

الگوریتم‌های یادگیری ماشین برای تولید مدل‌های پیشگو جهت مشخص نمودن اهداف اکتشافی کانی‌سازی طلا در منطقه تخت سلیمان

رضا قزلباش^{۱*}، مسعود اسمعیل‌زاده^۲

۱- دانشجوی دکتری دانشگاه صنعتی امیرکبیر

۲- دانشجوی دکتری و مدیر پروژه، موسسه امین ارومیه

(دریافت: ۱۳۹۹/۰۶/۲۲، پذیرش: ۱۳۹۹/۱۲/۲۳)

چکیده

تعیین فرآیندهای موثر در تشکیل کانسارهای فلزی که به عنوان کنترل‌کننده‌های کانی‌زایی در نظر گرفته می‌شوند، یک گام اساسی در مدل‌سازی پتانسیل معدنی می‌باشد. در این پژوهش، ۵ معیار اکتشافی حاصل از داده‌های ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری و ماهواره‌ای مرتبط با کانی‌زایی طلائی نوع اپی‌ترمال و کارلین در منطقه تخت سلیمان با هم ترکیب شدند. برای تولید نقشه ژئوشیمیایی چند عنصری، روش تحلیل مولفه‌های اصلی بر روی ۸ عنصر انتخاب شده مرتبط با کانی‌زایی اعمال گردید و مشخص شد که عنصر طلا با عناصر ردیاب خود یعنی آرسنیک و آنتیموان ارتباط مکانی و ژنتیکی بالایی در مولفه دوم (PC2) نشان می‌دهد. سپس ۱۰ لایه اکتشافی موثر با مقادیر پیوسته فازی بر اساس مقادیر مساحت زیر منحنی (AUC) منحنی‌های نرخ موفقیت برای تولید مدل‌های پیشگوی نواحی مستعد کانی‌زایی طلا انتخاب گردیدند. برای نیل به این هدف، دو روش نظارتی یادگیری ماشین شامل شبکه عصبی MLP و ماشین‌های بردار پشتیبان (SVM) با کرنل RBF بر اساس فرآیند آموزش و یادگیری مورد استفاده قرار گرفتند. نتایج نهایی بر اساس مقادیر AUC هر یک از منحنی‌های نرخ موفقیت مدل‌های مذکور، نشان داد که روش SVM-RBF از دقت بالاتر و عملکرد بهتر نسبت به روش شبکه عصبی MLP برخوردار می‌باشد که برای استفاده در مراحل اکتشاف تفضیلی جهت یافتن کانسارهای جدید طلا مناسب‌تر است.

کلید واژه‌ها: مدل‌سازی پتانسیل معدنی، الگوریتم‌های یادگیری ماشین، شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان.

۱. مقدمه

این هدف، می‌بایست داده‌های مکانی مختلف از منطقه مورد مطالعه و بر اساس نوع کانسارهای مورد نظر جمع‌آوری و توسط سیستم اطلاعات زمین‌مکانی (GIS) آنالیز و تلفیق شوند (کارانزا، ۲۰۰۸؛ بنهام کارتر، ۱۹۹۴؛ نجفی و همکاران، ۲۰۱۴؛ قزلباش و مقصودی، ۲۰۱۸). روش‌های دانش‌محور و داده‌محور که دو نوع روش اصلی مدل‌سازی پتانسیل معدنی برای تلفیق لایه‌های وزن‌دار مختلف جهت شناسایی نواحی امید بخش نوع خاصی از کانی‌زایی می‌باشند، بدین منظور مورد استفاده قرار می‌گیرند (بنهام کارتر، ۱۹۹۴؛ کارانزا، ۲۰۰۸؛ یوسفی و کارانزا، ۲۰۱۵؛ قزلباش و همکاران، ۲۰۱۹).

در اکتشافات اولیه و مقدماتی، شناسایی مناطقی که باید در مراحل بعدی مورد توجه قرار گیرند با استفاده از مدل‌سازی پتانسیل معدنی صورت می‌گیرد. مدل‌سازی پتانسیل معدنی در واقع یافتن مکان‌ها یا مناطقی است که یک سری معیارها و ملاک‌ها برای حضور ذخیره در آن‌ها صدق می‌کند و یک فرآیند پیچیده‌ای می‌باشد که نیازمند در نظر گرفتن همزمان مجموعه داده‌های مکانی مختلف (ژئوشیمی، ژئوفیزیک، دورسنجی، زمین‌شناسی و غیره) از منطقه مورد مطالعه می‌باشد که هدف نهایی آن، اکتشاف نوع خاصی از کانی‌زایی می‌باشد. جهت نیل به

روش‌های داده‌محور برای مناطقی که کارهای اکتشافی در آن‌ها به خوبی صورت گرفته است (نواحی قهوه‌ای)، مناسب هستند که

^۱ نویسنده پاسخگو : rezaghezelbash@aut.ac.ir

تصویر و توصیف می‌شوند. این نقشه‌های پیش‌گو در نهایت به منظور مشخص نمودن حدود نواحی هدف در اکتشافات بعدی (بیش‌تر) برای شناسایی محل ذخایر کشف نشده، تلفیق می‌شوند (قزلباش و همکاران، ۲۰۲۰).

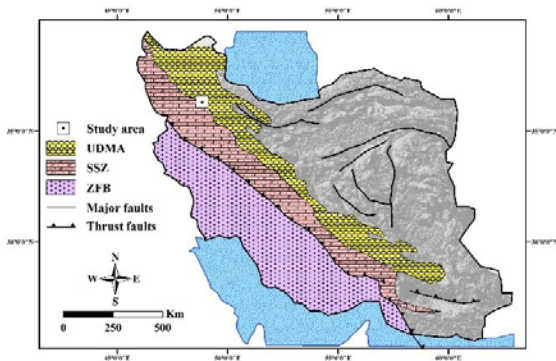
اخیراً الگوریتم‌های یادگیری ماشین نظیر ماشین‌های بردار پشتیبان (SVMs)، شبکه‌های عصبی مصنوعی (ANNs) و جنگل‌های تصادفی (Random forests) به‌عنوان روش‌های قدرتمند داده‌محور برای تولید مدل‌های پیش‌گوی نواحی کانی‌زایی پر پتانسیل با دقتی بالاتر از روش‌های دانش‌محور توسعه یافته‌اند. این الگوریتم‌ها در سالیان اخیر بنا به دلایل فراوان از جمله توانایی مدیریت داده‌های با حجم و ابعاد بزرگ (Big data)، توانایی تشخیص و مدیریت همبستگی‌های غیرخطی بین ویژگی‌های فضایی حاصل از معیارهای اکتشافی مختلف و کانسارهای شناخته شده از نوع خاص کانی‌زایی، عدم نیاز به وجود استقلال شرطی در بین ویژگی‌های فضایی ورودی، قدرت تفکیک نواحی اکتشافی هدف با استفاده از آموزش داده‌های ورودی بر اساس ویژگی‌های کانسارهای شناخته، شهرت و محبوبیت فراوانی بین مهندسی معدن و متخصصین علوم زمین یافته‌اند (سان و همکاران، ۲۰۱۹). الگوریتم‌های یادگیری ماشین در واقع مدل‌های پیش‌گوی خود کالیبراسیون محسوب می‌شوند که قادر به شناسایی الگوهای اکتشافی مورد نظر و کمینه کردن خطاهای پیش‌بینی حاصل از توابع رگرسیونی پیچیده با استفاده از تکرار فرآیند آموزش می‌باشند. زمانی که فرآیند آموزش به بلوغ کامل برسد و اتمام یابد، مدل پیش‌گوی تولید شده قادر به شناسایی اهداف اکتشافی کشف نشده خواهد بود.

به‌عبارت دیگر، مدل‌سازی پتانسیل معدنی در استفاده از روش‌های یادگیری ماشین یک مسئله طبقه‌بندی در نظر گرفته می‌شود (زو و کارانزا، ۲۰۱۱). زیرا منطقه مورد مطالعه توسط این الگوریتم‌ها می‌تواند به نواحی "مطلوب" یا "غیرمطلوب" تقسیم‌بندی گردد. چنین استراتژی طبقه‌بندی به شدت از چندین فاکتور نظیر کافی بودن داده‌های آموزشی ورودی، فراوانی متغیرهای پیش‌گو (مانند مکان‌های مربوط به حضور قطعی کانسارهای معدنی و همچنین مکان‌های مربوط به عدم حضور قطعی کانسارهای معدنی) و همچنین تعیین دقیق پارامترهای دخیل در الگوریتم‌های یادگیری ماشین جهت آموزش مدل تاثیر می‌پذیرد (قزلباش و همکاران، ۲۰۲۰). بنابراین انتخاب نوع الگوریتم مورد استفاده در مدل‌سازی پتانسیل معدنی بسیار مهم می‌باشد. برای نیل به این هدف، در این پژوهش از دو روش قدرتمند یادگیری ماشین شامل شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان برای تولید مدل‌های پیش‌گوی

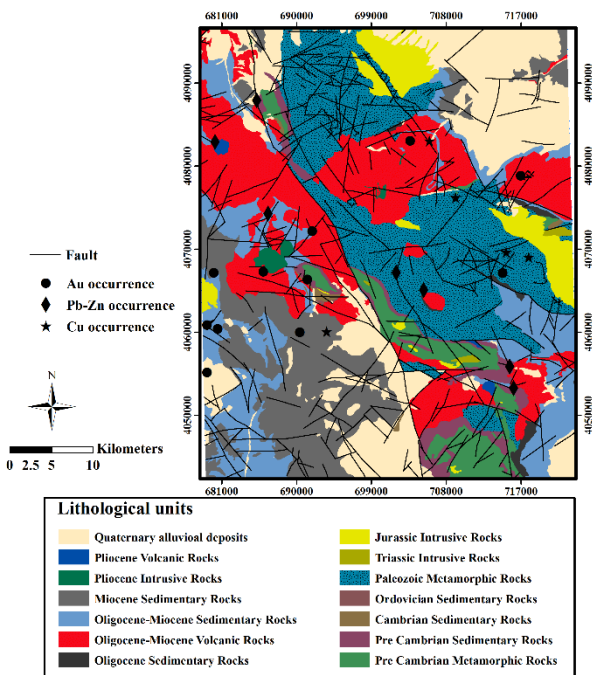
در این روش‌ها، کانسارها و اندیس‌های شناخته شده از منطقه مورد مطالعه که احتمال کانی‌زایی در آن‌ها بسیار بالا می‌باشد، برای تعیین روابط مکانی داده‌ها به‌عنوان نقاط آموزشی در نظر گرفته می‌شوند (عابدی و همکاران، ۲۰۱۳). انواع روش‌های داده‌محور شامل رگرسیون لجستیکی (چانگ و اگتربرگ، ۱۹۸۰)، وزن‌های نشانگر (بنهام کارتر، ۱۹۹۴) درخت‌های تصمیم‌گیری (ردی و بنهام کارتر، ۱۹۹۱) شبکه‌های عصبی مصنوعی (هریس و پن، ۱۹۹۹؛ قزلباش و همکاران، ۲۰۲۰)، ماشین‌های بردار پشتیبان (زو و کارانزا، ۲۰۱۱) و جنگل‌های تصادفی (گالیانو و همکاران، ۲۰۱۵) می‌باشند. روش‌های دیگر مدل‌سازی پتانسیل معدنی بر مبنای دانش کارشناسان متخصص می‌باشد که بیشتر برای مناطقی که در آن‌ها کارهای اکتشافی کمتری صورت گرفته است (نواحی سبز)، مناسب هستند. در این روش‌ها که به روش‌های دانش‌محور معروف هستند، وزن‌دهی به لایه‌های شاهد بر اساس نظرات کارشناسان متخصص صورت می‌گیرد (بنهام کارتر، ۱۹۹۴؛ کارانزا، ۲۰۰۸). انواع این روش‌ها شامل منطق بولی، همپوشانی شاخص (بنهام کارتر و همکاران، ۱۹۸۸)، منطق فازی (پوروال و همکاران، ۲۰۰۳) و تحلیل سلسله‌مراتبی (AHP) (قزلباش و مقصودی، ۲۰۱۸) می‌باشند.

روش‌های داده‌محور برای تعیین مناطق اکتشافی هدف جهت محدود کردن مناطق مورد اکتشاف به‌منظور شناسایی محل‌های کانی‌سازی کشف نشده، بر اساس فرض‌های زیر می‌بایست مورد توجه قرار گیرند (کارانزا، ۲۰۰۸): ۱) در یک منطقه مورد مطالعه، محل‌های وقوع ذخایر شناخته شده، مجموعه نمونه‌هایی با شباهت بالا به محل‌های حضور کانی‌سازی‌های ناشناخته هستند؛ ۲) این نمونه‌ها مجموعه اطلاعات زمین‌شناسی باارزشی از منظرها و الگوهای شاهد فضایی مانند آنومالی‌های ژئوشیمیایی، گسل‌ها، آنومالی‌های ژئوفیزیکی، سنگ میزبان کانی‌سازی و غیره را فراهم می‌کنند که همراه با ذخایر شناخته شده و در محل آن‌ها حضور دارند؛ ۳) این مجموعه اطلاعات متنوع زمین‌شناسی، می‌توانند یک مدل مفهومی از معیارهای پی‌جویی را برای محل ذخایر کشف نشده ارائه نمایند. مدل مفهومی به‌دست‌آمده، میزان و وابستگی وقوع ذخایر معدنی را به‌عنوان تابعی از حضور مهم‌ترین معیارها و شواهد فضایی منحصربه‌فرد بیان می‌کند. در واقع، مدل مفهومی، چارچوبی را برای ایجاد و کمی نمودن همراهی فضایی بین یک مجموعه از ذخایر شناخته شده با مجموعه شواهد و معیارهای شناسایی منحصربه‌فرد، در یک منطقه مورد مطالعه، فراهم می‌آورد. کمی نمودن همراهی فضایی بین ذخایر شناخته شده و مجموعه داده‌های شاهد و الگوهای فضایی خاص، شاخص‌هایی را آشکار می‌سازد که وابسته به وقوع ذخایر می‌باشند. این شاخص‌ها عموماً به‌صورت نقشه‌های پیش‌گو،

زرشوران، بایچه باغ و توزلار می‌باشد (شکل ۲).



شکل (۱). نقشه ساده‌شده زون‌های ساختاری در ایران (کمان ماگمایی ارومیه-دختر (UMDA)، زون سنندج-سیرجان (SSZ)، کمر بند چین خورده زاگرس (ZFB)) و موقعیت منطقه مورد مطالعه (علوی، ۱۹۹۴).



شکل (۲). نقشه زمین‌شناسی ساده شده ورقه ۱:۱۰۰۰۰۰ تخت سلیمان (باباخانی و قلمقاش، ۱۳۸۰).

۳. روش تحقیق

یکی از مهم‌ترین اهداف پتانسیل‌یابی معدنی، استفاده از روش‌هایی است که به‌وسیله آن‌ها بتوان نواحی پرتانسسیل از لحاظ کانی‌زایی مطلوب را جهت استفاده در مراحل بعدی اکتشاف شناسایی نمود. اساسی‌ترین فرآیند در مدل‌سازی پتانسیل معدنی، انتخاب و استخراج معیارهای اکتشافی مناسب مرتبط با کانی‌زایی و همچنین استفاده از روش‌های خلاقانه و قدرتمند برای استخراج ویژگی‌های اصلی معیارهای اکتشافی می‌باشد. تحلیل روابط

کانی‌زایی طلا در منطقه تخت سلیمان که دارای کانسارها و اندیس‌های فراوان طلا می‌باشد، استفاده شده است تا بتوان در اکتشافات تفضیلی تر جهت کاهش ریسک و عدم قطعیت اکتشافی و افزایش احتمال موفقیت، مورد استفاده قرار داد.

۲. زمین‌شناسی منطقه

ورقه ۱:۱۰۰۰۰۰ تخت سلیمان بخشی از چهارگوش ۱:۲۵۰,۰۰۰ تکاب می‌باشد که بین طول شرقی ۴۷°۰۰' تا ۴۷°۳۰' و عرض شمالی ۳۶°۳۰' تا ۳۷°۰۰' قرار گرفته است. منطقه مورد مطالعه در بخش مرزی قوس ماگمایی ارومیه-دختر (UDMA) و زون سنندج-سیرجان (SSZ) جای گرفته است (شکل ۱). قوس ماگمایی ارومیه-دختر در طی پدیده فرورانش نئوتتیس به زیر زون سنندج سیرجان شکل گرفته است (علوی، ۱۹۹۴). تناوبی از فعالیت‌های کوهزایی نظیر ماگماتیسیم، رسوبی شدن و متامورفیسیم در این محدوده قابل مشاهده است (اسدی و هیل، ۲۰۰۱). ساختارهای زمین‌شناسی در این منطقه به طور کلی شامل واحدهای دگرگونی پرکامبرین، ولکانیک‌های ترشیری و رسوبات کواترنری می‌باشد (اسدی و هیل، ۲۰۰۱) (شکل ۲).


از لحاظ سنگ‌شناسی، این منطقه بیشتر از سنگ‌های دگرگونی شیست، مرمر، گنایس و آمفیبولیت تشکیل شده است که با روند شمال غربی - جنوب شرقی در بخش میانی محدوده مورد نظر بلندترین ارتفاعات (کوه بلقیس و کوه قبله داغ) را تشکیل می‌دهند که توسط سنگ‌های آتشفشانی-رسوبی الیگو-میوسن پوشیده شده‌اند. ردیف چینه ای این سنگ‌ها در منطقه مورد بررسی به ترتیب از پایین به بالا شامل سنگ‌های دگرگونی پرکامبرین، سنگ‌های رسوبی پرکامبرین پسین - کامبرین پیشین و کامبرین - اردویسین، سنگ‌های دگرگونی پالئوزوئیک، توده‌های نفوذی دیوریتی، گرانودیوریتی و گرانیتی، سنگ‌های آتشفشانی - رسوبی الیگو - میوسن و نهشته‌های جوان پلیوسن و کواترنری می‌باشد (حسین زاده و همکاران، ۱۳۹۵) (شکل ۲).

کانی‌زایی طلا در این منطقه، به طور کلی با فرایندهای هیدروترمال مرتبط با توده‌های آذرین ترشیری در ارتباط است که از نقطه نظر کانی‌زایی طلا، توده‌های اسیدی وارد شیست‌های پرکامبرین شده‌اند (قربانی، ۲۰۱۳؛ مقصودی و همکاران، ۲۰۰۵). بخش وسیعی از منطقه را سنگ‌های رسوبی و آتشفشانی الیگو-میوسن پوشانده‌اند که بر روی سنگ‌های دگرگونی کهن قرار گرفته‌اند و میزبان‌های اصلی کانی‌زایی طلای اپی‌ترمال و کارلین درون محدوده مطالعاتی هستند (باباخانی، ۱۳۸۰). مهم‌ترین کانسارها و اندیس‌های طلای موجود در این منطقه شامل آق‌دره،

استفاده قرار گرفته است. یک شبکه MLP از سه لایه اصلی تشکیل شده است: ۱. لایه ورودی، ۲. لایه مخفی (میانی) و ۳. لایه خروجی. هر یک از این سه لایه حاوی یک یا چند نورون می‌باشند. لایه ورودی، متغیرهای ورودی را گرفته و آن‌ها را به بخش مرکزی شبکه MLP جهت پردازش منتقل می‌کند. در مرحله پردازش داده، لایه مخفی متغیرهای ورودی را پردازش کرده و ویژگی‌ها و اطلاعات موردنیاز را استخراج می‌کند و آن‌ها را از طریق یک تابع غیرخطی (تابع فعال‌سازی) آماده ورود به لایه خروجی می‌نماید. نتایج مربوط به لایه مخفی از طریق جمع وزنی در لایه خروجی جمع‌آوری می‌گردد. خروجی مدل MLP توسط فرمول ریاضی زیر قابل بیان می‌باشد (قزلباش و همکاران، ۲۰۲۰):

$$y = f \left(\sum_{i=1}^n w_i x_i + b \right) \quad (1)$$

که در فرمول بالا، w_i بردار وزنی، x_i بردار ورودی، b بایاس مدل و f تابع انتقال‌دهنده (فعال‌سازی) می‌باشند که در نهایت منجر به محاسبه y یعنی همان خروجی مدل می‌گردد. شکل (۳)، نمایی کلی از یک شبکه پرسپترون چندلایه (MLP) را نمایش می‌دهد.



Multi Layer Perceptron Neural Network

شکل (۳). ساختار کلی یک شبکه عصبی پرسپترون چند لایه (MLP-ANN).

۲-۳. ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان (SVMs) جزو الگوریتم‌های نظارتی یادگیری ماشین هستند که برای مسائل حل مسائل طبقه‌بندی مورد استفاده قرار گرفته‌اند. همانطور که در بخش‌های قبلی ذکر گردید، مدل‌سازی پتانسیل معدنی نوعی از مسائل طبقه‌بندی در نظر گرفته می‌شود، زیرا بوسیله آن، منطقه مورد نظر به بخش‌های "مطلوب" و "غیرمطلوب" از لحاظ نوع خاصی از کانی‌زایی طبقه‌بندی می‌گردد. بنابراین، روش SVM می‌تواند در

فضایی بین ویژگی‌های استخراجی و موقعیت کانسارهای شناخته شده می‌تواند توسط روش‌های عددی مختلفی صورت پذیرد؛ بنابراین انتخاب یک روش یا الگوریتم مناسب برای تولید یک نقشه پتانسیل معدنی ضروری می‌باشد. در واقع، انتخاب یک الگوریتم مناسب به ظرفیت یادگیری روابط بین ویژگی‌های شاهد ورودی و رخدادهای کانی‌زایی مربوط به کانسارهای شناخته شده بستگی دارد (گالیانو و همکاران، ۲۰۱۵).

روش‌های یادگیری ماشین مانند انواع روش‌های شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان نسبت به روش‌های آماری قدیمی‌تر از دقت و کیفیت بالاتری به‌ویژه زمانی که ابعاد داده‌های ورودی بالا بوده و روابط بین کانسارهای هدف و ویژگی‌های ورودی غیرخطی باشند، برخوردار می‌باشند. روش‌های یادگیری ماشین از پتانسیل بالایی برای شناسایی و مدل‌سازی روابط غیرخطی پیچیده بین رخدادهای کانی‌زایی و ویژگی‌های شاهد برخوردار می‌باشند (قزلباش و همکاران، ۲۰۱۹).

۱-۳. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی سامانه‌هایی رایانه‌ای هستند که از روی سامانه مغز انسان طراحی شده‌اند و از دو جنبه شبیه مغز انسان هستند. اول اینکه دانش در آن‌ها از راه یادگیری کسب می‌شود و دوم اینکه توان‌های ارتباطی بین نورونی به نام وزن‌های سیناپسی برای ذخیره دانش بکار می‌روند. شبکه‌های عصبی توان زیادی در حل مسائل پیچیده‌ای دارند که عوامل متعددی در فرایند و نتیجه آن تاثیر می‌گذارند. وجود یک کانسار، به‌وسیله متغیرهای زمین‌شناختی متعدد و مرتبطی کنترل می‌شود و در نتیجه یکی از کاربردهای شبکه عصبی می‌تواند در زمینه تهیه نقشه‌های پتانسیل معدنی باشد. شبکه‌های عصبی معمولاً شامل یک دسته لایه‌های مرتبط هستند که هر یک از لایه‌ها دارای واحدهای پردازش اصلی به نام نورون (سلول عصبی) می‌باشند. بر اساس یک مدل پذیرفته شده هر نورون از قسمت اساسی تشکیل شده است: (۱) مجموعه‌ای از سیناپس‌ها یا حلقه‌های مرتبط که هر کدام یک ورودی را به یک وزن سیناپسی مرتبط می‌کند، (۲) یک افزایشگر (جمع‌کننده) که ورودی‌های وزن‌دار را جمع می‌کند و (۳) تابع محرکی که ورودی‌های جمع شده را به خروجی‌ها تبدیل می‌کند (هسون، ۱۹۹۵).

شبکه‌های عصبی برحسب تعداد نورون‌ها، روش ارتباط نورون‌ها، شکل تابع محرک و الگوریتم یادگیری با یکدیگر متفاوت هستند. شبکه‌های عصبی مختلفی برای تولید مدل‌های پیش‌گوی نواحی کانی‌زایی استفاده شده‌اند. شبکه پرسپترون چند لایه یا به اختصار MLP، به دلیل ساختار انعطاف‌پذیر به عنوان یک شبکه پیش‌رونده، در بسیاری از شاخه‌های دیگر علوم زمین نیز مورد

مسئله بهینه‌سازی زیر فراهم می‌گردد:

$$\text{Minimize } \tau(w) = \frac{1}{2} \|w\|^2 \quad (7)$$

داده‌های اکتشافی آنالیز شده جهت یافتن اهداف اکتشافی مستعد، به دلیل پیچیدگی‌های زمین‌شناسی و ساختاری، داده‌های غیرقابل تفکیک در نظر گرفته می‌شوند. به همین دلیل، انواع مختلف توابع کرنل شامل کرنل‌های چند جمله‌ای، پایه شعاعی (RBF) و سیگموئیدی به عنوان توابع تصمیم‌گیرنده در روش SVM مورد استفاده قرار گرفته‌اند. در این پژوهش، تابع کرنل RBF، به دلیل توانایی مدیریت داده‌های با ابعاد زیاد و تنها نیاز به تنظیم دو پارامتر شامل پارامترهای C (موسوم به پارامتر هزینه) و λ (موسوم به پارامتر عرض RBF)، مورد استفاده قرار گرفت.


۴. نتایج و بحث

۴-۱. لایه‌های شاهد اکتشافی

بر اساس شواهد و داده‌های اکتشافی موجود از ورقه ۱:۱۰۰۰۰۰:۱ تخت سلیمان، ۵ معیار اصلی برای مدل‌سازی احتمال کانی‌زایی طلا در منطقه مطالعاتی مورد استفاده قرار گرفته‌اند که شامل: (۱) معیار ژئوشیمیایی (نقشه‌های ژئوشیمیایی چند عنصری حاصل از تحلیل مولفه‌های اصلی (PCA, 2) معیار ژئوفیزیکی (نقشه‌های ژئوفیزیکی مغناطیس هوابرد پس از اعمال فیلترهای برگردان به قطب (RTP)، مشتق اول و مشتق دوم)، (۳) معیار دورسنجی (نقشه‌های دگرسانی‌های گرمایی فراهم شده از پردازش و آماده‌سازی تصاویر ASTER و ETM+، (4) معیار زمین‌شناسی (واحد‌های سنگ‌شناسی مرتبط با کانی‌زایی طلا در محدوده مورد مطالعه) و (۴) معیار ساختاری (نقشه گسل‌ها و خطواره‌های موجود در منطقه مورد مطالعه) می‌باشند که ترکیب این معیارهای اکتشافی، می‌تواند منجر به شناسایی نواحی امیدبخش کانی‌زایی طلا در ورقه تخت سلیمان گردد.

روش تحلیل مؤلفه‌های اصلی (PCA) یک ابزار مناسب برای تبدیل مقادیر عیاری چند عنصری به حالت تک مؤلفه‌ای می‌باشد. طبق بررسی‌های آماری چند متغیره با استفاده از روش تحلیل مؤلفه‌های اصلی، مشخص شد که در مؤلفه اول PC1، ۴ عنصر نقره، کادمیوم، سرب و روی بیشترین همبستگی را نسبت به سایر عناصر دارند. همچنین در مؤلفه دوم PC2 عناصر آرسنیک و آنتیموان که به‌عنوان عناصر ردیاب کانی‌زایی طلا در کانسارهای اپی‌ترمال شناخته شده‌اند، با عنصر طلا بیشترین همبستگی را دارا می‌باشند که این امر نشان‌دهنده این است که PC2 به‌عنوان

رسیدن به چنین هدفی کمک نماید (زو و کارانزا، ۲۰۱۱). بردارهای پشتیبان در این روش هایپرپلان‌هایی را با حاشیه بیشینه برای جدا کردن کلاس‌های موجود در داده‌ها به شرط رسیدن به دقت مورد نظر، اعمال می‌کنند. در واقع، هدف اصلی الگوریتم SVM، به دست آوردن هایپرپلان‌های جداکننده بهینه بین دو کلاس داده با هدف بیشینه نمودن حاشیه‌ی نزدیک‌ترین نقاط دو کلاس و هم‌چنین کمینه نمودن خطای طبقه‌بندی می‌باشد (شکل ۴).



شکل (۴). بردارهای پشتیبان و هایپرپلان بهینه برای حالت دو کلاسه برای داده‌های قابل تفکیک.

در این روش فرض می‌شود که یک مجموعه داده آموزشی شامل k بردار ویژگی می‌باشد ($x_i \in R^n$) که در آن i برابر با تعداد بردارهای ویژگی در داده‌های آموزشی می‌باشد. داده‌هایی که به کلاس y_i تعلق دارند مقدار ۱ می‌گیرند و داده‌هایی که به این کلاس تعلق ندارند مقدار -۱ می‌گیرند. محاسبات مربوط به هایپرپلان‌های جداکننده در بخش پایین آورده شده است (کوازوگلو و کولکسن، ۲۰۰۹):

$$w x_i + b \geq +1 \text{ for } y_i = +1 \quad (2)$$

$$w x_i + b \leq -1 \text{ for } y_i = -1 \quad (3)$$

که برابر است با:

$$y_i (w x_i + b) \geq 1, \quad i = 1, 2, \dots, n \quad (4)$$

سپس هایپرپلان‌های جداکننده می‌توانند به عنوان یک تابع تصمیم‌گیری فرموله شوند:

$$f(x) = \text{sgn}(wx + b) \quad (5)$$

که در آن sgn یک تابع نشانه می‌باشد که به صورت زیر تعریف می‌گردد:

$$\text{sgn}(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{if } x = 0 \\ -1 & \text{if } x < 0 \end{cases} \quad (6)$$

هایپرپلان بهینه که می‌تواند داده‌ها را از هم تفکیک نماید، مطابق

فیلترهای برگردان به قطب (RTP)، مشتق اول و مشتق دوم، مقادیر حاصل شده به نرم افزار Arc GIS جهت تولید نقشه‌های مرتبط و شرکت در مدل سازی پتانسیل معدنی منتقل شدند.

جدول (۱). مقادیر لودینگ برای عناصر مختلف در هر مولفه اصلی و مقادیر ویژه و واریانس برای هر یک از مولفه‌های اصلی با استفاده از روش PCA

Elements	PC1	PC2	PC3
Au	-0.02	0.838	0.335
As	0.489	0.724	-0.155
Ag	0.709	0.14	0.094
Cd	0.838	0.303	-0.086
Cu	0.109	0.069	0.953
Pb	0.886	0.170	0.042
Sb	0.495	0.738	-0.111
Zn	0.874	0.141	0.146
Eigenvalue	3.304	1.935	1.097
Var. (%)	41.303	24.193	13.712
Cum. Var. (%)	41.303	65.496	79.208

در ورقه تخت سلیمان، اکثر کانسارهای طلا و فلزات پایه به ویژه در معادن طلای زرشوران، آق دره و سرب و روی انگوران توسط سازندهای رسوبی نفوذپذیر میزبانی شده‌اند. این سازندها به طور عمده شامل شیل‌های آهکی مربوط به دوره الیگو-میوسن، کربنات‌های کارستی، کربنات‌های آهن دار و مارل‌ها هستند. همچنین، کانی‌زایی طلا در این منطقه همبستگی شدیدی با سازندهای ولکانیکی مربوط به دوره الیگو-میوسن دارد (اسدی و هیل، ۲۰۰۱).

بر همین اساس واحدهای رسوبی و ولکانیکی الیگو-میوسن می‌توانند به ترتیب به عنوان میزبان و موتور حرارتی کانی‌زایی در منطقه مورد مطالعه، اطلاعات مؤثر و کارآمدی برای استفاده در مدل سازی پتانسیل کانی‌زایی طلا در اختیار قرار دهند. برای همین منظور با استفاده از نقشه زمین شناسی ورقه ۱:۱۰۰,۰۰۰ تخت سلیمان که توسط سازمان زمین شناسی و اکتشافات معدنی کشور تهیه و تدوین شده است، تمام واحدهای زمین شناسی موجود در منطقه به صورت دستی در محیط نرم افزار Arc GIS 10.2 به فرمت وکتور دیجیت شدند و به صورت شیپ فایل درآمدند. سپس بر اساس ویژگی‌های سنگ-چینه شناسی، نقشه‌های پیوسته‌ی فاصله از توده‌های رسوبی و ولکانیکی الیگو-میوسن جهت استفاده در مدل سازی پتانسیل معدنی تولید شد.

انتقال سیالات ماگمایی حاوی کانی‌زایی فلزی به ویژه طلا به شدت

لایه ژئوشیمیایی چند عنصری نماینده کانی‌زایی طلا در این منطقه است. همچنین، مولفه سوم PC3 نیز نماینده کانی‌زایی مس در محدوده مطالعاتی می‌باشد (جدول ۱). پس از بررسی‌های آماری چند متغیره با استفاده از روش تحلیل مؤلفه‌های اصلی، نقشه‌های آنومالی ژئوشیمیایی چند عنصری حاصل از مقادیر PC1، PC2 و PC3 جهت مدل سازی پتانسیل معدنی مورد استفاده قرار گرفتند. همچنین در این شکل‌ها، نحوه ارتباط آنومالی‌های چند عنصری با کانسارها اندیس‌های طلای شناخته شده در منطقه مطالعاتی مشاهده می‌گردد که به صورت چشمی می‌توان گفت مقادیر چند عنصری PC2 که حاوی تجمع عناصر طلا، آرسنیک و آنتیموان می‌باشد، بیشترین ارتباط مکانی را با کانسارها اندیس‌های شناخته شده طلا در منطقه تخت سلیمان نشان می‌دهد. لازم به ذکر است که عناصر آرسنیک و آنتیموان به عنوان ردیاب‌های عنصر طلا در کانی‌زایی‌های طلای تیپ اپی ترمال و کارلین شناخته می‌شوند.

یکی از مسائل مهم در تفسیر داده‌های مغناطیسی سنجی، حذف اثرات ناحیه‌ای (مناطق) که هدف عملیات اکتشافی نیستند) از داده‌های برداشت شده است. با حذف این اثرات، بی‌هنجاری‌های باقیمانده (محلی) که مربوط به ساختمان‌های زیرسطحی کم عمق تر هستند با وضوح بیشتری نمایان می‌شوند. به همین دلیل داده‌های برداشت شده پس از تصحیح‌های لازم باید با انتخاب فیلترهای مناسب به مؤلفه‌های ناحیه‌ای و باقیمانده تفکیک شوند (ویلسم و رمزی، ۱۳۹۳).

وجود توده‌های مغناطیسی و نحوه قرار گرفتن آن‌ها نسبت به جهت میدان مغناطیسی زمین و امتداد خطوط برداشت، باعث تغییر در شدت میدان یا شکل ناهنجاری حاصل از آن‌ها می‌گردد. برای حذف این مشکلات با اعمال فیلترهای رقومی این اثرات حذف می‌شوند. بنابراین شدت و شکل ناهنجاری‌های مشاهده شده، پس از حذف این اثرات بهبود می‌یابند. پس از برداشت‌های صحرائی و انجام تصحیح‌ها و اعمال فیلترهای لازم، نقشه‌های مختلفی با مقیاس مناسب تهیه می‌شوند و بر اساس نتایج به دست آمده خصوصیات منشا آنومالی‌ها تفسیر می‌شوند.

جهت تهیه لایه‌های ژئوفیزیکی در محدوده مورد مطالعه از داده‌های مغناطیس هوابرد موجود در سازمان زمین شناسی و اکتشافات معدنی کشور استفاده شده است. این داده‌ها در سال ۱۹۷۶ میلادی و در ارتفاع ۴۰۰ متری با خطوط پرواز ۷,۵ کیلومتری تهیه شده‌اند. برای پردازش این داده‌ها از نرم افزار Geosoft Oasis Montaj استفاده شد و پس از انجام تصحیح IGRF و به دست آوردن مقادیر زاویه میل و زاویه انحراف، اقدام به تهیه نقشه‌های پردازش شده این داده‌ها شد. پس از اعمال

کانی‌زایی هیدروترمال می‌توانند مورد استفاده قرار بگیرند.

در این پژوهش، پیش از اعمال روش‌های پردازش تصویر برای جداسازی آلتراسیون‌های هیدروترمال مرتبط با کانی‌زایی طلای اپی‌ترمال و کارلین، داده‌های ماهواره‌ای به صورت رادیومتری و هندسی کالیبره و تصحیح گردیدند. سپس تصاویر ماهواره ASTER برای استخراج آلتراسیون‌های هیدروترمال فیلیک، آرژیلیک، سیلیسیک و پروپیلیتیک با استفاده از روش تحلیل مولفه‌های اصلی (PCA) به کار گرفته شده است و همچنین تصاویر ETM+ برای تشخیص و جداسازی آلتراسیون‌های اکسید آهن در این محدوده استفاده شده است. در نهایت آلتراسیون‌های تشخیص داده شده در نرم‌افزار ENVI، به صورت شیپ فایل ذخیره شده و نقشه‌های نهایی پیوسته فاصله از آلتراسیون‌های آرژیلیک، فیلیک، سیلیسیک، پروپیلیتیک و اکسید آهن در محیط نرم‌افزار Arc GIS تولید شدند.

به منظور تلفیق لایه‌های اکتشافی مختلف از جمله لایه‌های ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری-تکتونیکی و آلتراسیونی و جهت تعیین اهداف اکتشافی، می‌بایست نقشه‌های رستری متعلق به لایه‌های اکتشافی که دارای مقادیر مختلف هستند به یک دامنه مشخص (۰ تا ۱) تبدیل شوند. به عبارت دیگر، یکسان‌سازی مقادیر ماکزیمم و مینیمم لایه‌های شاهد اکتشافی یک گام اساسی در مدل‌سازی پتانسیل معدنی در نظر گرفته می‌شود. توابع عضویت فازی بدین منظور در نرم‌افزار Arc GIS فراهم شده‌اند. از بزرگ‌ترین مزایای توابع فازی می‌توان به متراکم‌تر کردن آنومالی‌های حاصل از معیارهای اکتشافی مختلف اشاره نمود که باعث مشخص کردن دقیق‌تر اهداف اکتشافی می‌گردد.

بدین منظور، تمامی ۱۸ لایه‌ی شاهد اکتشافی ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری-تکتونیکی و آلتراسیونی که در مرحله قبل با سایز سلول ۱۰۰ متر × ۱۰۰ متر رستری شده بودند، تحت اعمال توابع عضویت فازی قرار گرفتند. برای لایه‌های ژئوشیمیایی مربوط به مولفه‌های اصلی اول، دوم و سوم، لایه‌های ژئوفیزیکی مغناطیس سنجی هوابرد و لایه چگالی گسل از تابع فازی MS-Large به عنوان بهترین تابع فازی ساز مقادیر بیشینه، استفاده گردید. همچنین برای دو لایه زمین‌شناسی فاصله از واحدهای سنگی رسوبی و ولکانیکی الیگو-میوسن، ۴ لایه فاصله از گسل‌های با روند شمالی-جنوبی، شرقی-غربی، شمال غرب-جنوب شرق و شمال شرق-جنوب غرب و ۵ لایه آلتراسیونی شامل فاصله از آلتراسیون‌های آرژیلیک، فیلیک، سیلیسیک، پروپیلیتیک و اکسید آهن از تابع فازی MS-Small استفاده شد.

تحت تاثیر دما، فشار، ترکیب سیال و نفوذپذیری سنگ‌های دربرگیرنده می‌باشد، که از میان آن‌ها نفوذپذیری به وسیله ویژگی‌های ساختاری یا به عبارت دیگر سیستم‌های گسلی کنترل می‌شود (سیبسون، ۱۹۹۶). بنابراین، سیستم‌های گسلی، مسیرهای همواری را برای بالا آمدن سیالات هیدروترمال و بجای گذاشتن مقادیر فراوانی از کانی‌های فلزی با ارزش از جمله طلا فراهم می‌کنند. وجود سیستم‌های گسلی با روند مشخص و همچنین محل برخورد گسل‌ها با یکدیگر، دو فاکتور کلیدی برای تشکیل کانسارهای هیدروترمال می‌باشند. بنابراین، گسل‌های با روندهای مختلف (شمالی-جنوبی، شرقی-غربی، شمال غرب-جنوب شرق و شمال شرق-جنوب غرب) می‌بایست شناسایی شده و طی آنالیزهای مختلف، موثرترین فاکتورهای ساختاری مرتبط با کانی‌زایی طلا شناسایی گردند.

در این مطالعه، گسل‌های ثبت شده در نقشه زمین‌شناسی تخت سلیمان با استفاده از تصاویر ماهواره‌ای بازبینی شده و توسط نرم‌افزار Arc GIS به فرمت شیپ تبدیل شدند. چهار دسته گسل با روندهای شمالی-جنوبی (۱۰۰°-۳۵۰° یا ۱۹۰°-۱۷۰°)، شرقی-غربی (۸۰°-۱۰۰° یا ۲۶۰°-۲۸۰°)، شمال غرب-جنوب شرق (۱۷۰°-۱۰۰° یا ۳۵۰°-۲۸۰°) و شمال شرق-جنوب غرب (۸۰°-۱۰۰° یا ۲۶۰°-۱۹۰°) شناسایی و تفکیک شدند. در مرحله بعدی، نقشه‌های پیوسته فاصله از گسل‌های با روندهای چهارگانه تهیه گردیدند. همچنین نقشه پیوسته چگالی گسل که نشان‌دهنده محل برخورد گسل‌ها با یکدیگر می‌باشد نیز تهیه گردید.

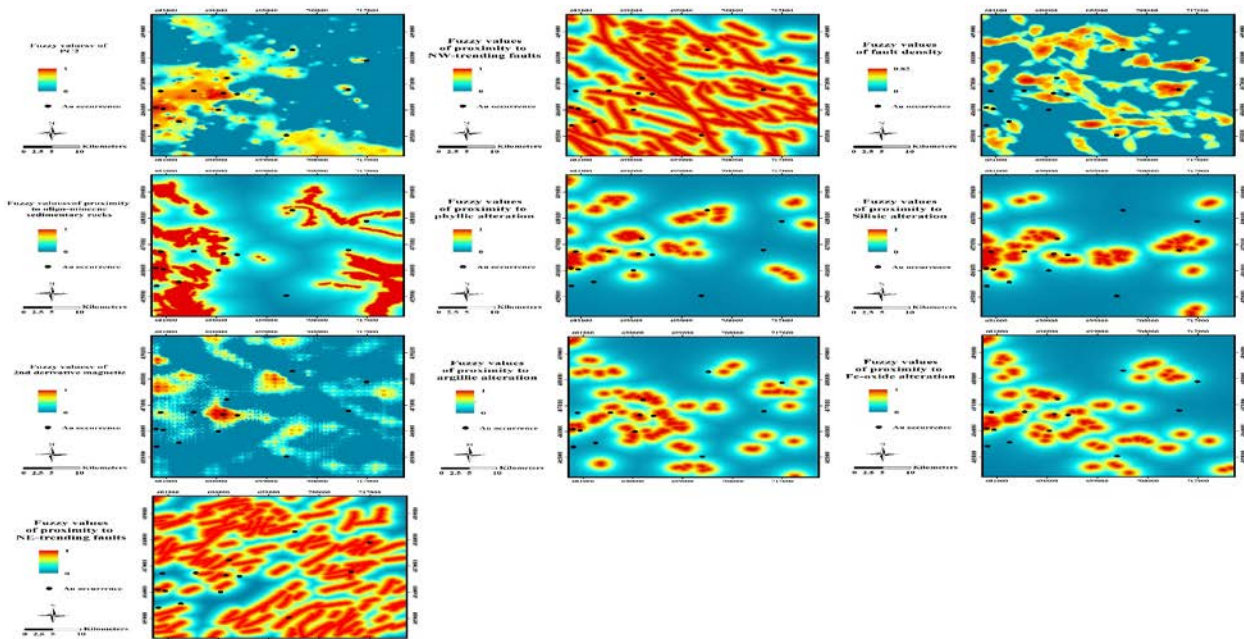
کانی‌زایی طلای اپی‌ترمال و کارلین (که اکثر کانسارهای طلای موجود در منطقه از این نوع هستند) به صورت کلی در نتیجه فرآیندهای هیدروترمال تشکیل شده‌اند که این فرآیندها به طور قابل توجهی، کانی‌شناسی و شیمی سنگ‌های میزبان را تحت تاثیر قرار می‌دهند. در واقع، آلتراسیون‌های هیدروترمال قادر هستند که یک مجموعه مشخص از کانی‌های فلزی را در نواحی سطحی‌تر زمین‌تنشین کنند که میزان آن‌ها بر اساس موقعیت، درجه و طول عمر این فرآیندهای هیدروترمال متغیر می‌باشد (سیمسون و همکاران، ۲۰۰۱). آلتراسیون‌های هیدروترمال مرتبط با کانی‌زایی نوع اپی‌ترمال وقتی که به سطح زمین می‌رسند، به صورت الگوهای زونالیته مشخص می‌شوند. آلتراسیون‌های هیدروترمال نظیر آرژیلیک، فیلیک، سیلیسیک، پروپیلیتیک و اکسید آهن، در بسیاری از کانسارهای اپی‌ترمال حضور دارند و سیستم‌های اپی‌ترمال بر اساس ساختار پیچیده خود، این آلتراسیون‌ها را بر روی سطح زمین ظاهر می‌کنند. این آلتراسیون‌ها به عنوان معیارهای اکتشافی بسیار مهم و مرتبط با

پژوهش، نمودارهای نرخ موفقیت هر یک از آن‌ها به طور جداگانه ترسیم گردید. سپس مقادیر مساحت زیر منحنی هر یک از آن‌ها به عنوان ملاک سنجش اعتبار و تاثیرگذاری محاسبه گردید (جدول ۲). در نهایت، بر اساس مقادیر AUC محاسبه شده برای لایه های شاهد اکتشافی، ۱۰ لایه با مقادیر AUC بالاتر از ۷۰٪ به عنوان موثرترین لایه های شاهد اکتشافی جهت شرکت در مدل سازی پتانسیل معدنی انتخاب گردیدند. ترتیب اهمیت لایه های موثر به صورت زیر می باشد:

لایه ژئوشیمیایی چند عنصری (PC2) (AUC=95.5%)، ۲. لایه فاصله از گسل‌های با روند شمال غربی- جنوب شرقی (AUC=79.39%)، ۳. لایه چگالی گسل (AUC=78.41%)، ۴. لایه زمین شناسی فاصله از سنگ‌های رسوبی الیگو- میوسن (AUC=76.64%)، ۵. لایه فاصله از آلتراسیون فیلیک (AUC=75%)، ۶. لایه فاصله از آلتراسیون سیلیسیک (AUC=74.42%)، ۷. لایه ژئوفیزیک مغناطیس مشتق دوم (AUC=74.37%)، ۸. لایه فاصله از آلتراسیون آرژلیک (AUC=72.72%)، ۹. لایه فاصله از آلتراسیون اکسید آهن (AUC=70.91%) و ۱۰. لایه فاصله از گسل‌های با روند شمال شرقی- جنوب غربی (AUC=70.23%). هم چنین، نقشه های پیوسته فازی شده هر یک از ۱۰ لایه اکتشافی موثر در شکل (۵) قابل مشاهده است.

برای ارزیابی کارایی لایه‌های شاهد اکتشافی جهت مشارکت در مدل سازی پتانسیل معدنی و همچنین عملکرد مدل‌های حاصل از پتانسیل‌یابی مواد معدنی می‌بایست از یک روش صحت سنجی دقیق ریاضی استفاده نمود. منحنی نرخ موفقیت، یکی از روش‌های صحت سنجی معتبر می‌باشد که با در نظر گرفتن هم‌زمان جوامع آنومالی حاصله و رخدادهای کانی‌زایی شناخته‌شده در منطقه مورد مطالعه، به‌طور کمی به ارزیابی صحت مدل سازی می‌پردازد (کارانزا و لپورت، ۲۰۱۵). برای تعیین میزان صحت مدل‌های حاصل از پتانسیل‌یابی معدنی و همچنین مقایسه کارایی لایه‌های اکتشافی شاهد به‌صورت هم‌زمان، از منحنی‌های نرخ موفقیت استفاده می‌گردد. در یک نمودار نرخ موفقیت، محور افقی نشان‌دهنده قسمتی از منطقه مورد مطالعه می‌باشد که به‌عنوان منطقه "مطلوب" پیش‌بینی شده است در حالی که محور عمودی نشان‌دهنده بخشی از کانسارها/اندیس‌های معدنی می‌باشد که به‌طور صحیح پیش‌بینی شده‌اند. در این نمودار از یک خط قطری (خط سنجش) برای تعیین میزان صحت و کارایی مدل سازی بهره گرفته می‌شود بدین‌صورت که اگر منحنی نرخ موفقیت ترسیم شده برای مدل نهایی بالاتر از خط سنجش قرار بگیرد، نشان‌دهنده ارتباط فضایی مثبت بین نواحی امیدبخش حاصل از مدل پیش‌بینی کننده و کانی‌زایی موجود در منطقه مورد مطالعه می‌باشد و برعکس.

برای مقایسه و ارزیابی کمی ۱۸ لایه شاهد اکتشافی در این



شکل (۵). نقشه های پیوسته فازی شده هر یک از ۱۰ لایه اکتشافی موثر

• تعداد رخدادهای معدنی "مطلوب" و "غیرمطلوب" می‌بایست یکسان در نظر گرفته شوند. زیرا عملکرد الگوریتم‌های یادگیری ماشین و دقت کلاسه‌بندی با این‌کار به صورت چشمگیری افزایش می‌یابد. در این تحقیق، ویژگی‌های فضایی ۱۴ عدد کانسارها/اندیس‌های طلای شناخته شده در منطقه به عنوان نقاط آموزشی مطلوب، و ویژگی‌های فضایی ۱۴ نقطه از منطقه که به احتمال خیلی زیاد کانی‌زایی طلا در آن‌ها وجود ندارد، به عنوان نقاط آموزشی غیرمطلوب در نظر گرفته شدند.

• ویژگی‌های نقاط آموزشی غیرمطلوب می‌بایست حتما متفاوت از ویژگی‌های نقاط آموزشی مطلوب (محل کانسارها/اندیس‌های معدنی) انتخاب گردند. بنابراین، فواصل دو سری ویژگی متناقض، بسیار زیاد از هم در نظر گرفته شدند.

• نقاط آموزشی غیرمطلوب می‌بایست حتما به صورت تصادفی از بخش‌های مختلف منطقه که کانی‌زایی مورد نظر وجود ندارد انتخاب شوند.

در این پژوهش، شبکه MLP با یک لایه میانی برای مدل‌سازی پتانسیل معدنی و تولید مدل‌های پیش‌گوی نواحی کانی‌زایی طلا

مورد استفاده قرار گرفت. همچنین، برای آموزش شبکه MLP

تعداد نورون‌های مخفی می‌بایست بر اساس مقدار خطای میانگین مربعات (MSE) تعیین گردد، زیرا که کمینه کردن مقدار MSE منجر به انتخاب تعداد بهینه نورون‌های مخفی می‌گردد. در این پژوهش، کمترین مقدار MSE برای تعداد ۵۵ نورون مخفی برای ۱۰ لایه محاسبه گردیده است. سپس، پارامترهای حاصل بر اساس کمترین مقدار MSE و همچنین تعداد بهینه نورون‌های مخفی برای اجرای فرآیند آموزش مورد استفاده قرار گرفتند. سپس، دقت مدل آموزش دیده با استفاده از نمودارهای پراکندگی که بر اساس مقادیر اولیه در مقابل مقادیر تخمین زده شده ترسیم گردیده‌اند (شکل ۶)، مورد ارزیابی قرار گرفت. همان‌طور که در شکل (۶) مشاهده می‌گردد، ضریب رگرسیونی برای رگرسیون خطی مقادیر اولیه در مقابل مقادیر تخمین زده شده‌ی مدل آموزش دیده (با مشارکت ۱۰ لایه) ۰/۹۹۹ می‌باشد و این بدان معنی است که خطاهای خروجی‌های شبکه‌های آموزش دیده بسیار ناچیز بوده و مقدار دقت شبکه آموزش دیده برای استفاده در مدل‌سازی پتانسیل کل محدوده بسیار بالا می‌باشد.

جدول (۲). مقادیر مساحت زیر منحنی (AUC) نرخ موفقیت ۱۸ لایه شاهد اکتشافی.

Evidence layer	AUC
PC1	55.5 %
PC2	95.5 %
PC3	50.48 %
NE-fault	70.23 %
NW- fault	79.39 %
N-fault	61.36 %
E-fault	56.31 %
Fault density	78.41 %
Phyllic	75.00 %
Argillic	72.72 %
Silicic	74.42 %
Fe-oxide	70.91 %
Propylitic	42.94 %
Oligo-Miocene sedimentary	76.64 %
Oligo-Miocene volcanic	59.82 %
RTP magnetic	60.36 %
1st derivative magnetic	66.06 %
2nd derivative magnetic	74.37 %

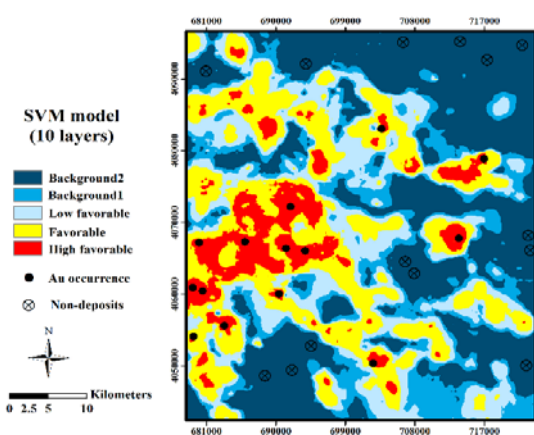
۴-۲. مدل‌سازی پتانسیل کانی‌زایی طلا

روش شبکه عصبی MLP مورد استفاده در این پژوهش نیازمند دو سری داده مربوط به ویژگی‌های فضایی به‌عنوان داده‌های "آموزشی" می‌باشد: (۱) مکان کانسارهای معدنی شناخته شده در منطقه که نشان‌دهنده حضور کانی‌زایی مطلوب در منطقه می‌باشد و (۲) مکان غیر کانسارها که در آن‌ها به طور قطعی کانی‌زایی مطلوب وجود ندارد. شناسایی و استخراج این داده‌های "آموزشی" که به‌عنوان الگو، ویژگی‌های فضایی چندبعدی را می‌توانند توصیف نمایند و قرار است با هدف شناسایی نواحی پرتانسیل طبقه‌بندی شوند، یکی از گام‌های اساسی در مدل‌سازی پتانسیل معدنی داده‌محور به شمار می‌رود. ویژگی‌های فضایی مربوط به مکان کانسارهای معدنی و غیر کانسارها از داده‌های مکانی حاصل از معیارهای ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری و دورسنجی شامل ۱۰ لایه موثر بر اساس منحنی‌های نرخ موفقیت (جدول ۲) به‌عنوان نقاط "آموزشی" و تمام پیکسل‌های مربوط به ۱۰ لایه اکتشافی به طور جداگانه به عنوان نقاط "آزمون" استخراج گردیدند. نکات زیر در انتخاب نقاط آموزشی حائز اهمیت هستند:

مورد استفاده قرار گرفتند)، با یکدیگر ترکیب شده و ماتریس مجموعه نقاط آموزشی را تشکیل دادند.

۲. ساختن بردارهای ماشین پشتیبان جهت آموزش داده‌های ورودی: مشابه مراحل ساختن شبکه MLP، برای استفاده از مدل SVM-RBF، داده‌های آموزشی آماده شده در مرحله قبل مورد استفاده قرار گرفتند. عملکرد این الگوریتم به شدت وابسته به انتخاب صحیح دو پارامتر C و λ می‌باشد. به همین جهت، برای ارزیابی عملکرد این دو پارامتر در افزایش دقت مدل و در واقع انتخاب صحیح این دو پارامتر جهت استفاده در مدل‌سازی، مجموعه‌ای از ماشین‌های بردار پشتیبان بر اساس مقادیر مختلف این دو پارامتر ساخته شدند و در نهایت $C=0.1$ و $\lambda=0.25$ به عنوان پارامترهای بهینه جهت تولید مدل‌های پیشگوی نواحی کانی‌زایی توسط روش SVM-RBF انتخاب شدند.

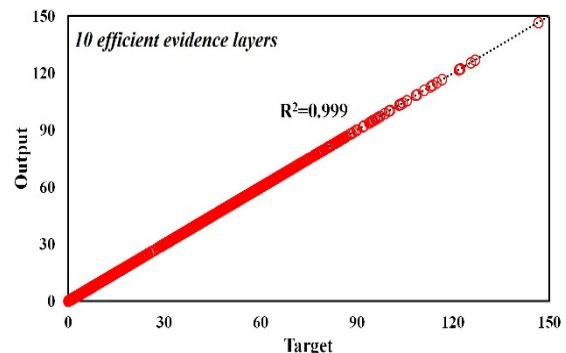
۳. تولید مدل‌های پیشگو: در این مرحله ماتریس داده‌های آزمون که مربوط به پیکسل‌های ویژگی‌های فزایی مختلف ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری و آلتراسیونی از کل محدوده می‌باشد، ساخته شد. برای کاهش عدم قطعیت سیستماتیک در مدل‌سازی پتانسیل معدنی که ممکن است از کلاسه‌بندی لایه‌های شاهد اکتشافی حاصل گردد، مقادیر پیوسته فازی هر یک از لایه‌ها به عنوان داده‌های آزمون مورد استفاده قرار گرفتند. سپس مدل SVM با کرنل RBF آموزش دیده، برای طبقه‌بندی ویژگی‌های مکانی مختلف مورد استفاده قرار گرفت. شکل ۸، مدل پیشگوی نواحی کانی‌زایی طلا توسط روش SVM-RBF با مشارکت ۱۰ لایه شاهد موثر را نمایش می‌دهد.



شکل (۸). مدل پیشگوی نواحی مستعد کانی‌زایی طلا با مشارکت ۱۰ لایه موثر شاهد با استفاده از روش داده‌محور SVM-RBF در ورقه تخت سلیمان.

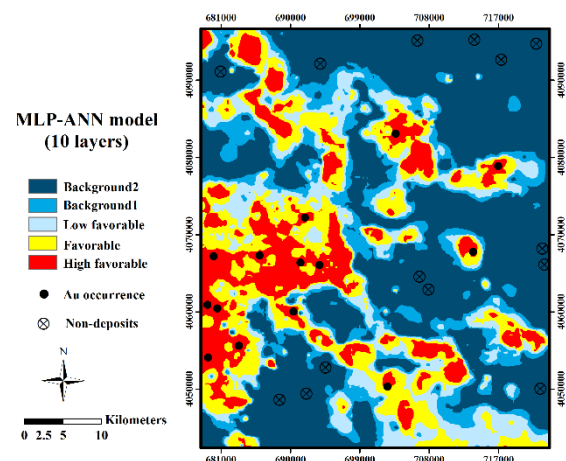
۴-۳. ارزیابی عملکرد مدل‌های پیشگوی تولید شده

در اینجا نیز برای مقایسه و ارزیابی کمی ۲ مدل پیشگوی تولید



شکل (۶). نمودار پراکندگی مقادیر واقعی آموزش دیده در مقابل مقادیر تخمین زده شده برای ساختن شبکه MLP برای داده‌های مربوط به ۱۰ لایه اکتشافی.

در مرحله بعد، پارامترهای تنظیم شده بر روی شبکه آموزش دیده بر اساس کمترین مقادیر MSE و مقادیر بهینه نورون‌های مخفی برای اجرای فرآیند آموزش بر روی داده‌های آزمون (پیکسل‌های استخراج شده از کل منطقه مورد مطالعه) مورد استفاده قرار گرفتند. در نهایت، مدل پیشگوی نهایی نواحی مستعد کانی‌زایی طلا بر اساس ۱۰ لایه موثر توسط روش MLP تولید گردید که نتیجه آن در شکل (۷) قابل مشاهده می‌باشد.



شکل (۷). مدل پیشگوی نواحی مستعد کانی‌زایی طلا با مشارکت ۱۰ لایه موثر شاهد با استفاده از روش داده‌محور MLP-ANN در ورقه تخت سلیمان.

در این پژوهش، الگوریتم SVM با کرنل RBF مطابق گام‌های زیر برای مدل‌سازی پتانسیل کانی‌زایی طلا در محدوده مورد مطالعه، استفاده گردید:

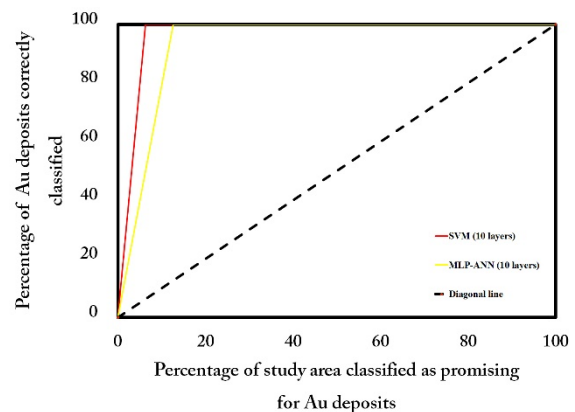
۱. آماده‌سازی داده‌های آموزشی: ویژگی‌های فزایی مختلف مربوط به مکان ۱۴ کانسار/اندیس طلا به عنوان نقاط مطلوب و هم‌چنین ویژگی‌های ۱۴ نقطه غیرمطلوب که به صورت تصادفی انتخاب گردیدند (همان داده‌های آموزشی که برای روش MLP

مدل پیشگوی تولید شده توسط روش SVM-RBF با مشارکت ۱۰ لایه اکتشافی موثر، بیشترین دقت و کمترین عدم قطعیت را در بین مدل‌های داده‌محور و دانش‌محور بر اساس مساحت زیر منحنی نرخ موفقیت دارد. بنابراین نواحی مستعد کانی‌زایی طلا که به عنوان مناطق مطلوب بر روی نقشه حاصل از این روش نشان داده شده‌اند، می‌توانند در اکتشافات تفضیلی‌تر برای یافتن کانسارهای طلای جدید در این منطقه استفاده گردند. بنابراین می‌توان اینگونه استنباط کرد که مدل‌سازی پتانسیل معدنی در مقیاس ناحیه‌ای و با استفاده از داده‌های از قبل موجود از منطقه مورد مطالعه و بکارگیری روش‌های قدرتمند برای ترکیب این داده‌ها، می‌تواند تا حد بسیار زیادی باعث صرفه جویی در وقت و هزینه‌های اکتشافی گردد و هم چنین باعث کاهش چشمگیر ریسک اکتشافی می‌گردد.

۶. مراجع

۱. باباخانی، ع.، قلمقاش، ج.، برگه شماره ۵۳۹۴ تخت سلیمان، از سری نقشه‌های زمین‌شناسی ۱:۱۰۰۰۰۰۰ ایران، انتشارات سازمان زمین‌شناسی و اکتشافات معدنی کشور، تهران، ۱۳۸۰.
۲. حسین‌زاده، ر.، ابراهیمی، ن.، همتیان، ج.، براتی، ب.، گزارش اکتشافات ژئوشیمیایی در ورقه ۱:۱۰۰۰۰۰۰ تخت سلیمان، سازمان زمین‌شناسی و اکتشافات معدنی کشور، تهران، ۱۳۹۵.
3. M. Abedi, S. A. Torabi, & G. H. Norouzi, "Application of fuzzy-AHP method to integrate geophysical data in a prospect scale, a case study: seridune copper deposit," *Boll Geofis Teor Appl.*, vol. 54(2), pp. 145-164, 2013.
4. M. Alavi, "Tectonics of the Zagros orogenic belt of Iran: new data and interpretations. *Tectonophysics*," vol. 229(3), pp. 211-238, 1994.
5. H. H. Asadi & M. Hale, "A predictive GIS model for mapping potential gold and base metal mineralization in Takab area," *Iran. Computers & Geosciences*, vol. 27(8), pp. 901-912, 2001.
6. G. F. Bonham-Carter, "Geographic Information Systems for geoscientists-modeling with GIS," *Computer methods in the geoscientists*, vol. 13, p. 398, 1994.
7. G. F. Bonham Carter, F. P. Agterberg, & D. F. Wright, "Integration of geological datasets for gold exploration in Nova Scotia. *Digital Geologic and Geographic Information Systems*," pp. 15-23, 1988.
8. Mineral prospectivity mapping in GIS (vol. 11). Elsevier.
9. E. J. M. Carranza & A. G. Laborte, "Random forest predictive modeling of mineral prospectivity with small number of prospects and data with missing values in Abra (Philippines)," *Computers & Geosciences*, vol. 74, pp. 60-70, 2015.
10. C. F. Chung & F. P. Agterberg, "Regression models for estimating mineral resources from geological map data," *Mathematical Geology*, vol. 12(5), pp. 473-488, 1980.
11. R. Ghezlbash & A. Maghsoudi, "A hybrid AHP-VIKOR approach for prospectivity modeling of porphyry Cu deposits in the Varzaghan District," *NW Iran. Arabian Journal of Geosciences*, vol. 11(11), p. 275, 2018b.

شده توسط روش‌های داده‌محور شبکه‌های عصبی مصنوعی MLP و ماشین‌های بردار پشتیبان (SVM) با مشارکت تمامی ۱۰ لایه شاهد موثر ژئوشیمیایی، ژئوفیزیکی، زمین‌شناسی، ساختاری-تکتونیکی و آلتراسیونی، از منحنی‌های نرخ موفقیت استفاده گردیده است. برای مقایسه کارایی هر یک از مدل‌های پیشگوی تولید شده، منحنی نرخ موفقیت آن‌ها به صورت یک‌جا در یک نمودار ترسیم گردید (شکل ۹). همانگونه که در شکل مشخص شده است، مساحت زیر منحنی مدل پیشگوی حاصل از روش ماشین‌های بردار پشتیبان (SVM) بالاتر از مساحت زیر منحنی مدل پیشگوی حاصل از روش شبکه‌های عصبی مصنوعی MLP قرار گرفته است و نشان دهنده این است که مدل SVM از اعتبار بیشتری برای پیجویی و اکتشاف کانسارهای جدید طلا در منطقه مورد مطالعه دارد که در فازهای بعدی اکتشاف می‌تواند به طور موثری مورد استفاده قرار گیرد.



شکل ۹). منحنی‌های نرخ موفقیت برای ۲ مدل پیشگوی داده‌محور.

۵. نتیجه‌گیری

انتخاب روش مناسب برای تلفیق کردن لایه‌های شاهد اطلاعاتی حاصل از منابع مختلف، یکی از عوامل اصلی افزایش دقت مدل‌سازی و کاهش عدم قطعیت سیستماتیک می‌باشد. در این پژوهش، دو روش داده‌محور (که وزن‌دهی به لایه‌های اکتشافی بر اساس مکان و ویژگی‌های کانسارها/اندیس‌های شناخته شده در منطقه مورد مطالعه انجام می‌گیرد) شامل ماشین‌های بردار پشتیبان (SVM) و شبکه‌های عصبی مصنوعی برای تولید مدل‌های پیشگوی کانی‌زایی طلا مورد استفاده قرار گرفتند. نتایج حاصل در این پژوهش نشان داد که روش‌های داده‌محور نظارتی (یعنی بر مبنای آموزش شبکه) نظیر روش‌های یادگیری ماشین تا چه اندازه می‌توانند دقت مدل‌سازی را در مکان‌هایی که به تعداد کافی کانسار/اندیس معدنی وجود دارد، نسبت به روش‌های دانش‌محور افزایش دهند.

21. R. K. T., Reddy & G. F. Bonham-Carter, "A decision-tree approach to mineral potential mapping in Snow Lake area," Manitoba, Canadian Journal of Remote Sensing, vol. 17(2), pp. 191-200, 1991.
22. V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, & M. J. O. G. R. Chica-Rivas, "Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines, Ore Geology Reviews, vol. 71, pp. 804-818, 2015.
23. R. H. Sibson, "Structural permeability of fluid-driven fault-fracture meshes," Journal of Structural Geology, vol. 18(8), pp. 1031-1042, 1996.
24. M. P. Simpson, J. L. Mauk, & S. F. Simmons, "Hydrothermal alteration and hydrologic evolution of the Golden Cross epithermal Au-Ag deposit," New Zealand, Economic Geology, vol. 96(4), pp. 773-796, 2001.
25. T. Sun, F. Chen, L. Zhong, W. Liu, & Y. Wang, "GIS-based mineral prospectivity mapping using machine learning methods: A case study from Tongling ore district," eastern China, Ore Geology Reviews, vol. 109, pp. 26-49, 2019.
26. M. Yousefi & E. J. M. Carranza, "Fuzzification of continuous-value spatial evidence for mineral prospectivity mapping. Computers & Geosciences," vol. 74, pp. 97-109, 2015.
27. R. Zuo & E. J. M. Carranza, "Support vector machine: a tool for mapping mineral prospectivity," Computers & Geosciences, vol. 37(12), pp. 1967-1975, 2011.
12. R. Ghezelbash, A. Maghsoudi, & E. J. M. Carranza, "Performance evaluation of RBF-and SVM-based machine learning algorithms for predictive mineral prospectivity modeling: integration of SA multifractal model and mineralization controls," Earth Science Informatics, vol. 12(3), pp. 277-293, 2019.
13. R. Ghezelbash, A. Maghsoudi, & E. J. M. Carranza, "Sensitivity analysis of prospectivity modeling to evidence maps: Enhancing success of targeting for epithermal gold, Takab district," NW Iran. Ore Geology Reviews, vol. 120, p. 103394, 2020.
14. M. Ghorbani, "The economic geology of Iran: mineral deposits and natural resources. Springer Science & Business Media," 2013.
15. D. Harris & G. Pan, "Mineral favorability mapping: a comparison of artificial neural networks, logistic regression, and discriminant analysis," Natural Resources Research, vol. 8(2), pp. 93-109, 1999.
16. M. H. Hassoun, "Fundamentals of artificial neural networks," MIT press, 1995.
17. T. Kavzoglu & I. Colkesen, "A kernel functions analysis for support vector machines for land cover classification," International Journal of Applied Earth Observation and Geoinformation, vol. 11(5), pp. 352-359, 2009.
18. A. Maghsoudi, M. Rahmani, & B. Rashidi, "Gold deposits and indications of Iran," 2005.
19. A. Najafi, M. H. Karimpour, & M. Ghaderi, "Application of fuzzy AHP method to IOCG prospectivity mapping: A case study in Taherabad prospecting area," eastern Iran, International journal of applied earth observation and geoinformation, vol. 33, pp. 142-154, 2014.
20. A. Porwal, E. J. M. Carranza, & M. Hale, "Knowledge-driven and data-driven fuzzy models for predictive mineral potential mapping," Natural Resources Research, vol. 12(1), pp. 1-25, 2003.