدوسی) هر سلول در شبکه سطحی به نزدیک‌ترین بروزند گسل و شکستگی در منطقه مطالعاتی محاسبه شود. با این حال، مطالعات تکتونیکی نشان داده‌اند که سیستم‌های گسلش متنوعی با جهت‌گیری‌های فضایی مختلف در منطقه مطالعاتی فعالیت نموده‌اند که هر کدام از این دسته شکستگی‌ها ممکن است معرف پدیده‌های زمین‌شناسی معینی باشند. سیستم گسل و شکستگی در محدوده معدنی کال کافی در سه دسته گسل‌های با روندهای E-W، NE-SW و NW-SE قابل جدایش هستند. بدین ترتیب، مقادیر مجاورت فضایی هر سلول شبکه سطحی به گسل‌های با روند E-W، NE-SW و NW-SE در محدوده کال کافی محاسبه شده و در بازه [0,1] استانداردسازی شده‌اند. نقشه‌های توزیع فضایی ویژگی‌های ساختاری استخراج شده در راستای روندهای E-W، NE-SW و NW-SE در شکل‌های (۳-ج) تا (۳-ه) نمایش داده شده‌اند.

۲-۴. بازشناسی الگوی کانه‌زایی زیرسطحی

داده‌های عیارسنجی حاصل از حفاری‌های نیمه‌عمیق (تعداد ۶۵ نمونه سنگی برداشت شده در امتداد ۴ ترانسه) و عمیق (تعداد ۳۴۷ نمونه مغزه‌ای برداشت شده در طول ۱۵ گمانه) در منطقه مطالعاتی به عنوان اطلاعات مرجع جهت تولید مجموعه داده‌های آموزشی (برای آموزش مدل‌های یادگیری) و آزمایشی (برای ارزیابی عملکرد مدل‌های یادگیری) استفاده شده‌اند.



از ماتریس اختلاط طبقه‌بندی [۱۱] استفاده شده است. در کاربردهای هوش مصنوعی، جدول یا ماتریس اختلاط، نتایج حاصل از طبقه‌بندی را بر اساس اطلاعات واقعی موجود نمایش می‌دهد و برای ارزیابی صحت الگوهای بازشناسی شده به کار می‌رود. اعتبارسنجی نتایج از طریق محاسبه ماتریس‌های اختلاط نشان داده است که مدل‌ها توانسته‌اند به واسطه صحت‌های طبقه‌بندی مناسب در مورد مجموعه داده‌ی آموزشی (۱۰۰٪) برای هر چهار مدل، برازش بسیار مطلوبی به متغیرهای اکتشافی داشته باشند.

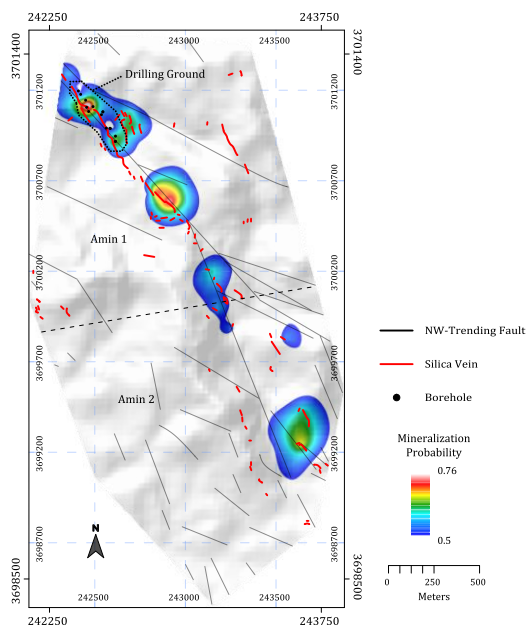


شکل (۴). توزیع فضایی موقعیت نقاط برچسب‌دار آموزشی و آزمایشی جهت بازشناسی الگوی کانه‌زایی با استفاده از مدل‌های هوش مصنوعی در محدوده معدنی کال‌کافی.

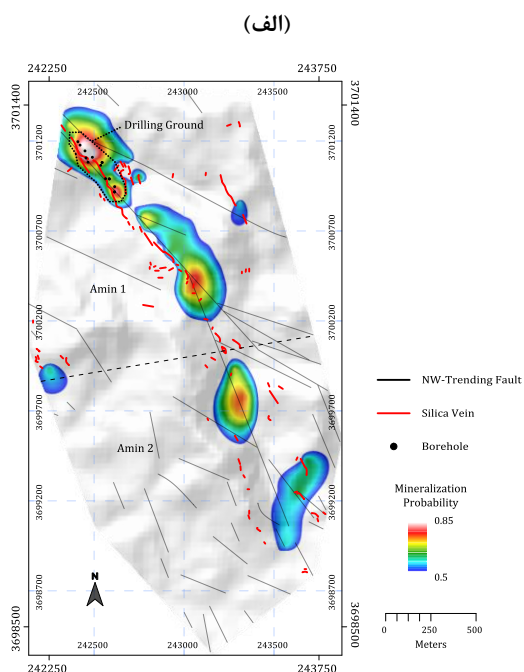
پس از این که مدل‌های هوش مصنوعی به نحو شایسته‌ای آموزش داده شدند، توابع طبقه‌بندی ساخته شده به مجموعه داده آزمایشی (با ابعاد 13×19) اعمال شده‌اند تا میزان صحت تعمیم‌پذیری مدل‌ها نیز سنجیده شود. صحت‌های طبقه‌بندی در مورد مجموعه داده آزمایشی به صورت ۸۹٪ برای مدل LR و ۱۰۰٪ برای مدل‌های SVM، RF و FCDNN به دست آمده است. میزان صحت قابل قبول داده‌های آزمایشی نشان می‌دهد که مدل‌های آموزش دیده می‌توانند با درجه اطمینان بالایی به داده‌های کل منطقه (مجموعه داده فاقد برچسب) تعمیم داده شوند. لذا با اعمال مدل‌ها به ویژگی‌های پیشگوی کانه‌زایی در شبکه سطحی محدوده (مجموعه داده فاقد برچسب)، الگوهای فضایی کانه‌زایی زیرسطحی در منطقه مطالعاتی تولید شده‌اند (شکل ۵).

با تجمیع داده‌های برچسب‌دار حاصل از پردازش اطلاعات گمانه‌ها و ترانسه‌ها، مجموعاً تعداد ۳۲ نقطه معرف کانه‌زایی زیرسطحی در محدوده معدنی کال‌کافی ساخته شده است (شکل ۴). با این حال، باید در نظر داشت که گمانه‌ها و ترانسه‌های اکتشافی حفر شده به دلیل دارا بودن اعماق محدود، صرفاً جهت برچسب‌دار نمودن سلول‌های معرف کانه‌زایی (و نه عدم کانه‌زایی) زیرسطحی می‌توانند استفاده شوند. به منظور تعیین موقعیت‌های مرتبط با عدم کانه‌زایی، تعداد ۳۲ نقطه عدم کانه‌زایی به صورت تصادفی جهت برچسب‌دار کردن سلول‌های منفی در منطقه مطالعاتی تولید شده است (شکل ۴). بدین ترتیب، مجموعاً تعداد ۶۴ نقطه برچسب‌دار جهت آموزش مدل‌های هوش مصنوعی و بازشناسی الگوهای کانه‌زایی زیرسطحی در محدوده معدنی کال‌کافی تولید شده است. در نهایت، با استخراج مقادیر ویژگی‌های اکتشافی پیشگوی ۱۳ گانه در مختصات فضایی ۶۴ سلول برچسب‌دار، مجموعه داده مورد نیاز جهت اجرای مدل‌های یادگیری به صورت ماتریسی با ابعاد 13×64 آماده‌سازی شده است.

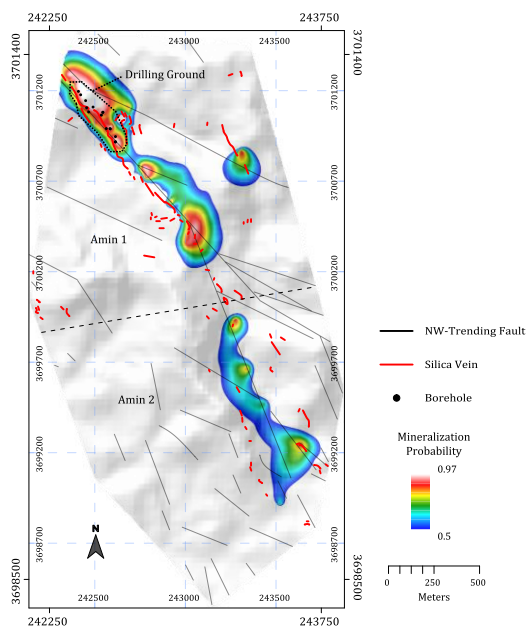
مجموعه داده آموزشی طی رویکردی تصادفی به دو بخش مجموعه داده آموزشی (کسر ۷۰٪ از نمونه‌ها) و مجموعه داده آزمایشی (کسر ۳۰٪ از نمونه‌ها) بخش‌بندی شده است (شکل ۴). تکنیک‌های یادگیری مبتنی بر هوش مصنوعی شامل مدل‌های SVM، LR، RF و FCDNN بر روی داده‌های آموزشی (با ابعاد 13×45) برازش یافته و نهایتاً صحت مدل‌های حاصل با استفاده از داده‌های آزمایشی (با ابعاد 13×19) ارزیابی شده است. در پژوهش حاضر، جهت اجرای مدل SVM از تابع کرنل RBF استفاده شده است، چرا که ثابت شده است که خطاهای RBF در مقایسه با سایر توابع کرنل متداول به مراتب کمتر هستند [۱۵]. همچنین، از رویکرد اعتبارسنجی متقابل 10-fold [۴۹] به عنوان روشی متداول برای تعیین پارامترهای بهینه در مدل آموزش SVM استفاده شده است. در مورد مدل RF، پس از اجرای فرآیند آزمون و خطا و پایش مقادیر خطاهای تولید شده، تعداد ۱۰۰ درخت به عنوان مقدار بهینه تعیین گردیده و مدل RF با مجموعه داده‌ی آموزشی، آموزش داده شده است. به علاوه، از راهکار آزمون و خطا (بر مبنای کمینه شدن خطای طبقه‌بندی) برای تنظیم پارامترهای بهینه در مدل آموزش FCDNN استفاده شده است. در نتیجه این فرآیند، یک ساختار چهار لایه‌ای با آرایش (1-5-9-13) به عنوان معماری بهینه مدل FCDNN انتخاب شده است. همچنین از توابع لجستیک، پس‌انتشار (با نرخ یادگیری ۰٫۱) و مرتبه‌ی توپولوژی به عنوان توابع فعال‌سازی، یادگیری و بروزرسانی استفاده شده است و مدل FCDNN طی ۲۰۰ تکرار با مجموعه داده آموزشی آموزش داده شده است. برای کشف میزان صحت فرآیند آموزش،



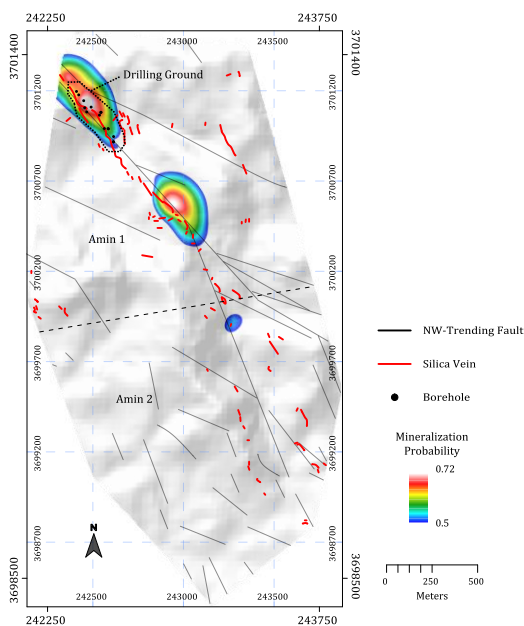
(د)



(الف)



(ب)



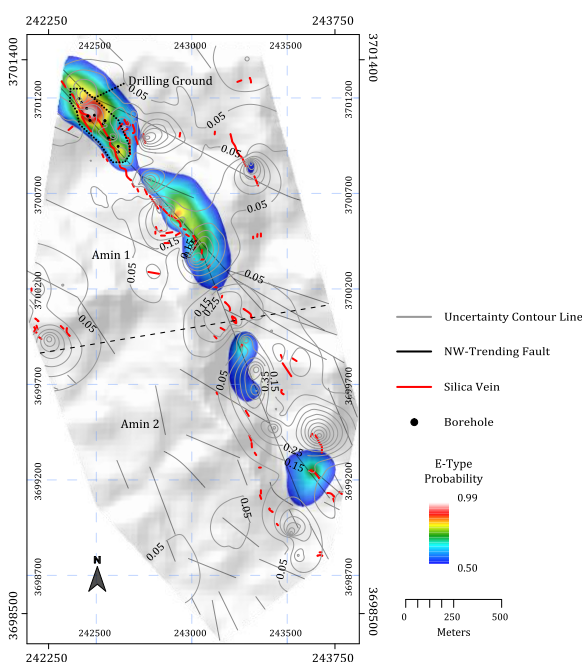
(ج)

شکل (۵). نقشه‌های پتانسیل معدنی حاصل از مدل‌های (الف) SVM، (ب) LR، (ج) RF و (د) FCDNN نشان دهنده نواحی امیدبخش کانه-زایی طلا در نواحی زیرسطحی محدوده معدنی کال کافی.

۳-۴. مدل‌سازی نواحی امیدبخش معدنی

نقشه‌های پتانسیل معدنی حاصل از مدل‌های یادگیری مختلف دارای تفاوت‌هایی در الگوی فضایی نواحی امیدبخش هستند که ناشی از عدم قطعیت‌هایی است که در نتیجه فرآیند آموزش مدل‌های هوش مصنوعی به نقشه‌های پتانسیل معدنی تحمیل می‌شوند. به منظور حل این مسئله، رویکرد متوسط‌گیری مدل [۱۲] می‌تواند برای حصول یک الگوی ترکیبی که تمام

اکتشافی آتی در منطقه مطالعاتی، با در نظر گرفتن توأمان نقشه-های پتانسیل کانه‌زایی تلفیقی (نقشه E-type) و عدم قطعیت حاصل شده و در شکل (۶) نشان داده شده است. این الگو نشان می‌دهد که راستای عمومی نواحی امیدبخش منطبق بر جهت-گیری رگه‌های سیلیسی و اکسید آهن کانه‌دار و گسل‌های با روند NW-SE مدل سازی شده است. نواحی با عدم قطعیت پایین در این الگو، منطبق بر مناطقی هستند که در آن‌ها احتمالات کانه-زایی حاصل از مدل‌های RF، LR، SVM و FCDNN بالاترین میزان توافق را با یکدیگر داشته‌اند. این نواحی بایستی همراه با احتمالات کانه‌زایی E-type در طراحی اولویت‌های اکتشافی آتی مد نظر قرار گیرند.



شکل (۶). الگوی اکتشافی نهایی کانه‌زایی زیرسطحی در محدوده معدنی کال کافی، همپوشانی شده بر روی رگه‌های سیلیسی و سیستم گسل/ شکستگی‌های با روند NW-SE. فاصله خطوط تراز کنتورهای عدم قطعیت برابر ۰,۱ می‌باشد.

همان‌گونه که در شکل ۶ مشاهده می‌شود، بالاترین میزان امیدبخشی کانه‌زایی زیرسطحی طلا در شمال محدوده و در مجاورت رگه سیلیسی کانه‌دار و گسل‌های اصلی با روند NW-SE توزیع شده است. گمانه‌های حفر شده در فاز مقدماتی به درستی منطبق بر نواحی با بالاترین احتمالات کانه‌زایی و نیز پایین‌ترین درجات عدم قطعیت انتخاب و حفر شده‌اند. بر اساس الگوی اکتشافی نهایی و با معیار قرار دادن بیشینه‌سازی احتمالات کانه‌زایی و کمینه‌سازی عدم قطعیت، سه زون هدف اکتشافی جدید مطابق با جدول ۱ در محدوده معدنی کال کافی تعریف و اولویت‌بندی شده‌اند. این حوزه‌های امیدبخش می‌توانند به عنوان

نقشه‌های پتانسیل معدنی را به نحو شایسته‌ای نمایندگی می‌کند، مورد استفاده قرار گیرد. فرآیند این تکنیک بدین صورت است که مقادیر احتمالات کانه‌زایی در سلول‌های هر کدام از نقشه‌های رستری تولید شده با روش‌های یادگیری مختلف، تحت یک میانگین‌گیری وزن‌دار قرار می‌گیرند. در این رویکرد، وزن اختصاص داده شده به هر سلول، معادل میزان صحتی است که روش هوش مصنوعی در مدل‌سازی آن داشته است. به عبارت ساده‌تر، برای سلول‌های شبکه در نقشه‌های پتانسیل معدنی حاصل از مدل‌های SVM، LR، RF و FCDNN، به ترتیب اوزان ۱، ۰,۸۹، ۱ و ۱ اختصاص می‌یابد. نقشه پتانسیل کانه‌زایی میانگین‌گیری شده (تلفیقی) تحت عنوان نقشه E-type نام-گذاری می‌شود. به عبارت دیگر، نقشه احتمالات E-type مدل میانگین‌گیری شده‌ای از تمام نقشه‌های پتانسیل معدنی (حاصل از مدل‌های هوش مصنوعی) است، با این نکته که صحت هر نقشه پتانسیل معدنی به صورت وزن در محاسبه میانگین دخالت داده شده است. بدین ترتیب، احتمالات کانه‌زایی موجود در سلول‌های نقشه E-type، برآیندی از احتمالات موجود در نقشه‌های پتانسیل معدنی حاصل از تک تک مدل‌های هوش مصنوعی است. از سوی دیگر، بدیهی است که هرچه میزان تنوع در مقادیر احتمالات کانه‌زایی یک سلول شبکه بیشتر باشد، قابلیت اطمینان مقادیر E-type تخمین زده شده برای سلول نیز کم‌تر خواهد بود، چرا که نشان می‌دهد که مدل‌های یادگیری مختلف، در احتمالات کانه‌زایی پیشگویی شده اتفاق نظر نداشته‌اند. از این رو، با توجه به اوزان اختصاص داده شده به سلول‌های شبکه، واریانس وزن‌دار مقادیر احتمالات کانه‌زایی موجود در هر سلول (یعنی، چهار مقدار احتمال مختلف با چهار وزن گوناگون) محاسبه شده و به عنوان شاخصی از عدم قطعیت تعیین شده برای E-type سلول در نظر گرفته می‌شود.

به منظور تولید الگوی E-type کانه‌زایی زیرسطحی طلا و عدم قطعیت‌های مربوطه در منطقه مطالعاتی، مقادیر احتمالات کانه‌زایی حاصل از مدل‌های SVM، LR، RF و FCDNN در شبکه‌های رستری با 349×349 گره (ابعاد سلول $5 \text{ m} \times 5 \text{ m}$) استخراج شده و سپس با استفاده از روش min-max در بازه‌ی [0,1] استانداردسازی شده‌اند تا نقشه‌های پتانسیل کانه‌زایی حاصل از مدل‌های یادگیری مختلف دارای مقیاس‌های عددی یکسان باشند. با در نظر گرفتن اوزان ۱، ۰,۸۹، ۱ و ۱ برای مدل‌های SVM، LR، RF و FCDNN، میانگین و واریانس وزن‌دار مقادیر احتمالات کانه‌زایی در هر کدام از سلول‌های شبکه محاسبه شده و به ترتیب به عنوان پتانسیل کانه‌زایی ترکیبی (E-type) و عدم قطعیت مربوطه در نظر گرفته شده‌اند. الگوی اکتشافی نهایی جهت تصمیم‌گیری در خصوص فعالیت‌های

بررسی اهمیت ویژگی‌های پیشگوی کانه‌زایی در پیش‌بینی کانه‌زایی زیرسطحی نشان می‌دهد که رگه‌های سیلیسی و گسل‌های با روند NW-SE به ترتیب، بالاترین درجه اهمیت را در شناسایی الگوی کانه‌زایی زیرسطحی در محدوده معدنی کال کافی داشته‌اند. این نتایج، بر اهمیت ویژه رگه‌های سیلیسی / اکسید آهن و نیز سیستم شکستگی‌ها و گسل‌های NW-SE در کنترل فرآیندهای متالوژنیک و هدایت سیالات کانه‌ساز در محدوده معدنی کال کافی تأکید دارد. گسل‌های با روند NW-SE با ایجاد مسیرهایی برای عبور سیالات هیدروترمال و همچنین نهشته شدن آن‌ها در فضاهای به وجود آمده و تشکیل رگه‌ها در این محیط، به عنوان کنترل کننده‌های مهم فرآیندهای کانه‌ساز در منطقه مطالعاتی عمل نموده‌اند. بنابراین، نتایج پژوهش نشان می‌دهد که این دو ویژگی اکتشافی بایستی به طور ویژه و با اهمیت بالا در طراحی‌های اکتشافی آتی در منطقه مطالعاتی مد نظر قرار گیرند. همچنین، روش گرانی‌سنجی یکی از روش‌های ژئوفیزیکی معتبر در زمینه اکتشاف فلزات سنگین همچون طلا است. لذا پیشنهاد می‌شود که پس از طراحی شبکه و برداشت داده‌های گرانی‌سنجی، آنومالی‌های حاصل از پردازش داده‌های ژئوفیزیکی نیز به عنوان یک لایه اکتشافی معتبر در مدل‌سازی پتانسیل کانه‌زایی در محدوده کال کافی مد نظر قرار گیرند.

۶. مراجع

- [1] D. Harris and G. Pan, "Mineral favorability mapping: a comparison of artificial neural networks, logistic regression, and discriminant analysis," *Nat. Resour. Res.*, vol. 8, pp. 93-109, 1999.
- [2] V. N. Vapnik, "An overview of statistical learning theory," *IEEE Trans. neural networks*, vol. 10, no. 5, pp. 988-999, 1999.
- [3] S. Theodoridis and K. Koutroumbas, "Chapter 4 - Nonlinear Classifiers BT - Pattern Recognition (Fourth Edition)," Boston: Academic Press, 2009, pp. 151-260.
- [4] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5-32, 2001.
- [5] A. M. Gonbadi, S. H. Tabatabaei, and E. J. M. Carranza, "Supervised geochemical anomaly detection by pattern recognition," *J. Geochemical Explor.*, vol. 157, pp. 81-91, 2015.
- [6] H. Geranian, S. H. Tabatabaei, H. Asadi Haroni, and J. M. Carranza, "Application of Discriminant Analysis and Support Vector Machine in Mapping Gold Potential Areas for Further Drilling in the Sari-Gunay Gold Deposit, NW Iran," *Nat. Resour. Res.*, vol. 25, no. 2, pp. 145-159, 2016.
- [7] H. Zekri, D. R. Cohen, A. R. Mokhtari, and A. Esmaeili, "Correction to: Geochemical Prospectivity Mapping Through a Feature Extraction-Selection Classification Scheme," *Nat. Resour. Res.*, vol. 28, no. 3, pp. 867-868, 2019.
- [8] M. Abedi, G.-H. Norouzi, and A. Bahroudi, "Support vector machine for multi-classification of mineral prospectivity areas," *Comput. Geosci.*, vol. 46, pp. 272-283, 2012.
- [9] M. Abedi and G.-H. Norouzi, "Integration of various geophysical data with geological and geochemical data to

اولویت‌های اکتشافی آتی در پروژه معدنی کال کافی مد نظر قرار گیرند. همچنین لازم به توضیح است که از منظر اقتصادی، اجرا و بهره‌گیری از نتایج این تحقیق می‌تواند ارزشمند تلقی شود. به منظور کشف کانه‌زایی موجود در ناحیه کال کافی، تا کنون ۱۶ حلقه گمانه اکتشافی حفر شده است. از طرفی، اکتشاف زون‌های هدف معرفی شده در جدول ۱، مستلزم طراحی و اجرای حداقل ۷ حلقه گمانه می‌باشد. به عبارت دیگر، استفاده از نتایج این تحقیق (صرف‌نظر از مزیت‌های فنی جهت طراحی فاز اکتشاف آتی) می‌تواند دست کم ۴۳٪ ارزش افزوده برای پروژه معدنی کال کافی به همراه داشته باشد.

جدول (۱). مشخصات مناطق هدف اکتشافی تعریف شده در محدوده معدنی کال کافی.

اولویت	زون هدف اکتشاف	موقعیت	امیدبخشی معدنی	عدم قطعیت
۱	Target I	جنوب امین ۱	بالا	پایین
۲	Target II	شرق امین ۲	حد واسط	حد واسط
۳	Target III	شمال امین ۲	پایین	بالا

۵. نتیجه‌گیری

مدل‌های هوش مصنوعی (SVM، LR و RF) و یادگیری عمیق (FCDNN) توانسته‌اند عملکرد قابل توجهی در پیش‌بینی کانه‌زایی طلا در نواحی زیرسطحی محدوده معدنی کال کافی به نمایش بگذارند. این روش‌ها موفق به برآزش مناسب به ویژگی‌های اکتشافی پیشگوی کانه‌زایی (صحت بالای آموزش) و نیز تعمیم‌پذیری مناسب به داده‌های جدید (صحت بالای آزمایش) گردیده‌اند. میزان صحت بالای مدل‌ها نشان داد که توابع یادگیری حاصل می‌توانند با درجه اطمینان قابل قبولی به داده‌های کل منطقه تعمیم داده شوند و بدین لحاظ، کاربرد الگوهای اکتشافی حاصل از این تکنیک‌ها جهت مدل‌سازی پتانسیل معدنی طلا در نواحی عمیق محدوده معدنی کال کافی توجیه‌پذیر است.

الگوی اکتشافی نهایی که از برهم‌نهی نقشه‌های E-type و عدم قطعیت حاصل شده است، محصول نهایی مجموعه پردازش‌های صورت گرفته در این تحقیق است که دورنمای جامع و کارآمدی از توزیع فضایی کانه‌زایی زیرسطحی طلا در محدوده معدنی کال کافی ارائه می‌کند. این الگو علاوه بر این که مرز نهایی کانسنگ و باطله را در اعماق منطقه مطالعاتی منعکس می‌کند، عدم قطعیت توأم با الگوی کانه‌زایی را نیز بیان می‌کند. با توجه به هزینه‌های بالای عملیات حفاری، این الگوی اکتشافی می‌تواند ابزار کارآمدی در راستای کاهش هزینه‌های ناشی از حفاری‌های شناسایی اضافی و طراحی بهینه حفاری سیستماتیک در محدوده معدنی کال کافی ارائه نمایند.

- the use of explicit spatial information,” *Comput. Geosci.*, vol. 63, pp. 22–33, 2014.
- [26] H. T. X. Doan and G. M. Foody, “Increasing soft classification accuracy through the use of an ensemble of classifiers,” *Int. J. Remote Sens.*, vol. 28, no. 20, pp. 4609–4623, 2007.
- [27] J. R. Harris, M. Naghizadeh, P. Behnia, and L. Mathieu, “Data-driven gold potential maps for the Chibougamau area, Abitibi greenstone belt, Canada,” *Ore Geol. Rev.*, p. 105176, 2022.
- [28] P. O. Gislason, J. A. Benediktsson, and J. R. Sveinsson, “Random forests for land cover classification,” *Pattern Recognit. Lett.*, vol. 27, no. 4, pp. 294–300, 2006.
- [29] C. M. Yeomans, R. K. Shail, S. Grebby, V. Nykänen, M. Middleton, and P. A. J. Lusty, “A machine learning approach to tungsten prospectivity modelling using knowledge-driven feature extraction and model confidence,” *Geosci. Front.*, 2020.
- [30] Z. Wang, R. Zuo, and Y. Dong, “Mapping Geochemical Anomalies Through Integrating Random Forest and Metric Learning Methods,” *Nat. Resour. Res.*, pp. 1–14, 2019.
- [31] E. J. M. Carranza and A. G. Laborte, “Data-driven predictive mapping of gold prospectivity, Baguio district, Philippines: Application of Random Forests algorithm,” *Ore Geol. Rev.*, vol. 71, pp. 777–787, 2015.
- [32] E. J. M. Carranza and A. G. Laborte, “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, Jan. 2015.
- [33] C. Kirkwood, M. Cooper, A. Ferreira, and D. Beamish, “Unmixing and mapping components of Northern Ireland’s geochemical composition using FastICA and random forests,” *EarthArXiv*, 2020.
- [34] A. Ford, “Practical Implementation of Random Forest-Based Mineral Potential Mapping for Porphyry Cu–Au Mineralization in the Eastern Lachlan Orogen, NSW, Australia,” *Nat. Resour. Res.*, vol. 29, no. 1, pp. 267–283, 2020.
- [35] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi, “A survey of deep neural network architectures and their applications,” *Neurocomputing*, vol. 234, pp. 11–26, 2017.
- [36] C. Jianping, X. Jie, H. U. Qiao, Y. Wei, L. Zili, H. U. Bin, and W. Wei, “Quantitative geoscience and geological big data development: a review,” *Acta Geol. Sin. Ed.*, vol. 90, no. 4, pp. 1490–1515, 2016.
- [37] S. Haykin, “A comprehensive foundation,” *Neural networks*, vol. 2, no. 2004, p. 41, 2004.
- [38] K. Yamazaki, V.-K. Vo-Ho, D. Bulsara, and N. Le, “Spiking neural networks and their applications: A Review,” *Brain Sci.*, vol. 12, no. 7, p. 863, 2022.
- [39] C. M. Bishop, “Neural networks and their applications,” *Rev. Sci. Instrum.*, vol. 65, no. 6, pp. 1803–1832, 1994.
- [40] P. A. Dowd and C. Sarac, “A neural network approach to geostatistical simulation,” *Math. Geol.*, vol. 26, pp. 491–503, 1994.
- [41] J. C. Davis and R. J. Sampson, *Statistics and data analysis in geology*, vol. 646. Wiley New York et al., 1986.
- [42] D. R. Cohen, D. L. Kelley, R. Anand, and W. B. Coker, determine additional drilling for copper exploration,” *J. Appl. Geophys.*, vol. 83, pp. 35–45, 2012.
- [10] H. Granian, S. H. Tabatabaei, H. H. Asadi, and E. J. M. Carranza, “Multivariate regression analysis of lithochemical data to model subsurface mineralization: a case study from the Sari Gunay epithermal gold deposit, NW Iran,” *J. Geochemical Explor.*, vol. 148, pp. 249–258, 2015.
- [11] M. Story and R. G. Congalton, “Accuracy assessment: a user’s perspective,” *Photogramm. Eng. Remote Sensing*, vol. 52, no. 3, pp. 397–399, 1986.
- [12] J. Wang and R. Zuo, “Model averaging for identification of geochemical anomalies linked to mineralization,” *Ore Geol. Rev.*, p. 104955, 2022.
- [13] S. Theodoridis and K. Koutroumbas, “Chapter 10 - Supervised Learning: The Epilogue BT - Pattern Recognition (Fourth Edition),” Boston: Academic Press, 2009, pp. 567–594.
- [14] F. Maepa, R. S. Smith, and A. Tessema, “Support vector machine and artificial neural network modelling of orogenic gold prospectivity mapping in the Swayze greenstone belt, Ontario, Canada,” *Ore Geol. Rev.*, vol. 130, p. 103968, 2021.
- [15] R. Zuo and E. J. M. Carranza, “Support vector machine: a tool for mapping mineral prospectivity,” *Comput. Geosci.*, vol. 37, no. 12, pp. 1967–1975, 2011.
- [16] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M. Chica-Rivas, “Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines,” *Ore Geol. Rev.*, vol. 71, pp. 804–818, 2015.
- [17] A. R. Mokhtari, “Hydrothermal alteration mapping through multivariate logistic regression analysis of lithochemical data,” *J. Geochemical Explor.*, vol. 145, pp. 207–212, 2014.
- [18] M. A. McCarthy, M. A. Burgman, and S. Ferson, “Sensitivity analysis for models of population viability,” *Biol. Conserv.*, vol. 73, no. 2, pp. 93–100, 1995.
- [19] E. J. M. Carranza and M. Hale, “Geologically constrained fuzzy mapping of gold mineralization potential, Baguio district, Philippines,” *Nat. Resour. Res.*, vol. 10, no. 2, pp. 125–136, 2001.
- [20] E. J. M. Carranza, M. Hale, and C. Faassen, “Selection of coherent deposit-type locations and their application in data-driven mineral prospectivity mapping,” *Ore Geol. Rev.*, vol. 33, no. 3–4, pp. 536–558, 2008.
- [21] Y. Liu, Q. Xia, Q. Cheng, and X. Wang, “Application of singularity theory and logistic regression model for tungsten polymetallic potential mapping,” *Nonlinear Process. Geophys.*, vol. 20, no. 4, pp. 445–453, 2013.
- [22] Y. Xiong and R. Zuo, “GIS-based rare events logistic regression for mineral prospectivity mapping,” *Comput. Geosci.*, vol. 111, pp. 18–25, 2018.
- [23] J. R. Harris, E. Grunsky, P. Behnia, and D. Corrigan, “Data-and knowledge-driven mineral prospectivity maps for Canada’s North,” *Ore Geol. Rev.*, vol. 71, pp. 788–803, 2015.
- [24] B. Waske and M. Braun, “Classifier ensembles for land cover mapping using multitemporal SAR imagery,” *ISPRS J. Photogramm. Remote Sens.*, vol. 64, no. 5, pp. 450–457, 2009.
- [25] M. J. Cracknell and A. M. Reading, “Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and

- [46] S. P. Vriend, *Practical applications of multivariate statistics in exploration geochemistry*. Faculteit Aardwetenschappen, 1990.
- [47] M. Templ, P. Filzmoser, and C. Reimann, "Cluster analysis applied to regional geochemical data: problems and possibilities," *Appl. Geochemistry*, vol. 23, no. 8, pp. 2198–2213, 2008.
- [48] R. H. Sillitoe, "Characteristics and controls of the largest porphyry copper-gold and epithermal gold deposits in the circum-Pacific region," *Aust. J. Earth Sci.*, vol. 44, no. 3, pp. 373–388, 1997.
- [49] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," in *Ijcai*, 1995, vol. 14, no. 2, pp. 1137–1145.
- "Major advances in exploration geochemistry, 1998{\textendash}2007," *Geochemistry Explor. Environ. Anal.*, vol. 10, no. 1, pp. 3–16, 2010.
- [43] B. Liu, S. Guo, Y. Wei, and Z. Zhan, "A Fast Independent Component Analysis Algorithm for Geochemical Anomaly Detection and Its Application to Soil Geochemistry Data Processing," *J. Appl. Math.*, vol. 2014, 2014.
- [44] G. J. S. Govett, *Rock geochemistry in mineral exploration*, vol. 3. Elsevier, 2013.
- [45] R. J. Howarth, *Handbook of exploration geochemistry: statistics and data analysis in geochemical prospecting*. 1983.