

مقایسه عملکرد شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تهیه مدل سه بعدی زون های کانی سازی (مطالعه موردی: کانسار مس پورفیری میدوک، ایران)

زهرا شفیعی^۱، ملیحه عباس زاده^{۲*}، سعید سلطانی محمدی^۳، مجتبی دهقانی جوزم^۴

۱. گروه مهندسی معدن، دانشگاه کاشان، ایران، shafiee.zahra1991@gmail.com

۲. گروه مهندسی معدن، دانشگاه کاشان، ایران، abbaszadeh@kashanu.ac.ir

۳. گروه مهندسی معدن، دانشگاه کاشان، ایران، saeedsoltani@kashanu.ac.ir

۴. مجتمع مس شهربابک، کرمان، ایران، mdjavazm@gmail.com

(دریافت: ۱۳۹۷/۱۱/۰۷ - پذیرش: ۱۳۹۸/۰۹/۲۵)

چکیده

به دلیل ارتباط زون های کانی سازی با تغییرپذیری عیار در کانسارهای مس پورفیری، تهیه مدل سه بعدی این زون ها یکی از گام های پیش از تخمین در ارزیابی این تیپ کانسارها به شمار می آید. کیفیت این مدل تاثیر بسزایی بر کیفیت تخمین های ارایه شده برای عیار، طراحی مناسب استخراج بلندمدت و در نهایت کاهش مشکلات بین معدن و کارخانه فرآوری دارد. روش معمول برای تهیه این مدل استفاده از روش مدل سازی محدود است که فرآیندی پیچیده و زمان بر است. یکی از راه حل های ممکن برای تهیه این گونه مدل ها استفاده از روش های نامحدود همچون روش های هوشمند است. در این مقاله تلاش شده است تا عملکرد دو روش هوشمند شبکه عصبی مصنوعی و ماشین بردار پشتیبان طبقه بندی کننده در جداسازی زون های کانی سازی (شامل زون شسته شده، زون هیپوژن و زون سوپرژن) کانسار مس میدوک مورد مطالعه و بررسی قرار گیرد. برای این منظور از مختصات جغرافیایی (طول و عرض و ارتفاع) داده های حاصل از گمانه های اکتشافی به عنوان ورودی و زون های کانی سازی مشاهده شده در آن ها به عنوان خروجی مدل استفاده شده است. بررسی نتایج حاصل از این الگوریتم های هوشمند در جداسازی زون های زمین شناسی نشان می دهد که روش ماشین بردار پشتیبان طبقه بندی کننده نسبت به شبکه عصبی مصنوعی عملکرد مطلوب تری دارد. عملکرد مطلوب تر روش ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی با استفاده از دقت بالاتر این روش در مراحل آموزش، آزمایش و همچنین مقایسه میان مدل بلوکی طبقه بندی شده با برداشت های انجام گرفته از چال های آتشفشانی نشان داده شده است.

کلمات کلیدی

شبکه عصبی مصنوعی، ماشین بردار پشتیبان، کانسار مس پورفیری، جداسازی زون های کانی سازی.

۱- مقدمه

مصنوعی و روش ماشین بردار پشتیبان^۱ نیز می‌توان استفاده کرد. مبنای این رویکرد طبقه‌بندی و تقسیم‌کناسار به نواحی کوچکتر بر اساس شباهت‌های موجود میان پارامترها در این نواحی است.

در سال‌های اخیر روش‌های هوشمند به عنوان ابزاری برای حل مسایل پیچیده شناخته شده است. شبکه‌های عصبی مصنوعی و ماشین‌های بردار پشتیبان به عنوان دو روش هوشمندی شناخته می‌شوند که پیش از این در بسیاری از مسایل مرتبط با علوم زمین به ویژه مدل‌سازی زمین‌شناسی و ارزیابی ذخیره موفقیت‌آمیز عمل کرده‌اند. به عنوان نمونه از شبکه عصبی مصنوعی در جداسازی زون‌های آلتراسیون و کانی‌زایی [۱۱-۱۳] و تخمین عیار [۱۱، ۲۳-۱۴] استفاده شده است. از میان کاربردهای ارائه شده برای روش ماشین بردار پشتیبان در مدل‌سازی زمین‌شناسی و ارزیابی ذخیره نیز می‌توان به جداسازی زون‌های آلتراسیون [۲۴-۲۶]، تفکیک واحدهای سنگی و کانی‌زایی [۲۷، ۲۸]، طبقه‌بندی لیتولوژیکی بر اساس لاگ‌های چاه‌پیمایی [۲۹]، ارائه مدل تخمین‌گر کانی‌سازی [۲۶] و تخمین عیار [۲۳، ۳۰] اشاره کرد. در این مقاله عملکرد دو روش شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان در جداسازی زون‌های کانی‌سازی در کانسار مس پورفیری میدوک مورد مقایسه قرار گرفته است.

۲- مواد و روش‌ها

۲-۱- شبکه‌های عصبی مصنوعی

هدف از تشکیل یک شبکه عصبی مصنوعی ایجاد مکانیزمی برای حل مسایل مهندسی با الهام از الگوی رفتاری سلول‌های بیولوژیکی است [۳۱] و به عنوان جایگزینی برای محاسبات سخت و برنامه‌ریزی شده به آن‌ها نگریسته می‌شود. کوچکترین واحد پردازشگر اطلاعات و سلول اساسی یک شبکه عصبی مصنوعی نرون است. نرون هر تعداد از ورودی‌ها را دریافت کرده و سینگال خروجی را تولید می‌کند. هر نرون شامل یک تابع ورودی یا تابع جمع‌بندی^۲ است که نتیجه حاصل از آن به عنوان منبع تغذیه تابع انتقال یا تابع تحریک^۳ به حساب می‌آید [۳۲]. در شکل ۱ ساده‌ترین ساختار یک نرون مصنوعی و اجزای آن نمایش داده شده است.

کانسارهای مس پورفیری مهم‌ترین منابع جهانی مس‌اند و بیش از ۶۰ درصد تولید جهانی و در حدود ۶۵ درصد منابع شناخته شده مس دنیا را تشکیل می‌دهند [۱، ۲]. این کانسارها به دلیل تناژ زیاد (به طور معمول صدها میلیون تا میلیارد تن)، طول عمر بالای معدن (چندین دهه) و آهنگ بالای تولید (میلیاردها کیلوگرم مس در سال) تاثیرات عمده اقتصادی و اجتماعی دارند [۳].

یکی از مطالعات زمین‌شناسی مهم در مورد این تیپ کانسارها، جدایش زون‌های کانی‌سازی است. جداسازی زون‌ها علاوه بر تسهیل مراحل عملیات اکتشافی بر بهبود کیفیت تخمین عیار نیز موثر است. علاوه بر این جداسازی زون‌های کانی‌سازی در کانسارهای مس پورفیری در تعیین پتانسیل اقتصادی و بهره‌برداری آن‌ها نقش موثری را ایفا می‌کند. جدایش صحیح زون‌ها ضمن تسهیل فعالیت‌های لازم برای بهره‌برداری کانسنگ، باعث تعیین نقاط پرتانسیل برای ادامه عملیات استخراج نیز خواهند بود [۴].

یکی از مراحل دشوار مدل‌سازی ذخایر معدنی تقسیم‌بندی پیکره کانسار به زون‌های مختلف بر اساس نتایج برداشت شده از گمانه‌های اکتشافی و نقشه زمین‌شناسی سطحی است. در کاربردهای صنعتی عموماً این مرحله بر اساس روش مدل‌سازی محدود انجام می‌گیرد. در این روش، ابتدا مرز بین زون‌های مختلف بر اساس مشاهدات انجام شده در گمانه‌ها در تعدادی مقطع دو بعدی ترسیم و سپس با برقراری ارتباط بین این مقاطع مدل سه‌بعدی زون‌ها تهیه می‌شود. از این روش با عنوان روش مدل‌سازی قطعی نیز یاد می‌شود زیرا در این روش اصولاً به عدم قطعیت مدل حاصل توجهی نمی‌شود. اگرچه این روش متداول‌ترین روش مورد استفاده در صنعت به شمار می‌رود اما به شدت زمان‌بر و پیچیده است. روش دیگر استفاده از مدل‌سازی ریاضی (نزدیکترین همسایگی یا چندضلعی)، زمین آماری و هوشمند است که به ویژه در شرایطی که فاصله‌داری گمانه‌ها از هم زیاد است؛ می‌توان از آن استفاده کرد. در مورد استفاده از مدل‌سازی زمین آماری تحقیقات وسیعی در زمینه استفاده از روش‌های کریجینگ شاخص [۵]، شبیه‌سازی زمین آماری زنجیره‌ای [۶]، چندگوسی [۷]، گوسی منقطع [۸] و همچنین مطالعه عدم قطعیت مدل‌های حاصل [۹، ۱۰] انجام گرفته است. همان‌طور که اشاره شد از روش‌های هوشمند (همچون روش شبکه‌های عصبی


1- Support vector machines

2- Summation function

3- Activation or Transfer function

آزمایش مدل با استفاده از سومین گروه از داده‌ها، یعنی داده‌های آزمایش^۳ که در فرآیند یادگیری مدل استفاده نشده‌اند، انجام می‌شود. در آموزش شبکه‌های عصبی علاوه بر روش آموزش، روند آموزش نیز در سرعت یادگیری و دقت شبکه عصبی موثر است. معمولاً یکی از دو روند آموزش الگو به الگو^۴ و آموزش گروهی^۵ در ساخت مدل‌های شبکه عصبی به کار می‌رود [۳۷]. مراحل مدل‌سازی به روش شبکه‌های عصبی مصنوعی به شرح زیر است:

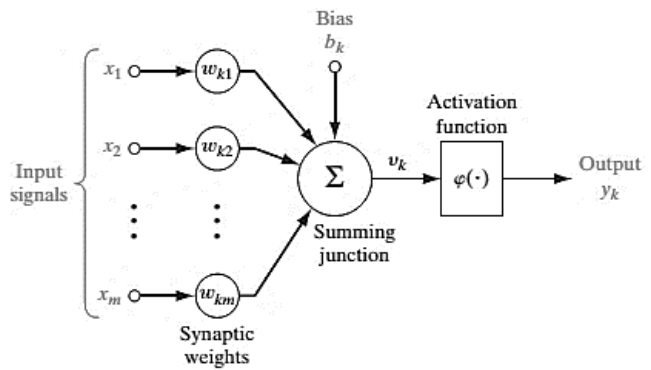
- آماده‌سازی مجموعه داده‌های آموزش، اعتبارسنجی و آزمایش
- طراحی ساختار شبکه عصبی مصنوعی
- تعیین مقادیر اولیه اوزان w و بایاس به صورت تصادفی
- محاسبه اوزان و بایاس بهینه بر اساس فرآیند تکرار
- وارد کردن ورودی و خروجی داده‌های آموزشی
- انتخاب پارامترهای بهینه مدل
- آزمایش و ارزیابی مدل



شکل ۲- نمایش ساختار کلی یک شبکه عصبی با یک لایه پنهان [۳۱].

۲-۲- ماشین‌های بردار پشتیبان

ماشین‌های بردار پشتیبان در دهه ۹۰ میلادی توسط



شکل ۱- نمایش ساختار یک نرون مصنوعی و اجزا آن [۳۱].

شبکه‌های عصبی از لایه‌های به هم پیوسته‌ای تشکیل شده‌اند که پردازش اطلاعات در این لایه‌ها انجام می‌گیرد و هر لایه می‌تواند متشکل از یک یا چند نرون باشد. این لایه‌ها عبارتند از لایه ورودی که شامل ورودی‌های شبکه عصبی است، یک یا چند لایه پنهان که شامل تعدادی نرون است و لایه خروجی که شامل خروجی‌های شبکه است [۳۳]. در شکل ۲ ساختار کلی یک شبکه عصبی با یک لایه پنهان نشان داده شده است. رابطه ریاضی ورودی- خروجی یک نرون در رابطه یک ارایه شده است:

$$a = f(wp + b) \quad (1)$$

که در آن:

p بردار ورودی

a بردار خروجی

w وزن متناظر برای هر ورودی

b بایاس

f تابع تحریک [۳۴]

در مقایسه با یک نرون بیولوژیکی، w معادل شدت سیناپس، تابع جمع‌بندی و تابع تحریک معادل هسته سلول و a معادل سیگنال گذرنده از اکسون خواهد بود [۳۵]. وزن‌های شبکه، قبل از به کار بردن مدل شبکه عصبی، تعیین می‌شوند. به همین منظور تمامی داده‌ها به سه گروه تقسیم می‌شوند [۳۶]. اولین گروه داده‌ها، به عنوان داده‌های آموزش^۱ برای تعیین وزن شبکه به کار می‌رود. فرآیند آموزش یا یادگیری بر اساس این دسته از داده‌ها انجام می‌گیرد. دومین گروه از داده‌ها که داده‌های اعتبارسنجی^۲ نامیده می‌شوند برای ارزیابی نتایج مرحله آموزش و تصمیم‌گیری در مورد توقف آموزش شبکه استفاده می‌شوند. تعیین دقت مدل و یا به عبارتی

3- Testing data
4- Epochs
5- Batch

1- Training data
2- Validation data

وینیک توسعه داده شدند [۳۵]. ایده اساسی یک ماشین بردار پشتیبان، یافتن یک ابر صفحه بهینه به عنوان سطح تصمیم‌گیری به گونه ای است که حاشیه بین دو کلاس را بیشینه کند. در صورتی که داده‌ها به صورت خطی جدایی‌پذیر نباشد، داده‌ها با تابعی تحت عنوان کرنل به صورت غیرخطی به فضایی با ابعاد بالاتر منتقل می‌شوند و ابر صفحه بهینه در فضای جدید که جدایش خطی امکان‌پذیر است، تعیین می‌شود [۳۸] (شکل ۳). اگر 1 داده‌های آموزشی موجود باشد که هر یک با (x_i, y_i) نشان داده می‌شود، بردار ویژگی n بعدی و $y_i \in \{-1, 1\}$ برچسب آن است. هدف یافتن ابر صفحه‌ای است که دو کلاس با برچسب 1 و -1 را با بیشترین حاشیه از هم جدا کند. این ابر صفحه را می‌توان با رابطه ۲ بیان کرد:

که در آن:
 w بردار وزن (بردار عمود بر ابر صفحه)
 b بردار بایاس
 $\phi(0)$ تابع کرنل مناسب برای انتقال داده‌ها به فضایی با ابعاد بالاتر (متداول‌ترین انواع تابع کرنل در جدول ۱ آورده شده است).
 بیشینه کردن حاشیه بین دو کلاس معادل کمینه کردن اندازه w است که منجر به حل مساله کمینه‌سازی مقید می‌شود [۴۰].

$$w^T \phi(x) + b = 0 \quad (2)$$

$$w^T x_i + b \geq 1 \text{ for } y_i = +1 \quad (4)$$

$$w^T x_i + b \leq -1 \text{ for } y_i = -1$$

نقاط داده‌ای ویژه‌ای که نامعادله‌های موجود در رابطه ۴ را به معادله تبدیل می‌کنند، بردارهای پشتیبانی نامیده می‌شوند. این نقاط (x_i, y_i) نزدیکترین نقاط داده‌ای به ابر صفحه بهینه است. فاصله هندسی متناظر میان بردار پشتیبانی x^* و ابر صفحه بهینه از رابطه ۵ محاسبه می‌شود:

$$r^* = \frac{g(x^*)}{\|w\|} \quad (5)$$

ماشین بردار پشتیبان طبقه‌بندی کننده (SVC) برای یافتن یک ابر صفحه با حاشیه بیشینه، p را با توجه به w و b بیشینه می‌سازد (رابطه ۶) [۴۱]:

$$\max_{w, b} \left(\frac{2}{\|w\|} \right) \quad (6)$$

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


بیشینه‌سازی فوق با مساله کمینه‌سازی زیر معادل است (رابطه ۷):

$$\min_{w, b} \left(\frac{1}{2} \|w\|^2 \right) \quad (7)$$

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

اطلاعات بیشتر در مورد ماشین‌های بردار پشتیبان در مراجع علمی آورده شده است [۴۲، ۴۳]. مراحل مدل‌سازی به روش ماشین بردار پشتیبان عبارت است از [۴۴]:

- آماده‌سازی مجموعه داده‌های آموزش و آزمایش
- انتخاب تابع کرنل مناسب
- انتخاب پارامترهای بهینه مدل
- آموزش مدل با استفاده از پارامترهای بهینه
- آزمایش مدل



شکل ۳- نمایش ابر صفحه بهینه که حداکثر حاشیه و در نتیجه حداکثر شدن تفکیک بین کلاس‌ها را به دنبال دارد به همراه انتقال داده‌ها به فضایی با ابعاد بیشتر برای جدایی خطی [۴۱].

فاصله هندسی مطلوب میان نمونه x و ابر صفحه بهینه به شکل رابطه ۳ است:

$$r = \frac{g(x)}{\|w\|} \quad (3)$$


مطالعات زمین‌شناسی اقتصادی انجام گرفته در سطح و بر روی مغزه‌های حفاری وجود چهار زون شسته شده (لیچ)، هیپوزن، سوپرزن و اکسیدی در این کانسار را نشان داده است. بخش بالایی کانسار را زون شسته شده تشکیل می‌دهد که این زون از شیب توپوگرافی تبعیت می‌کند و دارای ضخامت حداقل ۵۰ و حداکثر ۳۰۰ متر است. این بخش پایین‌ترین عیار مس و در حدود چند ده تا صد ppm دارد. زون اکسید در زیر بخش فروشست و بالای زون سوپرزن به ضخامت ۱۰ متر دیده می‌شود. کانه‌های این زون شامل مالاکیت، آزوریت، فیروزه، کریزوکلا و کالکانتیت است. میانگین عیار مس اکسیدی ۰/۵ درصد برآورد شده است [۴۶]. عمده ماده معدنی واقع در زون شسته شده و اکسید تاکنون استخراج شده‌اند. در زیر زون‌های اکسید و شسته شده، زون سوپرزن حاوی کانه‌های کالکوسیت، کولین و دیژنیت قرار دارد که در داخل آن‌ها بقایایی از کانه‌های زون هیپوزن شامل کالکوپریت و بورنیت نیز دیده می‌شود. میانگین عیار مس سوپرزن ۱/۳۴ درصد است. در نهایت، عمیق‌ترین بخش مینرالیزه توده نفوذی مس پورفیری، زون هیپوزن است. تماس بین زون سوپرزن و هیپوزن تدریجی بوده و اغلب تفکیک دقیق این دو زون مشکل است، شاخص عمده این منطقه وجود کانی‌های کالکوپریت، بورنیت و کالکوسیت اولیه است. کالکوپریت اصلی‌ترین کانی مس در زون هیپوزن است. میانگین عیار مس هیپوزن حدود ۰/۷۴ درصد است [۴۶]. فراوانی نسبی هر یک از این زون‌ها در اطلاعات ثبت شده از مغزه‌های حفاری در جدول ۲ آورده شده است. همان‌طور که مشاهده می‌شود زون هیپوزن با ۱۷۳۱۴ بار تکرار در داده‌ها، فراوان‌ترین زون به شمار می‌رود و زون‌های اکسید و لیچ به ترتیب با ۸۶۷ و ۸۶۷ بار تکرار فراوانی نسبی ناچیزی دارند. فراوانی زون‌های اکسیدی و شسته شده در سطح است و در عمق مشاهده نشده‌اند. همچنین مطالعات سنگ‌شناسی انجام شده نیز نشانگر وجود ۴ گروه اصلی سنگ شامل کوارتزیدوریت، آندزیت، توف و دایک‌ها در محدوده کانسار است. اطلاعات مربوط به فراوانی هر یک از گروه‌های سنگی در جدول ۳ آورده شده است. واحد سنگی کوارتزیدوریتی با ۱۸۳۳۱ بار تکرار در داده‌ها، فراوان‌ترین واحد سنگی به شمار می‌رود و واحدهای سنگی دایک و توف به ترتیب با ۱۵۶ و ۲۰۹ بار تکرار فراوانی نسبی ناچیزی دارند. در این مقاله تلاش شده است تا از اطلاعات حاصل از برداشت انجام شده در گمانه‌های اکتشافی برای مدلسازی زون‌های کانی‌سازی به روش‌های هوشمند استفاده شود.

جدول ۱- متداول‌ترین توابع کرنل به کار گرفته شده در مسایل تفکیک‌ناپذیر خطی [۴۱].

نام کرنل	فرمول
خطی	$K(x_j, x_j) = x_i x_j$
چندجمله‌ای	$K(x_j, x_j) = (x_i x_j + 1)^d, d \in \mathbb{Z}^+$
تابع پایه شعاعی	$\exp = \left(\frac{-\ x_i - x_j\ ^2}{2y^2} \right) \delta \in \mathbb{R}$
سیگموئید	$K(x_j, x_j) = \tanh(\lambda x_i x_j + r), \lambda >$

۲-۳- مطالعه موردی

کانسار مس پورفیری میدوک که در ۱۳۲ کیلومتری شمال غربی کانسار مس پورفیری سرچشمه قرار گرفته است از مهم‌ترین کانسارهای مس پورفیری در استان کرمان محسوب می‌شود. این کانسار در بخش شمال غربی مجموعه آتشفشانی-رسوبی دهج-ساردوئیه کرمان (جنوب شرقی کمربند آتشفشانی-نفوذی ارومیه-دختر) و در ۴۲ کیلومتری شمال شرق شهرستان شهربابک واقع شده است. این کانسار با سن ۱۲/۵ میلیون سال در سنگ‌های آتشفشانی و آذر آواری ائوسن با ترکیب آندزیت، آندزیت بازالت و داسیت (مجموعه رازک) واقع شده است [۴۵]. عملیات اکتشاف در میدوک سابقه طولانی دارد. فعالیت‌های اکتشافی این معدن از سال ۱۳۴۴ (هم‌زمان با شروع فعالیت معدن مس سرچشمه) آغاز و تاکنون ۲۱۳ گمانه در این منطقه حفر شده است. در شکل ۴ موقعیت گمانه‌های اکتشافی حفر شده در این کانسار نشان داده شده است.



شکل ۴- موقعیت گمانه‌های اکتشافی حفر شده در کانسار میدوک.


جدول ۲- فراوانی نسبی زون‌های موجود در مغزه‌های حفاری برداشت شده از منطقه مورد مطالعه.

زون	زون شسته شده	زون هیپوژن	زون سوپرژن	زون اکسیدی
فراوانی	۱۵۴۷	۱۷۳۱۴	۵۶۴۴	۸۶۷
فراوانی نسبی (درصد)	۶۱	۶۸٫۲	۲۲٫۳	۳٫۴

جدول ۳- فراوانی نسبی واحدهای سنگی موجود در مغزه‌های حفاری برداشت شده از منطقه مورد مطالعه.

واحد سنگی	کوارتز دیوریتی	آندزیتی	دایک	توف
فراوانی	۱۸۳۳۱	۵۶۰۹	۲۰۹	۱۵۶
فراوانی نسبی (درصد)	۷۵	۲۳	۱	۱

شرط توقف فرآیند آموزش نیز بر مبنای تعداد دفعات مجاز عدم کاهش متوالی خطای اعتبارسنجی پیش از توقف عملیات^۲ تعریف شد. بر اساس فرآیند سعی و خطا و همچنین مرور مطالعات پیشین، مقدار این پارامتر معادل ۳۰ قرار داده شد. دقت حاصل از آموزش این شبکه عصبی مصنوعی برابر ۹۲٫۳ درصد و دقت حاصل از آزمایش آن ۹۳٫۱۱ درصد است. میانگین مربعات خطا در مراحل آموزش و آزمایش برابر ۰٫۲ درصد است. ماتریس خطای طبقه‌بندی زون‌های کانی‌سازی مجموعه آزمایش در جدول ۴ ارائه شده است. با توجه به نتایج مطلوب حاصل از مدل‌سازی شبکه عصبی مصنوعی، از مدل به دست آمده برای طبقه‌بندی مدل بلوکی در کانسار مس پورفیری میدوک استفاده شد که نتایج آن در شکل‌های ۶ در قالب Validation threshold مدل بلوکی سه بعدی ارائه شده است.



شکل ۵- نمایی از شبکه عصبی پرسپترون ۳ لایه در نظر گرفته شده برای تفکیک زون‌های کانی‌سازی در کانسار مس پورفیری میدوک.

جدول ۴- ماتریس خطای طبقه‌بندی زون‌های کانی‌سازی مجموعه آزمایش.

نتایج کلاسه بندی			واقعی
سوپرژن	هیپوژن	شسته شده	
۷۷	۱	۱۳۵	شسته شده
۱۳۰	۳۰۶۹	۱۱	هیپوژن
۸۲۹	۶۲	۱۷	سوپرژن

۲-۲- مدل‌سازی به روش ماشین بردار پشتیبان

کارایی یک مدل مبتنی بر روش ماشین بردار پشتیبان طبقه‌بندی‌کننده تا حد زیادی وابسته به مقادیر پارامترهای

۳- بحث و نتیجه‌گیری

۳-۱- نتایج مدل‌سازی به روش شبکه عصبی مصنوعی

برای جداسازی زون‌های حاصل از کانی‌سازی، مدل شبکه عصبی مصنوعی در نرم‌افزار وکا^{۳٫۸} ایجاد شد که در آن سه گره ورودی معرف مختصات هر نقطه (شامل X, Y, Z) و گره خروجی معرف زون‌های کانی‌سازی ثبت شده در هر نمونه (LEA, HYP, SUP) بود (شکل ۸). تعداد نرون‌های لایه پنهان بر اساس یک روش تجربی با احتساب تعداد ورودی‌ها (مختصات مکانی) و خروجی‌های شبکه (زون‌های کانی‌سازی) ۱۲ نرون در نظر گرفته شد. این روش بیان می‌کند که تعداد بهینه نرون‌های لایه پنهان در یک شبکه سه لایه‌ای (یعنی تنها شامل یک لایه پنهان) برابر است با دو برابر مجموع تعداد نرون‌ها در لایه‌های ورودی و خروجی [۴۷]. در این مطالعه حدود ۸۰ درصد داده‌های گمانه‌های اکتشافی (۱۷۳۲۶ داده) به عنوان داده‌های آموزش و ۲۰ درصد باقیمانده داده‌ها (۴۰۳۳ داده) به عنوان داده‌های آزمایشی در نظر گرفته شده است. از آنجا که یکی از روش‌های بسیار موفق در زمینه ارتقا فرآیند آموزش، الگوریتم لونیبرگ-مارکوارت است [۴۸]، این الگوریتم برای آموزش مدل انتخاب شد. این الگوریتم بر مبنای رگرسیون غیرخطی گوس-نیوتون و روش گرادینان نزولی توسعه یافته است [۴۸]. همچنین از یک تابع تانژانت سیگموئیدی به عنوان تابع تحریک استفاده شد. در نهایت

2- Validation threshold

1- Weka 3.8

ماتریس خطای طبقه‌بندی زون‌های کانی‌سازی مجموعه آزمایش در جدول ۷ ارائه شده است. با توجه به نتایج مطلوب حاصل از مدل‌سازی انجام شده به روش ماشین بردار پشتیبان، از مدل به دست آمده برای طبقه‌بندی مدل بلوکی در کانسار مس پورفیری میدوک استفاده شد که نتایج آن در شکل ۶ در قالب مدل بلوکی سه بعدی ارائه شده است.

جدول ۵- پارامترهای بهینه مدل‌سازی به وسیله ماشین بردار پشتیبان به دست آمده از روش جستجوی شبکه‌ای همراه با اعتبارسنجی ۱۰ تایی.


γ	C	پارامترهای بهینه مدل
۰٫۰۰۱	۶۵۵۳۶	

جدول ۶- نتایج حاصل از مدل ماشین بردار پشتیبان طبقه‌بندی کننده برای طبقه‌بندی زون‌های کانی‌سازی در کانسار مس پورفیری میدوک برای داده‌های آموزش و آزمایش.

آموزش	آزمایش	
۹۴٫۳۶	۹۵٫۵۷	دقت
۰٫۱۹	۰٫۱۷	خطای جذر میانگین مربعات
۲۵۳۹	۶۳۳	تعداد داده

جدول ۷- ماتریس خطای طبقه‌بندی زون‌های کانی‌سازی مجموعه آزمایش.

نتایج طبقه‌بندی			واقعی
سوپرژن	هیپوژن	شسته شده	
۱۲۰	۲۱	۲۰۳	شسته شده
۹۸	۳۴۳۸	۹	هیپوژن
۹۲۲	۱۷۴	۲۰	سوپرژن

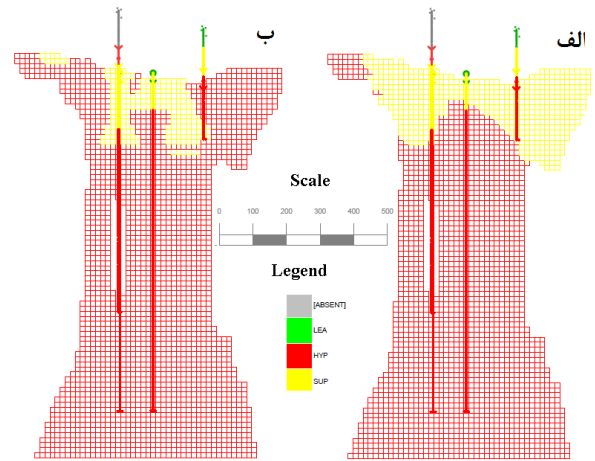


شکل ۶- مدل سه بعدی زمین‌شناسی طبقه‌بندی شده بر اساس (الف) شبکه عصبی مصنوعی و (ب) ماشین بردار پشتیبان.

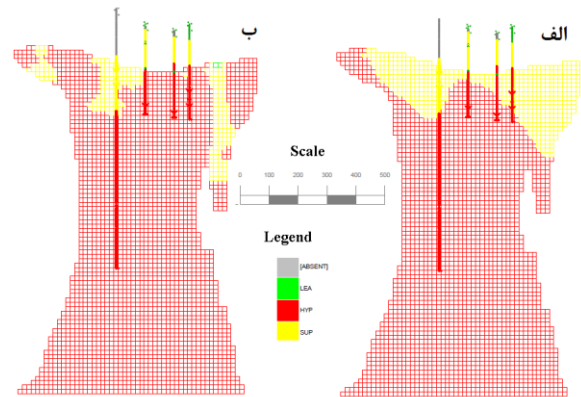
مدل شامل پارامتر جریمه^۱ و پارامتر کرنل^۲ است. برای دستیابی به مدلی که قدرت تعمیم بالایی داشته باشد لازم است این پارامترها به دقت تعیین شوند. انتخاب بهینه این پارامترها می‌تواند کیفیت عملکرد مدل را تحت تاثیر قرار دهد و در نتیجه مدلی با پارامترهای نامناسب ممکن است، نتایج نامطلوبی را ایجاد کند [۴۹-۵۳]. امروزه روش‌های متعددی برای تعیین پارامترهای مدل ماشین بردار پشتیبان به کار گرفته می‌شود. برخی از این روش‌ها مبنای تجربی و برخی نیز مبنای علمی دارند. در بین این روش‌ها، روش جستجوی شبکه‌ای^۳ با استفاده از اعتبارسنجی متقابل^۴ نسبت به سایر روش‌ها متداول‌تر است [۴۴، ۵۲، ۵۸-۵۴] و در این مقاله نیز از این روش به همراه اعتبارسنجی متقابل برای تنظیم پارامترهای مدل استفاده شده است. در این روش، ابتدا بهترین مقدار برای پارامترها در یک شبکه درشت انتخاب و سپس با تعریف یک شبکه ریزتر در اطراف آن، مقدار بهینه برای پارامترها محاسبه خواهد شد [۴۱]. محاسبات مربوط به روش جستجوی شبکه‌ای در نسخه ۳٫۸ نرم‌افزار Weka با هدف تنظیم پارامترهای مدل انجام شد. با توجه به اینکه در این مطالعه برای مدل‌سازی به روش ماشین بردار پشتیبان طبقه‌بندی کننده کرنل پایه شعاعی (RBF) به عنوان تابع کرنل انتخاب شده است، پارامترهایی از مدل که با روش جستجوی شبکه‌ای تنظیم می‌شود شامل C (پارامتر جریمه) و γ (پارامتر کرنل) است. مقادیر پارامترهای بهینه به دست آمده از روش جستجو شبکه‌ای همراه با اعتبارسنجی متقابل ۱۰ تایی در جدول ۵ ارائه شده است. پس از تعیین مقادیر بهینه پارامترهای مدل (جدول ۵) آموزش مدل با استفاده از داده‌های آموزش (حدود ۸۰ درصد داده‌ها) و بر اساس پارامترهای بهینه با تابع LIBSVM [۳۹] در نرم‌افزار Weka انجام شد. سپس کارایی مدل ایجاد شده با داده‌های آزمایش (حدود ۲۰ درصد داده‌ها) مورد بررسی قرار گرفت. از مجموع ۲۵۳۹ داده آموزش، ۲۳۹۶ و از ۶۳۳ داده مجموعه آزمایش، ۶۰۵ مورد به درستی طبقه‌بندی شده‌اند. بنابراین دقت حاصل از مدل ماشین بردار پشتیبان طبقه‌بندی کننده برای داده‌های آموزش برابر ۹۴٫۳۶ درصد و برای داده‌های آزمایش معادل ۹۵٫۵۷ درصد و میانگین مربعات خطا در مراحل آموزش و آزمایش به ترتیب برابر ۰٫۱۹ و ۰٫۱۷ درصد است (جدول ۶).

- 1- Penalty parameter
- 2- Kernel parameter
- 3- Grid search
- 4- Cross validation

ترسیم برای مدل بلوکی طبقه‌بندی شده بر اساس هر دو روش، عملکرد آن‌ها مقایسه شود. در این مقایسه از دو معیار نحوه برخورد زون‌ها با گمانه‌های اکتشافی در بخش‌های مختلف و وضعیت مورد انتظار بر اساس دانش زمین‌شناسی اقتصادی استفاده شد. هر چه زون‌های جداسازی شده و موقعیت قرارگیری آن‌ها روی مدل بلوکی به زون‌های گمانه‌های اکتشافی شباهت بیشتری داشته باشد، عملکرد آن روش مطلوب‌تر است. در شکل‌های ۷ و ۸ نتایج حاصل از جداسازی بر اساس دو روش هوشمند برای دو مقطع قائم انتخابی نشان داده شده است. برای کارایی بیشتر شکل‌های محدود ارایه شده، از دو مقطع قائم با راستای شمالی-جنوبی استفاده شد. همانطور که مشاهده می‌شود، اگرچه برتری عددی روش ماشین بردار پشتیبان در اعتبارسنجی متقابل چشم‌گیر نیست ولی در میزان تطابق مدل بلوکی با گمانه‌های اکتشافی، عملکرد آن بسیار مطلوب‌تر است. به نحوی که همان‌طور که در شکل ۷ و ۸ مشاهده می‌شود، برخلاف روش شبکه عصبی، مدل بلوکی حاصل از ماشین بردار پشتیبان با گمانه‌های اکتشافی تطابق بسیار بالایی دارد و با هیچ یک از گمانه‌ها عدم تطابق کامل را نشان نمی‌دهد و تنها برای بخش‌هایی از گمانه‌ها که در زون گذار از سوپرزن به هیپوزن است، این عدم تطابق مشاهده می‌شود. این در حالی است که در مدل بلوکی حاصل از شبکه عصبی، برای برخی از گمانه‌ها عدم تطابق بین مدل با واقعیت به صورت صددرصدی است. از طرف دیگر، همان‌طور که بر اساس دانش زمین‌شناسی اقتصادی کانسارهای مس پورفیری انتظار می‌رود، در تمامی مناطق زون سوپرزن بر روی زون هیپوزن (شکل ۶-الف) و زون شسته شده بر روی زون سوپرزن (شکل ۶-الف و ۷-الف) باید قرار گیرد. همان‌طور که پیش از این نیز اشاره شد، عمده بخش‌های زون شسته شده و اکسید پیش از این مورد استخراج قرار گرفته‌اند و به همین دلیل در بخش مدلسازی شده تنها رخداد بسیار محدودی از زون شسته شده مشاهده می‌شود که همان‌طور که انتظار می‌رود در هر دو مدل حاصل از روش‌های شبکه عصبی و ماشین بردار پشتیبان بر روی زون سوپرزن قرار گرفته است (شکل ۶). به طریق مشابه در هر دو مدل، زون سوپرزن بر روی زون هیپوزن قرار گرفته است که با دانش زمین‌شناسی اقتصادی تطابق کامل دارد. نکته‌ای که در این زمینه لازم است به آن اشاره شود، پیوستگی زون سوپرزن مدلسازی شده به روش شبکه عصبی مصنوعی است که از لحاظ بصری می‌تواند نکته مثبتی برای روش شبکه عصبی تلقی شود اما همان‌طور که در شکل‌های ۷ و ۸ نیز مشاهده می‌شود گمانه‌های اکتشافی انقطاع زون سوپرزن را در برخی از بخش‌ها نشان می‌دهند که تاییدی بر صحت بیشتر خروجی مدل ماشین بردار پشتیبان است.



شکل ۷- تطابق زون‌های زمین‌شناسی گمانه‌های اکتشافی و مدل بلوکی طبقه‌بندی شده بر اساس روش‌های الف) شبکه عصبی مصنوعی و ب) ماشین بردار پشتیبان برای یکی از مقاطع قائم انتخابی کانسار مس میدوک به عنوان نمونه.



شکل ۸- تطابق زون‌های زمین‌شناسی گمانه‌های اکتشافی و مدل بلوکی بر اساس روش‌های الف) شبکه عصبی مصنوعی و ب) ماشین بردار پشتیبان برای یکی از مقاطع قائم انتخابی کانسار مس میدوک به عنوان نمونه.

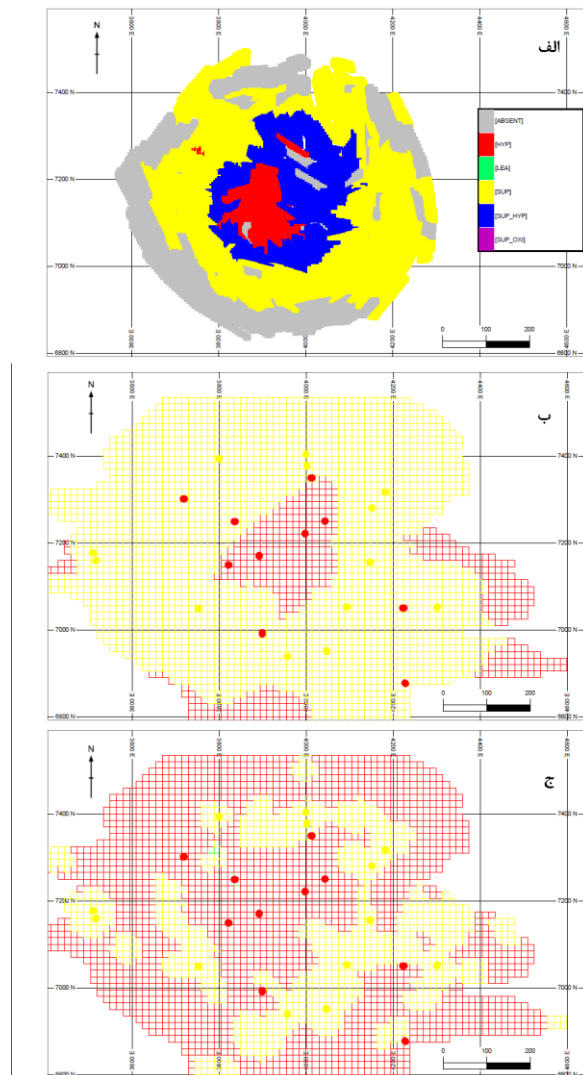
۴- بحث

در این بخش تلاش شده است تا کیفیت طبقه‌بندی ارایه شده بر اساس سه رویکرد اعتبارسنجی متقابل، مقایسه بصری و مقایسه نتایج با اطلاعات حاصل از چال‌های آتشیاری، مورد بررسی قرار گیرد. پارامترهای آماری حاصل از اعتبارسنجی متقابل موید کیفیت مطلوب طبقه‌بندی انجام گرفته بر اساس دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان است، بر اساس این معیار کیفیت طبقه‌بندی بر اساس روش ماشین بردار پشتیبان اندکی بیش از روش شبکه عصبی مصنوعی است. در رویکرد بصری تلاش شد تا با بررسی چشمی مقاطع قائم

که تغییر بین زون‌ها ناگهانی نیست و یک زون گذار بین آن‌ها وجود دارد، در چال‌های آتشیاری به جز زون‌های لیچ، سوپرزن و هیپوزن، زون‌های گذار سوپرزن-هیپوزن و لیچ-سوپرزن نیز ثبت شده است. پیش از مقایسه خروجی روش‌های هوشمند با چال‌های آتشیاری، مدل‌های حاصل با اطلاعات گمانه‌های اکتشافی در همان تراز (که به صورت دایره‌های توپر رنگی در شکل ۹-ب و ۹-ج نمایش داده شده‌اند) مقایسه شد. همان‌طور که مشاهده می‌شود با وجود تفاوت‌های ظاهری این دو مدل، هر دو مدل با داده‌های گمانه‌های اکتشافی (که بخشی از آن‌ها به عنوان آموزش و بخشی به عنوان تست در مرحله قبل استفاده شده‌اند) همخوانی دارند. درصد تطابق در مدل حاصل از روش ماشین بردار پشتیبان بالاتر است. مقایسه مدل‌های بلوکی با داده‌های برداشت شده از چال‌ها نشان می‌دهد که تقریباً هر دو مدل توانسته‌اند، بخش‌هایی را که در چال‌های آتشیاری به صورت سوپرزن و هیپوزن مشاهده شده‌اند، تقریباً درست تفکیک کنند ولی عملکرد آن‌ها در مورد زون گذار سوپرزن-هیپوزن و بخش‌هایی که از آن داده چال آتشیاری برداشت شده است، متفاوت بوده است. همچنین بررسی انجام شده مشخص کرد که بخشی از تفاوت در خروجی روش‌های هوشمند با چال‌های آتشیاری ناشی از عدم تطابق مشاهده شده بین رکوردهای ثبت شده برای گمانه‌های اکتشافی با چال‌ها نیز است.

۵- نتیجه‌گیری

در این مقاله، از روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای جداسازی زون‌های سوپرزن، هیپوزن و شسته شده در کانسار مس پورفیری میدوک استفاده شده است. بر اساس مطالعات اعتبارسنجی، مقایسه بصری و مقایسه نتایج با داده‌های برداشت شده از چال‌های آتشیاری عملکرد این دو روش با یکدیگر مقایسه شد. مقایسه انجام گرفته نشان داد که روش ماشین بردار پشتیبان عملکرد مطلوب‌تری در جداسازی زون‌های کانی‌سازی در این کانسار داشته است. در پایان با توجه به دسترسی به داده‌های برداشت شده از چال‌های آتشیاری یکی از پله‌های معدن، اقدام به مقایسه مدل‌های تهیه شده بر اساس روش هوشمند با مدل تهیه شده بر اساس داده‌های حاصل از چال‌های آتشیاری شد (از آنجا که فاصله‌داری داده‌های برداشت شده از چال‌های آتشیاری بسیار کم است، در مطالعات اعتبارسنجی، مدل حاصل بر اساس آن‌ها را می‌توان معادل (یا بسیار نزدیک) با واقعیت در نظر گرفت). این مقایسه نیز بیانگر عملکرد مطلوب‌تر این روش بود. اگرچه



شکل ۹- مقایسه بین مشاهده انجام گرفته در چال‌های آتشیاری (الف) و تفکیک انجام گرفته به روش‌های شبکه عصبی مصنوعی، (ب) و ماشین بردار پشتیبان (ج) در بخش‌های ب و ج گمانه‌های برخورد کرده با پلان نیز به صورت دایره‌های پر نشان داده شده است.

سومین رویکرد مورد استفاده برای مقایسه استفاده از داده‌های برداشت شده در چال‌های آتشیاری بود. برای این منظور اقدام به مقایسه وضعیت پیش‌بینی شده برای وضعیت قرارگیری زون‌های زمین‌شناسی با وضعیت مشاهده شده از قرارگیری آن‌ها در یکی از پله‌های معدن بر اساس داده‌های ثبت شده در چال‌های آتشیاری شد (شکل ۹). با توجه به دسترسی به داده‌های برداشت شده از چال‌های آتشیاری حفر شده در پله با تراز ارتفاعی ۲۴۹۷/۵ متر، از پلان‌های ترسیمی برای این تراز ارتفاعی برای مقایسه استفاده شد. همان‌طور که در شکل ۹-الف نیز مشاهده می‌شود. ثبت اطلاعات برای چال‌های آتشیاری با جزئیات بیشتری انجام گرفته است. از آنجا

- simulation*. Central European Journal of Geosciences, 2013. 5(1): p. 77-89.
8. Amirpoursaeid, F. and O. Asghari, *Application of truncated gaussian simulation to ore-waste boundary modeling of Golgohar iron deposit*. International Journal of Mining and Geo-Engineering, 2016. 50(2): p. 175-181.
 9. de Souza, L.E. and J.F.C. Costa, *Sample weighted variograms on the sequential indicator simulation of coal deposits*. International Journal of Coal Geology, 2013. 112: p. 154-163.
 10. Yamamoto, J.K., et al., *Post-processing for uncertainty reduction in computed 3D geological models*. Tectonophysics, 2014. 633(0): p. 232-245.
 11. Wu, X. and Y. Zhou, *Reserve estimation using neural network techniques*. Computers & Geosciences, 1993. 19(4): p. 567-575.
 12. Gholampour, O., et al., *Delineation of alteration zones based on kriging, artificial neural networks, and concentration-volume fractal modelings in hypogene zone of Miduk porphyry copper deposit, SE Iran*. Journal of Mining and Environment, 2018.
 13. Hezarkhani, A., P. Tahmasbi, and O. Asghari, *Separating the Sungun Copper Deposit Alteration Zones by Applying Artificial Neural Network*. Journal of Geoscience, 2010. 20(77): p. 41-46.
 14. Samanta, B., S. Bandopadhyay, and R. Ganguli, *Data segmentation and genetic algorithms for sparse data division in Nome placer gold grade estimation using neural network and geostatistics*. Exploration and mining geology, 2002. 11(1-4): p. 69-76.
 15. Koike, K., et al., *Neural network-based estimation of principal metal contents in the Hokuroku district, northern Japan, for exploring Kuroko-type deposits*. Natural Resources Research, 2002. 11(2): p. 135-156.
 16. Yama, B. and G. Lineberry, *Artificial neural network application for a predictive task in mining*. Mining engineering, 1999. 51(2): p. 59-64.
 17. Ke, J., *Neural-network modelling of placer ore grade spatial variability*. 2002, University of Alaska Fairbanks.
 18. Samanta, B., et al., *Sparse data division using data segmentation and Kohonen network for simulation*. Central European Journal of Geosciences, 2013. 5(1): p. 77-89.
- به صورت نسبی عملکرد روش ماشین بردار پشتیبان بهتر بوده است، ولی عملکرد این دو روش در بخش‌های مختلف کانسار متفاوت است، به نحوی که در برخی از بخش‌ها روش شبکه عصبی عملکرد بهتری داشته و در برخی از بخش‌ها ماشین بردار پشتیبان عملکرد بهتری داشته است، از این رو پیشنهاد می‌شود که در مطالعات آتی حتماً از روش‌های ترکیبی برای بهبود نتایج طبقه‌بندی استفاده شود. همچنین با توجه به اینکه عمده مطالعات انجام شده در زمینه کاربرد روش‌های هوشمند محدود به دو روش شبکه عصبی و ماشین بردار پشتیبان است، پیشنهاد می‌شود تا در ادامه مطالعات، استفاده از سایر روش‌های هوشمند نیز برای تهیه مدل بلوکی زمین‌شناسی مورد بررسی قرار گیرد.
- منابع**
1. Sinclair, W., *Porphyry deposits*. Mineral deposits of Canada: A synthesis of major deposit-types, district metallogeny, the evolution of geological provinces, and exploration methods: Geological Association of Canada, Mineral Deposits Division, Special Publication, 2007. 5: p. 223-243.
 2. Singer, D., V. Berger, and B. Moring, *Porphyry copper deposits of the world: Database and grade and tonnage*. 2008, USGS, 2008-1155: 3-42.
 3. Ayuso, R.A., et al., *Porphyry copper deposit model: Chapter B in Mineral deposit models for resource assessment*. 2010, US Geological Survey.
 4. Afzal, P., et al., *Delineation of mineralization zones in porphyry Cu deposits by fractal concentration-volume modeling*. Journal of Geochemical Exploration, 2011. 108(3): p. 220-232.
 5. Emery, X., *Probabilistic modelling of lithological domains and its application to resource evaluation*. Journal of the Southern African Institute of Mining and Metallurgy, 2007. 107(12): p. 803-809.
 6. Yu, X. and X. Li. *The Application of Sequential Indicator Simulation and Sequential Gaussian Simulation in Modeling a Case in Jilin Oilfield*. in *Future Control and Automation*. 2012. Berlin, Heidelberg: Springer Berlin Heidelberg.
 7. Yunsel, T.Y. and A. Ersoy, *Geological modeling of rock type domains in the Balya (Turkey) lead-zinc deposit using plurigaussian*

- Application of support vector machine for the separation of mineralised zones in the Takht-e-Gonbad porphyry deposit, SE Iran.* Journal of African Earth Sciences, 2018. 143: p. 301-308.
29. Al-Anazi, A. and I. Gates, *Support vector regression for porosity prediction in a heterogeneous reservoir: A comparative study.* Computers & Geosciences, 2010. 36(12): p. 1494-1503.
 30. Chatterjee, S. and S. Bandopadhyay, *Goodnews Bay Platinum Resource Estimation Using Least Squares Support Vector Regression with Selection of Input Space Dimension and Hyperparameters.* Natural Resources Research, 2011. 20(2): p. 117-129.
 31. Haykin, S., *Neural networks: a comprehensive foundation, 1999.* Mc Millan, New Jersey, 2010.
 32. Dowd, P. and C. Sarac, *A neural network approach to geostatistical simulation.* Mathematical Geology, 1994. 26(4): p. 491-503.
 33. Dutta, S., *Predictive performance of machine learning algorithms for ore reserve estimation in sparse and imprecise data.* 2006: ProQuest.
 34. Berry, M.J. and G. Linoff, *Data mining techniques: for marketing, sales, and customer support.* 1997: John Wiley & Sons, Inc.
 35. Haykin, S., *Neural Network, A comprehensive Foundation-1994.* Amerika Serikat.
 36. Coulibaly, P., F. Anctil, and B. Bobee, *Daily reservoir inflow forecasting using artificial neural networks with stopped training approach.* Journal of Hydrology, 2000. 230(3-4): p. 244-257.
 37. Omid, M., M. Omid, and M. Esmaeeli Varaki. *Modelling hydraulic jumps with artificial neural networks.* in *Proceedings of the Institution of Civil Engineers-Water Management.* 2005. Thomas Telford Ltd.
 38. Watanachaturaporn, P., M.K. Arora, and P.K. Varshney. *Hyperspectral image classification using support vector machines: A comparison with decision tree and neural network classifiers.* in *American Society for Photogrammetry & Remote Sensing (ASPRS) 2005 Annual Conference, Reno, NV.* 2006.
 39. Burges, C.J., *A tutorial on support vector machines for pattern recognition.* Data mining neural network and geostatistical ore grade modeling in Nome offshore placer deposit. Natural resources research, 2004. 13(3): p. 189-200.
 19. Samanta, B., R. Ganguli, and S. Bandopadhyay, *Comparing the predictive performance of neural networks with ordinary kriging in a bauxite deposit.* Mining Technology, 2005. 114(3): p. 129-139.
 20. Mahmoudabadi, H., M. Izadi, and M.B. Menhaj, *A hybrid method for grade estimation using genetic algorithm and neural networks.* Computational Geosciences, 2009. 13(1): p. 91-101.
 21. Tahmasebi, P. and A. Hezarkhani, *Application of optimized neural network by genetic algorithm, IAMG09.* 2009, Stanford University, California.
 22. Jafrasteh, B. and N. Fathianpour, *A hybrid simultaneous perturbation artificial bee colony and back-propagation algorithm for training a local linear radial basis neural network on ore grade estimation.* Neurocomputing, 2017. 235: p. 217-227.
 23. Jafrasteh, B., N. Fathianpour, and A. Suárez, *Comparison of machine learning methods for copper ore grade estimation.* Computational Geosciences, 2018. 22(5): p. 1371-1388.
 24. Abbaszadeh, M., A. Hezarkhani, and S. Soltani-Mohammadi, *An SVM-based machine learning method for the separation of alteration zones in Sungun porphyry copper deposit.* Chemie der Erde-Geochemistry, 2013. 73(4): p. 545-554.
 25. Abbaszadeh, M., A. Hezarkhani, and S. Soltani-Mohammadi, *Classification of alteration zones based on whole-rock geochemical data using support vector machine.* Journal of the Geological Society of India, 2015. 85(4): p. 500-508.
 26. Abbaszadeh, M., A. Hezarkhani, and S. Soltani-Mohammadi, *Proposing drilling locations based on the 3D modeling results of fluid inclusion data using the support vector regression method.* Journal of Geochemical Exploration, 2016. 165: p. 23-34.
 27. GODARZI, M.S., et al., *COMPARISON OF SUPPORT VECTOR MACHINE, NEURAL NETWORK, AND MAXIMUM LIKELIHOOD METHODS FOR THE SEPARATION OF LITHOLOGICAL UNITS.* 2012.
 28. Mahvash Mohammadi, N. and A. Hezarkhani,

- 17(1): p. 113-126.
50. Hsu, C.-W., C.-C. Chang, and C.-J. Lin, *A practical guide to support vector classification*. 2003.
 51. Lin, S.-W., et al., *Parameter determination of support vector machine and feature selection using simulated annealing approach*. *Applied soft computing*, 2008. 8(4): p. 1505-1512.
 52. Momma, M. and K.P. Bennett. *A pattern search method for model selection of support vector regression*. in *Proceedings of the 2002 SIAM International Conference on Data Mining*. 2002. SIAM.
 53. Chang, C.-C. and C.-J. Lin, *LIBSVM: a library for support vector machines*. *ACM transactions on intelligent systems and technology (TIST)*, 2011. 2(3): p. 27.
 54. Frohlich, H. and A. Zell. *Efficient parameter selection for support vector machines in classification and regression via model-based global optimization*. in *Neural Networks, 2005. IJCNN'05. Proceedings. 2005 IEEE International Joint Conference on*. 2005. IEEE.
 55. Luo, L., et al., *A new parameter selection method for support vector machine based on the decision value*. *Journal of Convergence Information Technology*, 2010. 5(8): p. 36-41.
 56. Zhang, D., et al., *Parameter optimization for support vector regression based on genetic algorithm with simplex crossover operator*. *JOURNAL OF INFORMATION & COMPUTATIONAL SCIENCE*, 2011. 8(6): p. 911-920.
 57. Huang, Q., J. Mao, and Y. Liu. *An improved grid search algorithm of SVR parameters optimization*. in *Communication Technology (ICCT), 2012 IEEE 14th International Conference on*. 2012. IEEE.
 58. Lee, C.-Y. and S.-G. Chern, *Application of a support vector machine for liquefaction assessment*. *Journal of Marine Science and Technology*, 2013. 21(3): p. 318-324.
 - and knowledge discovery, 1998. 2(2): p. 121-167.
 40. Lorena, A.C. and A.C. De Carvalho, *Evolutionary tuning of SVM parameter values in multiclass problems*. *Neurocomputing*, 2008. 71(16-18): p. 3326-3334.
 41. Zuo, R. and E.J.M. Carranza, *Support vector machine: a tool for mapping mineral prospectivity*. *Computers & Geosciences*, 2011. 37(12): p. 1967-1975.
 42. Cortes, C. and V. Vapnik, *Support-vector networks*. *Machine learning*, 1995. 20(3): p. 273-297.
 43. Tax, D.M. and R.P. Duin, *Support vector domain description*. *Pattern recognition letters*, 1999. 20(11-13): p. 1191-1199.
 44. Hsu, C., C. Chang, and C. Lin, *A practical guide to support vector classification*. Taipei: Department of Computer Science National Taiwan University. 2010.
 45. Aliani, F., et al., *Geochemistry and petrography of the Meiduk porphyry copper deposit, Kerman, Iran*. *Australian Journal of Basic and Applied Sciences*, 2009. 3(4): p. 3786-3800.
 46. Zhou, P., et al., *Source mapping and determining of soil contamination by heavy metals using statistical analysis, artificial neural network, and adaptive genetic algorithm*. *Journal of Environmental Chemical Engineering*, 2015. 3(4, Part A.): p. 2569-2579.
 47. Karsoliya, S., *Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture*. *International Journal of Engineering Trends and Technology*, 2012. 3(6): p. 714-717.
 48. Rumelhart, D.E., G.E. Hinton, and R.J. Williams, *Learning representations by back-propagating errors*. *nature*, 1986. 323(6088): p. 533.
 49. Cherkassky, V. and Y. Ma, *Practical selection of SVM parameters and noise estimation for SVM regression*. *Neural Networks*, 2004.